

1st International Congress on **Artificial Intelligence and Data Science**

26-28 November 2021

Izmir, Turkey

Online Congress

PROCEEDING BOOK

**1st International Congress on Artificial Intelligence and Data
Science
Proceeding Book**

**1.Uluslararası Yapay Zeka ve Veri Bilimi Kongresi
Tam Metin Kitabı**

Editors / Editörler

Prof. Dr. Ayşegül ALAYBEYOĞLU

Dr. Serpil YILMAZ

Dr. Osman GÖKALP



İzmir Kâtip Çelebi Üniversitesi Yayın No: 24

Bu eserin, İzmir Kâtip Çelebi Üniversitesi Yönetim Kurulu'nun 22.12.2021 tarih ve 2021-46 sayılı toplantısında alınan 06 kararı uyarınca, elektronik kitap olarak yayımlanmasına karar verilmiştir.

Her hakkı saklıdır.

© İzmir Kâtip Çelebi Üniversitesi Yayınları
2021

Sertifika No: 46629

Editörler: Prof. Dr. Ayşegül ALAYBEYOĞLU
Dr. Serpil YILMAZ
Dr. Osman GÖKALP

ISBN: 978-605-70737-3-0

International Congress on Artificial Intelligence and Data Science (İzmir : 2021)
1st International Congress on Artificial Intelligence and Data Science Proceeding Book,
26-28 November 2021 = 1.Uluslararası Yapay Zeka ve Veri Bilimi Kongresi Tam Metin
Kitabı, 26-28 Kasım 2021 / Editors/Editörler: Ayşegül Alaybeyoğlu, Serpil Yılmaz, Osman
Gökalg -- İzmir : İzmir Kâtip Çelebi Üniversitesi, 2021.
Çevrimiçi (362 sayfa : şekil, tablo ; 26 cm.). -- (İzmir Kâtip Çelebi Üniversitesi; Yayın
No: 24)
ISBN: 978-605-70737-3-0
1. Yapay Zeka – Kongreler 2. Veri Bilimi – Kongreler
I. Alaybeyoğlu, Ayşegül – II. Yılmaz, Serpil – III. Gökalg, Osman

Adres : İzmir Kâtip Çelebi Üniversitesi Rektörlüğü, Balatçık Yerleşkesi, 35620 Çiğli
İzmir, Türkiye

Telefon : +90 232 329 3535 / 1255

E-posta : ykb@ikc.edu.tr

Belge-geçer : +90 232 386 0888

Web : ykb.ikc.edu.tr

Eserin hukuki ve etik sorumluluğu yazarlara aittir. Tüm hakları saklıdır. Bu kitabın
yayın hakkı İzmir Kâtip Çelebi Üniversitesi'ne aittir. İzinsiz kopyalanamaz ve çoğaltılamaz.

CONTENTS/İÇİNDEKİLER

	<u>Page/Sayfa</u>
Invitation/Davet	5-6
Committees/Kurullar	7-9
Congress Program/Kongre Programı	10 - 15
Proceeding Papers/Tam Metin Bildiriler	16 -360

Dear Colleagues and Participants;

We are delighted and honored to invite you to the 1st International Congress on Artificial Intelligence and Data Science, which will be held online between 26-28 November 2021, hosted by Artificial Intelligence and Data Science Application and Research Center of İzmir Kâtip Çelebi University.

The main topics of our congress are the new methods developed in the field of artificial intelligence and the systems developed for the application of artificial intelligence in many different areas such as health, engineering, education, law, marketing and finance, textile, city and regional planning

National and international speakers will be included in our Congress for which we organize to increase interaction and communication, to cooperate, to act together, to share knowledge and experience by bringing together researchers, industrial organizations, public institutions and organizations working in the field of artificial intelligence and data science. Oral presentations will be made on topics related to all areas of artificial intelligence.

We hope to see you among us at the 1st International Congress on Artificial Intelligence and Data Science, which will be enriched with your participation, and thank you in advance for your valuable contribution and participation.

Prof. Dr. Ayşegül Alaybeyođlu

Chair of the Congress

Değerli Meslektaşlarımız ve Katılımcılarımız;

İzmir Kâtip Çelebi Üniversitesi, Yapay Zeka ve Veri Bilimi Uygulama ve Araştırma Merkezi ev sahipliğinde, 26-28 Kasım 2021 tarihleri arasında online olarak düzenlenecek olan I.Uluslararası Yapay Zeka ve Veri Bilimi Kongresi'ne sizleri davet etmekten büyük mutluluk ve onur duymaktayız.

Kongremizin ana konularını, yapay zeka alanında geliştirilen yeni yöntemler ve mühendislikte yapay zeka ile yapay zekanın sağlık, eğitim, hukuk, pazarlama ve finans, tekstil, şehir ve bölge planlama gibi bir çok farklı alanlarda uygulanmasına yönelik olarak geliştirilen sistemlerin oluşturması planlanmaktadır.

Yapay zeka ve veri bilimi alanında çalışan araştırmacıları, endüstri kuruluşlarını, kamu kurum ve kuruluşlarını bir araya getirerek etkileşim ve iletişimi artırmak, iş birliği içinde olmak, birlikte hareket etmek, bilgi ve tecrübeleri paylaşmak amacıyla düzenlediğimiz uluslararası kongremizde, ulusal ve uluslararası konuşmacılara yer verilecek olup yapay zekanın tüm alanları ile ilgili konularda sözlü bildiri sunumları yapılacaktır.

Katılımlarınızla zenginleşecek olan I. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi'nde sizleri aramızda görmeyi umuyor, değerli katkı ve katılımlarınız için şimdiden teşekkür ediyoruz.

Prof. Dr. Ayşegül Alaybeyoğlu

Kongre Başkanı

COMMITTEES/KURULLAR

Honorary President/Onursal Başkan

Prof. Dr. Saffet KÖSE

İzmir Katip Çelebi Üniversitesi Rektörü

Congress Chair/Kongre Başkanı

Prof. Dr. Ayşegül ALAYBEYOĞLU

Organizing Committee/Düzenleme Kurulu

Prof. Dr. Adnan KAYA

Prof. Dr. Ayşegül ALAYBEYOĞLU

Doç. Dr. Merih PALANDÖKEN

Doç. Dr. Aytuğ ONAN

Dr. Öğretim Üyesi Osman GÖKALP

Dr. Öğretim Üyesi Serpil YILMAZ

Dr. Öğretim Üyesi Esra AYCAN BEYAZIT

Dr. Öğretim Üyesi Onan GÜREN

Scientific Secretariat/Bilimsel Sekreteryä

Fatma Günseli Çıklaçandır

fatma.gunseli.yasar@gmail.com

Hande Parlak

hndeparlk@gmail.com

SCIENTIFIC COMMITTEE/BİLİMSEL KURUL

Prof. Dr. Abd Samad Hasan Basari	Universiti Tun Hussein Onn Malaysia
Prof. Dr. Adnan Kaya	İzmir Katip Çelebi University
Prof. Dr. Aybars Uğur	Ege University
Prof. Dr. Ayşegül Alaybeyoğlu	İzmir Katip Çelebi University
Prof. Dr. Bilge Karaçalı	İzmir Institute of Technology
Prof. Dr. Bing Zhang	Sichuan University
Prof. Dr. Chirag Paunwala	Sarvajanik College of Engineering and Technology
Prof. Dr. Dunwei Gong	China University of Mining and Technology
Prof. Dr. Filiz Güneş	Yıldız Technical University
Prof. Dr. İbrahim Pirim	İzmir Katip Çelebi University
Prof. Dr. Müştak Erhan Yalçın	İstanbul Technical University
Prof. Dr. Narendra C. Chauhan	A D Patel Institute of Technology
Prof. Dr. Nejat Yumuşak	Sakarya University
Prof. Dr. Özlem Coşkun	Süleyman Demirel University
Prof. Dr. Saurabh Shah	GSFC University
Prof. Dr. Vedvyas Jayprakash Dwivedi	C. U. Shah University
Prof. Dr. Y. Cengiz Toklu	Beykent University
Prof. Dr. Zahriladha Bin Zakaria	Universiti Teknikal Malaysia
Orhan Balbal	Republic of Turkey Court of Cassation
Assoc. Prof. Dr. Ali Turgut	Tepecik Training and Research Hospital
Assoc. Prof. Dr. Amit Thakkar	Charusat University
Assoc. Prof. Dr. Aytuğ Onan	İzmir Katip Çelebi University
Assoc. Prof. Dr. Cemal Hanilçi	Bursa Technical University
Assoc. Prof. Dr. Cheng Jin	Beijing Institute of Technology
Assoc. Prof. Dr. Christos Volos	Aristotle University of Thessaloniki
Assoc. Prof. Dr. Gabriel Bekdaş	İstanbul University- Cerrahpaşa
Assoc. Prof. Dr. Gökçe Nur Yılmaz	TED University
Assoc. Prof. Dr. Hakan Özbaşaran	Eskişehir Osmangazi University
Assoc. Prof. Dr. Mehmet Ali Belen	İskenderun Technical University
Assoc. Prof. Dr. Merih Palandöken	İzmir Katip Çelebi University

“1. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi”

Assoc. Prof. Dr. Mohd Sanusi Azmi	Universiti Teknikal Malaysia Melaka
Assoc. Prof. Dr. Mustafa Emirođlu	Tepecik Training and Research Hospital
Assoc. Prof. Dr. Nour El Madhoun	Ecole d'ingénieurs informatique Paris-EPITA
Assoc. Prof. Dr. Peyman Mahouti	İstanbul University- Cerrahpaşa
Assoc. Prof. Dr. Sharnil Pandya	Symbiosis International University
Assoc. Prof. Dr. Sinan Melih Niđdeli	İstanbul University- Cerrahpaşa
Assoc. Prof. Dr. Trushit Upadhyaya	Charusat University
Assist. Prof. Dr. Amrithesh Kumar	National Institute Of Technology Silchar
Assist. Prof. Dr. Başak Esin Köktürk Güzel	İzmir Democracy University
Assist. Prof. Dr. Esra Aycan Beyazıt	İzmir Katip Çelebi University
Assist. Prof. Dr. Malaya Dutta Borah	National Institute Of Technology Silchar
Assist. Prof. Dr. Mehmet Erdal Özbek	İzmir Katip Çelebi University
Assist. Prof. Dr. Onan Güren	İzmir Katip Çelebi University
Assist. Prof. Dr. Osman Gököl	İzmir Katip Çelebi University
Assist Prof. Dr. Partha Pakray	National Institute Of Technology Silchar
Assist. Prof. Dr. Serpil Yılmaz	İzmir Katip Çelebi University
Assist. Prof. Dr. Taimoor Khan	National Institute of Technology Silchar
Assist. Prof. Dr. Volkan Kılıç	İzmir Katip Çelebi University
Dr. Arpan Desai	Charusat University
Dr. Kadriye Filiz Balbal	Ministry of Education
Dr. Mohd Ibrahim Shapiai Razak	Malaysia-Japan International Institute of Technology, Universiti Teknologi Malaysia
Dr. Zihao Chen	Harbin Institute of Technolgy

ICADA 2021 26-27 November 2021

26 NOVEMBER 2021 FRIDAY

10.00-11.15 Açılış Konuşmaları
Sanayi ve Teknoloji Bakanı Mustafa Varank’ın Yazılı Mesajı
Kongre Başkanı Prof. Dr. Ayşegül Alaybeyoğlu’nun Konuşması
Hasan Kalyoncu Üniversitesi Rektörü, Prof. Dr. Türkay Dereli’nin konuşması
İzmir Katip Çelebi Üniversitesi Rektör Yardımcısı, Prof. Dr. Adnan KAYA

11.15-11.30 ARA

11.30-12.00 Dr. Barbaros Kirişken
Vestel’de Yapay Zeka

1. SESSION 13.00-13.50

Session Chair: Dr. Serpil YILMAZ

No	ID	Paper Title
1	S-45	Çocukluk Çağı Anemisi Tanısında Makine Öğrenmesi Modellerinin Performansının Değerlendirilmesi
2	S-39	BERT Modeli ile COVID-19 Aşısı için Aşı Karşıtı Tweetlerin Arttığı Zaman Aralıklarının Tespiti
3	S-42	Fotoplethysmografi Sinyali Kullanan Akıllı Bileklikler için Kural Tabanlı Kan Basıncının Kestirimi için Yeni Bir Yöntem / A New Rule-Based Method for Smart Wristbands using Photoplethysmography Signal for Estimation of Blood Pressure
4	S-43	Prediction Diabetes using Machine Learning Techniques
5	S-38	Doğal Dil İşleme ve Makine Öğrenmesi Teknikleri ile Covid-19 Aşı Türlerinin Haber İçeriklerinin İncelenmesi

Discussion

2. SESSION 14.00-14.50

Session Chair: Assoc. Prof. Dr. Gökçe Nur YILMAZ

No	ID	Paper Title
6	S-55	Mikroskobik Kumaş Görüntülerinde Hata Tespiti için Derin Öğrenme Yaklaşımı
7	S-56	Snake Detection and Blurring System Using Deep Learning
8	S-57	Gender and Age Prediction Based on CNN Model
9	S-12	Deep Learning Based Traffic Sign Recognition in Digital Cluster System
10	S-24	Identification of Vehicle Lateral Dynamics in Carsim with a Deep Neural Network

Discussion

3. SESSION 15.00-15.50

Session Chair: Assoc. Prof. Dr. Mehmet Ali BELEN

No	ID	Paper Title
11	S-25	Yapay Sinir Ağı Tabanlı Mikroşerit Yansıtıcı Dizi Anten Birim Hücre Tasarımı
12	S-13	Bölge Tabanlı Evrişimli Sinir Ağı ile Yüz Tanıma
13	S-60	Siamese Networks for Predicting Remaining Useful Life of Machinery
14	S-61	KALİTE KONTROL KARTLARINDA YAPAY SİNİR AĞLARI İLE ÖRÜNTÜ TANIMA
15	S-49	CLASSIFICATION OF LAND-USE DATASET USING GOOGLNET & KNN

Discussion

4. SESSION 16.00-16.50

Session Chair: Dr. Osman GÖKALP

No	ID	Paper Title
16	S-34	Genetik Algoritma ile Çağrı Merkezi Çalışanları İçin Müşteri Atama Probleminin Optimizasyonu
17	S-10	Deprem Sonrası Hasarlı Yolların Yapay Zekâ İle Tespit Edilerek En Kısa Yol Güzergâhlarının Anlık Optimizasyonu
18	S-51	Predicting Mechanical Properties of Multifilament Polyester Woven Fabrics Using Artificial Intelligence Techniques
19	S-46	Uzun Süreli Kısa Bellek Ağı Yöntemi ile Trafik Yoğunluk Tahmini
20	S-20	Sezgisel Algoritmalarla Toplam Potansiyel Enerji Optimizasyonu Yönteminin Yapısal Çözümlemede Üstünlükleri ve Gelişmeler

Discussion

5. SESSION 17.00-17.50

Session Chair: Assoc. Prof. Dr. Orhan ER

No	ID	Paper Title
21	S-30	Kargo Teslimat Verileri Üzerinde Anomali Tespiti
22	S-36	Stock Price Prediction Using Deep Learning Methods in High-Frequency Trading
23	S-54	Sosyal Medyada Fenomenler ve Müşterileri Eşleyen Bir Çözüm Önerisi
24	S-03	Smart Parking
25	S-22	Prediction of Compressive Strength of Concrete via Machine Learning Methods

Discussion

27 NOVEMBER 2021 SATURDAY

1. SESSION 10.00-10.50

Session Chair: Assoc. Prof. Dr. Merih PALANDÖKEN

No	ID	Paper Title
26	S-48	Real Time Face Mask Detection on Surveillance Cameras in Edge Devices
27	S-18	Yapay Sinir Ağları İle Stronsiyum-90 Radyoizotopunun Nötron Reaksiyonlarının Tesir Kesiti Tahminleri
28	S-23	Yenilenebilir Enerjide Makine Öğrenimi Yöntemi ile Tahmin
29	S-21	Analysis of Kinematically Unstable Trusses with Finite Element Method with Energy Minimization
30	S-15	VERİ MADENCİLİĞİ İLE RÜZGAR TÜRBİNLERİNİN GÜÇ TAHMİNİ

Discussion

2. SESSION 11.00-11.50

Session Chair: Dr. Esra Aycan BEYAZIT

No	ID	Paper Title
31	S-52	Çok Alanlı Chatbot Mimarilerinde Avantajlı Performans ve Bellek Takası
32	S-62	PROTOTYPE OF A DIGITAL TWIN MODEL: A CASE STUDY ON CARTESIAN AXES CNC WORKBENCH
33	S-11	Using Ensemble Learning Methods For Predicting Successfulness of Startup Business
34	S-47	Taşınmaz Mal Değeri Kestiriminde Topluluk Algoritmalarının Doğruluk Analizi
35	S-31	Bir Minibar İçerisinde Faster R-CNN Evrişimsel Sinir Ağı Üzerinde Geliştirilen Modelin Nesne Tanıma Başarısına Tanıma Oranı ve Arka Planın Etkisinin Araştırılması

Discussion

3. SESSION 13.00-13.50

Session Chair: Assoc. Prof. Dr. Aytuğ ONAN

“1. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi”

No	ID	Paper Title
36	S-09	Sociological Dimensions of Algorithms
37	S-33	İş Sağlığı ve Güvenliği Alanında Yapay Zeka Uygulamaları
38	S-05	Yapay Zeka Konusunun Toplumsal Cinsiyet Kapsamında İncelenmesi: Mesleklere Yönelik Bir Araştırma
39	S-08	Gerçek Yapay Zekânın Önündeki Engel Bilinç midir?
40	S-06	Yapay Zekâ Etkisinde İç Mimarlığın Geleceği

Discussion

4. SESSION 14.00-14.50

Session Chair: Prof. Dr. Ayşegül ALAYBEYOĞLU

No	ID	Paper Title
41	S-14	Artificial Intelligence Applications in Renewable Energy
42	S-58	Derin Öğrenmeye Dayalı İkili Kodlar ile Verimli ve Hızlı İçerik Tabanlı Görüntü Erişimi
43	S-59	Hibrit Yüz Tanımlama Algoritması Geliştirilmesi ve Mevcut Modellerle Karşılaştırılması
44	S-02	AKILLI SULAMA SİSTEM TASARIMI
45	S-16	Genetik Algoritma Tabanlı Gri Tahmin Modeli Kullanarak Makine Arıza Zamanı Tahmini

Discussion

5. SESSION 15.00-15.50

Session Chair: Assoc. Prof. Dr. Levent AYDIN

No	ID	Paper Title
46	S-44	CONTROL OF THE FLUENCE PARAMETER FOR LASER THERAPY IN MELASMA TREATMENT WITH FUZZY LOGIC SYSTEM
47	S-50	Gerçek Ortamda Zeytin Meyvesinin YOLOv4 Nesne Tanıma Algoritması İle Tespiti
48	S-27	Yusuřuk Algoritması ile Termoplastik Hibrit Kompozitlerin Üretiminde Katkı Maddeleri Oranlarının Optimizasyonu
49	S-28	MASKE TESPİT VE ANLI UYARI SİSTEM TASARIMI
50	S-26	Optimum Design of the Rocket's Sub-units Based on Neuro-Regression Approach for Modeling
Discussion		
6. SESSION 16.00-16.50		
Session Chair: Dr. Fatih Soygazi		
No	ID	Paper Title
51	S-37	Yapay Zekanın Alt Dallarından Makina Öğrenmesi Yöntemleri ile Göğüs Kanseri Tespiti
52	S-19	Yüz Tanıma Algoritmalarının Arařtırmalarda Kullanım Şekline İliřkin Daraltılmış Literatür Çalışması
53	S-40	COVID19 Pandemisinde Türkiye İBBS-1 Bölgeleri Günlük Vaka Sayısı Trendinin Doğrusal Regresyonla Tahmini için Dijital bir Uygulama
54	S-41	DERİN ÖĞRENME YÖNTEMİYLE AKUT PULMONER EMBOLİNİN BİLGİSAYARLI TOMOGRAFİK PULMONER ANJİOGRAFİDE SEGMENTASYONU
Discussion		
17.00	KAPANIŞ KONUŞMASI	

- ***PROCEEDING PAPERS***
- ***TAM METİN BİLDİRİLER***

S-45 ÇOCUKLUK ÇAĞI ANEMİSİ TANISINDA

MAKİNE ÖĞRENMESİ MODELLERİNİN PERFORMANSININ DEĞERLENDİRİLMESİ

Banu İşbilen BAŞOK,¹ Veli İYİLİKÇİ², Murat ANIL³, Ayfer ÇOLAK⁴

¹Tıbbi Biyokimya Kliniği, SBÜ İzmir Tepecik Eğitim ve Araştırma Hastanesi, İzmir, Türkiye,
drisbilen@yahoo.com

² Tıbbi Biyokimya Kliniği, SBÜ İzmir Tepecik Eğitim ve Araştırma Hastanesi, İzmir, Türkiye,
veli931@gmail.com

³ Çocuk Sağlığı ve Hastalıkları Anabilim Dalı, İzmir Demokrasi Üniversitesi, İzmir, Türkiye,
murat.anil@uzem.idu.edu.tr

⁴ Tıbbi Biyokimya Kliniği, SBÜ İzmir Tepecik Eğitim ve Araştırma Hastanesi, İzmir, Türkiye,
ayfercolak@gmail.com

Giriş

Anemi; hemoglobin, hematokrit ya da eritrosit değerinin yaşa göre normal ortalama değerlerinin 2 standart sapmanın altında olması olarak tanımlanır. Çocukluk çağı anemisinde büyüme, gelişme ve kognitif fonksiyonlar ciddi düzeyde etkilendiğinden erken tanısı önemlidir. Aneminin kesin tanısında tam kan sayımı parametrelerinin yanı sıra, serum demir, demir bağlama kapasitesi, ferritin gibi biyokimyasal testlerin analizi ve yorumlanması gereklidir.

Amaç

Çalışmamızda yaş, cinsiyet ve biyokimyasal testleri kullanarak farklı makine öğrenme modellerinin anemi tanısı performansını değerlendirmeyi amaçladık.

Materyal ve Yöntem

1456 çocuk hastanın yaş, cinsiyet, tam kan sayımı, demir, demir bağlama kapasitesi, ferritin, B12, folat verileri Python Pandas, Matplotlib ve Scikit-learn kütüphaneleri kullanılarak Jupyter Notebook 6.4.0 yazılımında analiz edildi. Lojistik regresyon, lineer diskriminant analiz, K-en yakın komşu, karar ağacı, gaussian naive bayes, destek vektör ve rassal orman makine öğrenmesi modelleri oluşturuldu ve sınıflayıcıların model performansları doğruluk yüzdeleri üzerinden cross validasyon (n=10) ile belirlendi. Doğruluk yüzdeleri en yüksek 2 modelin performansı ROC analizi ile karşılaştırıldı.


Bulgular

Kız/erkek oranı 847/609, yaş (min-maks) 1-18 yıl idi. Modellerin test setindeki doğruluk performansları sırasıyla (%) 94, 92, 80, 97, 88, 78 ve 96 olarak tespit edildi. Doğruluğu en yüksek iki model olan karar ağacı ve rassal orman modellerinin area under curve (AUC) değerleri sırasıyla %92 ve %99 olarak belirlendi (Şekil1).

Sonuçlar ve Öneriler

Birçok hastalık durumunda da olduğu gibi anemi tanısında da tanı ve hastalığın doğru sınıflandırılması için birden fazla laboratuvar testinin değerlendirilmesi gerekir. Rassal orman sınıflayıcısı %99 AUC performansı ile anemi sınıflandırmasında oldukça etkin bir performans sağlamıştır. Test sonuç raporlarında analiz sonuçlarının yanı sıra bu çalışma örneğinde olduğu gibi makine öğrenmesi modellerinin sınıflandırma sonuçlarının raporlanması hastalığın erken tanısını sağlayabildiği gibi klinisyenlerin karar alma süreçlerini hızlandırabilir.

Anahtar Kelimeler: Anemi; tanı, makine öğrenmesi; sınıflandırma; karar ağacı; rassal orman



Şekil 1. ROC analizi.

Referanslar

1. Kliegmen RM, Blum NJ, Shah SS, et al. Nelson Textbook of Pediatrics. 21th ed. Canada: Elsevier; 2020.
2. Yazıcı S, Çelik T, Seyrek K. Çocukluk çağında anemi sıklığı. İzmir Dr. Behçet Uz Çocuk Hast. Dergisi 2012; 2(1):6-9
3. Manish Jaiswal, Anima Srivastava, Tanveer J. Siddiqui. Machine Learning Algorithms for Anemia Disease Prediction. In book: Recent Trends in Communication, Computing, and Electronics (pp.463-469), Springer Singapore, 2019.

S-39 BERT MODELİ İLE COVID-19 AŞISI İÇİN AŞI KARŞITI TWEETLERİN ARTTIĞI ZAMAN ARALIKLARININ TESPİTİ

Ülkü Tuncer KÜÇÜKTAŞ^{1*}, Fatih UYSAL², Fırat HARDALAÇ³, İsmail BİRİ⁴

¹ Elektrik-Elektronik Mühendisliği, Gazi Üniversitesi, Türkiye Cumhuriyeti, ulku.tuncer.kucuktas@gazi.edu.tr

² Elektrik-Elektronik Mühendisliği, Gazi Üniversitesi, Türkiye Cumhuriyeti, uysal@gazi.edu.tr

³ Elektrik-Elektronik Mühendisliği, Gazi Üniversitesi, Türkiye Cumhuriyeti, firat@gazi.edu.tr

⁴ Genel Cerrahi, Kuru Ankara Hastanesi, Türkiye Cumhuriyeti, genelcer44@hotmail.com

Özet

Covid-19'a karşı sunulan çözümlerden en etkili olanı geliştirilen çeşitli aşılar. Aşılar duyulan güvensizlik bu çözümün hızlı ve etkili kullanılmasına engel oluşturabilir. Toplumun düşüncelerini ifade etme araçlarından birinin sosyal medya olduğu söylenebilir. Sosyal medyada aşı karşıtlığının arttığı zaman aralıklarının belirlenmesi, kurumların aşı karşıtlığı ile mücadele ederken kullanacağı stratejiyi belirlemelerinde yardımcı olabilir. Ancak sosyal medya için girilen tüm tweetlerin takibinin ve kaydının insan gücü ile yapılması, çok iş gücü gerektireceğinden ve verimsiz olacağından dolayı çeşitli otomasyon çözümlerine ihtiyaç duyulmaktadır. Bu çalışma kapsamında derin öğrenme tabanlı bir doğal dil işleme (natural language processing) NLP modeli olan dönüştürücülerden çift yönlü kodlayıcı temsilleri (bidirectional encoder representations from transformers) BERT modeli kullanılmıştır. Haber, anlamsızlar, aşı karşıtlığı ve aşı destekleyenler olmak üzere 4 farklı kategoriye (sınıfa) ayrılmış 1506 tweetlik bir veri setinde model, 25 devir (epoch) boyunca 5e-6 eğitim oranıyla (learning rate) eğitilmiştir. Eğitilmiş model kullanılarak aşı karşıtı tweetlerin yoğunlaştığı aralıkların tespiti için 652840 tweetin ait olduğu kategoriler belirlenmiştir. Belirlenen kategorilerin zaman içerisinde değişimi görselleştirilip, değişime neden olabilecek olaylar belirlenmiştir. Model eğitimi sonucunda, test veri setinde 0.81 f-skoru ve sınıflar için ROC eğrisi altında kalan kalanlar (AUC değerleri) sırasıyla 0.99 / 0.91 / 0.92 / 0.92 olarak elde edilmiştir. Bu modelde, literatürdeki çalışmalardan farklı olarak bu tarz tweetlerin tespit edilip sansürlenmesinden farklı bir amaç ile belli bir zaman aralığında aşı karşıtı tweetlerin zamana göre atılma sıklığı ölçülüp görselleştirilerek kurumların strateji belirlerken kullanabilecekleri veri sağlayan yardımcı bir sistem tasarlanmıştır.

Anahtar Sözcükler: Covid-19; Derin Öğrenme; Doğal Dil İşleme; Twitter; Veri Madenciliği.

Abstract

The most effective of the solutions against Covid-19 is the various vaccines developed. Distrust of vaccines can hinder the rapid and effective use of this remedy. One of the means of expressing the thoughts of society is social media. Determining the time intervals during which anti-vaccination increases in social media can help institutions determine the strategy to be used in combating anti-vaccination. Recording and tracking every tweet entered with human labor would be inefficient, so various automation solutions are needed. In this study, The Bidirectional Encoder Representations from Transformers (BERT) model, which is a deep learning-based natural language processing (NLP) model, was used. In a dataset of 1506 tweets divided into four different categories as news, irrelevant, anti-vaccine, and vaccine supporters, the model was trained with a learning rate of $5e-6$ for 25 epochs. To determine the intervals in which anti-vaccine tweets are concentrated, the categories to which 652840 tweets belong were determined by using the trained model. The change of the determined categories overtime was visualized and the events that could cause the change were determined. As a result of model training, in the test dataset, the f-score of 0.81 and AUC values for different classes were obtained as 0.99/0.91/0.92/0.92, respectively. In this model, unlike the studies in the literature, an auxiliary system is designed that provides data that institutions can use when determining their strategy by measuring and visualizing the frequency of anti-vaccine tweets in a time interval, different from detecting and censoring such tweets.

Keywords: Covid-19; Deep Learning; Natural Language Processing; Twitter; Data Mining.

1. Giriş ve Amaç

Covid-19 dünya üzerinde milyonlarca ölüme sebebiyet vermesinin yanında devletleri sosyal ve ekonomik hayata zarar verecek önlemler almak zorunda bırakması ile insanlığa maddi ve manevi zararlar vermiştir. Covid-19 için sunulan çözümlerden en etkili olanlarına geliştirilen aşılara toplumun belirli bir kısmı şüphe duymaktadır. Literatürde islamofobi ve aşı karşıtlığı gibi zararlı görülebilecek konuların tespiti ve sansürü için tasarlanmış makine öğrenmesi algoritmaları bulunmaktadır. Bu çalışma kapsamında literatürde bulunan çalışmalardan farklı olarak aşı ile ilgili genel kanının zaman içerisinde nasıl değiştiğinin incelenebileceği bir araç geliştirilmeye çalışılmıştır. Literatürde aynı konuda tespit için kullanılan modellerden en iyi performans göstereni BERT olduğu için, bu çalışma kapsamında da BERT modeli kullanılmıştır [1]. 22 Temmuz 2021 ve 22 Ağustos 2021 tarihleri arasında atılmış tüm tweetler kazınarak, eğitilen BERT modeli ile kategorileri belirlenmiş ve zamana göre değişimleri görselleştirilmiştir.

1.1 Literatür Özeti

To ve arkadaşları, aşı karşıtı tweetlerin tespiti için BERT, Bi-LSTM (long short-term memory), destek vektör makineleri (support vector machine, SVM), ve saf bayes (naive bayes, NB) sınıflandırma metodlarını karşılaştırmışlardır. Toplam 1,651,687 tweet içeren çalışmanın

sonucunda BERT 0.95 f-skoru ile en büyük başarıyı göstermiştir [1]. Ruiz ve arkadaşları tarafından, doğal dil işleme yöntemleri kullanılarak aşı karşıtı ve aşı destekleyen internet grupları ve bu grupların birbiri ile olan ilişkisi incelenmiştir [2]. Ayan ve arkadaşları tarafından, twitter üzerinde islama fobi içeren tweetlerin tespiti için yapılan çalışmada 162.000 tweet içeren bir veri seti ile NB ve Ridge Regresyonu kullanmıştır [3]. Xue ve arkadaşları, twitter üzerinde covid-19 ile alakalı 4 milyon tweet üzerinde, Latent Dirichlet Allocation (LDA) yaklaşımını kullanarak incelemelerde bulunmuştur [4]. Budhwani ve Sun, Başkan Trump'ın "Çin virüsü" tweetini attığı 16 Mart 2020'den önceki ve sonraki tweet tartışmalarını karşılaştırmış ve Amerika Birleşik Devletleri'ndeki birçok eyalette insanların tweetlerinde "Çin virüsü" kullanımının önemli ölçüde arttığını tespit etmiştir [5].

2. Materyal ve Yöntem

2.1. Veri Seti

Twitter üzerinde paylaşılan 22 Temmuz 2021 - 22 Ağustos 2021 tarihleri arasında, içerisinde aşı sözcüğü geçen toplam 652840 tweet , snsrape kütüphanesi kullanan bir Python scripti ile çekilmiştir. Snsrape, sosyal ağ hizmetleri için bir kazıyıcıdır (scraper). Kullanıcı profilleri, hashtag'ler veya aramalar gibi şeyleri kazır ve kazılan öğeleri döndürür. Veri madenciliği için kullanılan araçlardan bir tanesidir [6]. Daha sonra bu kazınan tweetlerin içerisinden 1506 tanesi Doğal Dil İşleme modelinin eğitimi için rastgele seçilip 4 kategoriye ayrılmıştır. Veri setinin %80'i eğitim aşamasında, %20'si ise test aşamasında kullanılmıştır. Aşağıda belirtilen Tablo 1'de her bir kategoriye ilişkin olarak açıklamalar, miktarlar ve hastag'ler yer almaktadır.

Kategoriler	Açıklama	Adet	Popüler Hastag'ler
Haber	Kurumların yaptığı açıklamaları ve istatistikleri içeren tweetler	93	#asiol #sondakika #haber
Anlamsızlar	Aşı kelimesi içeren ancak fikir belirtmeyen tweetler	406	
Aşı Karşıtları	Aşı karşıtı tweetler	583	#asiolmayacağım #asizorbalıgnadiren
Aşı Destekleyenler	Aşı olunması yönünde tavsiye veren tweetler	424	#asiol #asiolalim #birliktebasaracağız

Tablo 1

2.2. Model


Aşı karşıtı tweetlerin tespiti için derin öğrenme temelli bir doğal dil işleme modeli kullanılmıştır. Bu model sınıflandırma ve soru cevaplama gibi geniş yelpazede görevler için kullanılabilen BERT modelidir. BERT modeli sadece son bir ek katmanını eğitilerek, kullanılabilir. Modelimiz için, MDZ Dijital Kütüphane ekibi (dbmdz) tarafından sağlanan önceden eğitilmiş bir tokenizer ve önceden eğitilmiş bir Türkçe BERT modeli kullanılmıştır [7]. BERT modeli diğer modellerden farklı olarak cümleyi hem sağdan sola hem soldan sağa değerlendirmeye çalışır ve bu sayede daha iyi sonuçlar elde etmeyi amaçlar. Bert modelinin ön-eğitimi (pre-train) NSP (next sentence prediction) denilen bir yöntem, Wikipedia ve BookCorpus gibi veri setleri kullanılır [8].

Çalışma kapsamında kullanılan veri seti ile, BERT modelinde ince ayar (fine-tune) yapılarak, 25 devir (epoch) boyunca 5e-6 öğrenme oranı (learning-rate) ile ADAM optimizör kullanılarak

eđitilmiřtir. Eđitim tamamlandıktan sonra model kullanarak 652840 tweet iin kategoriler belirlenmiřtir ve belirlenen kategoriler Python matplotlib kütüphanesi ile görselleřtirilmiřtir.


3. Bulgular

Veri setinde bulunan tweetlerin zaman göre atılma sıklıđı, modelin 652840 tweet iin yaptıđı tahminler kullanılarak elde edilen kategorilerin zaman iinde deđiřimi ve ařı karřıtı tweetlerin zaman ierisinde yüzde olarak deđiřimi Őekil 1’de bulunabilir.




Őekil 1

Modelin test veri seti ile değerlendirilmesi sonucu elde edilen ROC-eğrileri ve “Confusion matrix” i Şekil 2’de gösterilmiştir



Şekil 2

Modelin sınıflara göre f1-skoru, recall ve precision değerleri Şekil 3’de gösterilmiştir.



Şekil 3

4. Sonuçlar ve Öneriler

BERT dil işleme modeli, 1506 tweetten oluşan veri seti ile eğitiminin sonucunda tweetleri kategorilere ayırabilmiştir. Daha sonra 652840 tweetin kategorileri model ile belirlenmiş ve zamana göre değişimleri görselleştirilmiştir. Aşı olmayı destekleyen tweetlerin yüzde olarak en yüksek olduğu tarih 28 Temmuz ve Aşı karşıtı tweetlerin yüzde olarak en yüksek olduğu zamanlar 11 ve 19 Ağustos olarak tespit edilmiştir.

- 1) T.C. Sağlık Bakanı Sayın Dr. Fahrettin KOCA'nın 28 Temmuz 2021 tarihli Açıklaması [9]
- 2) T.C. Cumhurbaşkanı Sayın Recep Tayyip ERDOĞAN'ın 11 ve 19 Ağustos 2021 tarihli Açıklamaları [10,11]

Aşı ile ilgili bu açıklamalar incelendiğinde; 28 Temmuz açıklamasında yoğun bakımdaki hastaların çoğunluğunun aşı olmayanlar olması hakkında istatistikler verilirken 11-19 Ağustos açıklamalarında aşı olmayanlar için gelecek kısıtlama ve yasaklar açıklanmaktadır. Resmi kurumların ve/veya devlet yetkililerinin yaptığı açıklamaların, toplumun aşuya karşı tavrına etkisinin büyük olduğu sonucu çıkarılabilir. Bu açıklamalardan bilimsel veriler ile aşının faydalarını anlatan açıklama oldukça pozitif bir etki ile karşılanırken bu konuda yasaklar koymak toplumda bazı şüpheler oluşmasında etkili olduğu yorumu yapılabilir. Sivil toplum

kurumlarının ve devletin karar verici kuruluşların Covid-19 harici sorunlarda da halkın tepkisini ölçmek için doğal dil işleme ve sosyal medyayı kullanması daha iyi karar almalarında yardımcı olabilir.

Kaynakça

- [1] Q. G. To, K. G. To, V.-A. N. Huynh, N. T. Q. Nguyen, D. T. N. Ngo, S. J. Alley, A. N. Q. Tran, A. N. P. Tran, N. T. T. Pham, T. X. Bui ve C. Vandelanotte, «Applying Machine Learning to Identify Anti-Vaccination Tweets during the COVID-19 Pandemic,» *Int J Environ Res Public Health*, no. 18, p. 4069, 2021.
- [2] J. Ruiz, J. D. Featherstone ve G. A. Barnett, «Identifying Vaccine Hesitant Communities on Twitter and their Geolocations: A Network Approach,» %1 içinde *HICSS 2021*, 2021.
- [3] B. AYAN, B. KUYUMCU ve B. CİYLAN, «Detection of Islamophobic Tweets on Twitter Using Sentiment Analysis,» *GU J Sci*, cilt 7, no. 2, pp. 495-502, 019.
- [4] J. Xue, J. Chen, R. Hu, C. Chen, C. Zheng, Y. Su ve T. Zhu, «Twitter Discussions and Emotions About the COVID-19 Pandemic: Machine Learning Approach,» *J Med Internet Res.*, no. 11, pp. 25-22, 2020.
- [5] H. Budhwani ve R. Sun, «Creating COVID-19 Stigma by Referencing the Novel Coronavirus as the "Chinese virus" on Twitter: Quantitative Analysis of Social Media Data,» *J Med Internet Res.*, no. 5, pp. 6-22, 2020.
- [6] JustAnotherArchivist, «snsrape: A social networking service scraper in Python,» [Çevrimiçi]. Available: <https://github.com/JustAnotherArchivist/snsrape>. [Erişildi: 26 08 2021].
- [7] MDZ Digital Library team, «dbmdz Turkish BERT model,» MDZ Digital Library team (dbmdz) at the Bavarian State, [Çevrimiçi]. Available: <https://huggingface.co/dbmdz/bert-base-turkish-cased>. [Erişildi: 26 08 2021].
- [8] J. Devlin, M.-W. Chang, K. Lee ve K. Toutanova, «BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,» *arXiv preprint*, 2018.
- [9] Twitter, «28 Temmuz 2021 - Sağlık Bakanı Fahrettin Koca'nın Bilim Kurulu sonrası açıklaması,» [Çevrimiçi]. Available: <https://twitter.com/drFahrettinKoca/status/1420455185357361154>. [Erişildi: 26 08 2021].
- [10] «Aşı olmayanlar şehirler arası seyahat edebilecek mi?,» TRT HABER, [Çevrimiçi]. Available: <https://www.trthaber.com/haber/guncel/asi-olmayanlar-sehirler-arasi-seyahat-edebilecek-mi-asi-olmayanlara-pcr-testi-zorunlulugu-603441.html>. [Erişildi: 26 08 2021].
- [11] TRT HABER, «Cumhurbaşkanı Erdoğan: Aşı olmayandan PCR testi isteyeceğiz,» [Çevrimiçi]. Available: <https://www.trthaber.com/haber/gundem/cumhurbaskani-erdogan-asi-olmayan-pcr-testi-isteyecegiz-603030.html>. [Erişildi: 26 08 2021].

S-42 FOTOPLETİSMOGRAFİ SİNYALİ KULLANAN AKILLI BİLEKLİKLER İÇİN KURAL TABANLI KAN BASINCININ KESTİRİMİ İÇİN YENİ BİR YÖNTEM

Muhammed Kürşad UÇAR ¹

¹ Elektrik-Elektronik Mühendisliği, Mühendislik Fakültesi, Sakarya Üniversitesi, Sakarya, Türkiye, mucar@sakarya.edu.tr

<https://orcid.org/0000-0002-0636-8645>

Özet

Kan basıncının izlenmesi başta hipertansiyon hastaları olmak üzere pek çok sağlık kontrolünde sıklıkla kullanılan bir yöntemdir. Rutin ölçümlerde sfigmomanometre yardımıyla teknik personel tarafından yapılır. Kan basıncının sürekli izlenebilmesi için giyilebilir sensörler içeren teknik kullanım bilgisi gerektirmeyen yeni teknolojilere ihtiyaç duyulmaktadır. Bu çalışmanın amacı Fotoplethysmografi (PPG) Sinyali kullanan akıllık bileklikler için kural tabanlı sistolik ve diastolik kan basıncı hesaplamak için model geliştirmektir. Bunun için beş bireye ait üç günlük PPG ve Kan Basıncı (KB) verileri kullanılmıştır. Çalışmada, PPG sinyali filtrelenmiş ve 10 saniyelik epoklara ayrılmıştır. Her epoktan 25 adet özellik çıkarılmıştır ve ilgili özellikler seçilmiştir. Her epok için KH üzerinden sistolik ve diastolik kan basıncı hesaplanmıştır. Sistolik ve diastolik kan basıncı ölçümü için geliştirilen modellerin R performans değeri sırayla 0,95 ve 0,92'dir. Her model kısa 3-4 kural ile anlaşılabilir. Elde edilen sonuçlara göre PPG sinyali kullanan akıllı bilekliklerde kural tabanlı sistolik ve diastolik kan basıncının hesaplanabileceği değerlendirilmektedir.

Anahtar Sözcükler: *Fotoplethysmografi Sinyali, Kan Basıncı, Makine Öğrenmesi.*

A New Rule-Based Method for Smart Wristbands using Photoplethysmography Signal for Estimation of Blood Pressure

Abstract

Monitoring blood pressure is a method frequently used in many health controls, especially in hypertension patients. Routine measurements are made by technical personnel with the help of a sphygmomanometer. In order to continuously monitor blood pressure, new technologies that include wearable sensors and do not require technical usage knowledge are needed. This study aims to develop a model for calculating rule-based systolic and diastolic blood pressure for smart wristbands using Photoplethysmography (PPG) Signal. For this, three-day PPG and Blood Pressure (BP) data of five individuals were used. In the study, the PPG signal was filtered and divided into 10-second epochs. Twenty-five features were extracted from each epoch, and the relevant features were selected. For each epoch, systolic and diastolic blood pressures were calculated over BP. The R performance values of the

models developed for the measurement of systolic and diastolic blood pressure are 0.95 and 0.92, respectively. Each model can be understood with short 3-4 rules. According to the results obtained, it is evaluated that rule-based systolic, and diastolic blood pressure can be calculated in smart wristbands using PPG signal.

Keywords: Blood Pressure, Machine Learning, Photoplethysmography Signal.

1. Giriş

Hipertansiyon kalbinten çıkan atardamarlardaki kan basıncının gereğinden fazla yüksek olması olarak tanımlanabilir. Dünyada sıklıkla karşılaşılan bir sağlık problemidir [1]. Kan basıncının non-invaziv yöntemler ve yüksek doğruluk oranı ile ölçülmesi klinik teşhis, tedavi ve araştırmalar için büyük öneme sahiptir [2]. Hipertansiyon sağlık okuryazarlığı ile doğrudan ilişkili olduğu tespit edilmiş ve yaşam kalitesinin doğrudan etkilendiği tespit edilmiştir [3].

Hipertansiyon hastalarının kan basınçlarını sürekli takip etmeleri ve ilaç tedavilerini sürdürmeleri hayati öneme sahiptir [1], [3]. Tüm bu durumlar değerlendirildiğinde kan basıncının izlenmesi için pratik ölçülebilir, hasta konforunu bozmayan taşınabilir ve giyilebilir sensörler içeren yeni teknolojilere ihtiyaç vardır.


Literatürde kan basıncının hesaplanması için PPG ve Elektrokardiyografi Sinyali sıklıkla kullanılmaktadır [4]–[7]. Bu çalışmalarda genellikle KB sinyali tahmin edilmektedir [6]. Çalışmalarda genellikle zaman ve frekans domenlerinde özellik çıkarılır [4], [5]. Makine öğrenmesi algoritması olarak Yinelenebilir Yapay Ağlar (Recurrent Neural Networks - RNN), Long-Short Term Memory Neural Network (LSTM-NN) gibi ağlar tercih edilmiştir [4], [5].

Çalışmanın amacı Fotoplethysmografi Sinyali (PPG) kullanan akıllı bileklikler için kural tabanlı sistolik ve diastolik kan basıncının tahmini için kural tabanlı sistem geliştirmektir. Bu amaçla beş bireye ait dört günlük Kan Basıncı (KB) ve PPG sinyali verisi kullanılmıştır. İlk olarak PPG sinyali filtrelenmiş ve 10 saniyelik epoklara bölünmüştür. Her epoktan 25 adet zaman domeninde özellik çıkarılmıştır. Her epok için sistolik ve diastolik kan basıncı değerleri KH sinyali üzerinden hesaplanmıştır. Özellik seçme algoritması yardımıyla özellikler azaltılarak kural tabanlı modeller oluşturulmuştur.


Bu çalışmada literatürden farklı olarak PPG sinyali kullanan akıllı bileklikler sistolik ve diastolik kan basıncını hesaplayan kural tabanlı bir model önerilmiştir. Çalışmanın içerdiği yenilikler şunlardır: (1) Akıllı bileklik için sinyal tabanlı hesaplama yapılmaktadır. (2) Özellik seçme algoritması ile sinyal işleme iş yükü azaltılmıştır. (3) Kural tabanlı tahmin sistemi ile uygulanabilir modeller oluşturulmuştur. (4) Yüksek doğruluk oranına sahiptir.

2. Materyal ve Metot


Uygulama Şekil 1'deki sürece göre tasarlanmıştır. Akışa göre PPG sinyalleri sayısal filtreler yardımıyla temizlenmiştir. Ardından sinyal 10 saniyelik epoklara ayrılmıştır. Her epoktan özellik çıkarılmış ve seçilmiştir. Nihayetinde özellik matrisleri karar ağaçları yardımıyla kan basınçlarının hesaplanması için modeller oluşturulmuştur.



Şekil 1. Akış diyagramı



Şekil 2. Verilerin dağılımı



Şekil 3. Örnek BP Kan Basıncı Sinyali ve Kan Basıncı değerlerinin hesaplanması

2.1. Verilerin Toplanması

Çalışmada kullanılan veriler açık kaynaklı paylaşılan IEEE Dataport verisetidir [8], [9]. Çalışmada sağlıklı beş bireyden (Dört erkek yaş: $28 \pm 6,6$) üç gün boyunca günde ortalama 5-6 saat PPG ve Kan Basıncı (KB) kayıtları toplanmıştır. Birinci gün dördüncü bireyden alınan örnek bir kayıt Şekil 2'de gösterilmiştir.

2.2. Sinyal Ön İşleme

Sinyal ön işleme adımında PPG sinyali sayısal filtre (0,1-20 Hz IIR-Chebyshev Type II bant geçiren filtre) yardımıyla temizlenmiş. Geliştirilen modellerin hızlı sonuç üretebilmesi için her kayıt 10 saniyelik epoklara ayrılmıştır. Her epok için sistolik ve diastolik kan basıncı değerleri hesaplanmış ve ortalamaları alınmıştır. Hata oranını azaltmak için hesaplanan bu ortalama değerler 10 saniyelik epoklar için kan basıncı değerlerine karşılık gelmektedir. Şekil 3'te 10 saniyelik bir epok gösterilmiştir. Bu epok için PPG sinyali, KB sinyali ve epoğa açık kan basıncı değerlerinin örnek hesaplanması gösterilmiştir.

2.3 Özellik Çıkarma

Her epoktan 25 adet zaman domeni özelliği çıkarılmıştır. Özellikler ve numaraları şu şekildedir. 1 Basıklık (Kurtosis), 2 Çarpıklık (Skewness), 3 Çeyrekler arası genişlik (IQR), 4 Değişim katsayısı, 5 Geometrik ortalama, 6 Harmonik ortalama, 7 Hjort parametresi – Aktivite, 8Hjort parametresi – Hareketlilik, 9 Hjort parametresi – Karmaşıklık, 10 Maksimum, 11 Medyan, 12 Ortalama ya da meydan mutlak sapma, 13 Minimum, 14 Moment, merkezi moment, 15 Ortalama, 16 Ortalama eğri uzunluğu, 17 Ortalama enerji, 18 Ortalama karekök değeri, 19 Standart hata, 20 Standart sapma, 21 Şekil faktörü, 22 Tekil değer ayrışımı, 23 %25 kırılmış ortalama, 24 %50 kırılmış ortalama, 25 Ortalama Teager enerjisi'dir. Özelliklerin detaylı formülleri için ilgili makale incelenebilir [10].

2.4. Özellik Seçme

Çalışmada özellik seçme algoritması olarak Spearman Korelasyon Katsayısı kullanılmıştır [11]. Çalışmada kullanılan 25 adet özellik korelasyon değerlerine göre sıralanmıştır. Sistolik ve diastolik kan basıncının için geliştirilen modellerde en ilgiliden en ilgisiz özellik sıralaması şu şekildedir: 1, 2, 4, 5, 6, 7, 8, 9, 12, 14, 17, 18, 19, 20, 21, 22, 25, 24, 23, 15, 3, 16, 10, 13, 11'dir.

Özelliklerin sistolik ve diastolik kan basıncı modelleri için aynı olması parametrelerin benzer olması ile açıklanabilir (Şekil 3).

2.5. Karar Ağaçları

Çalışmada modelleme için karar ağaçları tercih edilmiştir [12]. Bu sayede pratikte gömülü sistemlere uygulanabilir karmaşıklığı az algoritma üretilebilecektir.

2.6. Performans Değerlendirme

Geliştirilen modellerin performansının kontrolü için Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Karekök Sapması (RMSE), Ortalama Mutlak Sapma (MAD), Korelasyon Katsayısı R, Açıklayıcılık Katsayısı R^2 ve Ortalama Hata Karesi (MSE) kullanılmıştır [10], [13].

R ve R^2 değerlerinin 1'e yakın olması MAPE, RMSE, MAD, SH ve MSE'nin 0'a yakın olması beklenir.

3. Sonuçlar

Çalışmanın amacı PPG sinyali kullanan akıllı bileklikler için kural tabanlı sistolik ve diastolik basıncının hesaplanmasıdır. Bu amaçla PPG sinyali filtrelenmiş ve 10 saniyelik epoklara bölünmüştür. Her epoktan 25 adet özellik çıkarılmış ve özellik seçme algoritması ile özellikler azaltılmıştır. Daha sonra karar ağaçları ile modeller oluşturulmuştur.

Sistolik kan basıncının hesaplanması için seçilen her özellik grubu ile karar ağacı modeli oluşturulmuştur (Tablo 1). Oluşturulan her modelin performansının benzer olması her özelliğin kan basıncı değerleri ile yüksek korelasyona ($R=1$) sahip olması ile açıklanabilir. Modellerin hata oranı (MAD) %2,77 ve model R değeri 0,95'tir (Tablo 1).

Tablo 1. *Sistolik ve Diastolik Kan Basıncı için geliştirilen model performansları*


Sistolik Kan Basıncı Modeli										Diastolik Kan Basıncı Modeli									
Bilgi		Performans Değerlendirme Kriterleri								Bilgi		Performans Değerlendirme Kriterleri							
Ö S	Ö S	MA PE	RM SE	M AD	S H	0 R	0 R ²	25 E	Ö S	Ö S	MA PE	RM SE	M AD	S H	0 R	0 R ²	15 E		
1	1	5	2.77	5.06	5	06	95	90	57	1	1	5	3.69	3.88	7	88	92	84	03
2	3	10	2.77	5.06	5	06	95	90	57	2	3	10	3.69	3.88	7	88	92	84	03
3	4	15	2.77	5.06	5	06	95	90	57	3	4	15	3.69	3.88	7	88	92	84	03
4	5	20	2.77	5.06	5	06	95	90	57	4	5	20	3.69	3.88	7	88	92	84	03
5	6	25	2.77	5.06	5	06	95	90	57	5	6	25	3.69	3.88	7	88	92	84	03

6	8	30	2.77	5.06	3.8	5.	0.	0.	25.	6	8	30	3.69	3.88	2.8	3.	0.	0.	15.				
7	9	35	2.77	5.06	3.8	5.	0.	0.	25.	7	9	35	3.69	3.88	2.8	3.	0.	0.	15.				
8	0	40	2.77	5.06	3.8	5.	0.	0.	25.	8	0	40	3.69	3.88	2.8	3.	0.	0.	15.				
9	1	45	2.77	5.06	3.8	5.	0.	0.	25.	9	1	45	3.69	3.88	2.8	3.	0.	0.	15.				
1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.	1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.
1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.	1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.
1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.	1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.
1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.	1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.
1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.	1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.
1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.	1	1	0	3	50	2.77	5.06	3.8	5.	0.	0.	25.


S: Seviye, ÖS: Özellik Sayısı, ÖY: Özellik Yüzde

Diastolik kan basıncının hesaplanması için seçilen her özellik grubu ile karar ağacı modeli oluşturulmuştur (Tablo 1). Oluşturulan her modelin performansının benzer olması her özelliğin kan basıncı değerleri ile yüksek korelasyona ($R=0,1$) sahip olması ile açıklanabilir. Modellerin hata oranı (MAD) %3,69 ve model R değeri 0,92'tir (Tablo 1).

Sistolik ve diastolik kan basıncının hesaplanması için karar ağacı modelleri tek özellik (Özellik Numarası 1) için Şekil 4'ta özetlenmiştir. Kuralların sade olması için tek özellik tercih edilmiştir. Model performansları eşit olduğu için özellik sayısının az olması kuralların okunabilirliğini arttıracaktır. Ağaç derinlik seviyesi arttırıldıkça doğruluk oranı artmaktadır. Ancak bu durumda ağaç karmaşıklığı artmaktadır. Bu sebeple bu çalışmada en az derinlikte en az özellik ilke sistolik ve diastolik kan basıncı tahmin edecek kurallar tespit edilmiştir.



Sistolik Kan Basıncı Kuralları



Diastolik Kan Basıncı Kuralları

Şekil 4. Kural tabanlı Kan Basıncının Tespit Edilmesi

4. Tartışma ve Sonuç

Bu çalışmada PPG sinyali kullanan akıllı bileklikler için sistolik ve diastolik kan basıncının hesaplanması için kural tabanlı modeller geliştirilmiştir. Kan basıncının izlenmesi ve ihtiyaca göre ilaç tedavisinin uygulanması Hipertansiyon hastaları için hayati öneme sahiptir [1]. Sıklıkla kullanılan tansiyon cihazlarının sürekli kullanımını pratik açıdan uygun değildir. Bu bakımdan giyilebilir sensörler içeren yeni teknolojilere ihtiyaç duyulmaktadır.

Programlama kolaylığı için kural tabanlı sistemler tercih edilir. Ancak kuralların çıkarılması her zaman kolay olmaz. Literatürde makine öğrenmesi algoritmalarıyla önerilen kan basıncı tahmin modellerinde genellikle kurallar bulunmamaktadır [4], [5], [14].

ECG ve PPG sinyali ile LSTM tabanlı yapılan bir çalışmada kan basıncı hesaplama modelinin performans değeri $R=0,72-0,75$ olarak belirlenmiştir [4]. Bu çalışmada önerilen modellerin performans değeri ise $R=0,92-0,95$ arasında değişmektedir. Modellerde PPG sinyali tercih edilmiştir. LSTM'in gömülü sistem kullanımı henüz yaygın ve kullanışlı değildir. Bu bakımdan incelendiğinde önerilen modeller literatür ile uyumlu ve kullanışlıdır.

Yapılan farklı bir çalışmada, klasik tansiyon ölçüm düzeneği ve koldan PPG sinyali ile kan basıncı hesaplanması yapılmıştır [15]. Modelde Gaussian Process Regresyon metodu kullanılırken model performansı $R=0,70-0,92$ olarak hesaplanmıştır. Sistem performansı her ne kadar iyi olsa da sürekli vücuda entegre kullanım kolaylığı bulunmamaktadır.

Referanslar

- [1] P. D. Karakurt, “Hipertansiyon ve Evde Bakım,” *Atatürk Üniversitesi Hemşirelik Yüksekokulu Derg.*, vol. 10, no. 1, pp. 97–104, 2007, Accessed: Jun. 03, 2021. [Online]. Available: <https://dergipark.org.tr/en/pub/ataunihem/issue/2636/33917>.
- [2] S. Tanaka, M. Nogawa, T. Yamakoshi, and K. Yamakoshi, “Accuracy Assessment of a Noninvasive Device for Monitoring Beat-by-Beat Blood Pressure in the Radial Artery Using the Volume-Compensation Method,” *IEEE Trans. Biomed. Eng.*, vol. 54, no. 10, pp. 1892–1895, 2007, doi: 10.1109/TBME.2007.894833.
- [3] E. Öncü, “Sağlık Okuryazarlığının Hipertansiyon Kontrolünde Önemi,” *Dünya İnsan Bilim. Derg.*, vol. 2018, no. 1, pp. 45–70, May 2018, Accessed: Jun. 03, 2021. [Online]. Available: <https://dergipark.org.tr/en/pub/insan/694112>.
- [4] Ü. Şentürk, K. Polat, and İ. Yücedağ, “A non-invasive continuous cuffless blood pressure estimation using dynamic Recurrent Neural Networks,” *Appl. Acoust.*, vol. 170, p. 107534, Dec. 2020, doi: 10.1016/j.apacoust.2020.107534.
- [5] U. Senturk, I. Yuicedag, and K. Polat, “Cuff-less continuous blood pressure estimation from Electrocardiogram(ECG) and Photoplethysmography (PPG) signals with artificial neural network,” in *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, Jul. 2018, pp. 1–4, doi: 10.1109/SIU.2018.8404255.
- [6] S. H. Liu, S. H. Lai, J. J. Wang, T. H. Tan, and Y. F. Huang, “The Cuffless Blood Pressure Measurement with Multi-dimension Regression Model based on Characteristics of Pulse Waveform,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Jul. 2019, pp. 6838–6841, doi: 10.1109/EMBC.2019.8856749.
- [7] M. Lubin, D. Vray, and S. Bonnet, “Blood pressure measurement by coupling an external pressure and photo-plethysmographic signals,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Jul. 2020, vol. 2020-July, pp. 4996–4999, doi: 10.1109/EMBC44109.2020.9176730.
- [8] C. Landry, E. T. Hedge, R. L. Hughson, S. D. Peterson, and A. Arami, “Wearable

- Physiological and Blood Pressure Measurements During Activities of Daily Living,” *IEEE Dataport*, 2021, doi: <https://dx.doi.org/10.21227/wysp-gt69>.
- [9] C. Landry, E. T. Hedge, R. L. Hughson, S. Peterson, and A. Arami, “Accurate Blood Pressure Estimation during Activities of Daily Living: A Wearable Cuffless Solution,” *IEEE J. Biomed. Heal. Informatics*, 2021, doi: 10.1109/JBHI.2021.3054597.
- [10] M. K. Uçar, Z. Uçar, K. Uçar, M. Akman, and M. R. Bozkurt, “Determination of body fat percentage by electrocardiography signal with gender based artificial intelligence,” *Biomed. Signal Process. Control*, vol. 68, p. 102650, Jul. 2021, doi: 10.1016/j.bspc.2021.102650.
- [11] R. Alpar, *Uygulamalı istatistik ve geçerlilik güvenirlilik: Spor, sağlık ve eğitim bilimlerinden örneklerle*, 2nd ed. Ankara: Detay Yayıncılık, 2016.
- [12] A. T. Azar and S. M. El-Metwally, “Decision tree classifiers for automated medical diagnosis,” *Neural Comput. Appl.*, vol. 23, no. 7–8, pp. 2387–2403, Dec. 2013, doi: 10.1007/s00521-012-1196-7.
- [13] M. K. Uçar, M. Nour, H. Sindi, and K. Polat, “The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets,” *Math. Probl. Eng.*, vol. 2020, pp. 1–17, 2020, doi: 10.1155/2020/2836236.
- [14] Ü. Şentürk, K. Polat, and İ. Yücedağ, “Towards wearable blood pressure measurement systems from biosignals: a review,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 27, no. 5, pp. 3259–3281, Oct. 2019, doi: 10.3906/elk-1812-121.
- [15] A. S. Alghamdi, K. Polat, A. Alghoson, A. A. Alshdadi, and A. A. Abd El-Latif, “Gaussian process regression (GPR) based non-invasive continuous blood pressure prediction method from cuff oscillometric signals,” *Appl. Acoust.*, vol. 164, p. 107256, Jul. 2020, doi: 10.1016/j.apacoust.2020.107256.

S-43 PREDISCTION DIABETES USING MACHINE LEARNING TECHNIQUES

Şeyma KIZILTAŞ¹, Dr. Mustafa YENİAD²

¹ Computer Engineering, Ankara Yıldırım Beyazıt University, Turkey,
kiziltasseyma@gmail.com

² Computer Engineering, Ankara Yıldırım Beyazıt University, Turkey, myeniad@ybu.edu.tr

Özet

Teknoloji, insanların yaşam biçimini iyileştirmek için sürekli geliyor ve sağlık sektöründe kullanılan teknoloji de hızla değişiyor. Örneğin hastalıkların teşhis ve tedavisinde farklı teknolojik cihazlar kullanılmaktadır. Gelişen teknoloji ile birlikte bilgisayar sistemleri ile hastalıkların teşhisinin yapılabileceği ortaya çıkmıştır. Makine öğrenmesi algoritmaları birçok alanda olduğu gibi sağlık alanında yüksek performans göstermesi nedeniyle sıklıkla başvurulan bir tekniktir. Bu çalışmanın amacı, diyabet teşhisinde kullanılabilecek farklı türde makine öğrenimi sınıflandırma algoritmalarını araştırmak ve karşılaştırmalı analizlerini göstermektir. Çalışmada, literatürde sıkça kullanılan yedi sınıflandırma algoritması kullanılmıştır. Bu algoritmalar, Lojistik Regresyon, K-En Yakın Komşu, Çok Katmanlı Algılayıcılar, Rastgele Orman, Karar Ağaçları, Destek Vektör Makinesi ve Naive Bayes sınıflandırma algoritmalarıdır. İlk olarak algoritmaların sınıflandırma başarıları karşılaştırılmıştır. Bu karşılaştırmalar, doğruluk, duyarlılık, kesinlik ve F1 skoru oranları üzerinden yapılmıştır.

Anahtar Sözcükler: *Karar Ağaçları, Makina Öğrenmesi, Naive Bayes, Şeker Hastalığı, Yapay Sinir Ağları.*

Abstract

Technology is continuously developing to improve the way people live and technology used in healthcare industry is also changing quickly. For instance, different technological devices are used for the diagnosis and treatment of diseases. It has been revealed that diagnosis of disease can be made by computer systems with developing technology. Machine learning algorithms are used in the field of health, as like as sales and marketing, logistics and finance areas, due to their high performance. The aim of this study is to explore different types of machine learning classification algorithms that can be used in diabetes diagnosis and to show their comparative analysis. In the study, seven classification algorithms were used in the literature. These algorithms are Logistic Regression, K-Nearest Neighbor, Multi-Layer Perception, Random Forest, Decision Trees, Support Vector Machine and Naive Bayes. Firstly, classification performance of algorithms are compared. These comparisons are based on accuracy, sensitivity, precision, and F1-score.

Keywords: *Artificial neural network, Decision Tree, Diabetes Disease, Machine learning, Naive Bayes.*

1. Introduction

Diabetes mellitus is generally well-known as diabetes. Diabetes mellitus occurs when the pancreas cannot produce enough insulin or the one it produces cannot be used effectively. Insulin provides that sugar is stored as glycogen in the cell. Diabetics cannot use the glucose that passes from food to the blood, so blood sugar level rises. This event is called hyperglycemia. This situation causes damage to many tissues and organs in the long term such as eyes, kidneys, nerves, heart and blood vessels. Diabetes can be classified into three different types such as diabetes 1, diabetes 2, and gestation diabetes. Diabetes is a major health issue that has reached alarming levels in the world. Recent researches by World Health Organization (WHO) showed a great increase in number of diabetic patients and the deaths that are attributed to diabetes each year. In 2014, 8.5% of adults that aged 18 years and older had diabetes. In addition, according to the International Diabetic Federation (IDF) Diabetes Atlas 9th Edition 2019, 578 million people will have diabetes in 2030. Diabetes is a chronic disease. Therefore, it is significant that diabetes might be uncovered at an early stage.

Machine learning is a branch of artificial intelligence (AI) and computer science which provides systems with the ability to learn and improve from its own experience. Machine learning methods are used in the health sector because the number of data is very large and the analysis takes time. Researches have shown that machine learning techniques can be used for diabetes prediction such as [1]. In this study, machine learning classification algorithms which are Naive Bayes (NB), Logistic Regression (LR), Multi-Layer Perception (MLP), Support Vector Machine (SVM), K-Nearest Neighbor (K-NN), Decision Tree (DT) and Random Forest (RF) were implemented. The dataset is Pima Indians Diabetes Data (PIDD).

2. Literature Review

There are many studies for diabetes in the field of machine learning. Because diabetes is a chronic disease and should be diagnosed at an early stage. Various machine learning-based methods have been proposed on diabetes disease recognition.

Deepti Sisodia and Dilip Sisodia applied several machine learning algorithms to diagnose diabetes disease [2]. Naïve Bayes (NB), Decision Tree (DT) and Support Vector Machine (SVM) methods were used by the authors. Pima Indian Diabetes Dataset (PIDD) was used and the performances of the classifications were tested by the WEKA tool. The highest accuracy was obtained by the Naive Bayes which was 76.30%.

Islam and Jahan applied various machine learning methods which can be used in diabetes prediction [3]. Naïve Bayes (NB), Logistic Regression (LR), Multilayer Perception (MLP), Support Vector Machine (SVM), Decision Tree (DT), Random Forest (RF), AdaBoost, One Rule, K-Nearest Neighbor (K-NN) methods were used by the authors. Pima Indian Diabetes Dataset (PIDD) was used. The highest accuracy was obtained by the Logistic Regression which was 78.01%.

Kaur and Kumari also applied five machine learning algorithms to predict diabetes mellitus [4]. These algorithms are Radial Basis Function (RBF), Multifactor Dimensionality Reduction (MDR), K-Nearest Neighbor (kNN), Kernel Support Vector Machine (SVM) and Artificial

Neural Network (ANN). Pima Indian Diabetes Dataset (PIDD) was used and highest accuracy was obtained by the Kernel Support Vector Machine (SVM) which was 89%.

Saru and Subashree analyzed machine learning techniques to predict diabetes [5]. Pima Indian Diabetes Dataset (PIDD) was used as the dataset. Logistic regression with Support Vector Machine (SVM), Decision Tree (DT), K-NN (k=1) and k-NN(k=3) are the classifiers. The highest accuracy was obtained by the Decision Tree which was 94.4%.

Kumari and Chitra applied Support Vector Machine (SVM) to diagnosis of diabetes [6]. Also Pima Indian Diabetes Dataset (PIDD) was used as the dataset. The accuracy was recorded as 78%.

Al-Zebari and Sengur compared machine learning algorithms for diabetes disease detection [7]. Decision Trees (DT), Logistic Regression (LR), Discriminant Analysis (DA), Support Vector Machines (SVM), k-Nearest Neighbors (k-NN) and ensemble learners techniques was used in the work. In this study, Pima Indian Diabetes Dataset (PIDD) was used and the Logistic Regression method had the best accuracy with 77.9%.

Table 1. *Comparison of the best models of the papers.*

Paper	Best Model	Accuracy
Sisodia and Sisodia [2]	Naive Bayes	76.30%
Islam and Jahan [3]	Logistic Regression	78.01%
Kaur and Kumari [4]	Kernel Support Vector Machine	89%
Saru and Subashree [5]	Decision Tree	94.4%
Kumari and Chitra [6]	Support Vector Machine	78%
Al-Zebari and Sengur [7]	Logistic Regressions	77.9%

Table 1 shows the best model and accuracy in the studies described above.

3. Materials and Methods

3.1. Data

The dataset used in the study is Pima Indian Diabetes (PIDD). The dataset can be found on the Kaggle website [8]. The original owner of this dataset is the National Institute of Diabetes and Digestive and Kidney Diseases. PIDD has been gathered among the Pima Indian female population aged at least 21 years near Phoenix, Arizona. This dataset contains 768 samples with 9 attributes. This dataset has 8 specific variables. The description of the data is given below in Table 2. [3]

Table 2. Attribute’s name and their types.

Attribute	Description	Type
Pregnancies	Number of times pregnant	Numeric
Plasma-Glucose	Plasma glucose concentration a 2 hours in an oral glucose tolerance test	Numeric
BloodPressure	Diastolic blood pressure (mm Hg)	Numeric
SkinThickness	Triceps skin fold thickness (mm)	Numeric
Insulin	2-Hour serum insulin (mu U/ml)	Numeric
BMI	Body mass index (weight in kg/(height in m) ²)	Numeric
DiabetesPedigreeFunction	Diabetes pedigree function	Numeric
Age	Age of the patient (years)	Numeric
Outcome	Class variable (0 or 1)	Nominal

There are 500 instances of class 0 and 268 class 1. Waikato Environment for Knowledge Analysis (WEKA) tool has been used to categorize the data in this paper. WEKA is developed at University of Waikato. WEKA version 3.8 was used in this study.

3.2. Data preprocessing

Data may not always be complete and there may be abnormal values, impossible data combinations, missing values, duplicate data in the data set. Data preprocessing is required task to clean data and increase the accuracy and effectiveness of a machine learning model.

When the Pima Indian Diabetes dataset was analyzed, it was found that many attributes had impossible values with 0's. The numbers of missing values for each attribute are as follows:

- Pregnancies: 110
- Glucose: 5
- BloodPressure: 35
- SkinThickness: 227
- Insulin: 374
- BMI: 11

To eliminate missing values in this study, zero values for the pregnant attribute were left assuming they were real values and 234 samples that have at least two impossible value for attribute of the glucose, blood pressure, skin thickness, insulin and bmi were removed. After the pre-processing 534 instances are remain out of 768.

3.3. Performance Evaluation

While classifying the data in this study, 10-fold cross validation was applied as a test option. Cross-validation is preferred for overfitting problem and small datasets. In 10-fold cross validation, the data file is divided into ten and nine parts are used for training and one part for testing, this process is repeated ten times. In this study, WEKA tool was used and results of algorithms were compared. To compare the results, the number of values which are true positives (TP), true negatives (TN), false positives (FP), and false negatives (FN) were used in the confusion matrix and applying the following equations with these numbers, accuracy, sensitivity, precision and F1-score ratios were calculated.

- Accuracy: Shows ratio of correctly classified samples to the total number of tested samples. It is defined as in Equation 1.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- Sensitivity (Recall): Shows ratio of positive classification of instances i.e. TP to the sum of TP and FN as shown in Equation 2.

$$Sensitivity = \frac{TP}{TP+FN} \quad (2)$$

- Precision: Shows ratio of positive sample that were correctly classified to the total number of positive predicted samples as shown Equation 3.

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

- F1-score: It is a way of combining the precision and recall of the model as shown in Equation 4.

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

4. Classification Outcomes

The results of the different classification methods tested with the WEKA tool are shown in Table 3. SVM had the highest accuracy (78.65%) whereas K-NN obtained lowest accuracy (71.16%). Total accuracy is above 71% in all cases. The second highest accuracy (77.71%) obtained from LR. Sensitivity and precision are quite gladsome. Also, RF acquired third highest accuracy (76.77%).

Table 3. Result of algorithms.

Algorithm	Accuracy (%)	Sensitivity (%)	Precision (%)	F1-score (%)
Naïve Bayes	75.65	82.35	81.44	81.89
Support Vector Machine	78.65	89.91	80.45	84.91
Decision Tree	74.71	78.99	82.45	80.68
Logistic Regression	77.71	89.07	79.89	84.23
Random Forest	76.77	85.99	80.57	83.19
K-Nearest Neighbor	71.16	80.39	77.35	78.84
Multi-Layer Perceptron	74.71	82.35	80.32	81.32

5. Conclusion

Millions of people around the world suffer from diabetes. However most of these people don't even know if they have the disease. Early diagnosis of diabetes can abate long-term complications and cost. Therefore, multiple machine learning algorithms applied and analyzed for PIDD. The results show that the best performance was produced by an SVM algorithm. Generally, all techniques produced an accuracy score of around 70%. Further analysis of attributes and different combination of feature selection is necessary to achieve higher accuracy. Also, much more datasets can be generated, real datasets can be taken or deep neural networks can be applied to consider the real impact of the performance of the algorithms.

Referanslar

- [1] Q. Zou, K. Qu, Y. Luo, D.Yin, Y. Ju and H. Tang, “Predicting diabetes mellitus with machine learning techniques,” *Frontiers in Genetics*, vol. 9, Nov., 2018.
- [2] D. Sisodia and D. S. Sisodia, “Prediction of diabetes using classification algorithms”, *Procedia Computer Science*, vol. 132, pp. 1578-1585, 2018.
- [3] M. A. Islam, and N. Jahan, “Prediction of onset diabetes using machine learning techniques,” *International Journal of Computer Applications*, vol. 180, no. 5, Dec., pp.7-11, 2017.
- [4] H. Kaur, and V. Kumari, “Predictive modelling and analytics for diabetes using a machine learning approach,” *Applied computing and informatics*, 2020.
- [5] S. Saru, and S.Subashree, “Analysis and prediction of diabetes using machine learning,” *International Journal of Emerging Technology and Innovative Engineering*, vol. 5, no. 4, Apr., 2019.
- [6] V. A. Kumari and R.Chitra, “ Classification of diabetes disease using support vector machine,” *International Journal of Engineering Research and Applications*, vol. 3, no. 2, pp. 1797-1801, 2013.
- [7] A. Al-Zebari, and A.Sengur, “Performance comparison of machine learning techniques on diabetes disease detection,” In *Proc. IEE International Informatics and Software Engineering Conference '11*, 2019, pp. 1-4.
- [8] “Pima Indians Diabetes Database,” *Kaggle*, Oct. 6, 2016. [Online]. Available: <https://www.kaggle.com/uciml/pima-indians-diabetes-database>. [Accessed Oct. 10, 2020].

S-38 DOĞAL DİL İŞLEME VE MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE COVID-19 AŞI TÜRLERİNİN HABER İÇERİKLERİNİN İNCELENMESİ

Merve CENGİZ¹, Senem VAHAPLAR²

¹ Veri Bilimi, Dokuz Eylül Üniversitesi, Türkiye, merveccengiz@hotmail.com

² Veri Bilimi, Dokuz Eylül Üniversitesi, Türkiye, senem.sahan@deu.edu.tr

Özet

Bu çalışmada covid-19 aşılı ile ilgili olan haberler hakkında fikir sahibi olmak amacıyla Doğal Dil İşleme teknikleri kullanılmıştır ve haberlerin halka yansıtılma niteliğinin pozitif negatif durumu analiz edilmiştir. Makine öğrenmesi teknikleri kullanılarak aşı ile ilgili bir haberin sunduğu içeriğin pozitif olup olmadığı tahmin edilmiştir. Karşılaştırmalı metin madenciliği kütüphaneleri, skorlama teknikleri ve makine öğrenmesi algoritmaları kullanılarak daha doğru sonuca ulaşılması hedeflenmiştir. Bu amaçla haber makaleleri farklı ön işleme sürecinden geçirildikten sonra skorlanarak pozitif ve negatif olup olmadığı belirlenmiştir. Lojistik Regresyon (LR), Random Forests (RF), Sınıflandırma ve Regresyon Ağaçları (CART), Gradient Boosting-Extreme Gradient Boosting Machines algoritmaları (GBM-XGBM), Count ve TF-IDF ile çıkarılan özellikler üzerinde değerlendirilmiş ve karşılaştırmalar yapılmıştır. Sonuç olarak, aşı ile ilgili haberlerin çoğunlukla pozitif olduğu belirlenmiştir. En sık söz edilen aşı türünün Moderna olduğu gözlenmiştir. Bir haber içeriğinin pozitif olup olmadığını tahmin etmede GBM yönteminin karşılaştırılan farklı metriklere göre en iyi performansa sahip olduğu belirlenmiştir.

Anahtar Sözcükler: Doğal Dil İşleme, Makine Öğrenmesi, Covid-19, Aşı.

Abstract

In this study, Natural Language Processing techniques were used to have an idea about the news in regarding of covid-19 vaccines and the positivity-negativity of the reflection of them to the public was analyzed. It was predicted whether the content of a news about a vaccine was positive or not by using machine learning techniques. It was aimed to achieve more accurate results with comparative text mining libraries, scoring techniques and machine learning algorithms. For this purpose, sentiment of news articles was measured after different preprocessing techniques and it was determined whether they were positive or negative. Prediction performances of Logistic Regression, Random Forests, Classification and Regression Trees, Gradient Boosting-Extreme Gradient Boosting Machines algorithms were assessed on features which are extracted by using Count and TF-IDF techniques. Consequently, it was determined that the news about the vaccine was mostly positive, and the negative content was caused by bad reasons. It has been observed that the most frequently mentioned vaccine is Moderna. According to the different metrics, it has been determined that the GBM method has the best performance in predicting whether a news content is positive or not.

Keywords: *Natural Language Processing, Machine Learning, Covid-19, Vaccine.*

1. Giriş

Literatürde, doğal dil işleme kullanılarak çıkarılan özelliklerin makine öğrenmesi algoritmaları kullanılarak sınıflandırıldığı çalışmalar bulunmaktadır. Dai ve Mikdash (2015), tweetlerden grip hastalığı ile ilgili olanları tespit etmek için doğal dil işleme yöntemleri ile özellik çıkarımı yaparak iki sınıflandırma yaklaşımını birleştiren bir hibrit sınıflandırma yöntemi önermişlerdir: Manuel olarak tanımlanan özellikler ve makine öğrenimi yaklaşımlarıyla oluşturulan özellikler [12]. Rudra ve diğ. (2017), Ebola ve MERS salgınları ile ilgili paylaşılan tweetleri hastalıklarla ilgili farklı kategorilere ayırmak için özellik çıkarımı yapmışlardır ve sınıflama algoritmaları kullanmışlardır [7]. Tavoshi ve diğ., (2020) İtalya’da aşı ile ilgili paylaşılan tweetleri aşı yanlısı, aşya karşı ve nötr olarak sınıflandırmışlardır. Bunun için BOW (Bag of Words) tekniği kullanarak tweetlerden özellik çıkarımı yapmışlardır. Özelliklerin frekansını TF-IDF yöntemi ile belirleyerek denetimli makine öğrenmesi algoritmalarını karşılaştırmışlardır. Sonuç olarak %64 doğruluk skoru ile Destek Vektör Makinelerinin en iyi performansla sahip olduğunu tespit etmişlerdir [9].

Bu çalışmada en çok okunan uluslararası haber ajansları içerisinde 5 ajans web sitesinden alınan covid-19 aşılı ile ilgili olan haberlerin doğal dil işleme teknikleri ile işlenerek özellik çıkarımı yapılmıştır. Böylece covid-19 aşılı ile ilgili halka yansıtılan haberlerin pozitif ve negatiflik durumu analiz edilmiştir. Aynı şekilde en çok kullanılan aşılılar tespit edilmiş ve olumlu-olumsuz durumu incelenmiştir. Count ve TF-IDF teknikleri kullanılarak çıkarılan özellikler üzerinde denetimli makine öğrenmesi algoritmaları kullanılmış böylece bir makalenin aşılılarla ilgili içeriğinin pozitif olup olmadığı tahmin edilmiştir.

2. Materyal ve Metot

2.1. Veri Seti

Bu çalışmada veri setini oluşturmak için Web Scraping tekniği kullanılmıştır. Öncelikle uluslararası düzeyde en çok okunan haber ajanslarından 5 tanesi (CNN, Euronews, Reuters, Sputnik, The Guardian) seçilmiştir. Ajansların web sitesinden anahtar kelime olarak “covid-19 vaccine” kelime grubu aratılarak çıkan makaleler veri setini oluşturmuştur. Aşılılarla ilgili içeriği daha yoğun olan ve fazla sayıda makaleye ulaşmak amaçlandığından tek kelimeli “vaccine”, “covid-19” vb. arama yapmak yerine tüm haber sitelerinde "covid-19 vaccine" kelime grubu ile arama yapılmıştır. Haberlerin güncel olması amacıyla her bir ajans sitesinden 18.08-23.08.2021 tarihleri arasındaki 20 adet makale çekilmiştir.

2.2. Doğal Dil İşleme

Çekilen veriler metin tabanlı olduğu için ön işleme sürecinden geçirilmiş ve analizde kullanılabilir hale getirilmiştir. Ön işleme sürecinde uygulanan adımlar: 1. Tokenization (Cümleleri kelimelere ayırma) 2. Stopwords (Gereksiz-etkisiz kelimelerin çıkarılması) 3. Lemmatization (Kelimelerin köklerini alma) 4. Büyük küçük harf dönüşümü 5. Noktalama işaretleri ve sayıları kaldırma 6. Seyrek frekanstaki kelimelerin silinmesi.

Çalışmada her bir makalenin cümlesi doküman olarak baz alınmıştır. Ön işleme adımlarını uygulamak için nltk ve spacy olmak üzere 2 farklı ön işleme tekniği kullanılmıştır. Bu tekniklerin sonuçları karşılaştırılmıştır. Sentiment skorlama aşamasında nltk ve VADER (Valence Aware Dictionary and sEntiment Reasoner) olmak üzere 2 farklı teknik kullanılmıştır. Bu tekniklerin sonuçları karşılaştırılmıştır. Buradaki amaç cümleleri pozitif ve negatif olarak gruplayarak ikili bağımlı değişken oluşturmaktır. Özellik çıkarımı için ağırlıklandırma aşamasında Count Vectors ve TF-IDF Vectors (Term Frequency - Inverse Document Frequency) işlemi yapılmıştır. Count Vectors: Dokümandaki metni kelime (terim) bazında ayırıp her terimin frekansını verir. TF-IDF Vectors: TF, Terim Frekansını ifade eder:

$$\frac{(Bir\ t\ teriminin\ bir\ dokümanda\ gözlenme\ frekansı)}{(Dokümandaki\ toplam\ terim\ sayısı)}$$

IDF ise, Ters Doküman Frekansını ifade eder:

$$\frac{(\log(Toplam\ doküman\ sayısı))}{(İçinde\ t\ terimi\ olan\ doküman\ sayısı)}$$

Sonuç olarak TF-IDF vektörü:

$$TF - IDF\ Vectors = TF * IDF$$

şeklinde hesaplanır. Bu vektör, kelime bazında (words) ve 1,2’li, 3’lü ... kelime grupları (n-grams) bazında olmak üzere 2 farklı şekilde terim frekansını verir [2,4]. Bu çalışmada n-gram aralığı (1,3) olarak alınmıştır.

2.3 Makine Öğrenmesi Algoritmaları

Lojistik Regresyon (LR): Lojistik regresyon analizinde bağımlı değişken iki kategorilidir. Genel kullanım amacı bağımlı değişkeni etkileyen en önemli bağımsız değişkenleri belirleyerek riski yorumlamaktır [5].

Sınıflandırma ve Regresyon Ağaçları (CART): Hem regresyon hem de sınıflandırma için kullanılan, tüm veri setinden başlayarak art arda iki alt düğüm oluşturarak ilerleyen bir yöntemdir. Veriyi bölmedeki amaç yaprağın en saf derecede olmasıdır. Bölünmelerde homojenliği en yüksek olan değişken seçilir. Homojenliği ölçmek için bu çalışmada sınıflandırma analizi için gini impurity ölçüsü kullanılmıştır [1].

Random Forests (RF): Ağaçlar için gözlemler bootstrap örnekleme seçim yöntemi ile seçilir. Her düğümde bölünmeler yapılırken tüm değişkenler arasından en iyi p/3 tane ayırıcı değişken rastgele seçilir. En iyi rastgele değişken seçimi gini impurity ölçüsü ile belirlenir. Bu seçilmişler arasından rastgele bir seçim daha yapılır o da bölünmede kullanılacak olan değişkendir. Oluşturulan tüm ağaçların kendi tahmin performansına göre ağırlıklandırma yapar [1,8].

Gradient Boosting Metotlar (GBM-XGBM): Diğer ağaç yöntemlerinden farklı olarak, amaç fonksiyonunu en aza indiren parametrelerin optimal değerini bulmak için kullanılan Gradyan Azalma (Gradient Descent) optimizasyon algoritmasına dayanır. Bu algoritma ile bir model bir önceki modelin hatasına göre veri setine farklı ağırlıklar vererek hata azaltılmaya çalışılır.

XGBM, GBM'nin hız ve tahmin performansını arttırmak üzere optimize edilmiştir [6, 10, 11, 13].

Veri setinde eğitim ve test seti oranı 0.30'dur. 10 kat çapraz geçerlilik yöntemi kullanılmıştır. Bağımlı değişkenin grup genişliklerinin dengelenmesi için LR, CART ve RF modellerinde class_weight parametresi, Gradient Boosting modellerinde ise scale_pos_weight parametresi “balanced” olarak ayarlanmıştır. Böylece orijinal verideki bağımlı değişkenin grupları arasındaki oran korunmuştur.

2.4. Model Performanslarının Belirlenmesi

Sınıflandırma modellerini karşılaştırmak amacıyla karmaşıklık matrisinden faydalanarak hesaplanan performans metrikleri kullanılmıştır [3].

Tablo 1. Karmaşıklık Matrisi.

Gerçek	Tahmin	
	Pozitif	Negatif
Pozitif	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
Negatif	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

Duyarlılık, gerçekte negatif olan cümlelerin içinde modelin de negatif olarak belirleme oranı:

$$TP/(TP + FN)$$

Özgüllük, gerçekte pozitif olan cümleler içinde modelin de pozitif olarak belirleme oranı:

$$TN/(TN + FP)$$

Kesinlik, modelin negatif olarak tahmin ettiği cümlelerin gerçekte negatif olma oranı:

$$TN/(TN + FP)$$

F-Measure, modelin gücü (Duyarlılık ve Kesinlik ölçülerinin harmonik ortalaması):

$$2/((1/Duyarlılık) + (1/Kesinlik))$$

Doğruluk, pozitif ve negatif olan cümleleri doğru tahmin etme oranı:

$$(TP + TN)/Toplam$$

Makine öğrenmesi algoritmalarında riskli durum genellikle bir hastalığı ya da başarısızlığı ifade etmektedir ve araştırmacının odaklandığı durum, riskli olan kategoriyi tahmin etmektir. Bu çalışmada ise cümlelerin negatif olması bir hastalığı ya da risk olarak görülen bir durumu ifade etmemektedir. Dolayısıyla sadece negatif içeriklerin doğru tahmini değil aynı zamanda

pozitifliğin doğru tahmin edilmesi de önemlidir. Bu amaçla, bulgular kısmında sunulan performans ölçüleri her iki durum için de verilmiştir.

2.5. Veri Görselleştirme

Bu çalışmada görselleştirme metotlarından biri olan WordCloud kullanılmıştır. Bu teknik kelime frekanslarına göre farklı renk ve desenlerle oluşturulan metin görselleridir.

Bu çalışmadaki tüm analizler Anaconda Navigator ortamında Python programlama dili kullanılarak gerçekleştirilmiştir. Kullanılan kütüphaneler: numpy, pandas, newspaper, spacy, Negspacy, nltk, textblob, sklearn, imblearn, xgboost, WordCloud.

3. Bulgular

Haber siteleri üzerinden toplamda 100 adet İngilizce makale çekilmiştir. Ön işleme aşamasındaki Tokenization adımında nltk kütüphanesi, diğer adımlarda ise spacy kütüphanesinin daha iyi sonuçlar verdiği gözlenmiştir. Dolayısıyla cümlelerin ayırımında nltk sonuçları kullanılırken; kelimelerin stopword olup olmadığı, sıfat-isim-fiil tanımlama, özel isim bulmada ise spacy sonuçları kullanılmıştır. Sentiment skorlama aşamasında kullanılan nltk ve VADER teknikleri sonuçlarına bakıldığında her iki tekniğin de negatifliği tanımlamada yeterli olmadığı görülmüştür. Buradaki sorun literatürde “negation handling” olarak geçen olumsuzluk durumundan kaynaklanmaktadır. Bu çalışmada Negspacy kütüphanesi kullanılarak cümlelerdeki olumsuzluk yaratan kelimeler belirlenmiş ve bu cümleler skorlama aşamasından önce manuel olarak negatif şekilde tanımlanmıştır. İlk sonuçlara göre VADER tekniğinin anlamca nltk kütüphanesine göre daha doğru olduğu gözlenmiştir. Skorlama sonucunda 2001 adet pozitif ve 779 adet negatif içerik bulunmuştur. Haberlere göre en fazla söz konusu olan aşı türleri ve bu aşularla ilgili yapılan pozitif ve negatif olarak geçme sıklığı ile ilgili bilgiler Tablo 1’de verilmiştir. Bu sonuçlara göre uluslararası düzeyde en sık söz edilen ilk 3 aşının Moderna, Pfizer-BioNTech ve Oxford/AstraZeneca olduğu gözlenmiştir. Aşıların pozitif ve negatif olarak geçme sıklıklarına bakıldığında aşularla ilgili haberlerin çoğunluğunun pozitif olduğu gözlenmiştir. Ülkemizde kullanılan Sinovac aşısının frekansının 1 olduğu ve bunun da negatif olduğu gözlenmiştir. Son dönemde ülkemizde Sinovac ile beraber Biontech aşısı da kullanılmaya başlanmıştır. Çalışma, güncel makaleleri içerdiğinden Sinovaca ilgili haber sayısının az olması beklenen bir sonuçtur.

Tablo 1. *Aşıların Makalelerde Geçme Sıklığı.*

Aşı	Frekans (Poz./Neg.)
Moderna	57 (48/9)
Pfizer- BioNTech	51 (47/7)
Oxford/AstraZeneca	23 (16/7)
Sputnik	2 (1/1)
Sinovac	1 (0/1)


Çalışmada kullanılan modellerin performans karşılaştırması Tablo 2’de verilmiştir. Genel olarak modellerin pozitif cümleleri doğru tahmin etmekte başarılı olduğu belirlenmiştir. RF modelinin her iki vektör türünde, GBM modelinin ise TF-IDF vektör türünde duyarlılığı çok yüksek çıkmıştır. Negatif cümlelerde genellikle kesinlik oranı duyarlılık oranından yüksek çıkmıştır, dolayısıyla F-measure ölçüsüne dayanarak yorumlandığında orta düzeyde ya da daha düşük oranda tahmin performansı gözlenmiştir. Bu sonucun, cümlelerde negatifliği tanımlamada yararlanan “olumsuzluk durumunu tanımlama tekniği” kullanılmasına rağmen negatif cümleleri iyi ayırt edememesi nedeninden kaynaklandığı sonucuna varılmıştır.

Sonuç olarak, doğruluk skorlarına bakıldığında Count vektör düzeyinde tahmin performansı en düşük bulunan model GBM; en yüksek modeller ise LR, RF ve XGBM olmuştur. Bu modellerin negatif kesinliğinin diğer oranlara göre yüksek fakat duyarlılığının az olduğu gözlenmiştir. TF-IDF vektör düzeyinde tahmin performansı en düşük olan CART, en yüksek bulunan model ise GBM’dir. Bu çalışmanın geliştirilmesi için overfitting durumunun araştırılarak hiperparametre ayarlaması kullanılabilir. Ayrıca negatifliği tanımlamada daha gelişmiş teknikler kullanılabilir.

Tablo 2. Modellerin Tahmin Performansları.

Model	Count Vectors				TF-IDF Vectors			
	Kesinlik	Duyarlılık	F-Measure	Doğruluk	Kesinlik	Duyarlılık	F-Measure	Doğruluk
LR								
Pozitif	0.84	0.88	0.86	0.79	0.80	0.88	0.84	0.76
Negatif	0.67	0.60	0.63		0.63	0.49	0.55	
CART								
Pozitif	0.83	0.84	0.83	0.77	0.81	0.84	0.82	0.75
Negatif	0.61	0.60	0.61		0.59	0.53	0.56	
RF								
Pozitif	0.80	0.94	0.86	0.79	0.78	0.97	0.86	0.78
Negatif	0.76	0.45	0.57		0.81	0.35	0.49	
GBM								
Pozitif	0.83	0.73	0.78	0.71	0.83	0.97	0.90	0.84
Negatif	0.51	0.66	0.57		0.88	0.54	0.67	
XGBM								
Pozitif	0.83	0.87	0.85	0.79	0.83	0.87	0.85	0.78
Negatif	0.66	0.58	0.62		0.65	0.57	0.61	

Bu çalışmanın sonucunda elde edilen kelimelerin görseli Şekil 1’de gösterilmiştir. Sonuca göre vaccine, vaccination ya da vaccinate kelimelerinin yanı sıra country, people kelimeleri en çok geçen kelimelerden olmuştur.



Şekil 1. WordCloud.

Referanslar

- [1] A. Cutler. "Trees and random forests." NIH 1R15AG037392-01 92, 2013. [Online]. Available: <https://math.usu.edu/~adele/RandomForests/UofU2013.pdf>. [Accessed June. 15, 2021].
- [2] A. Öztürk, Ü. Durak, F. Badıllı. “Twitter verilerinden doğal dil işleme ve makine öğrenmesi ile hastalık tespiti.” Konya Mühendislik Bilimleri Dergisi, vol. 8, no. 4, pp. 839-852, 2020.
- [3] D. M. Powers. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. arXiv preprint arXiv: 2010.16061, 2020.
- [4] H. K. Küçükkartal. (2020). “Twitter'daki verilere metin madenciliği yöntemlerinin uygulanması” Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi, vol. 1, no. 2, pp. 10-13, 2020.
- [5] D. W. Hosmer Jr, S. Lemeshow, R. X. Sturdivant, Applied Logistic Regression. John Wiley & Sons, 2013.
- [6] J. H. Friedman. "Greedy function approximation: a gradient boosting machine." Annals of Statistics, pp. 1189-1232, 2001.
- [7] K. Rudra, A.Sharma, N.Ganguly, M. Imran, Classifying information from microblogs during epidemics. In Proc. International Conference on Digital Health 2017, pp. 104-108.
- [8] L. Breiman. "Random forests." Machine Learning, vol. 45, no. 2, pp. 5-32, 2001.
- [9] L. Tavoşchi, F. Quattrone, E. D'Andrea, P. Ducange, M. Vabanesi, F. Marcelloni, P. L. Lopalco. “Twitter as a sentinel tool to monitor public opinion on vaccination: an opinion mining analysis from September 2016 to August 2017 in Italy.” Human Vaccines & Immunotherapeutics, vol. 16, no. 5, pp.1062-1069, 2020.
- [10] M. Llew, B. Jonathan, B. Peter, F. Marcus. Boosting algorithms as gradient descent, in S. A. Solla, T. K. Leen, K. R. Muller, editors, Advances in Neural Information Processing Systems, MIT Press, 2000.
- [11] T. Chen, C. Guestrin, “Xgboost: A scalable tree boosting system”, In Proc. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining'22, 2016, pp. 785-794.
- [12] X. Dai, M. Bikdash, “Hybrid classification for tweets related to infection with influenza. In Proc. IEEE SoutheastCon 2015, pp.1-5.
- [13] XGBoost Machines,” [Online]. Available: <https://xgboost.readthedocs.io/en/latest/index.html>. [Accessed July. 8, 2021].

S-55 MİKROSKOBİK KUMAŞ GÖRÜNTÜLERİNDE HATA TESPİTİ İÇİN DERİN ÖĞRENME YAKLAŞIMI

Mehmet Ali BALCI ^{1,*}, Ömer AKGÜLLER ², Duygu YAVUZKASAP AYAKTA ³

¹ Matematik Bölümü, Muğla Sıtkı Koçman Üniversitesi, Türkiye, mehmetalibalci@mu.edu.tr

² Matematik Bölümü, Muğla Sıtkı Koçman Üniversitesi, Türkiye, oakguller@mu.edu.tr

³ Ar-Ge Merkezi, Yünsa Yünlü Sanayi ve Ticaret AŞ., Türkiye, textilengineer.duygu@gmail.com

Özet

Proses hatalarının temel nedenlerini belirlemeye çalışan mühendisler için faydalı bilgiler sağlayan hata denetimi ve eğilim izleme, verim kalite kontrolü için çok önemlidir. Bununla birlikte, yarı iletken cihaz imalatındaki kusurlar, üretim süreci karmaşık olduğu için geniş bir görsel şekil ve doku yelpazesine sahiptir. Sofistike sürecin bir sonucu olarak, manuel hata sınıflandırmasının kalitesi, denetleyicinin uzmanlığına bağlıdır. Bu çalışmada, tutarsız manuel sınıflandırmanın ve maliyetli sorunların üstesinden gelmek için, otomatik hata sınıflandırması için evrişimli sinir ağı tabanlı bir öğrenme yöntemi sunulmaktadır.

Anahtar Sözcükler: *Derin Öğrenme; Evrişimli Sinir Ağı; Kumaş Hata Tespiti.*

Abstract

Defect checking and trend tracking are essential for yield quality control, providing useful information for engineers trying to identify the root causes of process failures. However, defects in semiconductor device fabrication come in a wide range of visual shapes and textures, as the manufacturing process is complex. As a result of the sophisticated process, the quality of manual error classification depends on the expertise of the inspector. In this study, a convolutional neural network-based learning method for automatic error classification is presented to overcome inconsistent manual classification and costly problems.

Keywords: *Convolution Neural Networks; Deep Learning; Fabric Defect Detection.*

1. Giriş

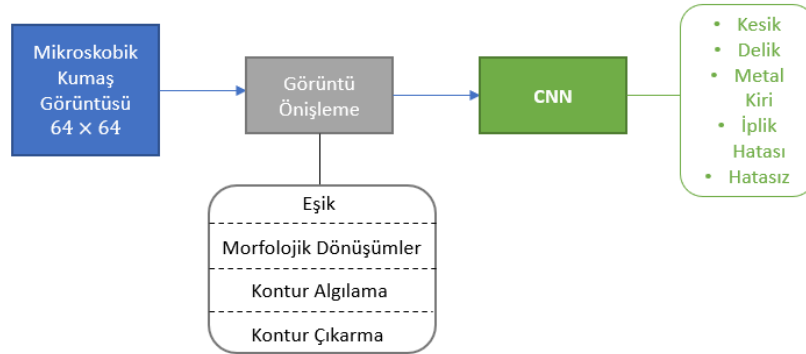
Dokuma tekstil imalat sanayinde kumaş kusurları, kumaşın dokunması sırasında meydana gelen hataları ifade eder. Geleneksel olarak, kumaş muayenesi vasıflı insan işçiler tarafından yapılır. Ancak insan müdahalesi ile sadece %60-75 kusurların başarılı bir şekilde gözlemlenebildiği ve çok fazla zaman gerektirdiği, bunun da verimliliği ve üretimi etkileyebileceği bildirilmektedir [1]. İhmal nedeniyle, kusurlardan herhangi biri kontrol edilmezse, kumaş maliyetinde %45-65 oranında azalmaya neden olabilir [2]. Son yıllarda, %90 hata tespit doğruluğu [3,4,5] gibi

gelişmiş sonuçların da gösterdiği gibi, otomatik hata tespit sistemi önem kazanmaktadır. Dokuma kumaş hatalarının belirlenmesi ve nedenlerinin giderilmesi için Prolog dili ile yazılarak, Visual Basic aracılığıyla arayüzü hazırlanan uzman sisteme hata fotoğrafları da eklenerek FDD-Expert Uzman Sistem geliştirilmiştir [6]. Geliştirilen sistemlerin uzman kişilerden daha yüksek doğrulama payına sahip olabilmesi ve kullanıcı dostu olarak endüstriyel ölçekte kullanımının pratik hale getirilebilmesi son yıllarda önem kazanmıştır.

Sunulan bu çalışmada mikroskopik kumaş görüntüleri üzerinden hata tespiti yapılması için bir yöntem önerilmektedir. Yöntem ilk olarak mikroskopik kumaş görüntüleri üzerinden görüntü işleme teknikleri uygulanarak sınıflandırma aşımının girdilerini elde eder. Daha sonra Lenet-5 Evrişimli Sinir Ağı modeli kullanılarak kumaş görüntülerinin hata sınıflarının tespiti sağlanır.

2. Materyal ve Yöntem

Bu çalışmamızda [6] tarafından önerilen mikroskopik kumaş görüntü verilerinin kesik, delik, metal kiri, iplik hatası ve hata içermeyen görüntülerinin sınıflandırılması için bir yöntem sunulmaktadır. Şekil 1, yöntemin genel mimarisini göstermektedir. Yöntem, görüntü işleme ve sınıflandırma olmak üzere iki aşamadan oluşmaktadır. Görüntü işleme aşamasında, arka plan olmayan nesnelere tespit etmek için geleneksel görüntü işleme teknikleri kullanılmış, ardından sınıflandırma modelinin girdisi olarak kabul edilen arka plan olmayan nesnelere ayıklanmış ve kırılmıştır. Sınıflandırma aşamasında, çeşitli arka plan olmayan nesnelere sınıflandırmak için bir Evrişimli Sinir Ağı (CNN) modeli kullanılmıştır.



Şekil 1. Yöntemin Mimarisi

2.1. Görüntü Önleme

Mikroskop tarafından yakalanan görüntüler birden fazla nesne türü içerebilir. Bu nedenle, sınıflandırıcıyı eğitmek için görüntünün tamamını kullanmak yerine, önce nesnelere algılanmalı ve kırılmalıdır. Arka plan olmayan nesnelere segmentlere ayırmak ve kırpmak için çalışmamızda sırasıyla Gauss bulanıklık dönüşümü, eşik, morfolojik dönüşümler ve kontur çıkarma yöntemleri kullanılmıştır.

Eşik kısmında uygulanan uyarlamalı eşikleme yöntemi $T(x, y)$ eşik değeri olmak üzere

$$dst(x, y) = \begin{cases} \text{Maksimum Değer}, & src(x, y) > T(x, y) \\ 0, & \text{aksi durumda} \end{cases} \quad (1)$$

denklemlerle verilir. Uyarlanabilir eşik uygulanmadan önce, performansı iyileştirmek için gri tonlamalı görüntüde Gauss bulanıklık dönüşümü kullanılmıştır. Parametrelerin farklı kombinasyonları ile birkaç deney yapılmış, kumaş görüntüsü için en uygun parametreleri bulmak için verileri gözlemlenmiş, ardından da eşik görüntüsü elde edilmiştir. Eşik görüntüsü daha sonra ön plan nesnelere ait küçük delikleri kapatmak için kapatma tekniği kullanılarak morfolojik bir dönüşümden geçirilmiştir. Kapanış olarak genişleme ve ardından erozyon uygulanmıştır. Genişleme, ikili görüntüdeki beyaz bölge kısımlarını artırırken erozyon tam tersidir ve onları aşındırır. Kontur algılama sırasında, belirli piksellerden daha fazla alana sahip nesnelere ayıklanmıştır. Şekil 2 görüntü ön işleme aşamasını göstermektedir.




Şekil 2. Görüntü Ön İşleme Süreci

2.2. Sınıflandırma

CNN, giriş görüntüsünden özelliklerin hiyerarşisini öğrenir ve diğerlerinin yanı sıra görüntü sınıflandırma, nesne algılama, doğal dil işleme yaygın olarak kullanılır. Bir CNN mimarisi tipik olarak, sonunda tamamen bağlı olan bazı evrişim ve havuzlama katmanlarından oluşur. Evrişim katmanı, görüntüden öznitelikleri çıkarmak için kullanılan ilk katmandır; görüntü ile matris evrişimi gerçekleştirmek ve özellik haritasını elde etmek için filtreler tanımlanmıştır. Havuzlama katmanı, parametre sayısını azaltmak için kullanılır; özellik küçültme sayısı filtre boyutu tarafından tanımlanır. Havuzlama, korunması gereken değerlerin türüne bağlı olarak maksimum, ortalama ve toplam havuzlama olmak üzere üç türdür. Tamamen bağlı katman, sonuçları en temel sinir ağına düzleştirir. Genellikle, sınıf olasılığını elde etmek için sınıflandırmanın sonunda bir softmax etkinleştirme işlevi kullanılır.

Sınıflandırma aşamasında, ayarlı LeNet-5 [6] ağı kullanılmıştır. Renkler, sınıflandırma modeli hakkında bilgi sağlamayacağından, veriler CNN'de eğitimden önce gri tonlamalı görüntülere aktarılmıştır. Şekil 3 sınıflandırma modülünün mimarisini göstermektedir.




Şekil 3. Sınıflandırma Mimarisi

Mikro ölçekli kusur tespitinde ortalama havuzlama, birkaç özelliğin göz ardı edilmesine neden olabilir. Ancak, tüm özellikler verilerimiz için çok önemlidir. Bu nedenle, ortalama havuzlama modelden çıkarılmış ve mikro ölçekli kusur tespiti için daha etkili sonuçlar elde edilmiştir.

3. Bulgular

Mikroskobik kumaş verileri kesik, delik, metal kiri, iplik hatası ve hatasız olmak üzere 5 sınıfta değerlendirilmiştir. Her bir sınıfa ait 2250 adet 64×64 boyutlu görüntü verisi bulunmaktadır. Sınıflandırma modülünün girdileri ön işleme tabi tutulmuş görüntü verileridir. Her bir görüntü verisi için deneysel sonuçlar çerçevesinde Gauss çekirdeğinin yarıçapı 4, morfolojik dönüşümlerin ise yarı çapları 0,5 olarak belirlenmiştir. Toplam 11250 adet ön işlenmiş görüntü verisinin 7500 adeti CNN ağının eğitimi, eğitim sürecinde aşırı uyum gösterme probleminden kaçınmak için 1250 adeti doğrulanması ve 2500 adeti de test için kullanılmıştır.

CNN ağının eğitimi sürecinde Adam optimizasyonu kullanılmıştır. Eğitim sürecinde 50 tur seçilmiş ve her bir tura ait eğitim sonuçlarının grafikleri Şekil 4’te sunulmuştur.



Şekil 4. Eğitim sürecinin kayıp, hata oranı ve F1-skoru verileri

Eğitim süreci sonrası elde edilen modele test verileri uygulanmış ve Şekil 5’te sunulan karışıklık matrisi elde edilmiştir.

	Kesik	Delik	Metal Kiri	İplik Hatası	Hatasız	
Kesik	473	6	8	6	7	500
Delik	12	452	11	14	11	500
Metal Kiri	8	11	461	12	8	500
İplik Hatası	8	12	9	470	1	500
Hatasız	9	11	6	7	467	500
	510	492	495	509	494	

Şekil 5. Karışıklık Matrisi

4. Sonuç ve Öneriler

İnsan iş gücünün kullanıldığı kumaş hatalarının denetim süreci verimliliği ve üretimi olumsuz yönde etkileyebilir. Sunulan bu çalışmada, kumaş hatasının denetimi için derin öğrenme temelli bir yöntem sunulmuştur. Yöntem ilk olarak mikroskobik kumaş görüntülerini çeşitli görüntü işleme aşamalarına tabi tutar. İlk olarak görüntünün düzgünleştirilmesi için Gauss bulanıklaştırma yöntemi kullanılmış ve uyarlamalı eşik yöntemi ile görüntü işlenmiştir. Daha sonra morfolojik yöntemler ile görüntüdeki konturlar belirlenmiş ve bu konturlar üzerinden evrişimli sinir ağı ile bir sınıflandırma yapılmıştır.

Sınıflandırma süreci test edildiğinde kesik sınıfının doğruluk oranı %94.6, delik sınıfının doğruluk oranı %90.4, metal kiri sınıfının doğruluk oranı %92.2, iplik hatası sınıfının doğruluk oranı %94 ve son olarak da hatasız kumaş sınıfının doğruluk oranı %93.4 olarak tespit edilmiştir. Yöntemin ortalama doğruluk oranı ise %92.92 dir.

Kumaş üretim sürecinde bilinen yaklaşık 70 farklı hata tipi vardır. İleriki çalışmalarda farklı hata tiplerinin sınıflandırılması, farklı kumaş görüntülerinin ve geliştirilmiş evrişimli sinir ağı modellerinin kullanılması hedeflenmektedir.

Referanslar

- [1] A. Kumar, “Computer-vision-based fabric defect detection: A survey”. IEEE transactions on industrial electronics, Vol 55, no. 1, pp. 348-363, 2008.
- [2] M. Patil, S. Verma, and Y. Wakode, “A review on fabric defect detection techniques”. Int. Res. J. Eng. Technol, Vol 4, no. 9, pp.131-136, 2017.
- [3] H. Ngan, G. Pang, and N. Yung, “Automated fabric defect detection—a review”. Image

- and Vision Computing, Vol 29, no. 7, pp. 442–458, 2017.
- [4] W. Ouyang, B. Xu, J. Hou, and X. Yuan, “Fabric defect detection using activation layer embedded convolutional neural network”. IEEE Access, Vol 7, pp.70130-70140. 2019.
- [5] X. Wan, X. Zhang, and L. Liu, “An Improved VGG19 Transfer Learning Strip Steel Surface Defect Recognition Deep Neural Network Based on Few Samples and Imbalanced Datasets”. Applied Sciences, Vol 11, no. 6, pp.2606, 2021.
- [6] P. Bergmann, M. Fauser, D. Sattlegger, and C. Steger, “MVTec AD--A comprehensive real-world dataset for unsupervised anomaly detection”. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 9592-9600), 2019.
- [5] J. Gerald, “Sega Ends Production of Dreamcast,” vnunet.com, para. 2, Jan. 31, 2007. [Online]. Available: <http://nli.vnunet.com/news/1116995>. [Accessed Sept. 12, 2007].
- [6] B.Barış, “Dokuma kumaş hatalarının belirlenmesi ve nedenlerinin giderilmesi için bir uzman sistem uygulaması,” Tekirdağ Namık Kemal Üniversitesi Tekstil Mühendisliği Anabilim Dalı Doktora Tezi, 2018.

S-56 SNAKE DETECTION AND BLURRING SYSTEM USING DEEP LEARNING

Selay TEKGÜL¹, Gokce NUR YILMAZ²

¹Computer Engineering, TED University, Turkey, selay.tekgul@tedu.edu.tr

²Computer Engineering, TED University, Turkey, gokce.yilmaz@tedu.edu.tr

Abstract

Even though some people do not care about the appearance of snake images and videos on visual media, there is a significant portion of them who are uncomfortable of seeing snakes as well as their images and videos. In order to assist these people to view images and videos on any terminal device in the most comfortable way as possible, this paper proposes an object detection and blurring system using deep learning with YOLO. The performance evaluation results present that the proposed system can detect the snake images and blur their unexpected appearances in the most efficient way as possible.

Keywords: *blur, deep learning, object detection, phobia, snake.*

Introduction

It is a fact that there is a significant attention that humans pay to the animals because of the effects of the inheritance [1]. Especially for the snakes, not only the effect of live snakes but also their photographs can cause a great deal of fear, i.e., phobia of snakes. Therefore, their unexpected appearance on the visual media sources e.g., TV, movies, photography is a problem for people who are suffering from that fear. As a result of the problem caused by these unfiltered visual media sources, the quality of their life is affected negatively.

Considering this fact, a model including snake detection on images and videos, as well as blurring the snakes is developed. Therefore, the proposed model consists of two stages:

1. Detection of the snakes on the visual source
2. Blurring the detected objects

For the first stage, YOLOv4 [2], which is a state-of-the-art, real-time object detection system, is used. YOLO has several advantages when it is compared to other object detection algorithms such as EfficientDet developed by Google Brain Team [3], CNN, fast R-CNN and faster R-CNN. One of the most significant advantages is that YOLO considers an image completely. Therefore, it results in better and faster detections with YOLO [2]. After the performance evaluation results derived using the first stage, it is observed that 92% f1 score is achieved using YOLO for the snake detection.

The second stage relying on the blurring operation is implemented considering with another blurring method from OpenCV that is a software library which includes open-source machine learning and computer vision algorithms [4].

The rest of the paper is organized as follows. In the second section, the proposed model is introduced. The results and discussions are presented in section 3. Finally, section 4 concludes the paper and discuss about future work.

Proposed Model

In the proposed model for the snake detection, the YOLO approach is exploited due to the advantages it provides compared to other object detection algorithms including CNN, fast R-CNN and faster R-CNN in terms of considering the entire image and faster detection [2]. The proposed model of this study is presented in Figure 1.

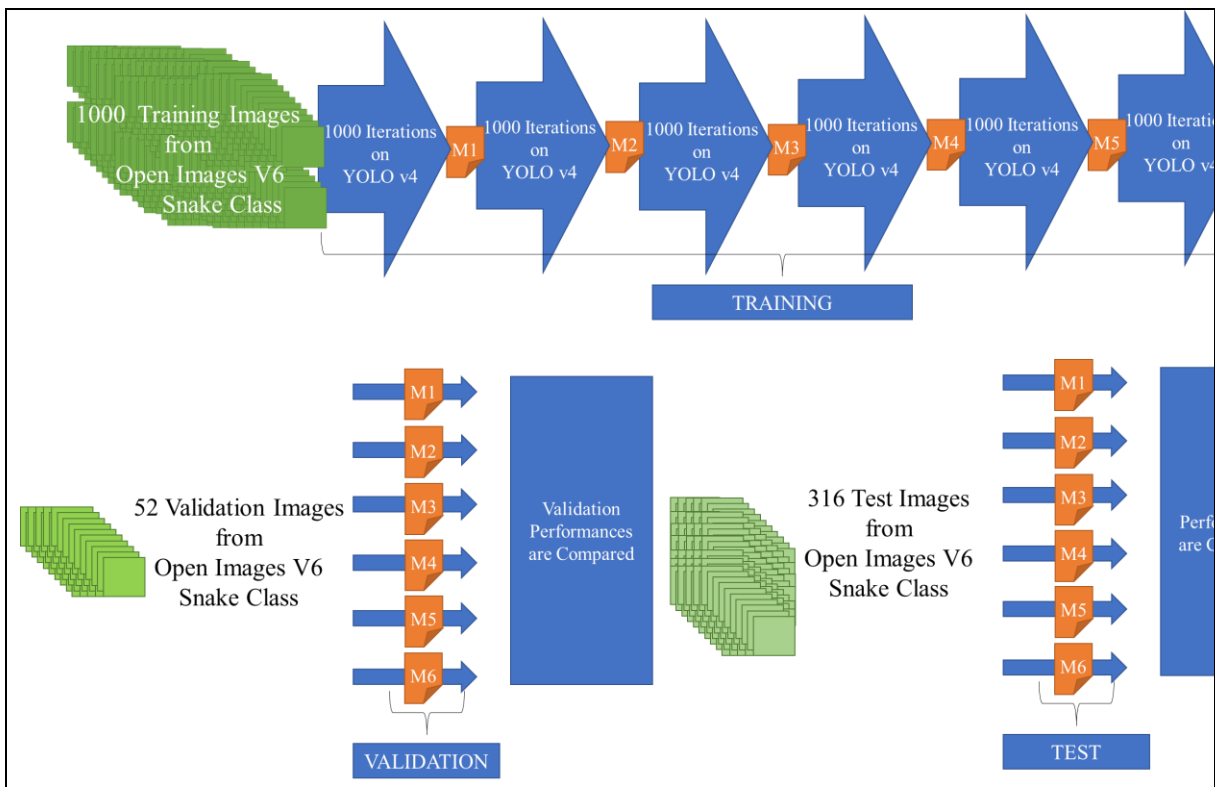


Figure 1. Proposed model.

As it can be seen from the figure, first of all, dataset is fed into the deep learning model for training purpose. As a dataset, the latest version of Open Image Dataset V6 [5] is used. Open Image Dataset V6 is a dataset of 9M image-level annotated images provided by Google [6]. 1000, 52 and 316 images of the “snake” class by Open Image Dataset V6 are used as training, validation, and test images, respectively, in this study.

Since there is only one class in the proposed model, it is decided to train the model for 6000 iterations based on the recommendations on [7] which particularly explains the selection of the number of iterations as 2000 per class but not less than 6000. During the training process, the

losses of the models after each iteration are also observed. When the losses are investigated, a decreasing trend is observed as a function of number of iterations. Moreover, the models that is encountered after each 1000 iterations are saved and ready to be used. Therefore, six models are derived due to the fact that 6000 iterations are divided by each 1000 iteration. As mentioned, there are six different trained models each encountered after 1000 iterations of training out of total 6000 iterations. The models will be stated as M1, M2, M3, M4, M5 and M6 after each 1000 iterations sequentially trained, respectively as they can be observed from the figure 1. Additionally, these six different models are used to detect the snakes on the validation and test set images. After models are used for detection on the validation and test sets, the performance values of the models are evaluated.

Consequently, as a second step of the solution, after determining the best model to be used in the test set, the detected bounded boxes where the snakes are predicted to be on the images are blurred with the blur method from OpenCV. This method uses the normalized box filter and kernel to blur the given image. In this study, the kernel size is selected as 53 to 53.

Results and Discussions

Corresponding performance values related with true positive (TP), false positive (FP), false negative (FN), precision, recall, F1 score, average intersection over union (IoU), average precision (AP) and mean average precision (mAP) of six models on the validation set which consists of 52 images are shown in the Table 1 by emphasizing the best scores on each column with bold texts.

Table 1. Comparison of the performances of six models on 52 images validation set.

Models	TP	FP	FN	Precision	Recall	F1	Average IoU	AP	mAP
M1	54	3	12	0.95	0.82	0.88	67.88%	94.28%	94.28%
M2	48	12	18	0.80	0.73	0.76	51.83%	68.39%	68.39%
M3	60	1	6	0.98	0.91	0.94	72.13%	94.94%	94.94%
M4	58	6	8	0.91	0.88	0.89	61.43%	88.36%	88.36%
M5	58	3	8	0.95	0.88	0.91	79.12%	88.76%	88.76%
M6	59	3	7	0.95	0.89	0.92	79.05%	93.66%	93.66%

The training, validation and testing are completed on a laptop computer with a single Nvidia 950M 4GB GPU and 8GB RAM on 64-bit Ubuntu 20.04 operating system using Python version 3.8.5 and OpenCV version 4.5.2. The training is completed within 18 hours and the detection process of the validation set examples took 10-11 seconds for each of the six models which would not affect the comparison of the models drastically. During the evaluation of training and detection times, the given environment characteristics should be taken into consideration. When the usage of GPU changes, the training and detection times would differ.

Predicted best detection performance on the test set is with model M3 due to its performance on the validation set examples, however, the best TP, FN and Recall values are encountered with model M6 as 218, 25 and 0.90 on the test set examples, respectively. On the other hand, the best FP, Precision, Average IoU, AP and mAP values are gathered when the model M5 is used for testing as 10, 0.96, 80.60%, 92.20% and 92.20%, respectively. Lastly, the best F1 score is the same for these two models, M5 and M6 and is 0.92.

The overall comparison of the performances of the models on the test set is put together Table 2.

Table 2. Comparison of the performances of six models on 316 images test set.

Models	TP	FP	FN	Precision	Recall	F1	Average IoU	AP	mAP
M1	205	24	38	0.90	0.84	0.87	66.17%	88.45%	88.45%
M2	160	53	83	0.75	0.66	0.70	49.79%	63.95%	63.95%
M3	214	21	29	0.91	0.88	0.90	67.75%	89.35%	89.35%
M4	212	24	31	0.90	0.87	0.89	63.04%	87.32%	87.32%
M5	217	10	26	0.96	0.89	0.92	80.60%	92.20%	92.20%
M6	218	12	25	0.95	0.90	0.92	79.78%	91.81%	91.81%

Problem that is attempted to solve in this paper is to detect as many snake images as precisely as possible when images are tested since when the phobia is considered, it should be guaranteed that none of the snake images will be shown to the viewer. Therefore, when the test results are investigated, since the given values with model M5 and M6 are pretty close to each other, the one whose recall is greater than other should be used before blurring as a final model. Additionally, with YOLO, real-time object detection is possible but requires a better GPU than the one used in the experiment of this study to propose a working model for commercial since the detection of 316 test images took 39-40 seconds to be completed in each of the six models.

Conclusions and Future Work

In this paper, a model for snake detection and blurring has been proposed. Six different models using state-of-the-art object detection algorithm YOLOv4 have been explored. The results of this work indicate that different models encountered with different number of iterations on training phase of the deep learning can vary in terms of detection of different kind of snake images. Generally, it can be said that more iterations would increase the precise detection of the snake images using the dataset that is used in this experiment.

To get the application useful in the real life, there are many possible future directions to improve the work: segmentation and tracking. In the testing of the models, it is observed that there are some body parts of the snakes that are not covered with the bounded box, also there are some areas in the bounded boxes that do not belong to the area where the snake objects reside. So, when it comes to the real-life application, viewer will see some parts of the snake objects occasionally and after blurring operation is completed some unrelated parts of an image

will be unseen. Therefore, the quality of a visual experience will end up decreasing for some level. In order to solve this problem, instead of bounding box detection, segmentation could be performed. With segmentation, more precise blurring operation would be completed, and the experience of a viewer would increase with a training using enough number of segmentation annotated images.

Also, if this approach will be adapted to be used on the videos, by implementing snake objects' tracking, the number of the snakes where the detection and blurring applied, on the frames would be increased.

References

- [1]E. Landova, J. Maresova, O. Simkova, V. Cikanova and D. Frynta, "Human responses to live snakes and their photographs: Evaluation of beauty and fear of the king snakes," *Journal of Environmental Psychology*, vol. 32, no. 1, pp. 69-77, 3 2012.
- [2]A. Bochkovskiy, C.-Y. Wang and H.-Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection," 2020.
- [3]M. Tan, R. Pang and Q. V. Le, "EfficientDet: Scalable and Efficient Object Detection," 2020.
- [4]OpenCV team, "About," OpenCV, 2021. [Online]. Available: <https://opencv.org/about/>. [Accessed 20 May 2021].
- [5]Google Inc., "Open Images V6 Snake Category Detection Type," 2021. [Online]. Available: <https://storage.googleapis.com/openimages/web/visualizer/index.html?set=train&type=detection&c=%2Fm%2F078jl>. [Accessed 20 May 2021].
- [6] Google Inc., "Overview of Open Images V6," Google Inc., 2021. [Online]. Available: <https://storage.googleapis.com/openimages/web/factsfigures.html>. [Accessed 21 May 2021].
- [7]AlexeyAB, "Yolo v4, v3 and v2 for Windows and Linux," 15 5 2021. [Online]. Available: <https://github.com/AlexeyAB/darknet>. [Accessed 21 May 2021].

S-57 GENDER AND AGE PREDICTION BASED ON CNN MODEL

Zeynep Dilay TOPTAŞ¹, Gokce NUR YILMAZ²

¹Computer Engineering Department, TED University, Turkey, zdilay.toptas@tedu.edu.tr

²Computer Engineering Department, TED University, Turkey, gokce.yilmaz@tedu.edu.tr

Abstract

Age is an important concept, which we come across at every field of our lives. Moreover, gender plays also crucial role in our life, especially in social aspects. Therefore, age and gender are considered as significant aspects while developing new visual technologies. Age prediction technology is currently and widely used in our many daily life applications such as surveillance cameras, security systems of buildings, and advertisement industry. Gender is also commonly utilized in many areas in our life including entertainment applications such as face and gender swapping games. In the light of these facts, in this study, a gender and age prediction model relying on Convolutional Neural Network (CNN) is developed. The performance evaluation results of the developed model present that the age and gender prediction becomes faster and more efficient compared to the other models in literature.

Keywords: *Age Prediction; convolutional neural network; gender prediction*

1. Introduction

Age prediction plays very crucial role especially in the cases and places where an age restriction exists such as movie theaters, tobaccos, and traffic control systems in order to control people whether they are eligible to watch a movie, drive etc. Places such as universities, stations, airports, shopping malls, and hotels already use age and gender prediction systems in order to maintain safety. Gender and age prediction systems can also be used by trading businesses in order to react more effectively to customers' needs and demands. For instance, in hairdressers, a projection based on hairstyle and hair color preferences of customers from different genders and age groups can be made. In this way, the hairdressers may offer the most appropriate hairstyle to their customers and earn more money thereby. Moreover, integrating age, as well as gender to the visual applications of daily life, such as security systems in airports, banks, and, shopping malls is beneficial in terms of providing easiness to detect dangerous people, especially in crowded areas [1][2].

Considering all of these aspects, it can be considered as a fact that improved age and face detection systems should be developed. Under the light of this fact, a gender and age prediction system relying on Convolutional Neural Network (CNN) is developed in this study. This study's main aim is to integrate CNN to gender and age detection skills. By this way, lack of speed in gender and age detection is fixed and the speed of gender and age detection is increased in a significant magnitude. CNN is a deep learning algorithm, which is commonly used at object or face detection. CNN's goal is to extract important information from the images. One of the main advantage of the CNN over other classification algorithms is that it uses much less preprocessing than them [3] [4].

In order to build the proposed model, many images of various individuals are collected to form a dataset. This image dataset is composed of various people’s images from different age and gender combinations. The images include many factors such as lighting, variety of poses, occlusion as well. One of the distinguishable novelty of the proposed model is that the gender and age detection are made in consideration of these factors. Moreover, the proposed model is validated by running the Python code on various environments except Google Collab. Moreover, the proposed model is tested with many image data.

The rest of the paper is organized as follows. In Section 2, the proposed model is introduced. The results and discussions are mentioned in Section 3. Section 4 concludes the paper and discusses about the future work.

2. Proposed Model

The proposed model detecting ages and genders of the image dataset is implemented on Google Collab Environment [5]. The proposed model is conducted with “age_gender.csv” dataset, which is found in the official Kaggle Website [6]. This dataset contains images of people’s faces of various genders and ages. Validation process is applied with the validation dataset, which is a part of the actual dataset. This dataset, which is used to establish the unbiasedness of the evaluation of the fit on a training dataset. The repository, which includes the weight files is copied into Google Collab Environment [5]. These weight files are important for machine learning mechanism to be implemented. The weight files are trained beforehand. The folder of the weight files, which is entitled as “modelNweight”, includes “caffe” models, which are deep learning frameworks and developed by Berkeley AI Research Unit [7]. When the consecutive function, which is the main source code of the gender and age detection system, is run, a Python file is created. In the main source code, first of all, example images in the dataset are retrieved as inputs and the program processes the face detection system. The function, getFaceBox reads along the face detector file and receives the coordinates of the images, where the faces are located. As the second stage of the image transformation to its gender and age inclusive state, a preprocessing operation takes place. This operation processes images. In the preprocessing stage, a function, namely blobFromImage makes the image files, which are going to be tested to have the same properties as the training dataset. Since each image has its distinct brightness, hue, or saturation level, blobFromImage function helps the images to remove these external properties from themselves and have the same level of properties among all the images in the dataset. Images become more simple without losing any important information, thereby. The simplified images are consecutively used in the gender and age detection. After all functions are defined, each preprocessed image is read by imread function, and sent to the gender and age detector function one by one [5][6][7].

3. Results and Discussions

In order to derive the gender and age prediction results using the proposed model, the dataset used in the training process is exploited. Then, the output images, which include the gender and age of the people in the images of this dataset, are obtained using the proposed model. Moreover, videos having people at different ages and genders are also utilized to derive the performance evaluation results. The performance evaluation results of the proposed model reveal that not only the faces on images but also faces on the videos can be efficiently detected. As can be observed from Figure 1 and 2, which present the sample images and snapshots of a video before and after age and gender prediction model, respectively, the proposed model can be able to correctly predict the gender and age of the people in the image and video. Moreover, the performance evaluation results present that the age and gender prediction is quite fast using the proposed model.




Figure 1. Sample Image (a) Before (b) After Age and Gender Prediction



Figure 2. Sample Snapshot of a Video (a) Before (b) After Age and Gender Prediction

4. Conclusions and Future Work

In this study, an age and gender prediction model relying on CNN has been formed. The proposed model has been constructed with no errors in terms of the application of the gender and age features to different images and videos. Moreover, the resulting outputs have been very often consistent with the given inputs. In addition, the performance evaluation results of the proposed model have revealed that it provides fast and efficient age and gender prediction. In future, more sophisticated systems, such as recognition systems, which recognizes people from their eye retina or fingerprint can also be integrated with the proposed model.

References

- [1] B. Agrawal, and M. Dixit, “Age Estimation and Gender Prediction Using Convolutional Neural Network,” Intelligent Computing Applications for Sustainable Real-World Systems. ICSISCET 2019. ,Proceedings in Adaptation, Learning and Optimization, vol 13. Springer, Cham,2020.
- [2] M. K. Benkaddour, S. Lahlali and M. Trabelsi, "Human Age And Gender Classification using Convolutional Neural Network," 2020 2nd International Workshop on Human-Centric Smart Environments for Health and Well-being (IHSH), 2021, pp. 215-220, doi: 10.1109/IHSH51661.2021.9378708.
- [3] C.-T. Huang, Y. Chen, R. Lin, and C.-C. J. Kuo, “Age/Gender Classification with Whole-Component Convolutional Neural Networks (WC-CNN)”, 2017.
- [4] G. Trivedi, and N. N. Pise, “Gender Classification and Age Estimation using Neural Networks: A Survey”, International Journal of Computer Applications (0975 – 8887),vol.176,no.23,2020.
- [5] M.Mohammed,”age&genderDetection.ipynb”.[Online].Available:<https://colab.research.google.com/drive/1IxtbkINjIshiC59bqftB7qMGyDXCr0Iz?usp=sharing#scrollTo=4Miwi6aYOsN8>. [Accessed:May 17, 2021].
- [6] N. Arora,”Age Gender CSV Dataset”.[Online].Available:<https://www.kaggle.com/general/180281>. [Accessed:May 17,2021].
- [7] Y. Jia, and E.Shelhamer,”Caffe”.[Online].Available: <https://caffe.berkeleyvision.org/>. [Accessed:May 17,2021].

S-12 DEEP LEARNING BASED TRAFFIC SIGN RECOGNITION IN DIGITAL CLUSTER SYSTEM

Akin Gumuskavak¹, Cemal Cicekdes², Ekrem Sahin³, Mustafa Ozcelikors⁴, Hasret Unal⁵, Huseyin Kilic⁶, Faruk Yildirim⁷, Fatih Boran⁸

^{1, 2, 3, 4, 5, 6, 7, 8} TTTech Auto Turkey, Turkey,

{akin.gumuskavak¹, cemal.cicekdes², ekrem.sahin³, mustafa.ozcelikors⁴, hasret.unal⁵, huseyin.kilic⁶, faruk.yildirim⁷}@redpine.com.tr

⁸ fatih.boran@tttech-auto.com

Abstract

Since instrument clusters are turning out to be more well known, digital cluster systems are extended with new features in order to improve safety and effectivity. However, product complexity is causing difficulties to be able to afford that much feature in one place. So as to handle this issue, all features needs to be in order and well designed. With this paper, a digital cluster system integrated with informational ADAS features in all-in-one software platform is presented. The work includes deep learning based object detection system for traffic sign recognition to increase safety of the driver and passengers. Said informational ADAS systems provides essential directives to driver and leads him/her to be more attentive. Presented work lays out how accuracy of an object detection model for traffic sign recognition can be improved and to be integrated in a software platform.

Keywords: ADAS, automotive, deep learning, instrument cluster, traffic sign recognition.

1. Introduction

Instrument cluster digitalization is rapidly becoming more popular as new solutions emerge in the recent years. Vehicles are now being designed to be more complex technologically. In addition to essential car manufacturing equipments, digital displays and user equipments are also being improved. Driving assistance systems are deployed to automobiles to be able to improve driving safety.

In autonomous and intelligent vehicles, safety systems have great importance for improving the quality of traffic. Traffic-sign recognition (TSR) plays a significant role to assist drivers against potential hazards and improve the experience of driving. Therefore, TSR is a popular task among software products like automated driver assistance systems and understanding of the urban environment scenes, including maintenance of traffic signs. The traffic signs are standardized in size and shape in each country. The TSR is a realistic task consisting some constraints and difficulties such as frame settings, being blocked by visual environment, physical damages, lack of light, vehicle movement and occasions in the process of its detection and recognition. [1] [2]

However, market still lacks digital clusters equipped with Advanced Driver Assistance System (ADAS) features. At the moment, most of the commercial instrument cluster products do not

support informational ADAS applications. With the growth of these productions where ADAS features and instrument cluster applications integrated in a single board, more cost efficient digital clusters can be produced.

In this paper, deep learning methods were used for traffic sign recognition solution and integrated to CLADIS, an all-in-one software platform for digital cluster and informational ADAS application development. With CLADIS, an easily portable Linux-based automotive product that supports deep learning features is developed. We aim to present CLADIS and discuss how real world traffic condition problems effect traffic sign recognition solutions and how better accuracy is achieved through improving dataset.

2. Methodology

The basic aim is to have a fast object detection model for traffic sign recognition combining with the instrument cluster system and help driver with informational directives. In the further subsections, the embedded environment that traffic sign recognition algorithm runs on, the deep learning model that is used for traffic sign recognition, and training environment in order to further explain the methodology that is used in CLADIS software platform were explained.

2.1. Embedded Environment

Cluster-ADAS Integrated System (CLADIS) is an all-in-one solution Linux-based software platform that is designed to be a cluster system that is integrated with ADAS features. CLADIS involves traffic sign recognition and lane detection in order to notify the driver of certain circumstances while driving.

CLADIS is developed using Yocto Project [3] which is an open source collaboration project that helps to create custom Linux-based systems regardless of the hardware and managing all software packages. By using Yocto Project, CLADIS software platform is developed to be scalable, modular, and platform independent. Therefore, CLADIS software platform which includes several sample user interfaces and ADAS applications, can be ported to almost any Linux platform.

Although CLADIS software platform is portable to any Linux-based development kit, a high performance sample platform was chosen in order to integrate deep learning features. For the sample system, NVIDIA Jetson Xavier NX platform is used due to its NVIDIA TensorRT [4] support, 364-core high performance GPU and hardware acceleration feature. In our evaluations, it is found that NVIDIA Jetson Xavier NX [5] is both an affordable and high performance development board that is the most suited for integration with CLADIS software platform.

Instrument cluster application in CLADIS utilizes Qt 5 framework [6] close by with Qt Quick and Qt Quick 3D to support extensive user interface animations and figures. It is simple instrument cluster application with informational ADAS support in the middle of the screen as it is shown in the Figure 1. We transmit and display processed traffic sign recognition and lane detection data in the instrument cluster application with some influential animations.



Figure 1. CLADIS User Interface Overview.

2.2. Model

The main goal of this work is to design fast and accurate object detector in production in accordance to instrument cluster system. So Yolo V4 [7] which is improved version of Yolo V3 [8] is used as an object detection model in this work.

Yolo V4 consist of:

- Backbone: CSPDarknet53 [9]
- Neck: SPP [10], PAN [11]
- Head: Yolo V3

2.3 Training

In order to achieve effective training process for deep learning applications in CLADIS, the GeForce RTX 2070 [12] which is a high-end graphics card by NVIDIA is used. Due to its powerful performance, trainings are performed within 3 days with 80000 batches, which represents the number of iterations in the training process.

To improve an object detection model accuracy, we have gathered representative data to be trained and dataset is expanded as much as possible. We proposed image collection operation in 6 phases as listed in Table 1. In each phase, we increased the number of images used for training, in order to achieve better accuracy. A partnership with ITU Racing Driverless has been made and TTVS [13] which is an open source GitHub repository for image sharing is integrated to dataset. The rest of the dataset is collected directly from Google Maps. A total of 3000 images were carefully selected and annotated from Google Maps.

Table 1. *TSR Dataset.*

Version	Training Image Count	Training Label Count	Validation Image Count	Validation Label Count
1	741	1250	84	202
2	1095	2210	126	311
3	1601	3362	401	887
4	3068	6036	401	887
5	4645	8486	401	887
6	4656	8452	484	1050

3. Discussion & Results

The dataset is designed to be able to detect 20 different types of traffic signs and percentage of each sign in dataset is represented in Figure 2. As it is seen from the figure, the distribution of different types of traffic signs has been made as homogeneously as possible to improve both the deep learning model accuracy and the model variety.




Figure 2. *Ratio of Signs in Dataset*

In this work, how an object detection model can be customized for specific purposes with Yolo models is investigated. Yolo V3 utilizes multi-scale fusion to provide predictions, and a single neural network is used to gather and preprocess the holistic picture. Yolo V4 adopts Yolo V3 as a one-stage dense prediction in the head. [14]. Yolo V4 was adopted to our CLADIS solution due to the fact that it is supported with NVIDIA TensorRT framework for embedded use cases and since Yolo V4 is a well established neural network model used widely in object detection in industry.

Based on our experiment result shown in Figure 3, the best object detection model performance we get is with more and balanced data. The highest average precision value is achieved with the model which is trained with more than 4500 images and almost 8400 labels in it. In this stage, results also show us that studying with local dataset is an important factor for the model’s accuracy. Mixed dataset could not be effective for the average precision value as much as local dataset. Hence, collecting representative data and creating a balanced dataset improved the accuracy of the model significantly.

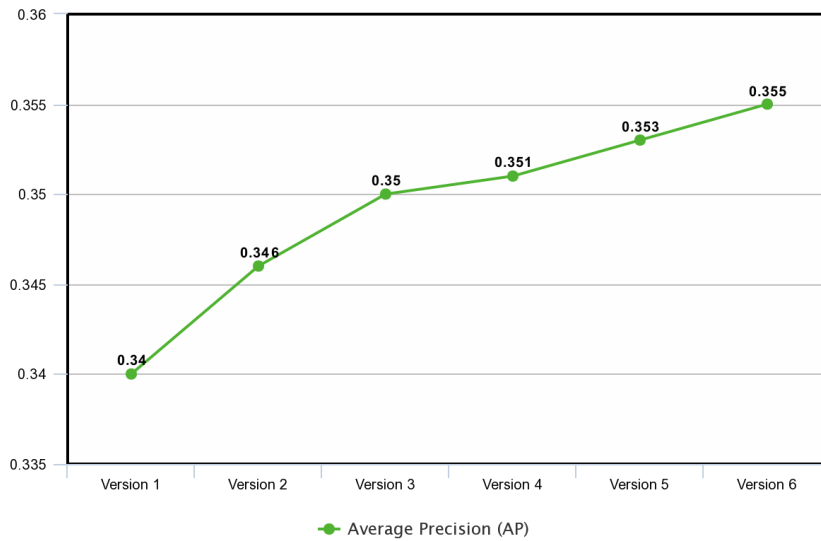


Figure 3. Average Precision (AP) Changes.

Overall integrated informational ADAS solution not only dramatically improved in terms of precision, but also in the user interface of the digital cluster, satisfactory warnings and indicators were observed, since the overall solution put deep learning algorithm to work in a practical embedded product.

References

- [1] A. Perkova, V. Varkentin and A. Fedorov, "Traffic Sign Recognition Using YOLOv3," 2020 International Conference Quality Management, Transport and Information Security, Information Technologies (IT&QM&IS), 2020, pp. 277-282, doi: 10.1109/ITQMIS51053.2020.9322986.
- [2] D. Yasmina, R. Karima and A. Ouahiba, "Traffic signs recognition with deep learning," 2018 International Conference on Applied Smart Systems (ICASS), 2018, pp. 1-5, doi: 10.1109/ICASS.2018.8652024.
- [3] Yocto Project: <https://www.yoctoproject.org/>, access September 2021.
- [4] TensorRT: <https://developer.nvidia.com/tensorrt>, access September 2021.
- [5] Jetson Xavier NX: <https://www.nvidia.com/tr-tr/autonomous-machines/embedded-systems/jetson-xavier-nx/>, access September 2021.
- [6] Qt: <https://www.qt.io/why-qt>, access September 2021.
- [7] Bochkovskiy, Alexey & Wang, Chien-Yao & Liao, Hong-yuan. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection.
- [8] Joseph Redmon and Ali Farhadi. YOLOv3: An incremental improvement. arXiv preprint arXiv:1804.02767, 2018. 2, 4, 7, 11.
- [9] Chien-Yao Wang, Hong-Yuan Mark Liao, Yueh-Hua Wu, Ping-Yang Chen, Jun-Wei Hsieh, and I-Hau Yeh. CSPNet: A new backbone that can enhance learning capability of cnn. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshop (CVPR Workshop), 2020. 2, 7.
- [10] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Spatial pyramid pooling in deep convolutional networks for visual recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI), 37(9):1904–1916, 2015. 2, 4, 7.
- [11] Shu Liu, Lu Qi, Haifang Qin, Jianping Shi, and Jiaya Jia. Path aggregation network for instance segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pages 8759–8768, 2018. 1, 2, 7.
- [12] GeForce RTX 2070: <https://www.nvidia.com/tr-tr/geforce/graphics-cards/rtx-2070/>, access September 2021.
- [13] TTVS: <https://github.com/ituracingdriverless/TTVS>, access September 2021.
- [14] C. Dewi, R. -C. Chen, Y. -T. Liu, X. Jiang and K. D. Hartomo, "Yolo V4 for Advanced Traffic Sign Recognition With Synthetic Training Data Generated by Various GAN," in IEEE Access, vol. 9, pp. 97228-97242, 2021, doi: 10.1109/ACCESS.2021.3094201.

S-24 IDENTIFICATION OF VEHICLE LATERAL DYNAMICS IN CARSIM WITH A DEEP NEURAL NETWORK

Hasan ŞENER¹, İ. Hakkı SAVCI², Uğur TÜMERDEM³

¹ Department of Mechanical Engineering, Marmara University, Turkey,
hasansener@marun.edu.tr

² Ford Otomotiv Sanayi A.Ş, Turkey, isavci@ford.com.tr

³ Department of Mechanical Engineering, Marmara University, Turkey,
ugur.tumerdem@marmara.edu.tr

Abstract

With recent advances in machine learning and artificial intelligence, autonomous driving is becoming a reality. The goal of this work is to obtain more accurate dynamical models of vehicles. For this purpose, we use the high fidelity simulation software Carsim. The lateral dynamics of a vehicle in Carsim is identified, as the vehicle moves on the track, with the use of a two stage Deep Neural Network (DNN). The results are in line with the measurements obtained from the high fidelity simulation and show that the DNN model is highly accurate. This approach can be used in the design of low-level motion control algorithms.

Keywords: *autonomous vehicle, deep neural network, nonparametric modelling, vehicle lateral dynamics.*

1. Introduction

Autonomous driving is a complex problem and the sub-problems can be grouped in three main areas: perception, planning and control. The focus of this work is on autonomous vehicle motion control. To control an autonomous vehicle there are several methods like Stanley Controller [1], Pure Pursuit Controller [2]. or Model Predictive Control (MPC) which can be used for optimal control and can work with nonlinear systems and constraints [3-5]. As the name suggests, MPC needs plant's dynamic model.

Identification of vehicle dynamics has been studied for a long time in the design of high performance controllers for driver assistance systems or autonomous navigation. Vehicle models can be constructed analytically in the form of dynamical differential equations in 3 Degrees of Freedom (DOF), namely in longitudinal, lateral and normal directions [6][7]. While these parametric models are simple and efficient they can have discrepancies from actual vehicle dynamics or high fidelity simulation models.

To create a high performance controller, it is necessary to model the vehicle as accurately as possible. Most of the literature uses the single track or bicycle model of vehicles [6]. These models are parameter dependent; however, vehicle dynamics are highly nonlinear and parameters may be time varying. In order to model/identify nonlinear vehicle dynamics neural networks are often utilized.

In [8], a generalized regression network is used for estimation of longitudinal acceleration, lateral acceleration and yaw angle using a separate model for each DOF. In [9], lateral motion of the vehicle is modeled with feedforward neural networks. In [10], neural networks with feedforward, fully connected feedforward, Box-Jenkins and cascade architectures are used for estimating yaw rate and slip angle of the vehicle. Results are compared to determine the most effective model in the study. Young Uk Yim and Se-Young Oh compared the open loop training and closed loop training methods in [11]. Open loop NN model is used for stabilization of the NN weight learning and closed loop training is used for long term prediction of the vehicle behavior.

In this paper, differently from the literature both feedforward NN and recurrent NN models are combined in cascade to obtain a deep neural network which is then used to identify vehicle lateral dynamics with only 2 inputs: vehicle speed and steering wheel angle. Proposed DNN consists of two stages. First stage uses feedforward NN to determine right and left tire angles, which are then fed to the second stage recurrent NN (RNN). Second stage is also composed of two different recurrent NNs to determine lateral velocity and angular velocity of the vehicle. To model NNs co-simulation technique is used in this study by using both MATLAB/Simulink and Carsim simultaneously. With the proposed approach parameter uncertainty due to air pressure in tires, normal load, coefficient of friction of tire and road interaction forces are also taken into taken account, and identification results are found to be highly accurate compared with measurement obtained from the high fidelity Carsim model.

2. Mathematical Vehicle Model

This section introduces the simplified single-track mathematical model of the vehicle dynamics. Variations of this model can also be referred as car-like robot model, bicycle model [12]. Vehicle motion is assumed to be planar, and therefore roll dynamics and lateral load transfer are neglected. Coordinate frame convention and forces acting on vehicle and tire are shown in Figure 1.




Figure 1. Coordinate frame convention and Tire forces

$$\ddot{x} = m^{-1}(F_{x,r} + F_{x,f} \cos(\delta) - F_{y,f} \sin(\delta)) + \psi \dot{y} \quad (1)$$

$$\ddot{y} = m^{-1}(F_{y,r} + F_{x,f} \sin(\delta) - F_{y,f} \cos(\delta)) - \psi \dot{x} \quad (2)$$

$$\ddot{\psi} = I_z^{-1}(l_f F_{x,f} \sin(\delta) + l_f F_{y,f} \cos(\delta) - l_r F_{y,r}) \quad (3)$$

$$v = \sqrt{\dot{x}^2 + \dot{y}^2}, \beta = \arctan\left(\frac{\dot{y}}{\dot{x}}\right) \quad (4)$$

$$\dot{X} = v \cos(\psi + \beta), \dot{Y} = v \sin(\psi + \beta) \quad (5)$$

Where, $\dot{x}, \dot{y}, \dot{\psi}$ are longitudinal, lateral and yaw velocity in the vehicle frame, $\ddot{x}, \ddot{y}, \ddot{\psi}$ longitudinal, lateral and yaw acceleration in the vehicle frame, m is the mass of the vehicle, ψ is the heading direction in global frame, β is the slip angle of the vehicle, δ denotes steering angle of the front wheel, l_r, l_f denotes distance from center of gravity of the rear and front axles respectively, $F_{i,j}$ (where, $i = \{x, y\}, j = \{f, r\}$) are tire forces which provides vehicle motion.

Tire forces are modeled with and expressed in corresponding tire coordinate frames shown in Figure 1. Therefore $F_{i,j}$ in Eqs. (1)-(3) should be modelled by using tire models [13-15]. Linear tire models expressed in [6, 16] can also be used for simplicity.

3. Proposed Deep Neural Network

As introduced in Section 2, vehicle models can be expressed in analytical form. However, while the analytical equations are simple and efficient; they are not accurate enough due to unidentified model parameters or the variation in the dynamics due to factors such as emergency maneuvers.

In order to solve this problem, in this paper a non-parametric black box modeling approach is utilized with the use of a DNN. Proposed DNN is made up of two stages. Since vehicles use Ackermann Steering, left and right front tires turn at different angles [17], and therefore a feedforward NN is used to estimate left and front tires' steering angles. These angles can be measured by Wheel Position Sensors (WPS) in real life [18], steering wheel angle and velocity of the vehicle can be directly taken by On Board Diagnostics (OBD) tools from vehicle CAN Bus.

It can be seen from Figure 1 that, front tire angles play a strong role in the dynamics of the vehicle since both front tires turn at different angles in a corner. In order to achieve a good control performance, vehicle motion must be estimated. For this purpose, DNN architecture is composed of two stages. First stage uses steering angle as input, then estimates left & right tire angles ($\delta_{f,r}, \delta_{f,l}$) with a feedforward NN. Second stage uses longitudinal velocity from vehicle, and the outputs of stage one NN, then estimates lateral velocity & angular velocity of the vehicle with two recurrent NNs.

Stage one NN is composed of 1 input layer $\in R^1$, 1 hidden layer $\in R^{10}$, and 1 output layer $\in R^2$. Activation functions of the hidden layer and output layer are *sigmoid* and *pure linear* respectively. Stage two NNs are composed of 1 input layer $\in R^3(\dot{x}, \dot{\delta}_{f,r}, \dot{\delta}_{f,l})$ and time delay (TDL) with $Z^{-1} \times 10$, 2 hidden layers $\in R^{20}, \in R^{10}$ and 1 output layer $\in R^1(\dot{y}, \dot{\psi})$. Activation function of the hidden layers and output layer are both *sigmoid functions*. Complete NN architecture is shown in Figure 2.

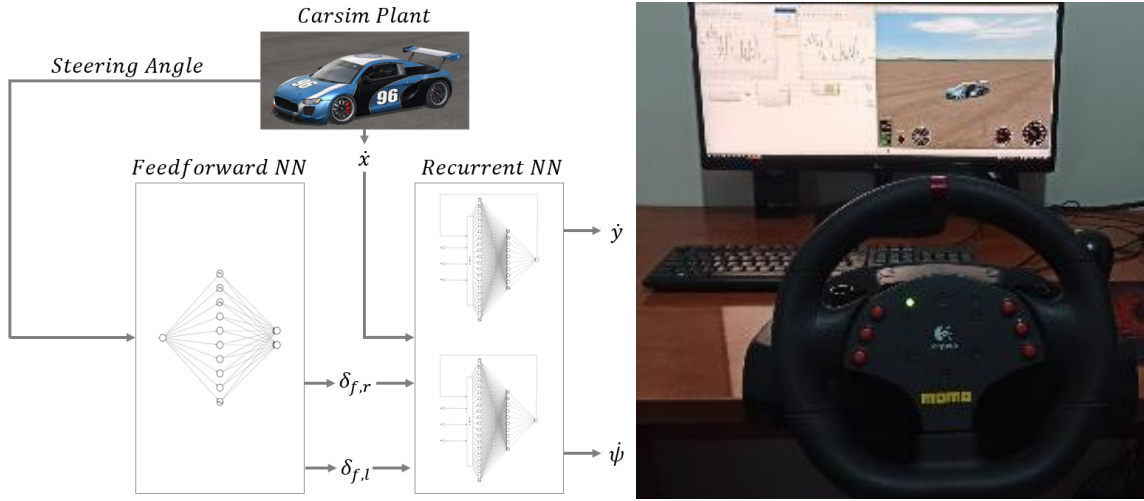


Figure 2. Complete NN Architecture and Experimental Setup

4. Co-Simulation Results

As shown in Figure 2 experimental setup for training data generation has been constructed in Carsim by using a Logitech Momo driving set consisting of an external throttle, brake pedals and a steering wheel. For lateral dynamics training data, Carsim vehicle is driven by a person at different speeds and different maneuvers are performed. Vehicle parameters used in the simulation are as follows; mass of the vehicle (m) is $1200kg$, front axle distance (l_f) from Center of Gravity (COG) is $1455mm$, rear axle distance (l_r) from COG is $1195mm$, yaw inertia (I_z) is $1065.2kgm^2$

Performance of the feedforward NN and recurrent NNs can be seen in Figure 3 and 4. Dashed lines show NN estimations. It can be clearly seen that error is near zero for tire angle estimation. Errors are found near ± 0.1 m/s for lateral velocity estimation and ± 0.1 rad/s for angular velocity estimation. Quantification of NN model errors are given in Table 1.

Table 1. RMS Error Summary

Estimation	Font Right Tire Angle ($\delta_{f,r}$)	Font Left Tire Angle ($\delta_{f,l}$)	Lateral Velocity (\dot{y})	Angular Velocity ($\dot{\psi}$)
RMS Error	3.83e-4 rad	3.58e-4 rad	0.0148 m/s	0.0214 rad/s
Network Type	Feedforward NN	Feedforward NN	Recurrent NN	Recurrent NN

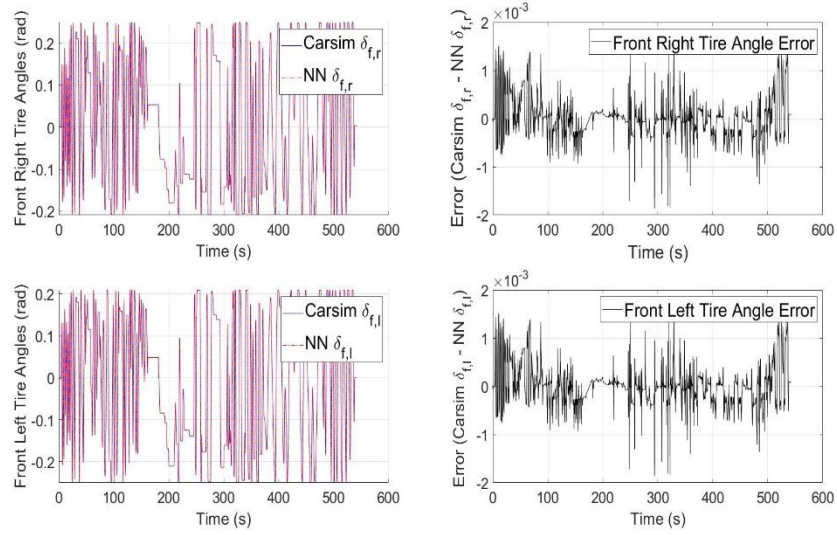


Figure 3. NN Identification Results for $\delta_{f,r}$, $\delta_{f,l}$

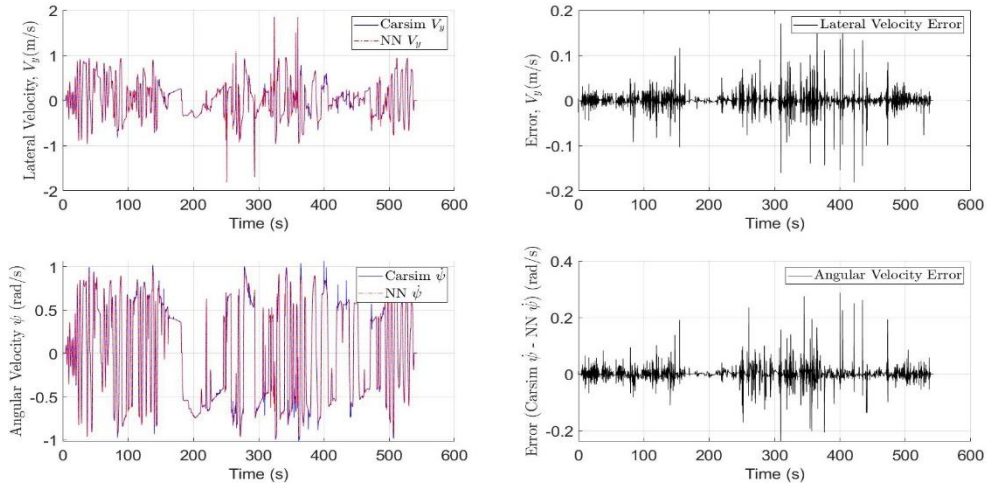


Figure 4. NN Identification Results for \dot{y} , $\dot{\psi}$

5. Conclusion

Co-simulation results show that, forward vehicle dynamics can be identified with small RMS errors using the proposed DNN approach. The proposed approach can also be extended to the identification of longitudinal and yaw dynamics without loss of generality. Future work includes developing motion controllers using the proposed DNN.

References

- [1] G. M. Hoffmann, C. J. Tomlin, M. Montemerlo, and S. Thrun, “Autonomous automobile trajectory tracking for off-road driving: controller design, experimental validation and racing,” 2007 American Control Conference, 2007.

- [2] H. Andersen, Z. J. Chong, Y. H. Eng, S. Pendleton, and M. H. Ang, “Geometric path tracking algorithm for autonomous driving in pedestrian environment,” 2016 IEEE International Conference on Advanced Intelligent Mechatronics (AIM), 2016.
- [3] J. Kabzan, L. Hewing, A. Liniger and M. N. Zeilinger, "Learning-Based Model Predictive Control for Autonomous Racing," in IEEE Robotics and Automation Letters, vol. 4, no. 4, pp. 3363-3370, Oct. 2019, doi: 10.1109/LRA.2019.2926677.
- [4] J. Liu, Z. Yang, Z. Huang, W. Li, S. Dang and H. Li, "Simulation Performance Evaluation of Pure Pursuit, Stanley, LQR, MPC Controller for Autonomous Vehicles," 2021 IEEE International Conference on Real-time Computing and Robotics (RCAR), 2021.
- [5] W. Zhang, “A robust lateral tracking control strategy for autonomous driving vehicles,” Mechanical Systems and Signal Processing, vol. 150, p. 107238, 2021.
- [6] R. Rajamani, Vehicle Dynamics and Control. New York: Springer, 2012.
- [7] A. B. Will and S. H. Z°ak, “Modelling and control of an automated vehicle,” Vehicle System Dynamics, vol. 27, no. 3, pp. 131–155, 1997.
- [8] V. Karri and D. Butler, “Using artificial neural networks to predict vehicle acceleration and yaw angles,” Proceedings of the 9th International Conference on Neural Information Processing, 2002. ICONIP '02., 2002.
- [9] A. D. Assi, “Modeling Lateral Motion of a Vehicle Using Neural Networks Technique.”, Journal of Kerbala University, vol. 13, no. 4, 2015
- [10] D. J. Broderick and D. M. Bevly, “Comparison of architectures for neural based modeling of lateral vehicle dynamics,” IFAC Proceedings Volumes, vol. 40, no. 19, pp. 243–248, 2007.
- [11] Se-Young Oh and Younguk Yim, “Modeling of vehicle dynamics from real vehicle measurements using a neural network with two-stage hybrid learning for accurate long-term prediction,” Proceedings 1999 IEEE International Symposium on Computational Intelligence in Robotics and Automation. CIRA'99 (Cat. No.99EX375), 1999.
- [12] B. Paden, M. Cap, S. Z. Yong, D. Yershov, and E. Frazzoli, “A survey of motion planning and control techniques for self-driving urban vehicles,” IEEE Transactions on Intelligent Vehicles, vol. 1, no. 1, pp. 33–55, 2016.
- [13] D. Schramm, M. Hiller, and R. Bardini, Vehicle Dynamics: Modeling and Simulation. UK, Springer, 2018.
- [14] E. Fiala, Lateral Forces At The Rolling Pneumatic Tire. Vdl, 1954.
- [15] H.B. Pacejka and o. Besselink, Tire and Vehicle Dynamics. Butterworth-Heinemann, 2012.
- [16] J. Filip, “Trajectory tracking for autonomous vehicles,” Dissertation, 2018.
- [17] W. F. Milliken and D. L. Milliken, Race car vehicle dynamics. Warrendale, Pa: Society of Automotive Engineers, 1995.
- [18] “(WPS): A&D,” A&D Company, 17-Aug-2020. [Online]. Available: <https://aanddtech.com> [Accessed: 14-Sep-2021]

S-25 YAPAY SİNİR AĞI TABANLI MİKROŞERİT YANSITICI DİZİ ANTEN BİRİM HÜCRE TASARIMI

Mehmet BEREKET^{1*}, Aysu BELEN², Mehmet Ali BELEN³

^{1*} İskenderun Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Hatay, Türkiye, mehmet.bereket@iste.edu.tr

² İskenderun Teknik Üniversitesi, İskenderun meslek Yüksek Okulu, Hibrid ve Elektrikli Araçlar Bölümü, Hatay, Türkiye, aysu.belen@iste.edu.tr

³ İskenderun Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Hatay, Türkiye, mali.belen@iste.edu.tr

Özet

Mikroşerit yansıtıcı dizi antenler (MYDA), geleneksel bir parabolik yansıtıcının eşdeğer performansını sağlamakla birlikte basit, hafif ve yüksek performanslı elektromanyetik ve mekanik niteliklere sahiptir. Bu yapıların tasarımındaki en büyük zorluk, dizi optimizasyonunda kullanılacak mikroşerit yamanın birim hücre modellemesinin hızlı ve doğru yapılmasıdır. Bu çalışma kapsamında, yapay sinir ağı tabanlı bir birim elemanın geometrik parametreleri ve çalışma frekansı açısından yansıma açısının karakterizasyonu için hızlı ve doğruluğu yüksek bir model oluşturmak hedeflenmiştir. Bu amaçla, 3 boyutlu elektromanyetik benzetim programı olan CST verileriyle eğitilmiş Çok Katmanlı Algılayıcı (ÇKA) sinir ağı kullanılarak Malta Çarmıhı şekilli yama modellenmiş ve elde edilen model ile mikroşerit yama birim elemanın geometrik parametreleri ve frekans alanındaki yansıma açısı için sürekli bir fonksiyon elde edilmiştir. Elde edilen fonksiyonun yansıtıcı dizi tasarımı için optimizasyon prosedürünün analitik fonksiyonlarını kullanmak kadar hızlı ve 3D simülatörler kadar doğru sonuç verdiği gözlenmiştir.

Anahtar Sözcükler: Çok Katmanlı Algılayıcı; X-Bant; Yapay Sinir Ağı; Yansıtıcı dizi anten.

Abstract

Microstrip reflectarray antennas (RAs) are designs that can achieve equivalent performance of parabolic reflector, but with simple and light electromagnetic and mechanical structures. The challenging problem in design of RA is the fast and accurate modelling of the unit element for the array optimization. 3D EM simulators are computationally very ineffective, thus in this study artificial neural network based unit element modelling for characterization of the reflection phase of the unit element in terms of its geometry, and operation frequency is studied. For this mean, a Malta Cross shaped design for X-band applications is taken into the consideration using Multilayer Perceptron (MLP) neural network trained the 3D CST microwave Studio simulator data. Validation of the MLP model is also worked out successfully with the 3D CST data. By this mean, a continuous function is obtained for the reflection phase of the unit element with respect to the variation of geometrical design parameters and operation frequency had been achieved which can be used for a design optimization process fast as analytical approach design while being accurate as 3D EM

simulator tools.

Keywords: Multi-Layer Perceptron; X-band; Artificial Neural Network; Reflectarray antenna.

1. Giriş

Yansıtıcı dizi antenler (YDA), karmaşık ve kayıplı iletim hattı besleme ağlarını kullanmaksızın hem geleneksel parabolik yansıtıcıların hem de faz dizili antenlerin avantajlarına sahiptirler [1-4]. Mikroşerit Yansıtıcı Dizi antenler (MYDA) ise hem elektromanyetik hem de mekanik açıdan kategorize edilebilecek birçok avantaja sahiptirler. Elektromanyetik olarak avantajları, yüksek kazanç değerine, düşük yan loblara, ışın yönlendirme yeteneğine sahip olmasıdır. Mekanik yönüne bakıldığında ise hafif ve düzlemsel bir tasarım olması ve kolay üretilmesi avantajlarıdır.


Yansıtıcı dizi antenlerde faz dağılımı, çok sayıda birim hücre ile gerçekleştirildiğinden geniş bir esneklik sağlanır. Birim hücre geometrisi ve bunların diziliminin optimizasyonu ile huzme şekillendirme işlemi düşük bir maliyet ile elde edilebilmektedir. Belirli bir (θ° , φ°) yönünde bir kalem ışını oluşturmak, klasik dizi teorisinden iyi bilindiği gibi, her bir YDA elemanın, gelen dalgayı bağımsız olarak yansıtacak şekilde, besleme horn anten faz merkezinden olan mesafeyle orantılı bir faz telafisinin tasarlanmasıyla sağlanabilir. Bu nedenle, faz ayarlanması yansıtıcı dizi tasarımında çok önemli bir süreçtir. Faz ayarlanması yönteminde, basitlik arzu edildiğinden değişken boyutlu yamalar tercih edilir. Şekillendirilmiş bir yama veya çoklu yamaları yansıtma yeteneği gibi gereksinimleri karşılamak veya aynı zamanda frekans davranışını ve bant genişliğini geliştirmek için, birkaç serbestlik derecesi gösteren gelişmiş eleman konfigürasyonlarının kullanılması gereklidir. Farklı parametrelerin yönetimi ve faz kompanzasyonunun sağlanması, bant genişliğinin artırılması, yüksek kazanç gibi gereksinimlerin birbirinin tersi olarak karşılanması ihtiyacı, gerekli çok amaçlı tasarım optimizasyonunu zorlu bir problem haline getirmektedir.

Hesaplama açısından verimli bir optimizasyon sürecine sahip olması açısından, birim elemanın girdi değişkenlerinin sürekli bir fonksiyonu olarak hareket etmek için, hızlı ve doğru bir birim eleman modeline ihtiyaç vardır. Daha sonra, bu hızlı ve doğru modeli kullanarak, hesaplama açısından verimli bir optimizasyon süreci gerçekleştirmek mümkündür.

Burada yapay zekâ kullanılarak, geometrik parametreler ve frekans açısından mikroşerit birim elemanın yansıma açısının karakterizasyonu için hızlı ve doğru bir model oluşturmak hedeflenmiştir. Bu amaçla, 3B elektromanyetik modelleme programı verileriyle eğitilmiş Çok Katmanlı Algılayıcı (ÇKA) sinir ağı kullanılarak X-bandı içindeki Malta Çarmıhı şekilli yamanın modellenmesi hedeflenmiştir. ÇKA modelinin validasyonu da Yapay Sinir Ağının 3B CST veri tasarımı ile başarılı bir şekilde yapılmıştır. İlk olarak, Şekil 1-2'de verilen değişken parametreleri ile Malta Çarmıhı şekilli bir birim hücre incelenmiştir. YSA modelinin oluşturulması adına Tablo 1'de verilen parametrik değerler kullanılarak bir dizi eğitim ve test seti oluşturulmuştur. Önerilen YSA tabanlı hücre modeli, 3B simülatörden elde edilen simüle edilmiş yansıma fazı değerleri kullanılarak ÇKA kara kutu modeli ile birlikte kullanılmıştır.

2. Birim Hücre Tasarımı

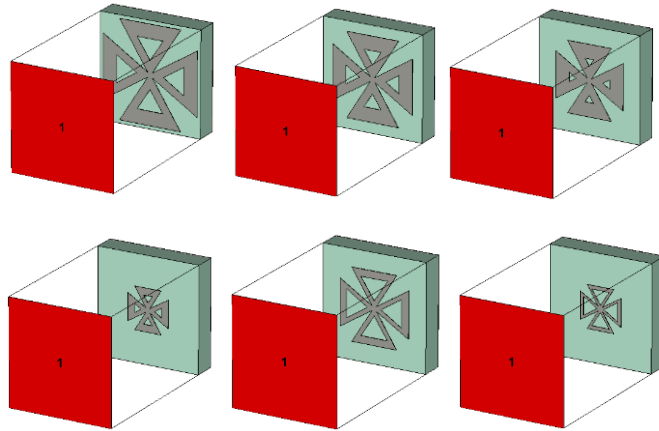
Bu çalışmada, birim hücre YDA tasarlamak için Şekil 1'deki Malta Çarmıhı birim hücrenin 3B simülasyon tabanlı modeli değişkenleri ile birlikte sunulmuştur. Tablo 1'de eğitim ve test veri setlerinin oluşturulmasında kullanılacak tasarım değişkenlerinin limitleri, şeklin verilen limitler içerisindeki değişimi ise Şekil 2'de verilmiştir. Basitlik adına, mikroşerit dielektrik malzemeye ait yükseklik değerleri sırasıyla 1.52 mm ve 6.15 mm (Rogers 3006 malzemesine uyumlu) olarak alınmıştır.



Şekil 1. Malta Çarmıhı birim hücrenin 3 boyutlu görünümü

Tablo 1. Birim Hücre Parametrelerinin Aralığı (Burada W=L=15 mm alınmıştır)

Parametre	Aralık	Adım aralığı
W1	2-7	0.1
L1	0.2-2	0.1
f (GHz)	8-12	0.5
Veri sayısı	8721	




Şekil 2. Birim hücrenin farklı parametrik değerlerdeki görünümü

3. ANN ile Birim Hücre Modellemesi

Birim hücrenin parametrik taramasından elde edilen veriler, Malta Çarmihı YDA elemanının YSA tabanlı modelinin oluşturulması için eğitim ve test verilerine ayrılacaktır. Bu işlem için k-fold validasyon yöntemi kullanılarak oluşturulan veriler eşit 2 parçaya (K=2) ayrılmıştır. Bu aşamada eğitim ve test verileri kullanılarak, Malta Çarmihı şekilli YDA'nın YSA tabanlı birim eleman modelinin oluşturulması için Çok Katmanlı Algılayıcı (ÇKA) Ağı kullanılmıştır. Şekil 3’de verilen ÇKA’ya ait ağ tasarımı parametreleri Tablo 2’deki gibi ele alınmıştır.

Tablo 2. ÇKA Ağının Kullanıcı Tanımlı Parametreleri

Gizli Katmandaki Nöron sayısı (N)	5, 10, 15
Aktivasyon Fonksiyonu	Tangent Sigmoid
Eğitim Algoritması	Levenberg–Marquardt
Maksimum epoch	2x(örnek sayısı)



Şekil 3. YDA elementinin Kara Kutu modeli

ÇKA ağının performansı, 10 bağımsız çalıştırma için yaygın olarak kullanılan Ortalama Mutlak Hata (OMH) ile değerlendirilecektir.

$$OMH = \frac{1}{N} \sum_{i=1}^N |T_i - P_i| \quad (1)$$

YSA modelinin daha iyi performans değerlendirmesi için, eğitim ve test veri setleri k=2 ile çapraz kat doğrulaması kullanılarak yapılmıştır. Elde edilen sonuçlar Tablo 3-5’de sunulmuştur.

Tablo 3. 5 Nöronlu tek katlı YSA Modelinin Performans Sonucu

Performans		OMH
K-Fold 1	En iyi	26.3
	En Kötü	115.6
	Ortalama	75.8
K-Fold 2	En iyi	36.3
	En Kötü	94.2
	Ortalama	55.1
Ortalama Performans	65.5	


Tablo 4. 5-10 Nöronlu YSA Modelinin Performans Sonucu

Performans		OMH
K-Fold 1	En iyi	14.7
	En Kötü	60.3
	Ortalama	33.7
K-Fold 2	En iyi	18.4
	En Kötü	55.2
	Ortalama	29.7
Ortalama Performans	31.7	

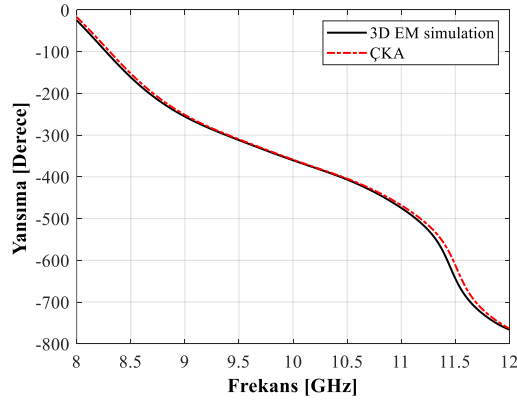
Tablo 5. 5-10-15 Nöronlu YSA Modelinin Performans Sonucu

Performans		OMH
K-Fold 1	En iyi	4.1
	En Kötü	9.8
	Ortalama	5.4
K-Fold 2	En iyi	4.8
	En Kötü	10.7
	Ortalama	6.1
Ortalama Performans	5.8	

Tablo 3-5'den de görüldüğü gibi gizli katmandaki nöron sayısı ve katman sayısı, YSA modelinde en önemli tasarım parametresidir. Optimal nöron sayısı $N=5-10-15$ ve gizli katman sayısı ise 3 olarak belirlenmiştir.



(a)



(b)

Şekil 4. Rastgele seçili tasarımlar için performans sonuçları (a) $W1=0.5$ [mm], $L1=0.2$ [mm], (b) $W1=0.7$ [mm], $L1=2.0$ [mm].

3. Sonuç

Simülasyon sonuçlarından da görüldüğü gibi, Malta Çarmıhı şekilli mikroşerit yama YDA birim hücresinin önerilen YSA tabanlı modeli, 3B simülasyon sonuçları ile yüksek doğruluk oranına sahiptir ve büyük ölçekli bir YDA tasarımının tasarım optimizasyon sürecinde birim eleman olarak kullanılmak için yeterlidir. Gelecekteki çalışmalarda, bu YSA tabanlı model ve optimizasyon algoritmalarının X bant büyük ölçekli yansıtma dizili anten tasarımında kullanılması hedeflenmektedir.

Referanslar

- [1] D.G. Berry, R.G. Malech, and W.A. Kennedy, The reflectarray antenna, *IEEE Trans Antennas Propagat* 11 (1963), 645–651.
- [2] P. Mahouti, “Application of artificial intelligence algorithms on modeling of reflection phase characteristics of a nonuniform reflectarray element.” *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields* 33, no. 2 (2020): e2689.
- [3] D.M. Pozar, S.D. Targonski, and H.D. Syrigos, Design of millimeter wave microstrip reflectarrays, *IEEE Trans Antennas Propagat* 45 (1997), 287–297.
- [4] J. Huang and J.A. Encinar, *Reflectarray antennas*, John Wiley & Sons, Inc., Hoboken, NJ, USA, 2007. ISBN:978-0-470- 08491-4.
- [5] A. Belen, F. Güneş, M. A. Belen, and P. Mahouti. “3D printed wideband flat gain multilayer nonuniform reflectarray antenna for X-band applications.” *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields* 33, no. 6 (2020): e2753.
- [6] M. Mahouti, N. Kuskonmaz, P. Mahouti, M. A. Belen, and M. Palandoken, “Artificial neural network application for novel 3D printed nonuniform ceramic reflectarray antenna,” *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 33(6), e2746, 2020.

**S-13 BÖLGE TABANLI EVRİŞİMLİ SİNİR AĞI İLE YÜZ TANIMA
FACE RECOGNITION WITH REGION BASED CONVOLUTIONAL NEURAL
NETWORK**

Demet Hanife SUNGUR^{1,*}, Pakize ERDOĞMUŞ²

¹ Bilgisayar Mühendisliği, Fen Bilimleri Enstitüsü, Düzce Üniversitesi, Türkiye,
demethanife@gmail.com

² Bilgisayar Mühendisliği, Mühendislik Fakültesi, Düzce Üniversitesi, Türkiye,
pakizeerdogmus@duzce.edu.tr

Özet

İnsanların göz veya parmak izi gibi biyometrik özelliklerinin yanı sıra müdahale veya temas olmadan kullanılabilir en belirgin ve temel özelliği yüzüdür. Bu çalışmanın amacı, derin öğrenme tekniği ve CNN algoritması kullanarak bir yüz tanıma sistemi geliştirmektir. Bunu sağlamak için araştırmacılar tarafından on iki öğrencinin 400 farklı fotoğrafını içeren özgün bir veri seti oluşturulmuştur. Öğrencilerin fotoğrafları, sınıf ortamında farklı oturma düzeninde farklı açılar oluşturacak şekilde kameraya karşı yerleri ve açıları değiştirilerek çekilmiştir. Veri seti eğitim ve test setlerine ayrılmış ve her bir öğrenci fotoğrafta ayrı ayrı etiketlenmiştir. Eğitim sürecinden sonra test seti üzerinde yüz tanıma süreci test edilmiştir. Sonuçları detaylı olarak karşılaştırmak ve incelemek için 300/100, 350/50 ve 380/20 olmak üzere üç farklı eğitim/test oranı kullanılmıştır. Önerilen yaklaşım, öğrencilerin yüz tanınması ile kimliklerinin belirlenmesinde umut verici sonuçlar vermiştir. 300/100 eğitim/test oranı kullanıldığında başarı oranı %73,25 iken, 350/50 ve 380/20 oranlarında sırasıyla %79,67 ve %81,67'ye yükselmiştir. Sonuç olarak yüzleri kolayca tanımak için uygun derin öğrenme modellerinin tatmin edici düzeyde kullanılabilirliği gösterilmiştir. Ayrıca bu modeller sadece yoklama veya güvenlik amaçlı değil, öğrencilerin duygularını tespit etmek için de kullanılabilir. Böylece öğrenme ortamının iyileştirilmesi ve öğrencilerin hazır bulunuşluklarının değerlendirilmesi mümkün olabilir.

Anahtar Sözcükler: *Derin öğrenme, görüntü işleme, nesne tespiti, R-CNN, yüz tanıma.*

Abstract

In addition to biometric features of people such as eyes or fingerprints, the most distinctive and basic feature that can be used without intervention or contact is the face. The aim of this study is to develop a face recognition system using deep learning technique and CNN algorithm. To achieve this, an original data set including 400 different photos of twelve students was created by the researchers. Photos of the students were taken in their own classroom by changing their places and angles to the camera to create different angles with different sitting patterns. The data set divided into training and test sets, and each students were labeled individually in each photos. After the training process, face recognition process was testing on the test set. To compare and examine the results in detail; three different training/test ratio; 300/100, 350/50, and 380/20; were used. The proposed approach yielded promising results in identifying students using face regions. A success rate of 73.25% was

obtained when the 300/100 training/test ratio was used, while the success rate increased to 79.67% and 81.67% for the 350/50 and 380/20 ratios, respectively. As a result, it has been shown that appropriate deep learning models can be used to recognizing the faces easily with a satisfying level. In addition, these models can be used not only for attendance or security purposes, but also for detecting the emotions of the students. Thus, it may be possible to improve the learning environment and evaluate the readiness of students.

Keywords: *Deep learning, face recognition, image processing, object detection, R-CNN.*

1. Giriş

Otomatik tanıma sistemlerinde iris, parmak izi ve yüz gibi biyometrik veriler kullanılabilir. Parmak izi, iris tanıma gibi özelliklerle çalışan sistemlerde kullanıcılara müdahale gerekli olabileceğinden, bu alternatiflere göre otomatik yüz tanıma çok daha cazip ve pratik olabilmektedir [1] [2]. Standart bir yüz tanıma işlemi üç aşamadan oluşmaktadır; Yüz tespiti, özellik çıkarma ve yüz tanıma [1] [3]. Bir görüntüdeki yüzün bulunması ile başlayan yüz tanıma süreci yüzün konumunun tespiti ve segmentlerine ayrılması ile devam eder. Yüzün ayırt edici özelliklerinden oluşan bir özellik vektörü kullanılarak bölümlenmiş yüzün temsili oluşturulur [1] [3] [4]. Veri tabanındaki özellik şablonu ile tek bir karşılaştırma yapılmasına doğrulama, veri tabanındaki tüm özellik şablonlarıyla karşılaştırma ise tanımlama olarak ifade edilebilir. Yüz tanıma bu iki alternatifle yapılabilir.

2. Amaç

Bu çalışmanın amacı, derin öğrenme tekniği ve CNN algoritması ile bir yüz tanıma sistemi geliştirilmesidir.

3. Materyal ve Yöntem

Çalışmada kullanılacak veri seti araştırmacılar tarafından bir sınıftaki öğrencilerin farklı oturma düzenlerinde farklı açılardan fotoğrafları çekilerek oluşturulmuştur. Veri seti, eğitim ve test seti olmak üzere ikiye ayrılmıştır. Her bir öğrenci, veri setindeki her bir fotoğraf için ayrı ayrı etiketlenmiştir. Dedektör nesnesi, eğitim süreci için bölge tabanlı evrişimli sinir ağı (region based convolutional neural network, R-CNN) Object Detector kullanılarak oluşturulmuştur. Eğitim sürecinden sonra test seti üzerinde algılama işlemi gerçekleştirilerek dedektör nesnesinin başarı oranı incelenmiştir. Yeni oluşturulan bu nesne algılama modeli kullanılarak veri setinin test kısmı ile test işlemi gerçekleştirilmiştir. Modeli karşılaştırmalı olarak derinlemesine incelemek için üç farklı eğitim/test oranı kullanılmıştır. Fotoğraf çekmek ve kullanmak için öğrencilerden ve velilerinden yazılı izin alınmıştır.

3.1. Evrişimli sinir ağı (Convolutional neural network, CNN)

Derin öğrenme için kullanılan en popüler modellerden biri olan CNN, biyolojik yapılardan ve süreçlerden esinlenerek bilgisayarla görme uygulamaları için geliştirilmiş çok katmanlı bir ağ modelidir. CNN’ler, öznelik çıkarma ve sınıflandırmayı birleştiren, görüntünün piksellerinden (veya diğer sinyallerden) doğrudan kalıpları tanımak için tasarlanmış ileri beslemeli sinir ağlarıdır. CNN, görüntü tanıma ve sınıflandırma ile ilgili uygulamalarda en güçlü sınıflandırma modeli olarak karşımıza çıkmaktadır. Yapısında, evrişim katmanı, havuzlama katmanı,

aktivasyon (ReLU) katmanı, tam bağı katman ve softmax gibi her birinin kendine özgü görevleri olan ayrı katmanlar içerir. Bir görüntü düzleştirildiğinde köşeler, renkli çizgiler ve oval kısımlar kaybolur. Bu nedenle görüntü üzerinde nesne tanıma için önemli olan bu detayların kaybolmaması için CNN kullanılması daha uygun olmaktadır [5]. CNN’de görüntüyü düzleştirmek yerine filtreler kullanılarak görüntünün farklı özellikleri ortaya çıkarılmaktadır.

Çok katmanlı bir algılayıcı olan CNN sayesinde görüntü içinde birden fazla yüz dahi olsa tanımlanabilmektedir [2] [6]. Son yıllarda yapılan çalışmalarla yüz tanımda hatalar azaltılmış olsa da hala bazı içsel ve dışsal parametrelere duyarlılığı sürmektedir [7]. Görüntülerdeki nesnelere ve yüzler farklı boyutlarda olabilir ve ayrıca farklı konumlarda yer alabilir, bu da çıktı katmanında farklılıklara neden olur. Bu nedenle, birden fazla bölge seçme problemini çözmek için standart bir CNN’de yüz tanıma problemlerini çözmek zordur. Standart bir CNN bu sorunları çözemeyebilir. Bu gibi problemleri çözmek için, bölge önerilerinin CNN ile birleştirildiği R-CNN geliştirilmiştir [8]. Belirli bir görüntü için R-CNN ile kutu şeklindeki sınırlar çizilebilir. Bu doğrultuda, bir R-CNN, dikdörtgen bölge önerilerini CNN özellikleriyle birleştiren bir derin öğrenme yaklaşımı olarak ifade edilebilir. Otonom sürüş, akıllı gözetim sistemleri ve yüz tanıma gibi alanlarda R-CNN kullanılabilir.

3.2. Bölge tabanlı evrişimli sinir ağı (Region based convolutional neural network, R-CNN)

Görüntü sınıflandırması için genellikle CNN kullanılırken, nesne tespiti yapılıyorsa R-CNN tercih edilir. Nesne tanıma, bir görüntüde hangi nesnelere bulunduğunu tanımlayan bir işlem iken, nesne tespiti yalnızca görüntüde hangi nesnelere bulunduğunu söylemekle kalmaz, aynı zamanda nesnelere görüntüdeki konumunu gösterir ve sınırlarını tespit eder. Bu nedenle, nesne tespiti ve sınıflandırma algoritmaları arasındaki fark, tespit algoritmalarında görüntüdeki konumunu belirtmek için ilgilene nesnenin etrafına bir sınırlayıcı kutu çizmektir. Ayrıca, görüntüde ilgilene birçok farklı nesne olabilir ve bir sınırlama kutusu yeterli olmayabilir, görüntüdeki ilgilene farklı nesnelere konumunu temsil eden birçok sınırlama kutusu çizmek gerekebilir [9] [10].

R-CNN ile nesne tespitinde görüntü önce bölge önerilerine bölünür ve ardından her bölge için CNN uygulanır. Bu doğrultuda, R-CNN, giriş görüntüsüne ek olarak ilgilene bölgenin (region of interest, ROI) de giriş olarak verildiği bir yapı olarak, daha özel bir CNN-özellikli bölgeler olarak ifade edilebilir.

Bölge önerilerini CNN özellikleriyle birleştiren R-CNN, iki aşamalı bir tespit algoritmasıdır. İlk olarak, bir görüntüdeki nesnelere içerebilecek bölgeler tanımlanır. Ardından, her bir bölgedeki nesne sınıflandırılır. Bu nedenle, bir R-CNN algoritması kullanılarak nesne tespiti üç işlemle gerçekleştirilir; i) bölgeleri bulma, ii) özellik çıkarma ve iii) sınıflandırma. İlk aşamada, bölge önerileri olarak adlandırılan, görüntüde bir nesneyi içere olasılığı olan bölgelerin bir alt kümesi bulunur. İkinci aşamada, bu bölge önerilerinden CNN özellikleri çıkarılmaktadır. Son olarak, önerilen bölgeler daha sonra eğitilmiş destek vektör makinesi (support vector machine, SVM) tarafından geliştirilir ve nesnelere, çıkarılan özellikler kullanılarak sınıflandırılır [8]. Bu çalışmada olduğu gibi, öğrencilerin yüzünü tanımda, görüntünün tamamına değil, öğrencilerin yüzünün bulunduğu alanlara odaklanılmaktadır. Sistemin daha etkin ve hızlı çalışmasını

sağlayan R-CNN bu aşamada devreye girmektedir. R-CNN dedektörü, öncelikle kenar kutuları (edge boxes) gibi bir algoritma kullanarak bölge önerileri üretir. Önerilen bölgeler kırpılır, yeniden boyutlandırılır ve sınıflandırılır. R-CNN dedektör algoritması çalışma prensibi Şekil 1’de gösterilmiştir.


3.3. Veri seti

Aynı sınıftaki on iki kız öğrencinin fotoğrafları farklı zamanlarda çekilmiştir. Öğrencilerin tamamı lisede ve 16 ile 18 yaş arasındadır. Öğrencilerin yerleri rastgele değiştirilerek farklı oturma düzenleri oluşturulmuş ve fotoğrafları tüm öğrencilerin yüzleri görünecek şekilde farklı açılardan çekilmiştir. Veri seti 400 farklı fotoğraftan oluşmaktadır. Tüm fotoğraflara öğrencilerin tamamı dahil edilmiş ve fotoğraflar aynı uygun mesafe korunarak çekilmiştir. Örnek bir fotoğraf Şekil 2’de gösterilmiştir. Tüm veri seti, karşılaştırmalı analiz için farklı oranlarda rastgele eğitim ve test seti olarak ayrılmıştır. Üç farklı eğitim/test oranı kullanılmıştır: İlk denemede eğitim için 300, test için 100 fotoğraf, ikinci ve üçüncü denemede sırasıyla 350/50 ve 380/20 fotoğraf kullanılmıştır.

3.4. Deneysel çalışmalar

Bu çalışmada, araştırmacılar tarafından çekilen fotoğraflarla oluşturulan veri seti üzerinde öğrencilerin yüz görüntülerinden kimlik tespiti yapılmıştır. Fotoğraflar 4032*2268 boyutunda Samsung 12 MP kamera kullanılarak çekilmiştir. İlk olarak eğitim aşaması Intel 9. nesil i7 işlemcili, 16 GB DDR IV hafızaya ve NVIDIA GeForce RTX 2070 8 GB ekran kartı hafızasına sahip bir bilgisayar ile test edilmiş ancak hafıza yetersiz gelmiştir. Bu nedenle, grafik kartı belleği ve işlemci hızı gibi sınırlı kaynaklar nedeniyle görüntülerin boyutu zorunlu olarak 420*236’ya indirgenmiştir. Tüm uygulamalar MATLAB© yazılımı ile oluşturulan uygulama üzerinde gerçekleştirilmiştir. 420*236 boyutuna indirgenen veri seti yeniden etiketlendi. On iki öğrencinin her biri, veri setindeki her bir fotoğraf için ayrı ayrı etiketlenmiştir. Etiketli görüntü için bir örnek Şekil 3’te görülmektedir.

Etiketler Export Labels ile gTruth nesnelere dönüştürülmüştür. Böylece eğitim süreci için kullanılacak etiketli görseller oluşturulmuştur. Dedektör nesnesi, eğitim süreci için R-CNN Object Detector kullanılarak oluşturulmuştur. Eğitim aşamasında etiketlenen bölgelerin koordinatları elde edildikten sonra önerilen R-CNN modeli ile bu koordinatlar eğitilmiştir. RcnObjectDetector nesne tespit işlevi, nesne tespitini gerçekleştirmiştir. Sınıflandırma classifyRegions ile yapılmıştır. Yüz tanıma konusunda başarılı sonuçlar veren AlexNet sinir ağı kullanılmıştır. imageInputLayer parametresinde resimlerin boyutuna göre 420*236 değiştirilmiştir. On iki öğrenci olduğundan fullyconnectedLayer parametresi 12 farklı etiketi temsil etmektedir. Eğitim aşaması, her bir eğitim süreci için 5,7 saat sürmüştür. Ardından eğitimi tamamlanan dedektör nesnesinin başarı oranını test etmek için test işlemi gerçekleştirilmiştir. Tüm işlemler 350 eğitim ve 50 test, 380 eğitim ve 20 test veri seti ile tekrarlanmıştır. Ayrıca literatürdeki çalışmalarda eğitim işlemi binlerce fotoğraf ile yapıldığından, ImageAugmenter işlemi ile veri seti artırılarak her üç eğitim/test oran seti için deneysel çalışmalar tekrarlanmıştır.



Şekil 1. Bölge tabanlı evrişimli sinir ağı dedektör algoritmasının çalışma prensibi.



Şekil 2. Veri setinden örnek bir fotoğraf.



Şekil 3. Etiketleme örneği.

4. Bulgular

Önceden eğitilmiş ağ üzerinde eğitim tamamlandıktan sonra oluşturulan model kullanılarak test setindeki görüntüler üzerinde deneysel çalışmalar yapılmıştır. Öğrencilerin test setindeki görsellerdeki tanıma sonuçları, her üç test seti için Şekil 4'te örnek olarak gösterilmiştir. Önerilen yaklaşım, eğitime ayrılan oran arttıkça yüz bölgelerini kullanarak öğrencilerin belirlenmesinde daha başarılı olmuştur. Ayrıca ImageAugmenter işlemi ile veri setinin artırılması sonuçlarda küçük bir miktar artış sağlamıştır. Önerilen yaklaşım, eğitim setinin 300 görüntü ve test setinin 100 görüntüden oluştuğu 300/100 seti için doğrudan (ImageAugmenter olmadan) test edildiğinde, %73,25'lik bir başarı oranı elde edilirken, 350/50 eğitim/test oranı kullanıldığında başarı oranı %79,67'ye yükselmiştir. Eğitim/test oranı 380/20 olarak alındığında ise başarı oranı %81,67'ye yükselmiştir. Diğer taraftan, artırma uygulaması ise her üç test setinde de benzer etki sağlayarak hepsinde benzer miktarda artış sağlamıştır. Eğitime ayrılan veri seti büyüdükçe başarı oranı artmış ve 300/100, 350/50 ve 380/20 setleri için sırasıyla %73,92, %78,33 ve %82,08 başarı oranlarına ulaşılmıştır.



Şekil 4. a) 300/100, b) 350/50 ve c) 380/20 test veri setinde başarılı tanınan öğrencilerin görüntü ve etiketleri.

5. Sonuçlar ve Öneriler

Bu çalışmada, öğrencilerin yüz görüntülerinden yola çıkarak kimlik tespiti için R-CNN derin öğrenme modeline dayalı bir yaklaşım önerilmiştir. Test veri seti üzerinde yapılan deneysel

çalışmalar sonucunda %82,08 doğrulukla sınıflandırma başarısı sonucuna ulaşılmıştır. ImageAugmenter uygulanmadığı durumlarda tahmin oranı %73,25 ile %81,67 arasında olsa bile modelin doğru sınıflandırma yaptığı görülmüştür. Dolayısıyla önerilen yaklaşımın farklı amaçlarla öğrencilerin yüzlerini tanımda ikincil bir araç olarak kullanılabilceği öngörülmektedir. Sonuç olarak öğrencilerin biyometrik özelliklerini belirlemek ve sınıfta daha kısa sürede yoklama alarak derse devam etmek için uygun derin öğrenme modellerinin kullanılabilceği gösterilmiştir.

Derin öğrenme kütüphaneleri kullanılarak oluşturulan model ile yüzlerin kolayca tanınmasının yanı sıra yeterli sayıda görsele sahip bir veri seti olması durumunda öğrencilerin duygularının da tanınması sağlanabilir. Bu, bireylerin stres ortamının daha kısa sürede belirlenmesini sağlayacaktır. Bu amaçla, yüz görüntülerinden sınıfların ortam koşullarını belirlemek için bir veri tabanı oluşturulabilir ve derin öğrenme ağlarına uygulanabilir. Böylece öğrenme ortamının iyileştirilmesi ve öğrencilerin hazır bulunuşluklarının değerlendirilmesi mümkün olabilir. Bu şekilde eğitimin etkisinin artması sağlanabilir. Ayrıca bireylerin farklı biyometrik özelliklerini tanımak için derin öğrenme modelleri kullanılabilir.

Referanslar

- [1] U. Jayaraman, P. Gupta, S. Gupta, G. Arora, and K. Tiwari, “Recent development in face recognition”, *Neurocomputing*, vol. 408, pp. 231-245, 2020.
- [2] M. Z. Khan, S. Harous, S. U. Hassan, M. U. Ghani Khan, R. Iqbal and S. Mumtaz, "Deep Unified Model For Face Recognition Based on Convolution Neural Network and Edge Computing," in *IEEE Access*, vol. 7, pp. 72622-72633, 2019.
- [3] J.X. Mi, D. Huang, B. Wang, X. Zhu, “The nearest-farthest subspace classification for face recognition”, *Neurocomputing*, vol. 113, pp. 241-250, 2013.
- [4] B. Li, C.H. Zheng, D.S. Huang, “Locally linear discriminant embedding: An efficient method for face recognition”, *Pattern Recognit*, vol.41, pp.3813-3821, 2008.
- [5] Y. Lu, S. Yi, N. Zeng, Y. Liu and Y. Zhang, “Identification of rice diseases using deep convolutional neural networks”, *Neurocomputing*, vol. 267, pp. 378-384, 2017.
- [6] E. Cengil and A. Çınar, “A new approach for image classification: convolutional neural network”, *Eur J Tech*, vol.6, pp. 96-103, 2016.
- [7] P.J. Thilaga, B.A. Khan, A.A. Jones and N.K. Kumar, “Modern face recognition with deep learning”, In *Proc. Second International Conference on Inventive Communication and Computational Technologies*, 2018, pp. 1947-1951.
- [8] R. Girshick, J. Donahue, T. Darrell and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation”, In *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 580-587.
- [9] A. Arı and D. Hanbay, “Tumor detection in MR images of regional convolutional neural networks”, *J Fac Eng Archit Gazi Univ*, vol. 34, pp.1395-1408, 2019.
- [10] Ö. İnik and E. Ülker, “Deep learning and deep learning models used in image analysis”, *Gaziosmanpasa J Sci Res*, vol. 6, pp. 85-104, 2017.

S-60 SIAMESE NETWORKS FOR PREDICTING REMAINING USEFUL LIFE OF MACHINERY

Ugur CEYLAN¹, Yakup GENÇ²

¹ Computer Engineering Department, Gebze Technical University, Turkey,
uceylan@gtu.edu.tr

² Computer Engineering Department, Gebze Technical University, Turkey,
yakup.genc@gtu.edu.tr

Abstract

Predictive maintenance tries to reduce cost in engine maintenance in power plants, aircrafts and factories by predicting when maintenance is needed (or by estimating the remaining useful life). Recently, with significant advances in deep learning and the availability of high volumes of data extracted from manufacturing processes, data-driven methods for predicting remaining useful life (RUL) have received a lot of attention. A major problem with data-based prognosis is that it is costly and requires large amounts of training data that are difficult to obtain in large numbers of failure cases (often impossible and expensive to obtain in the real world). This paper proposes a learning-based method for fault diagnosis requiring less data. To this end, we use a Siamese network architecture based on a specific deep Convolutional Neural Network (CNN) called InceptionTime. The siamese part of the network allows repeated use of the existing data to establish a similarity metric for two separate time windows. The C-MAPSS dataset supplied by NASA is employed to verify the proposed model to estimate RUL. Experiments demonstrate that our model can be used in fault diagnosis and provide satisfying prediction results with fewer data with comparable performances with state of art methods for RUL prediction.

Keywords: *Prognostics and Health Management, Remaining Useful Life, C-MAPSS, Siamese Networks, Deep Learning*

1. Introduction

Prognostics and health management (PHM) of mechanical material has attracted great attention and predicting remaining useful life (RUL) which is the total amount of cycles/time a given machinery/component can still work before failure is the heart of the PHM [1, 2]. By estimating the RUL of the machinery, it is likely allows to provide the mechanical action and offer a maintenance plan in a targeted way [3]. There are two main methods to estimate mechanical equipment RUL: data-driven approaches and model-based approaches. Basically, in the former approach, machinery has been executed until detected fault and it is needed enough failure samples while the latter system requires knowledge of physics breakdown progression [4]. In recent years, the remaining useful life (RUL) studies for data-driven approaches has drawn much attention because of escape of dependence on the theoretical understanding of complex systems, and besides, the main challenge in data-driven approaches is that it is usually difficult

to obtain high volume number of samples for failure progression which is expensive and labor demanding [4].

Recently, it has been shown that machine learning approaches, especially deep learning methods, perform powerful outcomes in areas such as computer vision, image processing, natural language processing [5]. Deep learning methods have been employed for fault diagnosis and applied to the RUL estimation problem, in particular using ensemble networks (different types of networks combination). Using a combination of a Convolutional Neural Network (CNN) and a Long Short-Term Memory (LSTM) neural network proposes an encouraging method to estimate RUL with a convenient and precise method that can be extended and adapted to obtain more accurately.

For instance, J. Li et al. [6] proposed a directed acyclic graph (DAG) network combining long short-term memory (LSTM) and a convolutional neural network (CNN) to estimate RUL. Unlike existing combined with CNN and LSTM predictive model, the proposed method organically combines CNN and LSTM rather than using just CNN for extracting features in this paper.

However, one of the biggest limitations is that they require a large number of labeled failure cases data. In many applications, it is sometimes not possible to collect a lot of data. We also need to retrain the model whenever we want to classify class or estimate the RUL of a new failure case data. Therefore, the proposed method aims to solve those problems by using a siamese network.

In this study, it has been used the turbofan engine degradation datasets were simulated by Commercial Modular Aero-Propulsion System Simulation (C-MAPSS) tool developed by NASA [7]. Each sub-dataset includes training data, test data, and actual RUL that corresponding to the last cycle of the test data. The training data comprises a certain number of engines data from a specific healthy state to failure, while the test data includes a certain number of engine data that is a bit before operating failure. Furthermore, the training and test data engines data with different initial healthy states, respectively. Engines because of different initial healthy states, the operating cycles of distinct engines are different in the same database. For example, in sub-dataset FD001 of the database, the test dataset includes 100 engines, with a minimum operating cycle of 31 and a maximum operating cycle of 303.

This paper proposed the Siamese network that based on a deep Convolutional Neural Network (CNN), called Inception-Time to increase the precision of RUL prediction performance by way of data preparation adapted to a classification task manner by specifying a threshold limit to RUL value to distinguish healthy and failure states and trained the Siamese network for learning of a similarity metric of pairs healthy and failure states time windows data and to estimate the RUL of the pairs of time window data as well.

The rest of the paper is organized as In Section 2, preprocessing of data which is input to the Siamese network explained. Also in this section details about the Siamese network are given. Experiment results are explained in Section 3 and lastly, Section 4 concludes this paper.

2. Methodology

InceptionTime is an ensemble of five deep learning models for time series classification, each one created by cascading multiple Inception modules [8], and each classifier (model) have the same architecture but with different randomly initialized weight values [9]. The core idea of an Inception module is to utilize multiple filters simultaneously to an input time series. The module involves filters of different lengths enabling the network to automatically extract related features from both long and short time series.

The network consists of a sequence of Inception modules followed by a Global Average Pooling layer and a Dense layer with a softmax activation function. We make some changes after the Global Average Pooling layer in the framework of the proposed method to adapt our case. Furthermore, InceptionTime introduces a further element within its network's layers: residual connections at every third inception module. Thus decreasing the vanishing gradient problem by allowing a direct flow of the gradient.

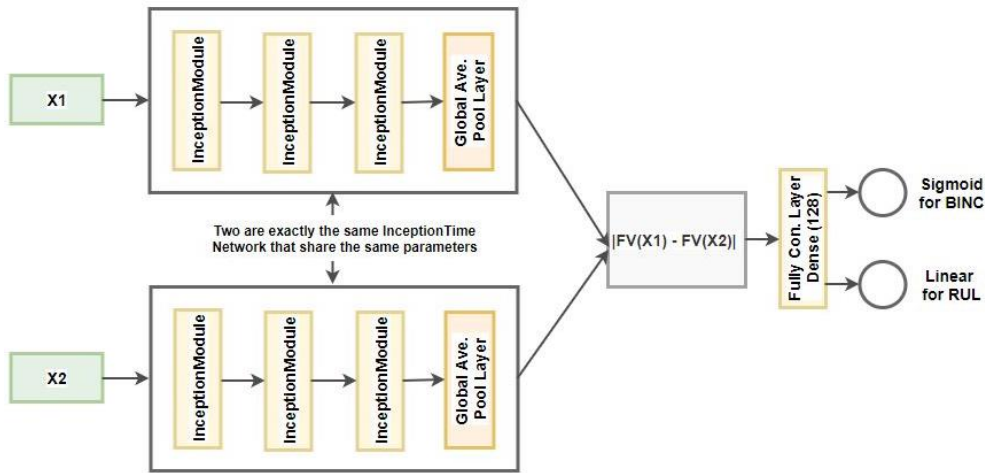


Fig 2. The architecture of proposed Siamese InceptionTime Network.

So, we use a Siamese architecture based on CNN called InceptionTime network (framework was illustrated in Fig. 2). The FD001 sub-dataset data has simply been processed and through into the Siamese to train network. The specific steps are explained as follows:

2.1. Data Preparation

We first prepare pairs of healthy and failure samples as input for the Siamese network. The sub-dataset has N attributes and the lifetime of the sensors are L_t cycles, i.e., machinery lifetime (see Fig. 3). The data is obtained by sliding the time window with the length of w_1 (length of time window) cycles, and the sliding step size is one cycle. The size of the array extracted each time by time window is $w_1 \times N$, and the number of arrays is $L_t - w_1$. So the corresponding RUL $[L_t - w_1, L_t - w_1 - 1, \dots, 0]$. The w_1 is selected as 30 for the FD001 sub-dataset. In our experiment we select 14 sensor outputs with regular trend [6] are chosen as input to the Siamese network, and these 14 sensors range output value varies according to each one, so we scaled data between $[0, 1]$. As a result, our input samples are 14×30 size time-series data.




Fig 3. *Extracting health/failure samples*

Then, a breakpoint RUL value which is 30 specified (which is illustrated with a solid red vertical line in Fig. 3) to discriminate between healthy and failure states for the FD001 sub-dataset, and according to this breakpoint value, healthy and failure samples were prepared. If the RUL value of input data is less than the breakpoint value, it was determined as a failure sample and other cases as an example of healthy samples.

So, the input of the Siamese InceptionTime network is pairs of the combination of healthy and failure samples. For binary classification (BINC output, see Fig. 2), data labeled as if a pair input data in the same status (in this study only pairing healthy sample vs healthy sample applied) then the label is 1 other case which is failure vs healthy samples then the label is 0. On the other hand, for output RUL (see Fig. 2), for each pair of input data labeled as minimum RUL value of input pair samples.

2.2. An InceptionTime Siamese Network

We proposed a Siamese network that used InceptionTime Network for RUL estimation. The network includes two identical paths that share the same weights and each composed of three Inception modules followed by a Global Average Pooling layer. So, two input samples (X_1 and X_2) are passed through the Siamese InceptionTime Network to generate a fixed-length feature vector for each ($FV(X_1)$ and $FV(X_2)$), then, we computed the absolute distance between these feature vectors and passed to a fully connected layer which is rectified linear unit (ReLU) activation function used here and lastly feed network through a sigmoid activation to determine if similar or not the two input samples and through a linear activation to estimate RUL pairs.

Depth of inception network set to 3 and each module filter number is 32 while each module applied three convolutions with [3, 5, 7] filters lengths. For training our network, we used Adam optimizer with 0.00006 learning rate, batch size set to 128.

To evaluate the performance of the proposed Siamese InceptionTime Network, root mean square error (RMSE) and Score metrics were used. RMSE is a usually utilized method for RUL prediction that gives the same penalties while the score has different penalties for early and late predictions [6]. Results of the proposed Siamese InceptionTime network are discussed in the following section.

3. Experiments and Results

We conducted experiments in the first dataset (FD001) of C-MAPSS to show the performance of the proposed method. We only used the data from 15 engines for training. We also trained the networks with the balanced version of the dataset by weighting randomly selecting samples from each engine according to the total dataset size. For the siamese network, the total pairs of data for training is 30000.

The proposed Siamese InceptionTime network was employed to estimate the RUL of the C-MAPSS engine dataset. For testing, each sample is to be predicted compared with the first healthy sample of a specific engine, and pairs are given to the Siamese InceptionTime network for prediction. For the FD001 database, the root mean square error (RMSE) is 16.94 and the score is 528.64 (compare these with the best results in the literature [6] with 11.96 and 229.00 respectively). The predicted RUL of each test engine in the FD001 sub-dataset is shown in Fig. 4. With the proposed method generally, the estimated value of the RUL can be observed close to the true value.

Fig. 5 demonstrates the predicted RUL and binary similarities generated by our algorithm on the two of the engines for the FD001 test sub-datasets. The green line shows the binary similarity (first healthy sample is compared sequentially with other samples of the engine). The RUL prediction results shown in blue successfully estimates the failure point indicated in dotted red.

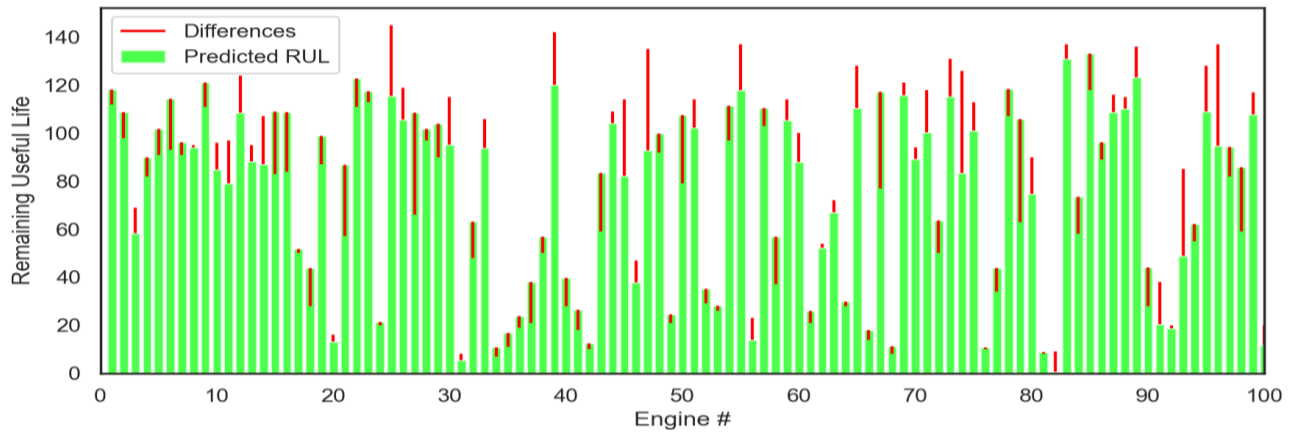


Fig 4. Predicted RUL for each engine in the FD001 test sub-dataset by the Siamese InceptionTime network.




Fig 5. Results on engine #41 and #42 in FD001 test sub-dataset where green shows binary similarity while blue shows the estimated RUL (best seen in color).

4. Conclusions

We propose a siamese network with temporal data processing capabilities for fault diagnosis classification. Since typical deep learning models do not train fine with small sets of training samples, this paper addresses the problem by allowing multiple uses of the data for learning a window-based similarity metric. InceptionTime network allows the temporal processing of the windows. The experiments for remaining useful life estimation show that our system performs well when trained with small sets of samples. While the existing results are promising, further architecture and hyperparameters optimization is still needed as the reported performance is slightly lower than the best state-of-art methods.

References

- [1] D. Wang, K. Tsui, and Q. Miao, “Prognostics and Health Management: A Review of Vibration Based Bearing and Gear Health Indicators”. In: IEEE Access ’Jun. 2018, pp. 665–676.
- [2] R. Zhao, “Deep learning and its applications to machine health monitoring”. In: Mechanical Systems and Signal Processing 115, 2019, pp. 213–237.
- [3] X. Si, “Remaining useful life estimation - A review on the statistical data driven approaches”. In: Eur. J. Oper. Res. 213, 2011, pp. 1–14.
- [4] Ö. Eker, F. Camci, and I. Jennions, “Major challenges in prognostics: study on benchmarking prognostic datasets”, 2012.
- [5] Y. Bengio, Y. LeCun, and G. E. Hinton, “Deep learning for AI”, In: Communications of the ACM 64 2021, pp. 58–65.
- [6] J. Li, X. Li, and D. He, “A Directed Acyclic Graph Network Combined With CNN and LSTM for Remaining Useful Life Prediction”, In: IEEE Access Jun 2019, pp. 75464–75475.
- [7] A. Saxena, “Damage propagation modeling for aircraft engine run-to-failure simulation”, In: 2008 International Conference on Prognostics and Health Management, 2008, pp. 1–9.

- [8] I. Fawaz, H. Lucas, B. Forestier, “InceptionTime: Finding AlexNet for time series classification”. *Data Min Knowl Disc* 34, 1936–1962, 2020.
- [9] C. Szegedy et al. “Going deeper with convolutions”, In: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 1–9.

S-61 KALİTE KONTROL KARTLARINDA YAPAY SİNİR AĞLARI İLE ÖRÜNTÜ TANIMA

Caner KONUK¹, Senem VAHAPLAR²

¹ İstatistik Bölümü, Dokuz Eylül Üniversitesi, Türkiye, canerkonuk@gmail.com

² İstatistik Bölümü, Dokuz Eylül Üniversitesi, Türkiye, senem.sahan@deu.edu.tr

Özet

Kalite, bir sürecin veya hizmetin ihtiyaçları karşılayabilmesinin bir ölçütüdür. Geleneksel istatistiksel kalite kontrol (İKK) yöntemlerinden en gelişmiş olan istatistiksel kalite kontrol kartları ise kalitenin belirli örüntülere göre incelenmesini sağlamaktadır. Kontrol kartlarındaki anormal örüntülerin belirlenmesi, sürecin veya hizmetin kontrol altında veya kontrol dışında olduğunu belirleyebilmek için önemli bilgiler sunmaktadır. Öte yandan bilgisayar ve veri bilimi alanlarındaki gelişmelerle beraber yapay sinir ağları (YSA) ile son yıllarda önemli ölçüde ilerlemeler gerçekleşmiştir. Özellikle örüntü tanımada YSA'nın başarısı birçok çalışma ile kanıtlanmıştır. Bu çalışmada, kontrol kartlarındaki örüntülerin tespiti için YSA modellerinden ikisi olan çok katmanlı algılayıcı (ÇKA) ve öğrenmeli vektör kuantalama (ÖVK) modelleri kullanılmıştır. Elde edilen sayısal sonuçlardan yola çıkarak kalite kontrol kartları için ÇKA ve ÖVK ile en iyi örüntü tanımayı sağlayan YSA modelinin belirlenmesi amaçlanmıştır.

Anahtar Sözcükler: *Çok Katmanlı Algılayıcı; Kontrol Kartında Örüntü Tanıma; Öğrenmeli Vektör Kuantalama; Yapay Sinir Ağları.*

Abstract

Quality is a measure of whether a process or service can fulfill needs. Statistical quality control charts, which are the most advanced of the traditional statistical quality control (SQC) methods, enable the quality to be examined according to certain patterns. Identifying abnormal patterns on control charts provides important information to determine whether the process or service is in-control or out-of-control. On the other hand, with the developments in the areas of computer and data, significant progress had been achieved in recent years with artificial neural networks (ANN). The success of ANNs, especially in pattern recognition, has been proven by many studies. In this study, two of the ANN models, multilayer perceptron (MLP) and learning vector quantization (LVQ) models, were used to detect the patterns in the control charts. Based on the numerical results obtained, it is aimed to determine the ANN model that provides the best pattern recognition with MLP and LVQ for quality control charts.


Keywords: *Artificial Neural Networks; Control Chart Pattern Recognition; Learning Vector Quantization; Multilayer Perceptrons.*

1. Giriş

1920'lerde, W.A. Shewhart ilk olarak, adını genellikle Shewhart kontrol kartı olarak taşıyan kontrol kartlarının kullanımını önermiştir. İKK kartlarının amacı, kritik kalite değişkenlerinin

davranışının görsel bir göstergesini sağlayarak sürecin stabilitesini etkileyen özel nedenlerin varlığını gösteren kontrol dışı sinyalleri tespit etmektir [1]. Bundan dolayı iyi bir süreç veya hizmet kalitesi açısından kontrol kartlarındaki örüntülerin mutlaka incelenmesi gerekmektedir. Bir kontrol kartında bir veya daha fazla gözlem, kontrol limitlerinin ötesine geçtiğinde ya da çizilen noktalar rastgele olmayan bir örüntü sergilediğinde, kontrol kartı süreç için kontrol dışı bir durumu belirtebilir [2]. Shewhart kontrol kartına alternatif olarak CUSUM, EWMA gibi birçok kontrol kartı çeşidi var olup bu çalışma Shewhart’ın \bar{X} kontrol kartındaki örüntüleri tanımaya yoğunlaşmaktadır. \bar{X} kontrol kartı çoğunlukla bir merkez çizgisi ile alt ve üst sınır limitleri içeren bir kontrol kartı çeşididir. Bir \bar{X} kontrol kartında sürecin ortalaması izlenmekle birlikte Şekil 1’de verilen temel yedi ana örüntü görüntülenebilir.

Bu örüntüler, kontrol edilen sürecin ortalamasının uzun vadeli durumunu belirtebilir. Özellikle, ilgilenilen süreç için kontrol dışı durumların gelecekte ortaya çıkma ihtimalinin olup olmadığını gösterebilirler. Bu nedenle, önleyici kontrol eylemleri ile ilgili önceden bilgi elde etmek adına kontrol kartı modellerini izlemek süreç için faydalıdır [3]. Süreçteki doğal olmayan bir örüntünün varlığını belirlemek genellikle kalite kontrol personelinin beceri ve deneyimine bağlıdır. Etkili bir otomatik kontrol kartı örüntü tanıma (KKÖT) sistemi, bu boşluğu telafi edebilir ve daha az sayıda yanlış alarm ile kontrol kartlarının daha iyi uygulanmasını sağlayabilir. KKÖT sistemi ayrıca Şekil 1’de verilen örüntülerin tutarlı ve tarafsız olarak yorumlanmasını da sağlayabilir [4].




Şekil 1. Temel Kontrol Kartı Örüntüleri.

İlk KKÖT yaklaşımı J.A. Swift (1987) tarafından uygulanmıştır. Bu yaklaşım ortalamadaki kayma ve varyans kaymasını hesaplamak için istatistiksel testler ve buluşsal yöntemlere dayanıyordu. Pugh (1989), kontrol kartlarındaki ortalama kaymalarını tespit etmek için YSA’yı kullanan ilk araştırmacılardan biridir. 1990’ların başından itibaren literatürde çok sayıda KKÖT çalışması geliştirilmiştir. Bu çalışmalar kural tabanlı sistemler ve YSA olmak üzere iki ana bölüme ayrılmaktadır [1].

Bu çalışma örnek bir YSA ile KKÖT sisteminin MATLAB R2018b ortamında kodlanmasıyla oluşturulmuştur. Çoğu çalışmadan farklı olarak bu çalışmada Şekil 1.’de verilmiş olan temel yedi örüntüden türetilmiş olan dokuz diğer örüntüde kullanılmıştır. Toplam on altı örüntü ile

oluşturulmuş olan ÇKA ve ÖVK YSA modelleri ile bu on altı örüntüyü tanıyabilen bir KKÖT sistemi oluşturulması amaçlanmıştır.



Şekil 2. Türetilmiş Kontrol Kartı Örüntüleri.

2. Yöntem

2.1. Verilerin elde edilmesi

İdeal olarak, bir KKÖT sisteminin geliştirilebilmesi ve doğrulanması için örnek örüntüler gerçek bir süreçten toplanmalıdır. Fakat oluşturulacak olan KKÖT sistemi çok sayıda örüntü gerektirdiğinden ve bu örüntüler ekonomik olarak süreçte mevcut olmadığından, genellikle simülasyon ile elde edilmiş veriler kullanılmaktadır. Bu diğer araştırmacılar tarafından da benimsenen yaygın bir yaklaşımdır [4]. Bu çalışmada da eğitim ve test için gereken veri setleri Denklem 1 ve Tablo 1.'de verilen örüntü formülleri kullanılarak simülasyon yoluyla elde edilmiştir. Ortalama ve standart sapma değerleri ilgilenilen sürece göre değişiklik göstermektedir. Bu çalışma için veriler, ortalaması 80 ve standart sapması 5 olan örnek bir sürece göre oluşturulmuştur.

$$y_t = \mu + r_t\sigma + d(t) \quad (1)$$

Tablo 1. Temel yedi kontrol kartı örüntüsü için simülasyon formülleri [5]

Örüntü Tipi	Örüntü Parametreleri	Parametre Değerleri	Örüntü Formülü (d(t))
NOR	Ortalama (μ) Standart Sapma (σ)	80 5	-
TEÇ	Periyodik Değişim Değeri (α) Periyod (T)	$1.5\sigma \leq \alpha \leq 2.5\sigma$ 8	$\alpha * \sin(2\pi t/T)$
SİS	Sistemik Hareket Değeri (u)	$1\sigma \leq u \leq 3\sigma$	$u(-1)^t$
ART	Trend Eğimi (g)	$0.05\sigma \leq g \leq 0.1\sigma$	$t * g$
AZT	Trend Eğimi (g)	$-0.1\sigma \leq g \leq -0.05\sigma$	$-t * g$
YAK	Kayma Pozisyonu (k) Kayma Miktarı (s)	$k = 1, k = 0$ $1.5\sigma \leq s \leq 2.5\sigma$	$k * s$
AAK	Kayma Pozisyonu (k) Kayma Miktarı (s)	$k = 1, k = 0$ $-2.5\sigma \leq \alpha \leq -1.5\sigma$	$-k * s$

Denklem 1 ve Tablo 1.’deki formüllerde $t (=1, \dots, n)$ bir örüntü için oluşturulan gözlem verisi sayısını, r_t standart normal dağılımla oluşturulan rassal sayıyı ve y_t t’inci gözlem verisinin değerini belirtmektedir. k değeri ise kayma pozisyonundan önce ise sıfır değeri ve kayma pozisyonundan sonra ise bir değerini almaktadır. Diğer parametreler ise verildikleri aralıklarda rastgele değerler almaktadır. Türetilmiş olan örüntülerin simülasyonu için ise Denklem (2) kullanılmıştır [5].

$$y_t = \mu + r_t\sigma + d_1(t) + d_2(t) \quad (2)$$

Denklem (2)’de $d_1(t)$ ve $d_2(t)$ birleştirilmek istenilen iki örüntünün formülleridir. Şekil 2’de verilmiş olan örüntüler Denklem (2) ile elde edilmiştir. Eğitim veri seti on altı örüntünün her

biri için 1500 örnek olmak üzere 24000 örnek ve 60 gözlem verisi (24000 x 60) olacak şekilde oluşturulmuştur. Test veri seti ise her örüntü için 150 örnek olmak üzere 2400 örnek ve 60 gözlem verisi (2400 x 60) olacak şekilde oluşturulmuştur.

2.2. Çok Katmanlı Algılayıcı (ÇKA) Yapısı

Bir ÇKA giriş ve çıkış katmanları arasında bir veya birden fazla katman içeren ileri beslemeli bir YSA'dır. Veri akışı giriş katmanından çıkış katmanına olacak şekilde katmanlar üzerindeki nöronlar ile yalnızca bir yönde gerçekleşir, bu nedenle ÇKA ileri beslemeli bir ağ çeşididir. Bu ağ türü genellikle geri yayılım algoritması ile eğitilir. Bir ÇKA'da eğitim süreci nöronlar arasındaki ağırlıkların belirlenmesi ile gerçekleşir [6-7]. Ayrıca gizli katman sayısını ve gizli katmandaki nöron sayılarını belirlemek için önceden belirlenmiş herhangi bir kural yoktur.

Bu ağ modeli ile oluşturulmuş olan çalışmada giriş katmanında veri seti 60 gözlemden oluştuğu için 60 nöron ve çıkış katmanı için ise her biri bir örüntüyü temsil eden örüntülerin toplam sayısına, yani 16 örüntünün tanınması amaçlandığı için 16 nöron bulunmaktadır. Çalışmada gizli katmandaki nöron sayısının belirlenmesi için gizli katmandaki nöron sayısı 30 nörondan 40 nörona kadar değiştirilerek denenmiştir.

Çalışmada öncelikle veriler, [-1,1] aralığında normalize edilmiştir. Ardından eğitim verilerinin tümünün ÇKA'ya girişi yapılmıştır. MATLAB® ortamında gizli katman ve çıkış katmanının her ikisi için de aktivasyon fonksiyonu olarak hiperbolik tanjant (tansig) fonksiyonu kullanılmıştır. Ağın eğitim parametreleri olan momentum katsayısı 0.5, öğrenme katsayısı 0.1, hata hedefi 0.01 ve epoch sayısı 2500 olarak belirlenmiştir. Ayrıca eğitim algoritması olarak oldukça iyi performans ve daha tutarlı sonuçlar sağladığından, 'traingdx' algoritması bu çalışma için benimsenmiştir. Özellikle 'traingdx' algoritması bu çalışmada ÇKA modelinin eğitim süresini, 'trainlm' algoritmasına göre önemli ölçüde kısaltmıştır.

2.3. Öğrenmeli Vektör Kuantalama (ÖVK) Yapısı

ÖVK'nın yapısı da aynı ÇKA'da olduğu gibi giriş ve çıkış katmanları içeren bir ileri beslemeli YSA'dır. ÖVK'da, ÇKA'dan farklı olarak ara katman rekabetçi katman olarak adlandırılmaktadır. Rekabetçi katman sınıflandırmanın otomatik olarak öğrenilmesini sağlayan katmandır. Bu sınıflandırma gerçekleştirilirken giriş katmanından gelen girdi vektörleri için öklid uzaklığı belirlenerek rekabetçi katmanında bulunan en yakın referans vektörlerine atanması yapılmaktadır [8-9].

ÖVK için öğrenme katsayısı ilk olarak 0.1 olarak değiştirilmiş fakat iyi sonuçlar elde edilemediği için tekrar varsayılan değer olan 0.01 olarak belirlenmiştir. Ayrıca ÖVK'da eğitim süresi ÇKA'ya göre daha uzun sürmesinden dolayı epoch sayısı olarak 50, 100 ve 150 değerleri denenmiştir. En uygun sonuçlar 100 epoch ile elde edildiğinden dolayı ÖVK için epoch sayısı 100 olarak belirlenmiştir. Epoch sayısı dışındaki parametreler, aktivasyon fonksiyonları (rekabetçi katman için softmax ve çıkış katmanı için purelin) ve eğitim algoritması (learnlv1) ÖVK için MATLAB® ortamındaki varsayılanlar olarak belirlenmiştir.

3. Sonuçlar

YSA'nın dezavantajlarından biri ağ parametrelerinin ve ara katmandaki nöron sayılarının deneme yanılma yoluyla belirlenmesidir. Bundan dolayı her iki ağ modeli için ara katmandaki nöron sayıları 29 nöron olarak belirlenerek, 35 nörona kadar test ve eğitim veri setleri bu aşamada ağa gösterilerek sınıflandırma yüzdeleri belirlenmiştir. Elde edilen sonuçlar Tablo 2.'de belirtilmiştir.

Tablo 2. ÇKA ve ÖVK ile elde edilen sınıflandırma yüzdeleri ve ortalamaları

Gizli katmandaki nöron sayısı	Model Adı (ÇKA)	Test sınıflandırma yüzdesi (ÇKA)	Eğitim sınıflandırma yüzdesi (ÇKA)	Model Adı (ÖVK)	Test sınıflandırma yüzdesi (ÖVK)	Eğitim sınıflandırma yüzdesi (ÖVK)
29	ÇKA – 1	%90.7	%91.1	ÖVK – 1	%90.6	%91.0
30	ÇKA – 2	%91.4	%91.8	ÖVK – 2	%85.1	%85.5
31	ÇKA – 3	%97.2	%97.2	ÖVK – 3	%90.5	%90.8
32	ÇKA – 4	%96.6	%97.0	ÖVK – 4	%85.8	%86.0
33	ÇKA – 5	%96.7	%97.4	ÖVK – 5	%85.2	%85.3
34	ÇKA – 6	%96.7	%97.3	ÖVK – 6	%90.4	%90.8
35	ÇKA – 7	%96.5	%97.0	ÖVK – 7	%85.0	%85.2
	ORTALAMA	%95.1	%95.5	ORTALAMA	%87.5	%87.8

Tablo 2. incelendiğinde ÇKA için ÇKA – 3 modeli ve ÖVK için ÖVK – 1 modeli test ve eğitim veri setlerinin her ikisi için de kendi modelleri içerisinde en iyi sınıflandırma yüzdelerine sahiptir. Bu çalışmada 16 örüntüyü en iyi tanıyan model %97.2 sınıflandırma yüzdesi ile ÇKA – 3 modelidir. Ayrıca ÇKA ve ÖVK için ortalama sınıflandırma yüzdeleri incelendiğinde ÇKA modellerinin genel olarak bu çalışma için ÖVK modellerine göre daha başarılı olduğu görülmektedir. Ayrıca ÖVK modeli de KKÖT sistemleri için gayet uygundur. Elde edilen sonuçlar ağ parametrelerine ve gizli katmandaki nöron sayısına göre değişiklik gösterebilmektedir.

Referanslar

- [1] W. Hachicha and A. Ghorbel, "A survey of control-chart pattern-recognition literature (1991–2010) based on a new conceptual classification scheme", *Computers & Industrial Engineering*, vol. 63, no. 1, pp. 204-222, 2012. Available: 10.1016/j.cie.2012.03.002.
- [2] D. Montgomery, *Introduction to statistical quality control*, 7th ed. New York, N.Y.: Wiley, 2013.
- [3] D. Pham and E. Oztemel, "Control Chart Pattern Recognition Using Combinations of Multi-Layer Perceptrons and Learning-Vector-Quantization Neural Networks", *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, vol. 207, no. 2, pp. 113-118, 1993. Available: 10.1243/pime_proc_1993_207_325_02.
- [4] S. Gauri and S. Chakraborty, "Improved recognition of control chart patterns using artificial neural networks", *The International Journal of Advanced Manufacturing Technology*, vol. 36, no. 11-12, pp. 1191-1201, 2007. Available: 10.1007/s00170-006-0925-4 [Accessed 10 August 2021].
- [5] Z. Hong, Y. Li and Z. Zeng, "Convolutional Neural Network for Control Chart Patterns Recognition", *Proceedings of the 3rd International Conference on Computer Science and Application Engineering- CSAE 2019*, 2019. Available: 10.1145/3331453.3360974 [Accessed 10 August 2021].
- [6] L. Abhishek, "Optical Character Recognition using Ensemble of SVM, MLP and Extra Trees Classifier", *2020 International Conference for Emerging Technology (INCET)*, 2020. Available: 10.1109/incet49848.2020.9154050 [Accessed 10 August 2021].
- [7] S. Haykin, *Neural networks and learning machines*, 3rd ed. New York, N.Y.: Pearson Education Inc., 2009.
- [8] E. Subiyantoro, A. Ashari and Suprpto, "Cognitive Classification Based on Revised Bloom's Taxonomy Using Learning Vector Quantization", *2020 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)*, 2020. Available: 10.1109/cenim51130.2020.9297879 [Accessed 10 August 2021].
- [9] Ş. Koltan Yılmaz and M. Yücel, "Concrete strength control charts pattern recognition based on Linear Vector Quantization neural networks", *Eurasian Academy of Sciences Eurasian Econometrics, Statistics & Empirical Economics Journal*, vol. 2, pp 1-15, 2015.

S-49 CLASSIFICATION OF LAND-USE DATASET USING GOOGLNET & KNN

Fatma Günseli YAŞAR ÇIKLAÇANDIR ^{1,*}, Semih UTKU ²

¹ Department of Computer Engineering, İzmir Kâtip Çelebi University, Turkey,
fatmagunseli.yasar@ikc.edu.tr

² Department of Computer Engineering, Dokuz Eylül University, Turkey,
semih@cs.deu.edu.tr

Abstract

Image processing, which is used in many fields, has also entered our lives in remote sensing. Images taken with a set of measuring instruments in remote sensing are easily analyzed by image processing. In this study, a combination method of GoogLeNet and KNN (K Nearest Neighbor) has been tested on the land-use dataset which has 2100 images belong to 21 different classes. The performance of the method has been evaluated in terms of accuracy, sensitivity, specificity, precision, and F-score. When the features drawn from the pool5-drop layer of GoogLeNet were classified using KNN, an accuracy rate of 89.52% was obtained. This study, in which the classification performance of 21 classes was evaluated separately, was compared with the results obtained in similar studies.

Keywords: *Convolutional neural networks; k nearest neighbor; land-use classification; remote sensing*

1. Introduction

Remote sensing is a branch of science that aims to take images of the earth through a set of measuring instruments and obtain information from these images [1]. Systems based on image processing are used in order to facilitate access to information from the images. Various methods are used to categorize different land types in the obtained images. Shafaey et al. divide the studies which try to classify remote sensing images into four different groups: the studies based on manually feature-based methods, unsupervised classification methods, supervised learning methods, and object-based methods [2]. Deep learning, which has popularity increasingly day by day, has also gained popularity in this field. It is one of the supervised learning methods. Studies conducted in recent years, unlike previous studies, are more based on deep learning. While high classification success rates plays a major role in this popularity. New studies are also being put forward to eliminate the disadvantages brought by deep learning. One of these disadvantages is completion time.

Li and Cheng use an improved version of KNN in their study [3]. While traditional KNN achieves 85% accuracy in classifying the dataset they use, they achieve 88% accuracy with its improved version. Djerriri and Karoui combine different methods based on supervised learning with CNN and compare their results [4]. In the study of [5], CNN-SVM becomes the method with the highest success rate. In order to question the effectiveness of the developed methods, it would be more accurate to compare them with other studies working on the same datasets. The studies mentioned below are used the same dataset. Luus et al. classify the dataset with an accuracy of 93.48% using a deep convolutional neural network (DCNN) [6]. Castelluccio et al.

investigate the performances of CaffeNet and GoogLeNet [7]. GoogLeNet (91.83%) is superior to CaffeNet (90.17%) in terms of performance. Weng et al. combine CNN with extreme machine learning (EML) and they perform the classification operation with 95.62% accuracy [8]. Cao et al. compare the performances of AlexNet, GoogLeNet, AlexNet-SVM, GoogLeNet-SVM, VGGNet-SVM in their studies [9]. They also compare the classification results of features drawn from different layers of the used transfer-based CNN methods. Ozyurt uses six different CNN architectures (Alexnet, VGG16, VGG19, GoogLeNet, ResNet, and SqueezeNet) for feature extraction [10]. Then, SVM is used to perform the classification task. In this study, it is emphasized that the developed method is better than the CNN architectures used in terms of speed and effectivity. An accuracy rate of up to 100% is achieved in these combinations. These studies are studies aimed at reducing the completion time. The studies based on deep learning combined with SVM have been carried out to reduce completion time ([4],[9],[10]). However, it has been observed that no other classifier other than SVM has ever been tested in this area.

In this study, GoogLeNet which is one of the well-known methods based on CNN, and KNN which is the most used method based on machine learning have been combined. The performance of the system has been evaluated using the UC Merced Land-use dataset.

2. Materials and Methods

2.1. Dataset

A widely used dataset named UC Merced Land-use has been used in this study [11]. There are 2100 images from 21 different classes. This dataset consists of the images from agricultural (a), airplane (b), baseball diamond (c), beach (d), buildings (e), chaparral (f), dense residential (g), forest (h), freeway (i), golf course (j), harbor (k), intersection (l), medium residential (m), mobile home park (n), overpass (o), parkinglot (p), river (q), runway (r), sparse residential (s), storage tanks (t), and tennis court (u). Each class contains a total of 100 images. These images are 256x256, and they are from RGB space. Figure 1 contains sample images from this dataset.



Figure 1. Dataset Samples (a) agricultural (b) airplane (c) baseball diamond (d) beach (e) buildings

2.2. GoogLeNet for feature extraction

GoogLeNet [12] consists of 22 layers and images with sizes of $224 \times 224 \times 3$ are used as input dataset in this model. The difference of GoogLeNet from other models commonly used in the literature is that it has inception modules [13]. Pre-trained deep learning networks such as GoogLeNet have superior success in extracting features in classification problems. For this reason, features have been extracted using GoogLeNet which is a pre-trained transfer learning algorithm in this study.

2.3 K Nearest Neighbor (KNN) for classification

KNN algorithm is a supervised classification algorithm. K is an input of the algorithm and it determines the number of nearest neighbors to look for in classifying each element in the dataset. Distance measures such as Euclidean and Manhattan are used to measure the distances between elements and their neighbors.

3. The Proposed System

The proposed system in this study consists of two steps (Figure 2):

- Step 1: Feature extraction
- Step 2: Classification

GoogLeNet is used in the first step of the study. The features extracted from the pool5-drop layer of GoogLeNet in step1 are the inputs of step 2. The results obtained from the KNN, which makes classification based on the distances between the elements, are analyzed in Chapter 4.




Figure 2. *Flow Chart of the System*

4. Experimental Results

The performance of the method has been evaluated in terms of accuracy, sensitivity, specificity, precision, and F-score. The accuracy of the system is 89.52%. In Table 1, the values of all parameters except accuracy for each class are given separately. Sensitivity, specificity, precision, and F-Score values obtained in the classification of images belonging to class “a” are 96.67%, 99.81%, 96.67%, and 96.67%, respectively.

It can be deduced which classes are classified more easily from this table (for example f: chaparral, and k: harbor). In other words, it is also seen which classes are more difficult to classify (for example e: buildings). Sensitivity is the ability of the system to accurately find land types belonging to any class. Specificity is the ability of the system to accurately find land types not belonging to any class. Precision returns how many of the cases we predicted as positive were positive. F-Score is the harmonic mean of the ratio of true positive values (recall) and precision (precision). Averages of sensitivity, specificity, precision, and F-Score are 89.87%, 99.42%, 89.52%, and 89.34%, respectively.

Table 1. GoogLeNet & KNN

Class	Sensitivity	Specificity	Precision	F-Score
(a)	96.67%	99.81%	96.67%	96.67%
(b)	93.55%	99.81%	96.67%	95.08%
(c)	93.75%	100%	100%	96.77%
(d)	93.75%	100%	100%	96.77%
(e)	85.00%	97.68%	56.67%	68.00%
(f)	100%	100%	100%	100%
(g)	85.19%	98.72%	76.67%	80.70%
(h)	82.86%	99.81%	96.67%	89.23%
(i)	96.55%	99.63%	93.33%	94.92%
(j)	93.33%	99.63%	93.33%	93.33%
(k)	100%	100%	100%	100%
(l)	82.86%	99.81%	96.67%	89.23%
(m)	71.43%	99.08%	83.33%	76.92%
(n)	75.68%	99.63%	93.33%	83.58%
(o)	92.86%	99.26%	86.67%	89.66%
(p)	96.67%	99.81%	96.67%	96.67%
(q)	96.15%	99.08%	83.33%	89.29%
(r)	84.85%	99.63%	93.33%	88.89%
(s)	89.29%	99.08%	83.33%	86.21%
(t)	100%	99.26%	86.67%	92.86%
(u)	76.92%	98.19%	66.67%	71.43%
Average	89.87%	99.42%	89.52%	89.34%

Table 2 gives the performance comparison between the proposed system and other studies using the same dataset. According to the results, the method which has a maximum accuracy rate (98.14%) is GoogLeNet-SVM used in the study of [9]. It is also tested in [10]. However, it is seen that ResNet-SVM and SqueezeNet give higher results than GoogLeNet-SVM. The method presented in this study has the lowest accuracy rate (89.52%) among the CNN-based studies in the table. However, a higher result is obtained than traditional KNN and improved-KNN presented in the study of [3]. Results of [3] are not included in the table because it uses a different dataset.

Table 2. Comparison with other studies

Study	Method	Accuracy
[6]	DCNN	93.48%
[7]	GoogLeNet	91.83%
	CaffeNet	90.17%
[8]	CNN-ELM	95.62%
[9]	AlexNet	95.80%
	GoogLeNet	95.06%
	AlexNet-SVM	97.11%
	GoogLeNet-SVM	98.14%
	VGGNet-SVM	96.99%
[10]	AlexNet-SVM	93.81%
	VGG-16-SVM	94.05%
	VGG-19-SVM	93.10%
	GoogLeNet-SVM	94.29%
	ResNet-SVM	96.90%
	SqueezeNet	95.24%
	GoogLeNet-KNN (proposed)	89.52%

5. Conclusion

Considering the advantages of deep learning especially in extracting the features, it is an understandable situation that its popularity has grown rapidly in recent years. A question comes to minds about that: How do we get results if we use deep learning in feature extraction and then insert the extracted features into another classifier? This study has been carried out to investigate the answer to this question. GoogLeNet and KNN which is based on supervised learning were combined. According to the experiments, we achieved 89.52% accuracy by using the GoogLeNet-KNN method, where Castelluccio et al. perform the classification with an accuracy rate of 91.83% [7]. The facts that there is not much difference between these two performances and that the performance of the combination used can be improved by some additions are positive findings for this combination. In this study, the effects of two different classifiers, SVM and KNN, on the success of GoogLeNet have been investigated. It is concluded that SVM is more successful than KNN in combination with GoogLeNet. Considering that the traditional KNN performs classification with 85% accuracy in another data set [3], it can be said that the combination proposed in the study improves the performance of KNN.

The classification performances of the system for different classes were listed in the paper. While the images of the chaparral and harbor classes were assigned to the correct classes with 100% success, the images of the buildings class were classified with the lowest success. F score of buildings class is 68.00%.

The next target of the authors is to develop the system performance. Different combinations will be tested on more than one dataset in this direction.

References

- [1] J. B. Campbell, and R. H. Wynne. Introduction to remote sensing. Guilford Press, 2011.
- [2] M. A. Shafaey, M.A.M. Salem, H. M. Ebied, M. N. Al-Berry, and M.F. Tolba, “Deep learning for satellite image classification,” In International Conference on Advanced Intelligent Systems and Informatics, 2018, pp. 383-391.
- [3] Y. Li, and B. Cheng, “An improved k-nearest neighbor algorithm and its application to high resolution remote sensing image classification,” In 2009 17th International Conference on Geoinformatics, 2009, pp. 1-4.
- [4] K. Djerriri, and M. S. Karoui, “Classification of quickbird imagery over urban area using convolutional neural network,” In 2017 Joint Urban Remote Sensing Event (JURSE), 2017, pp. 1-4.
- [5] M. Volpi, V. Ferrari, “Semantic segmentation of urban scenes by learning local class interactions,” In IEEE CVPR 2015 Workshop "Looking from above: when Earth observation meets vision" (EARTHVISION), Boston, USA, 2015.
- [6] F. P. Luus, B. P. Salmon, F. Van den Bergh, and B. T. J. Maharaj, “Multiview deep learning for land-use classification,” IEEE Geoscience and Remote Sensing Letters, 12(12), 2448-2452, 2015.
- [7] M. Castelluccio, G. Poggi, C. Sansone, and L. Verdoliva, “Land use classification in remote sensing images by convolutional neural networks,” 2015. arXiv preprint arXiv:1508.00092.
- [8] Q. Weng, Z. Mao, J. Lin, and W. Guo. “Land-use classification via extreme learning classifier based on deep convolutional features,” IEEE Geoscience and Remote Sensing Letters, 14(5), 704-708, 2017.
- [9] C. Cao, S. Dragičević and S. Li, “Land-use change detection with convolutional neural network methods,” Environments, 6(2), 25, 2019.
- [10] F. Özyurt, “Efficient deep feature selection for remote sensing image recognition with fused deep learning architectures,” The Journal of Supercomputing, 76(11), 8413-8431, 2020.
- [11] Y. Yang, and S. Newsam, “Bag-of-visual-words and spatial extensions for land-use classification,” In Proceedings of the 18th SIGSPATIAL international conference on advances in geographic information systems, 2010, pp. 270-279.
- [12] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, and A. Rabinovich, “Going deeper with convolutions,” In Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9.
- [13] A.S. Keçeli, and A. Kaya, “Detection of Violent Activities in Video Images with Lstm Network,” Dokuz Eylül University Faculty of Engineering Journal of Science and Engineering, 21(63), 933-939, 2019.

S-34 GENETİK ALGORİTMA İLE ÇAĞRI MERKEZİ ÇALIŞANLARI İÇİN MÜŞTERİ ATAMA PROBLEMİNİN OPTİMİZASYONU

Halime SUVAY EKER ¹, Mehmet Emin EKER ²

¹ Sosyal Bilimler Enstitüsü Sayısal Yöntemler Anabilim Dalı, İstanbul Üniversitesi, Türkiye, halime.suvayeker@gmail.com

² Doğuş Teknoloji, Türkiye, mehmetemineker@outlook.com

Özet

Çağrı merkezi çalışanlarının en büyük problemlerinden biri, adil müşteri dağılımıdır. Her çalışan benzer özelliklere sahip müşterilerle eşit oranda ilgilenmek ve adil prim dağılımı istemektedir. Bu problemin parametrelerinin ve girdi verilerinin çok fazla olması nedeniyle arama uzayı oldukça geniştir. Bu nedenle problem karmaşık yani NP – zor bir problem olmaktadır. Çözüm uzayının çok geniş olduğu bu tarz problemlere etkin bir çözüm getirebilmek için sezgisel bir arama yöntemi olan Genetik Algoritma tercih edilmektedir. Çalışma kapsamında Genetik Algoritma yöntemi kullanılarak çağrı merkezi çalışanlarına adil müşteri atamasını yapabilen C# programlama dilinde GeneticSharp kütüphanesi yardımı ile bir uygulama geliştirilerek en uygun çözüm aranmıştır. Genetik algoritmanın atama problemlerine etkin bir çözüm getirebildiği saptanmıştır.

Anahtar Sözcükler: *Adil Müşteri Dağılımı, Genetik Algoritma, Müşteri Atama, Müşteri Çizelgeleme.*

Abstract

One of the biggest problems of call center employees is fair customer distribution. Every employee wants to deal equally with customers with similar characteristics and to distribute premiums equally. Because of the large number of parameter and input data for this problem, the search space is large. Therefore, the problem is a complex, in other words NP – hard problem. Genetic Algorithm, which is an heuristical search method, is preferred in order to provide an effective solution to such problems where the solution space is very large. Within the scope of the study, an application was developed with the help of GeneticSharp library in C# programming language, which can assign fair customers to call center employees by using the Genetic Algorithm method, and the most appropriate solution was sought. It has been determined that the genetic algorithm can provide an effective solution to the assignment problems.

Keywords: *Fair Customer Distribution, Customer Assignment, Customer Scheduling, Genetic Algorithm.*

1. Giriş

İş dünyasında yer alan hemen hemen tüm mesleklerde farklı sorunlarla karşılaşılabilceği gibi çağrı merkezleri çalışanları da çeşitli sorunlar ile karşılaşabilmektedir. Çağrı merkezi çalışanlarına adil müşteri dağılımının yapılmaması önemli bir problemi oluşturmaktadır. Her çalışan diğer çalışanların ilgilendiği müşterilere benzer özelliklere sahip müşterilerin kendine

atanmasını böylelikle iş yükünde ve prim dağılımında eşitlik sağlanmasını ister. Ancak probleme ait parametrelerin ve girdi verilerinin çok fazla olması nedeniyle çözüm uzayı büyümekte adil bir atama yapılması zorlaşmaktadır.

Genetik Algoritma, makinelerin karşılaştıkları çeşitli problemlere insan zihnini taklit ederek çözüm yolları arayan yapay zekânın bir alt başlığıdır. Sezgisel bir arama tekniği kullanan genetik algoritma yöntemi karmaşık problemleri çözmek için sıklıkla kullanılmaktadır. Bu kullanımın en önemli sebebi de NP – zor problemlerin sistematik bir şekilde çözülebilmesine yöneliktir. Bu nedenle bu çalışmada bir sigorta acentesi bünyesinde çalışan 10 çağrı merkezi çalışanına 300 müşterinin adil bir şekilde ataması için genetik algoritma kullanılmıştır. Genetik algoritmanın çalıştırılabilmesi için C# programlama dilinde GeneticSharp kütüphanesi yardımı ile bir uygulama geliştirilmiştir. Uygulama çalıştırılarak yapılan atamalardan alınan sonuçlar incelendiğinde çalışanların primlerinin arasındaki farkların azaldığı, diğer parametrelerin de beklentiyi karşılayacak şekilde adil bir dağılım gerçekleştirdiği görülmüştür.

2. Genetik Algoritma

1960’lı yıllarda John Henry Holland tarafından ortaya atılan genetik algoritmalar evrimsel sistemin doğal sürecini bilgisayar ortamında simüle etmektedir. Doğal evrim sürecinde iyi özelliklere sahip bireyler daha uzun hayatta kalmakta ve kendi özelliklerini taşıyacak yeni bireyler oluşturabilmektedir. Aksine iyi özellik bulundurmayan zayıf bireyler çok az hayatta kalmakta veya hiç yeni birey oluşturamadan yok olmaktadır. Genetik algoritmalar da bu sisteme benzer bir şekilde işleyiş göstermektedir [1].

Genetik algoritmalar olası çözümlerden oluşan popülasyon adı verilen çözümler kümesi oluşturarak işe başlamaktadır. Popülasyon, kromozomlardan (bireylerden) rastgele seçilerek meydana gelmektedir. Kromozomlar içinde, genetik algoritmada optimize edilecek fonksiyonun parametrelerini taşıyan genler kodlanmaktadır. Fonksiyonun optimizasyonundaki performansına göre popülasyon havuzundan kromozom çiftleri seçilmektedir. Seçilen bu kromozom çiftinden kendi özelliklerini taşıyan yeni bir çocuk meydana getirilmektedir. Meydana gelen bu bireyler ebeveynlerinin yerine geçer ve yeni bir nesil oluşmaktadır. Artık popülasyonda yeni bireyler yerini almaktadır ve süreç tekrar ederek bir sonraki nesli meydana getirmektedir [1].

2.1. Genetik Algoritma Operatörleri

Genetik algoritmada çözüm kümesini oluşturan popülasyon incelenirken bir noktaya gelindikten sonra daha iyi kromozomlar üretilmemeye başlamaktadır. Bu durumu engellemek için kromozomlara belirli oranda çaprazlama ve mutasyon operatörleri uygulanmaktadır [2].

2.1.1. Çaprazlama

İki kromozomun bir araya gelerek karşılıklı gen değişiminin yapılması çaprazlama olarak ifade edilmektedir [2]. Çaprazlama operatörü popülasyon havuzunun potansiyelini araştırmaktadır ve bir önceki nesilden daha iyi özellikler bulandıran yeni kromozomlar üretmek amacıyla kullanılmaktadır [3].

2.1.2. Mutasyon

Popülasyon havuzunun mevcut problemi çözüme kullanılabilecek bir çözüm elde edemediği durumlarda mutasyon operatörü kullanılmaktadır [3]. Temel amacı popülasyondaki genetik çeşitliliğini korumak olan mutasyon operatörü yalnızca bir kromozom üzerine uygulanmaktadır [4].

2.1.3. Uygunluk

Popülasyon havuzunun oluşturulmasından sonraki adım uygunluk değerinin hesaplanmasıdır. Genetik algoritmanın her iterasyonunda popülasyonu meydana getiren her bir kromozomun uygunluk değeri bulunup belleğe kaydedilmektedir. Bu değer sayesinde diğerlerine göre daha iyi özelliklere sahip kromozomlar tespit edilmiş olur ve bir sonraki nesle aktarılma olasılığı daha yüksektir [5].

X kromozomuna ait değeri temsil etmek üzere i . kromozomun uygunluk değeri $f_i(X)$ 'dir. Problemin bütün parametrelerini ve kısıtlarını temsil eden iyi tanımlanmış bir uygunluk fonksiyonu, genetik algoritmanın verimli ve amaca uygun bir şekilde çalışabilmesi için önemlidir [5].

2.1.4. Seçim

Seçim operatörü, “En uygun olanın yaşaması” ilkesi doğrultusunda bir sonraki neslin popülasyonunu oluşturmak için mevcut popülasyondan uygun kromozomları belirlemek amacıyla kullanılmaktadır. Mevcut popülasyondaki kromozomların seçilerek gelecek nesillerdeki çocuk kromozomların ebeveynleri olabilmesi için sahip oldukları uygunluk değerine bakılmaktadır. Uygunluk değeri yüksek olan kromozomların seçilme şansı daha yüksektir. Uygunluk değeri yüksek olan ebeveynlerin sahip oldukları çocuk kromozomların daha yüksek uygunluk değerine sahip olacakları beklenmektedir [4].

3. Müşteri Atama Probleminin Genetik Algoritma ile Optimizasyonu

3.1. Problemin Tanımı

Problemin ele alındığı sigorta acentesi bünyesinde araçlar için kasko ve trafik poliçesi satmaktadır. Her ayın başında toplu olarak müşteri verileri ilgili firmaya iletilerek yeni müşteriler oluşturulmaktadır. Oluşturulan her bir müşterinin acente çağrı merkezi çalışanlarına adil bir şekilde ataması yapılması beklenmektedir. Atama yapılırken müşterinin trafik ve kasko poliçeleri göz önünde bulundurularak bu poliçelerin yenileme yılları, yenileme skorları ve primlerinin toplamı ve hangi bayi üzerinden geldiği bilgileri ile atamanın gerçekleştirilmesi istenmektedir.

3.2. Problemin Kısıtları

Probleme ait kısıtların belirlenmesi, çözüm kümesinin doğru bir şekilde belirlenmesinde önemli bir rol oynamaktadır. Ayrıca kısıtlar sayesinde çözüm uzayının sınırlılıkları da belirlenmiş olmaktadır [6].

Bu çalışmada ele alınan probleme ait kısıtlar da şu şekilde belirlenmiştir.

1. Her bir çağrı merkezi çalışanına en az bir müşteri ataması yapılmalıdır.

2. Her bir çağrı merkezi çalışanın ilgilendiği müşterilere ait kasko ve trafik poliçelerinin prim toplamlarının birbirlerine olabildiğince yakın olması gerekmektedir.
3. Her bir çağrı merkezi çalışanına olabildiğince aynı sayıda müşteri ataması yapılması gerekmektedir.
4. Bir müşterinin aynı sigorta şirketi üzerinden her yıl yapmış olduğu yenileme sayısı yenileme yılını ifade etmektedir. Her bir çağrı merkezi çalışanına olabildiğince aynı yenileme yılına sahip müşteri ataması yapılması gerekmektedir.
5. Her bir çağrı merkezi çalışanına atanan müşterilerin yenileme yılları toplamının olabildiğince birbirine yakın olması gerekmektedir.
6. Farklı bir proje kapsamında müşterilerin kasko ve trafik poliçelerini yenileme ihtimallerinin oranları tutulmuştur. Her bir çağrı merkezi çalışanına müşteri atanacağı zaman bu oranlar da dikkate alınmaktadır. Bu oranların olabildiğince birbirine yakın olması beklenmektedir.
7. Her bir çağrı merkezi çalışanına atanan müşterilerin yenileme skorları toplamının olabildiğince birbirine yakın olması gerekmektedir.
8. Problemin ele alındığı sigorta acentesi farklı sigorta bayileriyle çalışmaktadır. Müşteri verileri farklı bayilerden gelmektedir. Her bir çağrı merkezi çalışanına atanan müşterilerin bayi dağılımlarının olabildiğince birbirine yakın olması gerekmektedir.

3.3. Probleme Kullanılan Veriler

Söz konusu sigorta acentesinden alınan verilerde 10 adet çağrı merkezi çalışanı ve 300 adet müşteri bulunmaktadır.

Verilere müşterilerin yenileme yılları açısından bakıldığında aşağıda verilen Tablo 1’deki gibi görülmektedir.

Tablo 1. Müşterilere ait kasko ve trafik poliçelerinin yenileme yılı toplamı tablosu.

Müşteri Sayısı	Yenileme Yılı
1	15
1	18
1	34
2	7
2	11
5	14
5	16
7	10
15	3
15	5
15	12
17	8
29	4
37	6
54	2
94	1

Verilere müşterilerin yenileme skorları açısından bakıldığında aşağıda verilen Tablo 2’deki gibi görülmektedir.

Tablo 2. Müşterilere ait kasko ve trafik poliçelerinin yenileme skor toplamı tablosu.

Müşteri Sayısı	Yenileme Skoru
2	170
4	140
5	100
5	150
5	160
8	120
8	130
12	0
12	110
16	30
21	10
22	20
24	40
26	70
30	80
31	90
34	60
35	50

Verilere müşterilerin geldiği bayiler açısından bakıldığında aşağıda verilen Tablo 3'teki gibi görülmektedir.

Tablo 3. Müşterileri verilerinin geldiği bayiler tablosu.

Müşteri Sayısı	Bayi
9	BAYİ 1
36	BAYİ 2
37	BAYİ 3
45	BAYİ 4
173	BAYİ 5

3.4. Uygulama

3.4.1. Kromozom Yapısı

Çözüm için geliştirilen kromozom yapısı permütasyon kodlama kullanılarak oluşturulmuştur. Kromozomdaki gen sayısı müşteri sayısı kadar oluşturulmuştur. Her bir gendeki değer çağrı merkezi çalışanlarını temsil etmektedir.

Tablo 4. Kromozom yapısı tablosu.

Müş.1	Müş.2	Müş.3	Müş.4	Müş.5	Müş.6	Müş.7	Müş.8	Müş.9	Müş.10	...	Müş.300
3	2	4	10	8	6	4	2	10	1	...	8

Örneğin, Tablo 4’teki Müş.4 sütunu 10 numaralı çağrı merkezi çalışanına 4 numaralı müşterinin atandığını göstermektedir.

3.4.2. Genetik Algoritma Operatörleri

Çaprazlama işlemi için iki noktalı çaprazlama yöntemi, mutasyon işlemi için ise tersinme ile mutasyon yöntemi kullanılmıştır. Seçim işlemi gerçekleştirilmek üzere rulet tekerleği yöntemi tercih edilmiştir.


Seçim işleminin doğru bir şekilde çalışması için uygunluk değerinin hesaplanması gerekmektedir. Problem kapsamında istenen kısıtlar sağlamadığında her bir sağlanmayan kısıt için ceza puanı uygulanmıştır. Uygunluk değerinin 1’e ulaşması durumu tüm kısıtların sağlandığını göstermektedir.

$$Uygunluk\ Değeri = 1 / \sum_{i=1}^n Kısıt_i + 1 \quad (1)$$

Geliştirilen uygulama kullanılarak 10 çağrı merkezi çalışanına 300 müşterinin adil bir şekilde atanması problemi çözülmüştür. Elde edilen sonuçlar doğrultusunda belirlenen kısıtları hangi oranda sağladığına bakılmış ve uygulamanın başarısı değerlendirilmiştir.


3.5. Bulgular

Genetik algoritma çalıştırıldıktan sonra belirlenen kısıtlar dahilinde yapılan atama sonucunda elde edilen bulgular şu şekildedir. Her bir şekilde yer alan E1, E2, E3 ... E10 değerleri çağrı merkezi çalışanlarını ifade etmektedir.




Şekil 1. Yüzdeler prim dağılımı.

Yukarıda yer alan Şekil 1 her bir çağrı merkezi çalışanına atanan müşterilerin prim dağılımını göstermektedir. Her çalışana yaklaşık %10'luk prim dağılımı yapıldığı görülmektedir.




Şekil 2. Prim dağılımı miktarları.

Yukarıda yer alan Şekil 2'de her bir çağrı merkezi çalışanına düşen prim miktarı gösterilmektedir.




Şekil 3. Çağrı merkezi çalışanı başına düşen müşteri sayısı.

Yukarıda yer alan Şekil 3'te her bir çağrı merkezi çalışanına atanan müşterilerin sayısı gösterilmektedir.




Şekil 4. Yenileme yıllarının çağrı merkezi çalışanlarına dağılımı.

Yukarıda yer alan Şekil 4'te her bir çağrı merkezi çalışanına atanan müşterilere ait yenileme yıllarının dağılımı gösterilmektedir. Örneğin, yenileme yılı 3 olan müşteriler YY3 olarak ifade edilmiştir.



Şekil 5. Yenileme skorlarının çağrı merkezi çalışanlarına dağılımı.

Yukarıda yer alan Şekil 5’te her bir çağrı merkezi çalışanına atanan müşterilere ait yenileme skorlarının dağılımı gösterilmektedir. Örneğin, yenileme skoru 20 olan müşteri YS20 olarak ifade edilmiştir.




Şekil 6. Bayilerin çağrı merkezi çalışanlarına dağılımı.

Yukarıda yer alan Şekil 6’da her bir çağrı merkezi çalışanına atanan müşterilerin geldikleri bayilerin dağılımı gösterilmektedir.

3.6. Sonuçlar

Genetik algoritma Intel(R) Core(TM) i7-10875H CPU @ 2.30GHz işlemciye sahip bilgisayarda çalıştırılmıştır. Popülasyon büyüklüğü 50 olarak belirlenmiştir. Probleme ait tüm kısıtların genetik algoritma tarafından sağlanması yaklaşık 4 dakika ve 11145 nesil sürdüğü gözlemlenmiştir.



Şekil 7. Genetik algoritma uygunluk değeri zaman serisi.

Yukarıda yer alan Şekil 7’de uygunluk değerinin zamana göre değişimi gösterilmiştir. Uygunluk değerinin 1 olması yani tüm kısıtların %100 sağlanmış olması beklenmektedir. Şekil 7’de bu şartın sağlandığı ve uygunluk değerinin 1’e ulaştığı görülmektedir.

Genetik algoritmanın ele alınan müşteri atama problemine uygun bir çözüm getirdiği tespit edilmiştir. Alınan sonuçlara bakıldığında, 300 müşterinin toplam ₺529.538,06 olan prim değerinin 10 çalışana kişi başı en az ₺50.738,67 en çok ₺53.991,57 olacak şekilde atama yapılmıştır, bulunan bu değerler kişi başına yaklaşık %10 oranında prim dağılımı yapıldığını göstermektedir.

Şekil 4 ve Şekil 5’e bakıldığında müşterilerin yenileme yılı ve yenileme skorlarına göre her çalışana ilgilenmek üzere en az 23 en çok 33 müşteri atandığı görülmüştür. (300 müşterinin 10 çalışana 30’ar müşteri olacak şekilde atanması durumu müşterilerin hepsinin aynı özellikte olmamasından dolayı adillik durumunu bozmaktadır.) Bu da kısıtlar arasında yer alan her bir çağrı merkezi çalışanına olabildiğince aynı yenileme yılına sahip müşteri ataması, yenileme yılları toplamının olabildiğince birbirine yakın olması, yenileme yılı oranlarının olabildiğince birbirine yakın olması ve son olarak da yenileme skorları toplamının olabildiğince birbirine yakın olması durumlarını sağlar nitelikte olduğunu göstermektedir. Aynı bayiden gelen müşterilerin aynı çalışan üzerinde yoğunlaşmaması için her bir çalışana farklı bayideki müşterilerin atanması gerekmektedir. Şekil 6’ya bakıldığında da genetik algoritmanın her bir çağrı merkezi çalışanına istenildiği gibi olabildiğince birbirine eşit miktarda atama yaptığı ve geliştirilen uygulamanın bu şartı da sağlamış olduğu saptanmıştır.

Referanslar

- [1] T. Cura, *Modern Sezgisel Teknikler ve Uygulamaları*, İstanbul: Papatya Bilim, 2008.
- [2] Ç. Elmas, *Yapay Zeka Uygulamaları*, Ankara: Seçkin Yayıncılık, 2016.
- [3] Ç. Taşkın ve G. Gökay Emel, *Sayısal Yöntemlerde Genetik Algoritmalar*, Bursa: Alfa Aktüel Yayınları, 2009.
- [4] S. Taştan, “Genetik Algoritma Temelinde Rejim Değişikliği Modellerinin Belirlenmesi” Doktora Tezi, Cumhuriyet Üniversitesi, Sivas, 2012.
- [5] E. Önder, “Araç Rotalama Probleminin Parçacık Sürü ve Genetik Algoritma ile Optimizasyonu” Doktora Tezi, İstanbul Üniversitesi, İstanbul, 2011.
- [6] E. Akadal, “Ham Verilerin Genetik Algoritmalarla İlişkisel Veritabanlarına Dönüştürülmesi ve Bir Uygulama” Doktora Tezi, İstanbul Üniversitesi, İstanbul, 2017.

S-10 DEPREM SONRASI HASARLI YOLLARIN YAPAY ZEKÂ İLE TESPİT EDİLEREK EN KISA YOL GÜZERGÂHLARININ ANLIK OPTİMİZASYONU

Ramazan ÜNLÜ¹, Nurcan ŞİMŞEK^{2,*}

¹ Yönetim Bilişim Sistemleri Bölümü, Gümüşhane Üniversitesi, Türkiye,
ramazanunlu@gumushane.edu.tr

² Afet Yönetimi Bölümü, Gümüşhane Üniversitesi, Türkiye,
2009021027@ogr.gumushane.edu.tr

Özet

Depremlerden sonra afet bölgesindeki can ve mal kayıplarını minimize edebilmek ve etkili bir kriz yönetimi sağlayabilmek için afet bölgesindeki karayolu hasarlarını hızlı ve doğru tespit etmek hayati öneme sahiptir. Bu çalışmada; deprem ve depremlerden sonra ikincil afet olarak meydana gelen heyelan gibi beklenmedik afetlerde yol hasarlarının Evrişimli Sinir Ağları (CNN) ile en kısa sürede tespit edilerek klasik en kısa yol algoritması ile yeni güzergâhlar belirlenmeye çalışılmıştır. CNN algoritmasında, kullanılmayan ve kullanılabilen 552 resim kullanılarak test setinde 0.960 G-Ortalama puanı ile %97 doğruluk oranı elde edilmiştir.

Anahtar Sözcükler: Deprem, en kısa yol, yapay zekâ, yol hasar tespiti.

Abstract

In order to minimize the loss of life and property in the disaster area after the earthquakes and to provide an effective crisis management, it is vital to detect the road damage in the disaster area quickly and accurately.

In this study, it has been tried to determine the road damages in the shortest time with Convolutional Neural Networks (CNN) in unexpected disasters such as earthquakes and landslides that occur as a secondary disaster after earthquakes and to determine new routes with the classical shortest path algorithm. Using 552 images which are unusable and usable the CNN algorithm, an accuracy rate of 97% was achieved with a G-Mean score of 0.960 on the test set.

Keywords: Artificial intelligence, earthquake, road damage detection, shortest path.

1. Giriş

Alp-Himalaya deprem kuşağında yer alan Türkiye’de çevreye ve insanlara vermiş olduğu yıkım ve hasarlardan dolayı ilk sırada depremler ve jeolojik afetler yer almaktadır. Ülkemizde insanlara ve yapılara hasar veren afetlerin yüzdelik dilimine baktığımızda %61’ini depremler, %15’ini heyelanlar, %14’ünü seller, %5’ini kaya düşmeleri%4’ünü yangınlar ve %1’ini meteorolojik olaylar oluşturmaktadır[1]. Türkiye’deki nüfusun %98’i deprem tehlikesi bulunan bölgelerde yaşamaktadır. Sanayi kuruluşlarının da %98’i deprem tehlikesi olan bölgelerde yer almaktadır[2]. Dünyada yıkıcı deprem aktivitelerinin en çok görüldüğü bölgelerden biri olan; Türkiye’de depremlerde çok fazla sayıda bina hasar görmüş ya da yıkılmıştır. Depremler

sonucunda sadece binalarda hasar oluşmamış aynı zamanda kentsel alt yapı ve ulaşım ağlarında da ağır hasarlar meydana gelmiştir. Depremlerden sonra afet bölgelerine insani yardımın ulaşmasına, yaralıların sağlık kurumlarına taşınmasında ve afet bölgesindeki insanların toplanma alanlarına veya çadır kentlere tahliyesinin sağlanabilmesi için ulaşım sistemleri önemli bir yere sahiptir[3]. Acil kurtarma ekiplerinin ve insani yardım malzemelerinin afet bölgesine zamanında ulaştırılmaması insan hayatını olumsuz yönde etkileyebilir. Dijital dünyanın gelişmesiyle birlikte bir noktadan bir noktaya gitmek için klasik en kısa yol algoritması gibi birçok yöntem kullanılmaktadır. Afetlerde bu yöntemleri zamanında ve etkin bir şekilde kullanmak oldukça önem arz etmektedir.

Bu çalışmada depremlerden sonra insansız hava araçlarına takılan kameralar ile ya da CCTV(Close Circuit TeleVision(Kapalı Devre Televizyon)) kamera sistemleri ile CNN algoritması kullanılarak yollardaki hasar durumu belirlenerek klasik en kısa yol algoritması ile afet bölgesine yakın hasarsız yolların belirlenmesi amaçlanmaktadır.

2. Metod

Bu çalışmada en kısa yol algoritması ve CNN ile gerçek zamanlı uygulamalarda hasarsız ve ulaşılacak bölgeye en kısa yolu bulmak için birbirine entegre edilmiştir. Kullanılan veri seti ve yöntemler şu şekildedir:

2.1. Veri seti

Bu çalışmanın amacına uygun depremlerden sonra araç geçişine uygun olmayan yol resimleri ile araç geçişi için sorun teşkil etmeyen yol resimleri toplanmıştır. Resimler manuel olarak images.google.com gibi çeşitli kaynaklardan toplanmıştır. Çalışmamızda kullanılan hasarlı yol resimlerinde dikkat ettiğimiz nokta, yollardaki hasarların trafik geçişine izin vermeyecek kadar hasarlı olmasıdır. Hafif çatlaklar bulunan yollar trafik geçişine uygun olduğundan bu çalışmaya dahil edilmemiştir. 248’i hasarlı, 304’ü normal olmak üzere; toplamda 552 resim çalışmamızda kullanılmıştır.



Şekil 5 Hasarlı ve normal yollar dâhil olmak üzere veri örnekleri

2.2. Evrişimli sinir ağları

Evrişimli Sinir Ağları, trafik işareti tanımda [4], biyolojik görüntü segmentasyonunda [5] ve görüntü sınıflandırma [6] gibi çeşitli görsel tanıma problemlerinde önemli başarılar göstermiştir. Günümüz dünyasında çözülmesi gereken problemlerin karmaşıklığı ve verilerin boyutu göz önüne alındığında CNN yöntemi sığ sinir ağları, SVM ve lojistik regresyon gibi klasik makine öğrenmesi yöntemlerinden çok daha başarılı sonuçlar elde etmiştir [7-9].

2.3 VGG-16

Bu çalışmada [10] tarafından önerilen önceden eğitilmiş VGG-16 ağı kullanılarak ikili sınıflandırma yapılmıştır. Bu algoritma 5000 sınıfın üzerinde 3.2 milyondan fazla resim bulunan ImageNet veri tabanı üzerinden eğitilmiştir [11].

2.4. En kısa yol algoritması

En kısa yol bulma algoritması, özellikle ulaşım ve rota planlaması gibi durumlarda bir kaynaktan varış nokrasına kadar en kısa yolu bulmak için kullanılır. Kısa yol modeli problem grafiği teorisine dayanır ve mevcut yolları temsil eden düğümler arasındaki mesafeyi en aza indirmek amacıyla kullanılır. Bu model bir tam sayılı doğrusal programlama olarak formüle edilebilir. Ağırlıklar, kaynaklar (s) ve hedefler (w) $\in V$ ile yönlendirilmiş bir ağ verildiğini varsayalım. En kısa yolu bulmak için aşağıdaki optimizasyon problemini tanımlayabiliriz.

$$\min \sum_{u,v} x_{uv} w_{uv} \quad ((a))$$

Bağlı Olarak:

$$\sum_u x_{su} - \sum_v x_{vs} = 1 \quad ((b))$$

$$\sum_u x_{vt} - \sum_u x_{tu} = 1 \quad ((c))$$


$$\sum_q x_{pq} - \sum_r x_{rp} = 0, \text{ için } \forall p \in V - \{s, t\} \quad ((d))$$

$$((e))$$

$$x = 0 \text{ ya da } 1$$

Buradaki “x” ağdaki kenarı ifade eder en kısa yoldaysa “1” değilse “0” değerini alır ve “w” ise karşılık gelen kenarın ağırlığıdır. Amaç fonksiyonu (a), kat edilen toplam mesafenin minimizasyonunu belirtir. Kısıtlama (b), kaynaktan tek bir nokta olduğunu ve hedeften kaynağa dönüşün olmadığını ifade eder. Kısıtlama (c), hedefin tek bir noktadan geldiğini ve hedeften kaynağa dönüşün olmadığını ifade eder. Kısıtlama (d), herhangi bir düğümde bir girdi veya çıktı olmasını ya da girdi veya çıktı olmamasını sağlar. Kısıtlama (e), değişkenlerin integral alanını empoze eder.

Bu çalışmada şekil ikideki hibrit sistem önerilmiştir. Bu hibrit sistemde bulunan tüm yollar acil durum ekiplerinin kendi sistemlerinde mevcut olacaktır. Depremlerden sonra nasıl kullanılacağı Şekil 2 deki hibrit sistem üzerinden Tablo 2 de anlatılacaktır.



Şekil 6 Önerilen hibrit sistem örneği

Deprem sonrası A noktasındaki acil durum ekibinin B noktasındaki kritik bölgelere en hızlı şekilde ulaşması gerekmektedir. Eğer $3 \rightarrow 9$ rotasında kullanılmayacak kadar bir hasar meydana geldiğinde CNN algoritması ile tespit edildikten sonra hibrit sistemle A ile B noktasındaki mesafe Tablo 1 deki gibi hesaplanacaktır. Ceza sayısı 1000 gibi büyük bir sayı olmakta ve $\rho_{CNN} = \{0,1\}$ CNN tahmininden gelen ceza etkinleştirme puanıdır. Koyu yazıyla yazılan rota en kısa yoldur.

Tablo 1 CNN tarafından tahmin edilen hasarlı yol senaryosu ve tüm rotalar için A ve B noktasına olan toplam mesafe

Tüm rotolar	Amaç fonksiyonu= $\min \sum_{u,v} x_{uv} w_{uv} + M x_{uv} \rho_{CNN}$
A→1→4→7→B	$1x(3 + 3 + 5 + 3) = 14$, burada $\rho_{CNN} = 0$
A→1→4→6→B	$1x(3 + 3 + 4 + 4) = 14$, burada $\rho_{CNN} = 0$
A→2→5→6→B	$1x(4 + 2 + 3 + 4) = 13$, burada $\rho_{CNN} = 0$
A→2→5→9→B	$1x(4 + 2 + 5 + 3) = 14$, burada $\rho_{CNN} = 0$
A→3→9→B	$(1x3 + 1 \times 0 \times 1000) + (1x3 + 1 \times 1 \times 1000)$ $= 1003$, burada $\rho_{CNN} = 1$

Bu çalışmada depremlerden sonra hasar gören yolların CNN modeli ile tespiti yapıldıktan sonra en kısa yol algoritması ile entegre edilmiştir. Tablo 1 deki amaç fonksiyonundaki “x” ağıdaki kenarı ifade eder. En kısa yoldaysa “1” değilse “0” değerini alır. “W” ağıdaki kenarın ağırlığıdır. “M” ise sabit sayıdır ve ceza değişkeni olarak adlandırılabilir.

3. Bulgular

Toplanan veri seti %80 eğitim %15 test ve %15 doğrulama olarak bölümlere ayrıldı. Eğitilen model test setinin %5’i ile 12 kapalı yol ve 16 açık yol olmak üzere 28 farklı görüntü üzerinden test edilmiştir.

Tablo 2 Test veri kümesi için karışıklık matrisi

	Kapalı yol	Açık yol
Kapalı yol	12	0
Açık yol	1	15

Tablo 2’ye göre eğitilmiş model, mükemmel sonuç göstermiştir. 12 tane kapalı yolun 12 tanesini de kapalı olarak tahmin etmiştir. 16 tane açık yolun ise 15 tanesini açık olarak tahmin ederken 1 tanesini kapalı olarak tahmin etmiştir. Bu çalışmanın amacı kapsamında, modelin kapalı yollardan herhangi birini yanlış tahmin etmesi durumunda acil durum ekipleri için risk teşkil edebilirken açık yollardan 1 tanesini kapalı tahmin etmesi herhangi bir risk teşkil etmeyecektir.

Tablo 3 Modelin test setindeki performansı

Kayıp ve doğruluk değerlendirmesi	Performans
Test kayıp değeri	0.07403
Test doğruluk değeri	0.9642

Tablo 4 Duyarlılık, özgüllük ve G-Ortalama açısından modelin performansı

Değerlendirme metrikleri	Performans
Duyarlılık	0.923
Özgüllük	1
G-Ortalama	0.960

Modelin duyarlılık, özgüllük ve G-Ortalama değerleri Tablo 4 te gösterildiği gibi sırasıyla 0,923, 1 ve 0,960'tır. G-Ortalama puanının yüksek olması, modelin her iki sınıfa ait örnekleri doğru şekilde sınıflandırabileceğini göstermektedir.

4. Sonuçlar

Bu çalışmada depremlerden sonra afet alanlarına daha hızlı erişim sağlamak için hibrit bir sistem geliştirilmiştir. Bu sistemi iki ana bileşeni vardır:

1. Yolun kullanılabilir olup olmadığını tahmin etmek,
2. Bu tahmini en kısa yol algoritmasına entegre etmek.

İlk etabın geliştirilebilmesi için farklı kaynaklardan 552 farklı görüntü toplanmıştır. Toplanan veri seti derin bir CNN ağı için yeterince büyük olmadığından önceden eğitilmiş bir VGG16 modeli ile eğitilmiştir. Sonuçlara göre: VGG16 modeli eğitim, doğrulama ve test setlerinde sırasıyla% 90, % 80 ve % 70 doğruluk elde etmeyi başarmıştır. Önerilen çerçevenin ikinci aşaması, CNN tahminlerinin en kısa yol algoritmasına entegrasyonudur. Bunu yapmak için klasik en kısa yol optimizasyon algoritmasının amaç fonksiyonuna iki ekstra değişken ekledik. Bu değişkenlerden biri kullanılmayan yollar için ceza verir ve bu rota sistemden otomatik olarak kaldırılır. Ceza değişkeninin aktivasyonu CNN algoritmasının tahmini sayesinde

gerçekleştirilir. Algoritma rotanın kullanılabilir olduğunu tahmin ederse ($\hat{y} = 0$) ceza değişkeninin amaç fonksiyonu üzerinde herhangi bir etkisi olamayacaktır. Eğer algoritma yolların kullanılamayacağını öngörürse ($\hat{y} = 1$) ceza terimi etkinleştirilecek ve kullanılmayan kısmı içeren bu rota gözardı edilecektir.

Bu sistem, en kısa yol algoritmasını gerçek zamanlı olarak optimize etmek için tasarlanmıştır. Bu noktada veri sayısının azlığı bir dezavantaj olmakla birlikte, bu dezavantaj transfer öğrenme kullanılarak en aza indirilmeye çalışılmıştır.

Referanslar

- [1] İ. Yılmaz, ‘Afetlerde iyileştirme çalışmaları’,
Mevcut: http://auzefkitap.istanbul.edu.tr/kitap/acilyardimveafetyonetimi_ao/aic.pdf
- [2] TMMOB, ‘Türkiye’de deprem gerçeği ve TMMOB makine mühendisleri odasının önerileri’, Ankara, MMO/587, 2012
- [3] M. Tanarlan, ‘Deprem sonrası hasar görmüş veya görmesi muhtemel betonarme köprü rehabilitasyonu için öneriler’, İnşaat Mühendisleri Odası 6. Kentsel Altyapı Sempozyumu, Antalya, 2011, s.601-610
- [4] D. Cireşan, U. Meier, J. Masci, J. Schmidhuber, Multi-column deep neural network for traffic sign classification, Neural Networks. 32 (2012) 333–338.
- [5] F. Ning, D. Delhomme, Y. LeCun, F. Piano, L. Bottou, P.E. Barbano, Toward automatic phenotyping of developing embryos from videos, IEEE Trans. Image Process. 14 (2005) 1360–1371.
- [6] M. Oquab, L. Bottou, I. Laptev, J. Sivic, Learning and transferring mid-level image representations using convolutional neural networks, in: Proc. IEEE Conf. Comput. Vis. Pattern Recognit., 2014: pp. 1717–1724.
- [7] M.A. Hedjazi, I. Kourbane, Y. Genc, On identifying leaves: A comparison of CNN with classical ML methods, in: 2017 25th Signal Process. Commun. Appl. Conf., IEEE, 2017: pp. 1–4.
- [8] H. Wang, Z. Zhou, Y. Li, Z. Chen, P. Lu, W. Wang, W. Liu, L. Yu, Comparison of machine learning methods for classifying mediastinal lymph node metastasis of non-small cell lung cancer from 18 F-FDG PET/CT images, EJNMMI Res. 7 (2017) 11.
- [9] H. Gjoreski, J. Bizjak, M. Gjoreski, M. Gams, Comparing deep and classical machine learning methods for human activity recognition using wrist accelerometer, in: Proc. IJCAI 2016 Work. Deep Learn. Artif. Intell. New York, NY, USA, 2016.
- [10] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, ArXiv Prepr. ArXiv1409.1556. (2014).
- [11] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, L. Fei-Fei, Imagenet: A large-scale hierarchical image database, in: 2009 IEEE Conf. Comput. Vis. Pattern Recognit., Ieee, 2009: pp. 248–255.

S-51 PREDICTING MECHANICAL PROPERTIES OF MULTIFILAMENT POLYESTER WOVEN FABRICS USING ARTIFICIAL INTELLIGENCE TECHNIQUES

Nurselin ÖZKAN AYAZ ¹, Halil İbrahim ÇELİK ², Hatice Kübra KAYNAK ³

¹ Textile Engineering Department, Gaziantep University, 27310 Gaziantep, Turkey, nrsln.ozkan@gmail.com

² Textile Engineering Department, Gaziantep University, 27310 Gaziantep, Turkey, hcelik@gantep.edu.tr

³ Textile Engineering Department, Gaziantep University, 27310 Gaziantep, Turkey, tuluce@gantep.edu.tr

Özet

Filament inceliği, dokuma tipi ve dokuma yoğunluğu parametreleri, multifilament dokuma kumaşların mekanik özellikleri üzerinde büyük bir etkiye sahiptir. Bu çalışmada, multifilament dokuma kumaşların daha önce hesaplanan kopma uzaması ve kopma mukavemeti değerleri, Yapay Sinir Ağları (YSA) ve Bulanık Mantık (BM) yapay zeka teknikleri kullanılarak tahmin edilmiştir. Çalışmada kullanılan kumaşlar üç farklı mikrofilament inceliğine ve iki farklı konvansiyonel filament inceliğine sahiptir. Bezayağı, dimi ve saten dokuma çeşitlerine sahip kumaşlar dokuz farklı dokuma sıklığına sahiptir. Yapay Zeka (YZ) tekniği ile yapılan tahmin çalışmalarında ortalama hata yüzdesi %5'in üstüne çıkmamıştır. YSA ve BM modellerinden elde edilen tahmin sonuçları ile deneysel ölçüm sonuçları arasındaki lineer regresyon değeri (R^2) sırasıyla ortalama 0.91 ve 0.93 olarak elde edilmiştir.

Anahtar Sözcükler: *Bulanık Mantık; Mikrofiber Kumaş; Performans Tahmini; Yapay Zeka; Yapay Sinir Ağı.*

Abstract

The parameters of filament fineness, weaving type and weaving density have a great influence on the mechanical properties of multifilament woven fabrics. In this study, the breaking elongation and breaking strength values of multifilament woven fabrics, which were calculated before, were estimated using Artificial Neural Networks (ANN) and Fuzzy Logic (FL) artificial intelligence techniques. The fabrics used in the study have three different microfilament fineness and two different conventional filament fineness. Fabrics with plain, twill and satin weave types have nine different weaving densities. In the estimation studies made with Artificial Intelligence (AI) technique, the means error percentage did not exceed 5%. The average linear regression values (R^2) between the predicted results obtained from ANN and FL and experimental measurement results were obtained as 0.91 and 0.93 respectively.

Keywords: *Artificial Intelligence; Artificial Neural Network; Fuzzy Logic; Microfiber Fabric; Performance Prediction.*

1. Introduction

Fabrics woven from microfilament yarns have a wide range of uses, thanks to their many features such as being light, comfortable and acting as a barrier against the wind. Mechanical properties of the fabric such as breaking strength and elongation at break are depend on many parameters namely fiber type, yarn spinning method, yarn number, fabric physical properties, pattern type. So, modelling the fabric structure or generating a regression equation for fabric mechanical performance properties is very difficult and complex problem. This problem can be solved with the help of “Artificial Intelligence (AI)” methods that enable the prediction of some performance properties depending on the input variables. By means of trained data, a robust relationship can be built and more accurate and precise results can be obtained [1].

When the previous studies are investigated, it can be obviously seen that AI methods have been applied to prediction of fiber, yarn and fabric properties. ANN method have been used to estimate the quality characteristics and the performance of cotton elastane blend core yarn by using ANN [2, 3]. ANN method have been applied to predict the mechanical performance properties, namely tensile strength [4], weights, thicknesses [5], thermal resistance [6], shrinkage [7], drape [8] of the fabrics. Kargı worked about on prediction weft defects in fabric production with two methods that a multilayer perceptron model and multiple linear regression models [9] Chattopadhyay has worked on prediction yarn properties from fiber parameters with the ANN model [10]. Alsayed et al. used multifilament woven fabrics samples made from conventional and microfilament yarns. They applied the regression equation and fuzzy logic method to predict the air permeability performance of the samples. It was resulted that FL method provided higher accuracy than regression[11]. Safitri and Mulyana optimized woven fabric defect detection using image processing and fuzzy logic method [12]. Hamdi et al. made a research on the subject of predicting which drape parameters affect which drape phenomenon with a fuzzy logic model [13]. Chakraborty et al. have combined fuzzy logic model and grey relational analysis which is the multi-criteria decision making technique for predicting the best cotton fabric selection [14]. Chakraborty and Das constructed a fuzzy logic system to predict yarn quality characteristics from the ring spinning process parameters. It was concluded that the fuzzy model generated close results to experimental results [15].

2. Scope of the Study

In this study, the breaking strength and elongation values of multifilament woven fabrics were estimated using FL and ANN artificial intelligence techniques depending on some physical properties such as weave type, weft density and filament fineness. The main purpose of this study is to use artificial intelligence techniques to increase the accuracy rate and calculation speed that classical methods lack, by choosing the most suitable artificial intelligence technique for the specified problem type and the most efficient for this problem type. Looking at the literature, FL and ANN techniques were not compared to reveal the best model that predicts the mechanical properties of microfilament and multifilament woven fabrics.

3. Material and Methods

3.1 Material

Within the scope of this study, 1/1 Plain, 3/2 Twill (Z) and 4/1 Satin were selected as the weave type. For each weave pattern, four different weft densities were used by keeping the warp thread densities constant. To understand the effect of filament fineness, the weft yarn samples with a linear density of 110 dtex were used with 2 different conventional filament fineness (3.05 dtex and 1.14 dtex) and 3 different microfilament fineness (0.76 dtex, 0.57 dtex and 0.33 dtex). The data set were obtained from the experimental test results of Kaynak H.K doctoral thesis [1]. The fabric samples were applied breaking strength and breaking elongation test for both warp and weft direction according to TS EN ISO 13934-1: 2002 standard. Totally 20 different densities were taken for each weave type and 10 different experiments were applied to each density, and 600 experimental data were obtained for three weave types. Breaking strength and breaking elongation tests were applied in the warp and weft directions separately. 600 data were obtained in the weft and warp directions for each mechanical property. All fabric samples were conditioned according to TS EN ISO 139 (2008) in the standard atmosphere of 20 ± 2 °C and $65 \pm 4\%$ relative humidity before the tests were performed.

3.2 Methods

3.2.1 ANN model

In order to create an ANN with a high prediction accuracy, different neural network architecture can be built by changing number of hidden layer, number of neurons, learning rate or learning function. In ANN architecture developed in this study, number of filament, weave density, and weave type parameters were used as input variable and weft-warp way breaking strength and warp-weft way breaking elongation were selected as output. Different structures were attempted by changing number neurons in first and second layers of ANN so that the highest training accuracy was obtained. Totally 400 test results that was used for training and remaining 200 test results were used for testing operations. Separate networks were set up for each output, it was seen that each mechanical performance was affected differently by physical properties. The training input matrix of the ANN model were created by taking the experimental data made in 10 measurements according to the density values of the fabrics for each filament fineness in the fabric samples. Using the multilayer perceptron model, separate networks were built for each output performance property. Each output network is trained with the “*trainlm*” training function. A two-layer network was formed by trial and error method and the number of neurons used at each layer were shown in Table 1. In the training phase, the maximum iteration (epoch) numbers was 10000. During the train operation of each network, 70% of training data set was used for training process, 15% was used for validation and 15% was used for network testing. After the network is trained, overall correlation (R) values were obtained between target and output values as given Table 1.

Table 1. Constructed ANN Models

ANN Results					
	Training Rate	Learning Rate	Number of neuron first layer	Number of neuron second layer	R
Weft Breaking Strength	0.8	0.8	10	10	0.991
Warp Breaking Strength	0.85	0.8	20	15	0.915
Weft Breaking Elongation	0.8	0.8	15	10	0.974
Warp Breaking Elongation	0.85	0.75	30	10	0.938

3.2.2 Fuzzy Logic model

Since expert opinion was used while creating the Fuzzy Logic model, four physical properties were estimated in a single model. 400 experimental data were used to build the model, while 200 experimental data input and output which the same as established ANN model were used to calculate the model's accuracy. The purpose of this is to make an accuracy comparison between the two models. While creating the rules in the Matlab interface, the range with the highest frequency was given to the highest rate. For example, the weft breaking strength experimental data in plain pattern type ranged from 510 to 540, but concentrated between 510 and 520. Therefore, the desired result is more likely to be in this range. In fuzzy logic, a higher ratio is given to this range when creating the rules. The relationship between input variables and output variables were defined as “*if then*” statement rules such as “*If (number_of_filament is 36) and (weave_density is 2464) and (weave is plain) then (weft_breaking_strength is 600) (0.8)*”. A total of 313 rules were created to evaluate the different relationships between input and output. Since the rules created without giving a ratio decrease the accuracy of the model, each rule has been given a occurrence rate according to its frequency. The input values have been converted to fuzzy values by “*trimf*” membership function. The defuzzification method of the Fuzzy Logic model created with the *Mamdani* method was determined as centroid.

3.2.3 Mean Absolute Percentage Error

The mean absolute percentage error (MAPE) method was used to calculate the validity and reliability of the forecasting methods. MAPE is calculated as given Equation 3:

$$MAPE = \frac{100}{n} \sum_j^n \frac{|P_j - A_j|}{|A_j|} \quad (3)$$

Where n denotes size of the data set, A_j the actual values, P_j the predicted values.

4. Results

4.1 Prediction Results of ANN

In order to evaluate the success ratio of the networks, data set was divided as training and testing. For testing operation, 20 fabric samples were not entered into the training process of ANN. The actual and predicted results of each output variable was given in Figure 1. The linear regression of the predicted results were given in Figure 1. It is clearly seen that the experimental and the predicted mechanical properties are close to each other. While the highest regression value ($R^2=0.98$) was obtained with “Weft Breaking Strength”, the lowest regression ($R^2=0.81$) was obtained with “Warp Breaking Elongation”. According to the actual and predicted values of each output, MAPE values were calculated (Table 2). The lowest and highest MAPE values were obtained as 1.86 with “Warp Breaking Elongation” and 5.92 with “Weft Breaking Strength” respectively.

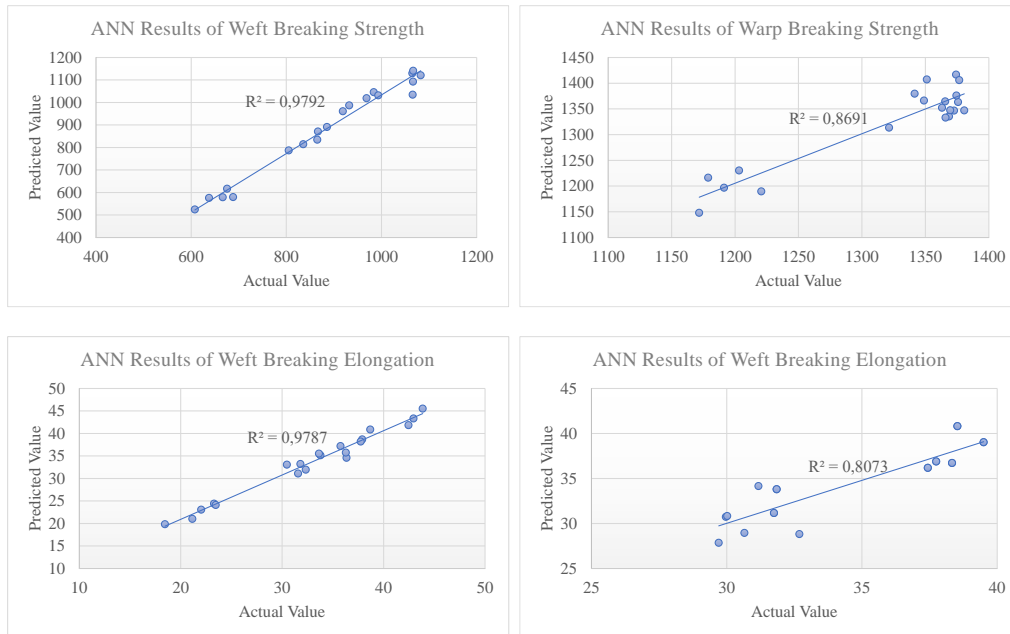


Figure 1. Linear Regression of Each ANN Output

Table 2. MAPE and Regression Results of Each ANN Output

		ANN Results	
		R^2	MAPE
Weft	Breaking	0.98	5.93
Strength			
Warp	Breaking	0.87	1.86
Strength			
Weft	Breaking	0.98	3.56
Elongation			
Warp	Breaking	0.81	4.26
Elongation			
Av		0.90	3.90

4.2 Prediction Results of Fuzzy Logic

In the fuzzy model created, the best values were reached with the trimf function as a result of trial and error by taking expert opinion. The linear regression between predicted values and actual values were given Figure 2.




Figure 2. Linear Regression of Each FL Output

The best MAPE value was obtained with warp breaking strength as 1.324, while the highest MAPE value was weft breaking elongation with 3.7 (Table 3) which indicates that the fuzzy model gave confidence result for prediction breaking elongation and breaking strength of the multifilament woven fabrics.

Table 3. MAPE and Regression Results of Each FL Output

		FL Results	
		R ²	MAPE
Weft	Breaking Strength	0.940	3.258
Warp	Breaking Strength	0.925	1.324
Weft	Breaking Elongation	0.968	3.706
Warp	Breaking Elongation	0.901	2.655
Av		0.93	2.74

5. Conclusion and Recommendation

According to the results of applied artificial intelligence method, it can be obviously said that the mechanical performance of multifilament and microfilament woven fabrics can be

predicted with very high accuracy. The regression values of each method are close to each other but it can be stated that FL has slightly higher accuracy than ANN method. When MAPE values are compared, it can be seen that the error percentage of both methods is very low. The test procedure of the fabric mechanical performance is difficult and takes long time. On the other hand, production of woven fabric samples requires higher cost. By using artificial intelligence methods and the data base of the company that comprise already performed test results, the new sample fabric production and test application can be eliminated. It will be very useful especially for the weaving companies that are always producing new designs and making fabric development.

References

- [1] H. K. Kaynak, ‘Filament mikroliflerden elde edilmiş iplikler kullanılarak dokunan kumaşların performans özelliklerinin araştırılması’, PhD Thesis, Doktora Tezi, Çukurova Üniversitesi, 271s, 2013.
- [2] E. C. Doran and C. Sahin, ‘The prediction of quality characteristics of cotton/elastane core yarn using artificial neural networks and support vector machines’, *Textile Research Journal*, vol. 90, no. 13–14, pp. 1558–1580, 2020.
- [3] E. C. Doran, C. Sahin, O. Balci, and M. Canak, ‘P088_0311_ An Artificial Neural Network approach for predicting the performance of cotton/Elastane Blend Core Yarn’, in *Proceedings of the 19th World Textile Conference-Autex 2019*, 2019, pp. 3–3.
- [4] F. Wang, Z. Chen, C. Wu, Y. Yang, D. Zhang, and S. Li, ‘A model for predicting the tensile strength of ultrafine glass fiber felts with mathematics and artificial neural network’, *The Journal of The Textile Institute*, vol. 112, no. 5, pp. 783–791, 2021.
- [5] E. Türker, ‘A research on estimation of the weave fabric properties with the artificial neural networks’, *Textile and Apparel*, vol. 27, no. 1, pp. 10–21, 2017.
- [6] Z. E. Kanat and N. Özdil, ‘Application of artificial neural network (ANN) for the prediction of thermal resistance of knitted fabrics at different moisture content’, *The journal of the textile institute*, vol. 109, no. 9, pp. 1247–1253, 2018.
- [7] M. Kalkanci, M. Sinecen, and G. Kurumer, ‘Prediction of dimensional change in finished fabric through artificial neural networks’, *Textile and Apparel*, vol. 28, no. 1, pp. 43–51, 2018.
- [8] A. H. Taieb, S. Mshali, and F. Sakli, ‘Predicting fabric drapability property by using an artificial neural network’, *Journal of Engineered Fibers and Fabrics*, vol. 13, no. 3, p. 155892501801300320, 2018.
- [9] V. S. A. KARGI, ‘A comparison of artificial neural networks and multiple linear regression models as in predictors of fabric weft defects’, *Textile and Apparel*, vol. 24, no. 3, pp. 309–316, 2014.
- [10] R. Chattopadhyay, ‘Artificial neural networks in yarn property modeling’, in *Soft Computing in Textile Engineering*, Elsevier, 2011, pp. 105–125.

- [11] M. Alsayed, H. İ. Çelik, and H. K. Kaynak, ‘Predicting air permeability of multifilament polyester woven fabrics using developed fuzzy logic model’, *Textile Research Journal*, vol. 91, no. 3–4, pp. 385–397, 2021.
- [12] R. Safitri and T. Mulyana, ‘Optimizing Woven Fabric Defect Detection Using Image Processing and Fuzzy Logic Method at PT. Buana Intan Gemilang’, 2017.
- [13] T. Hamdi, A. Ghith, and F. Fayala, ‘Fuzzy Logic Method for Predicting the Effect of Main Fabric Parameters Influencing Drape Phenomenon’, *Autex Research Journal*, vol. 20, no. 3, pp. 220–227, 2020.
- [14] S. Chakraborty, P. Chatterjee, and P. P. Das, ‘Cotton fabric selection using a grey fuzzy relational analysis approach’, *Journal of the Institution of Engineers (India): Series E*, vol. 100, no. 1, pp. 21–36, 2019.
- [15] S. Chakraborty and P. P. Das, ‘Fuzzy Modelling and Parametric Analysis of the Ring Spinning Process’, *Tekstil ve Mühendis*, vol. 26, no. 114, pp. 132–148, 2019.

S-46 UZUN SÜRELİ KISA BELLEK AĞI YÖNTEMİ İLE TRAFİK YOĞUNLUK TAHMİNİ

Sümeyye AYDIN ¹, Murat TAŞYÜREK ², Celal ÖZTÜRK ³

¹ Bilgisayar Mühendisliği, Kayseri Üniversitesi, Türkiye, sumeyyeaydin@kayseri.edu.tr

² Bilgisayar Mühendisliği, Kayseri Üniversitesi, Türkiye, murattasyurek@kayseri.edu.tr

³ Bilgisayar Mühendisliği, Erciyes Üniversitesi, Türkiye, celal@erciyes.edu.tr

Özet

Nüfus yoğunluğunun fazla olduğu ve buna bağlı olarak ulaşım sistemlerinin yaygın olarak kullanıldığı şehirlerde günlük planlanan işlerinin etkilenmemesi için trafik sistemlerinin çok etkin yönetilmesi gerekmektedir. Akıllı Ulaşım Sistemi (AUS), farklı ulaşım modları ve trafik yönetimi ile kullanıcıların daha iyi bilgi sahibi olmalarını ve ulaşım ağlarının daha güvenli, daha koordineli ve daha akıllı kullanımını sağlayan sistem olarak ifade edilmektedir. AUS modellerinin en önemli bileşenlerinden bir tanesi trafik yoğunluğunun önceden hesaplanabilmesidir. Kavşakların trafik yoğunlukları birbirine bağlı olan kavşakları etkilediğinden ve zamansal olarak değişiklikler gösterdiğinden zor bir problemdir. Derin öğrenme yöntemi trafik yoğunluk tahmininde son yıllarda yaygın kullanılan yöntemlerdendir. Bu çalışmada, İstanbul Büyükşehir Belediyesi'ne (İBB) ait açık veriler derin öğrenme yöntemlerinden uzun süreli kısa bellek ağı (LSTM) modeli ile belirli bir bölgenin trafik yoğunluğu tahmin edilmesi için önerilmiştir. Önerilen LSTM tabanlı modelin performansı klasik derin öğrenme yöntemi (DL) ile karşılaştırılmıştır. Deneysel değerlendirmeler, önerilen LSTM yönteminin DL yöntemine göre trafik yoğunluk tahmininde daha başarılı tahminler elde ettiğini göstermektedir.

Anahtar Sözcükler: Akıllı ulaşım sistemi; Derin öğrenme; İstanbul trafik yoğunluk tahmini; LSTM.

Abstract

In cities where population density is high and transportation systems are widely used, it is necessary to manage traffic systems more effectively in order not to affect the daily planned works. The Intelligent Transportation System (AUS) is expressed as a system that provides users with better information and safer, more coordinated and smarter use of transportation networks with different transportation modes and traffic management. One of the most important components of AUS models is the calculation of traffic density. The traffic density of intersections is a difficult problem as it affects other interconnected intersections and varies in time. Deep learning method is a widely used method in traffic density estimation, in recent years. In this study, it has been proposed to estimate the traffic density of a certain region with the long-term short memory network (LSTM) model, which is one of the deep learning methods, by using open data of Istanbul Metropolitan Municipality. The performance of the proposed LSTM-based model is compared with the classical deep learning method (DL). Experimental evaluations show that the proposed LSTM method is more successful in traffic density estimation than the DL method.

Keywords: *Intelligent transportation systems; Deep learning; Istanbul traffic density prediction; LSTM.*

1. Giriş

Akıllı Ulaşım Sistemleri (AUS) teknolojileri, gelişmiş iletişim teknolojilerini ulaşım altyapısına ve araçlara entegre ederek ulaşım güvenliğini ve hareketliliğini geliştirir ve üretkenliği artırır. AUS teknolojilerinin en önemli bileşenlerinden bir tanesi trafik yoğunluğunun tahmin edilebilmesidir. Yoğunluk, ulaşım kapasitesini aşan trafik talebi olarak ifade edilmektedir. Bir kavşağın trafik yoğunluğu birbirine bağlı olan diğer kavşakları da etkilediğinden ve zamansal olarak değişiklik gösterdiğinden dolayı zor bir problemdir. Trafik yoğunluğu günlük yaşam planlaması etkileyen ve dünyanın her tarafında giderek yaygınlaşan ciddi bir sorundur. Bu bildiride, LSTM tabanlı derin öğrenme yöntemi ile İstanbul Büyükşehir Belediyesi’ne (İBB) ait açık veriler kullanılarak belirli bölgede bulunan kavşakların yoğunluğun tahmin edilmesi önerilmiştir.

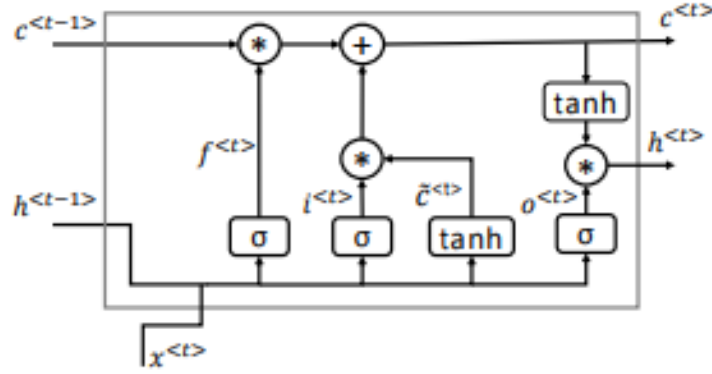
Derin öğrenme yöntemleri son zamanlarda doğal dil işleme ve gerçek zamanlı nesne algılama gibi birçok problemin çözümünde yaygın olarak kullanılmaktadır [1-3]. Literatürde, veri kümesine ve problemin türüne göre çok farklı derin öğrenme modelleri bulunmaktadır. Zamana bağlı değişen süreçlerde bazı derin yöntemleri yetersiz kalmaktadır. Tekrarlayan Sinir Ağları (RNN) zamana bağlı ilişkiler içeren veri kümelerinde başarılıdır [4]. RNN modeli ilk kez 1980’li yıllarda tanıtılmıştır [5]. Bununla birlikte, geleneksel RNN yöntemleri, girdi verisindeki uzun süreli bağımlılıkları yakalama sorunuyla karşı karşıyadır. Bu sorunu çözmek için uzun bir kısa süreli bellek ağı (LSTM) önerilmiştir [6]. Ma vd., uzak mikro yazılım sensör verileriyle trafik hızı tahmin etmek için LSTM modelini uygulamıştır [7]. Tian vd., trafik akışı tahmini için LSTM RNN modelini önermiştir [8] ve LSTM RNN yönteminin parametrik olmayan modellerin çoğundan daha iyi performansla sahip olduğunu tespit etmiştir [8]. Li vd., trafik akışı tahmini için LSTM ve GRU modelinin performansını değerlendirmiştir [9]. LSTM, optimum zaman gecikmelerini otomatik olarak hesaplayabildiğinden ve daha uzun zaman aralıklı zaman serilerinin özelliklerini yakalayabildiğinden, trafik akış tahmininde LSTM modeli ile daha iyi bir performans elde edilebilir [8].

Bu çalışmada, İBB açık ulaşım verisi kullanılarak trafik yoğunluğunun LSTM tabanlı derin öğrenme yöntemi ile tahmin edilmesi önerilmiştir. İstanbul, Türkiye’de nüfus yoğunluğu bakımından en kalabalık ve trafik sorunu da en büyük olan ildir [10,11]. Önerilen yöntem ile işe gidiş ve iş çıkış saatleri gibi trafik yoğunluğun fazla olduğu zaman dilimlerindeki belirli kavşakların trafik yoğunluklarının tahmin edilmesi amaçlanmaktadır. Önerilen LSTM tabanlı yöntemin performansı gerçek veriler üzerinde klasik derin öğrenme (DL) yönteminin performansı ile karşılaştırılmıştır.

2. Yöntem

2.1. LONG SHORT-TERM MEMORY (LSTM)

LSTM derin öğrenme algoritması, 1997’de Hochreiter ve Schmidhuber tarafından RNN mimarisinin dezavantajlarını yok etmek için ortaya atılan bir tekrarlayan sinir ağı olarak bilinmektedir [12]. LSTM ağının en önemli özelliği ağ ile ilgili geçmiş bilgileri de değerlendirmesidir. Temel LSTM diyagramı Şekil 1’de verilmiştir [13, 15].



Şekil 1. Temel LSTM blok diyagramı

LSTM ağları, üç iç hücre kapısına bölünerek RNN modelinin kaybolan gradyanları sorununu ele alır ve bilgileri uzun menzilli bir bağlamda depolamak için sözde bellek hücreleri oluşturur [14]. Tipik bir LSTM yapay sinir ağı hücresi giriş kapısı, giriş modülasyon kapısı, unutmaya kapısı ve çıkış kapısı olmak üzere temel olarak dört kapı ile yapılandırılır: Hücre kapıları tarafından kontrol edilir ve kapının durumuna göre değeri koruyabilir veya değeri sıfırlayabilir. Özellikle, mevcut hücre değerinin unutulup unutulmayacağını (unutma kapısı f_t), girişini okuyup okumayacağını (giriş kapısı i_t) ve yeni hücre değerini çıkışını (çıkış kapısı o_t) kontrol etmek için üç kapı kullanılır; ek olarak, \bar{c}_t adında bir giriş modülasyon kapısı vardır. LSTM ağı kapıları ve yürüttükleri işlemler, denklemler 1-6’da sunulmuştur.

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (2)$$

$$\bar{c}_t = \tanh(W_{xc}x_t + W_{ch}h_{t-1} + b_c) \quad (3)$$

$$c_t = f_t c_{t-1} + i_t \bar{c}_t \quad (4)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

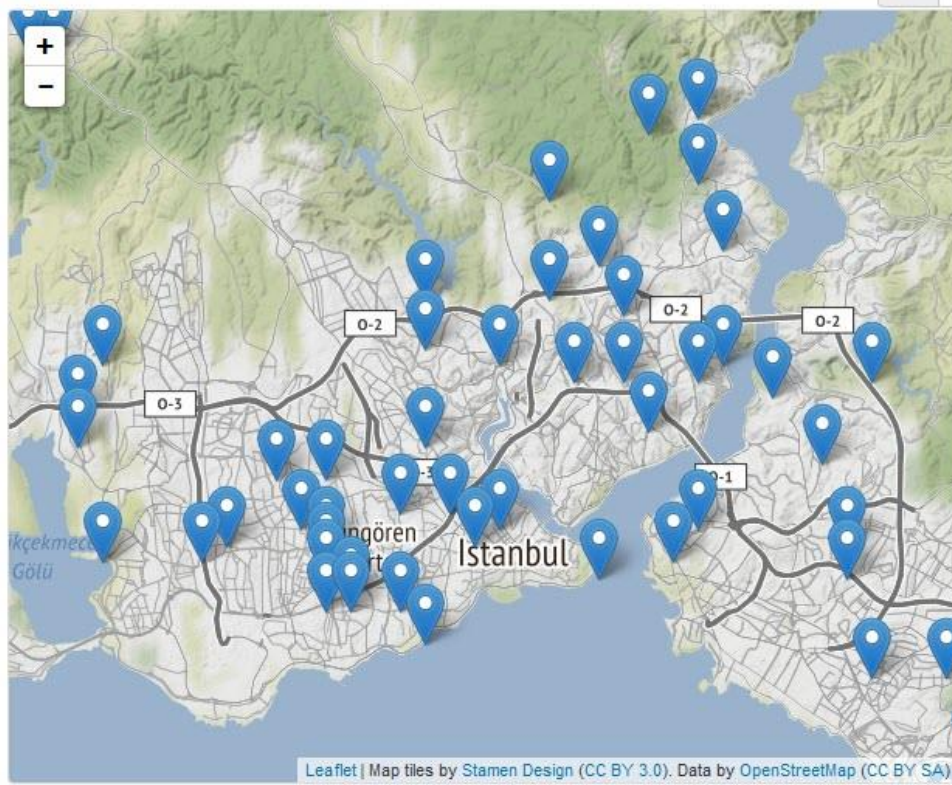
Giriş kapısı dışarıdan yeni bir giriş noktası alır ve yeni gelen verileri işler. Bellek hücresi giriş kapısı, son yinelemede LSTM yapay sinir ağı hücresinin çıkışından girdi alır. Unutmaya kapısı, çıktı

sonuçlarının ne zaman unutulacağına karar verir ve böylece giriş dizisi için en uygun zaman gecikmesini seçer. Çıkış kapısı, hesaplanan tüm sonuçları alır ve LSTM yapay sinir ağı hücresi [6] için çıktı üretir. LSTM modelleri, RNN ağının yapısına dayalı olarak bilgi işlem düğümlerini yeniden tasarlar.

3. Deneysel Değerlendirmeler

3.1. Veri Kümesi

Bu çalışmada, İstanbul Büyükşehir Belediyesi'ne ait 2020 Ağustos ayı trafik yoğunluk verileri kullanılmıştır [16]. İBB açık veri kümesi, zaman bilgisi, kavşakların konumları, kavşak bazlı araç sayısı, bu araçlara ait ortalama hız, maksimum hız ve minimum hız bilgilerini içermektedir. Bu çalışmada kullanılan veri kümesi 1.048.575 satır kayıt içermektedir. Bu çalışmada kullanılan kavşakların mekânsal konumları Şekil 2'de gösterilmiş ve veri kümesine ait özet bilgi Tablo 1'de sunulmuştur.



Şekil 2. Kullanılan veri setindeki hedef istasyonların konumu

Tablo 1'de genel bilgileri sunulan İBB açık veri kümesi detaylıca incelendiğinde, özellikle işe gidiş ve işten çıkış saatlerinde araç sayısında artış yaşanırken gece saatlerinde düşüş gözlemlenmiştir. Bu inceleme, trafikte bulunan araç sayısı zamana bağlı olarak değiştiğini göstermektedir. Trafik yoğunluğu zamana göre değiştiğinden dolayı eğitim işlemi öncesinde veriler tarih ve saat bazlı sıralanmıştır. Ayrıca saat verisi girdi olarak veri kümesine eklenmiştir.

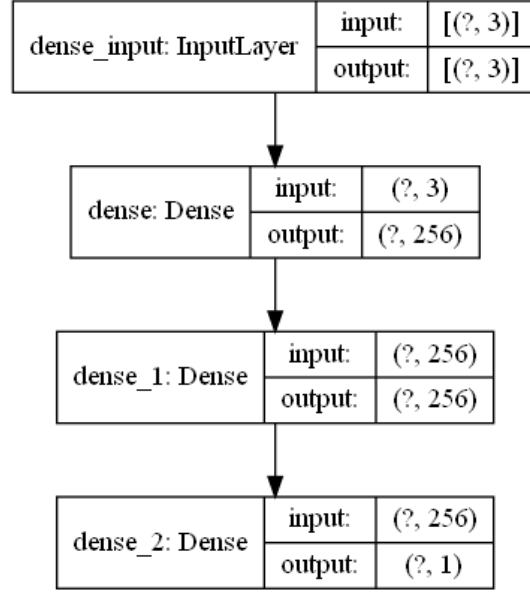
Trafikteki araç sayısının tespitinde sadece ilgili istasyondan belli zaman öncesine ait araç sayısı verisinin bilinmesi yeterli değildir. Bir kavşak kendisine yakın olan kavşakların yoğunluğundan da etkilenmektedir. Bir kavşak genellikle 4 koldan oluşur ve bu yüzden her bir kavşağa yakın olan 4 kavşağın bilinmesi önemlidir. Trafik yoğunluğu tahmin edilecek kavşağa yakın kavşaklardaki araç sayısının da LSTM modeline girdi olarak verilmesi tahmin yeteneğini güçlendirilecektir. Bu nedenle her bir kavşağın mekânsal olarak kendisine en yakın olan 4 kavşak mekânsal mesafe olarak Öklid mesafesi kullanılarak belirlenmiştir. Her bir kavşağın en yakın komşu olan 4 kavşak belirlendikten sonra aynı tarih ve saat diliminde bu komşu kavşaklarda bulunan araç sayıları yoğunluğu tahmin edilecek kavşak için girdi verisi olarak kullanılmıştır.

Tablo 1. Veri Sözlüğü.

Kolon	Tip	Etiket	Açıklama
DATE_TIME	text	Tarih	Tarih ve Saat bilgisini içeren alandır. Veri formatı YYYY-MM-DD HH24:MI:SS formatındadır. * Tarih kırılımı saatliktir.
LONGITUDE	text	Boylam	Boylam bilgisini içeren alandır.
LATITUDE	text	Enlem	Enlem bilgisini içeren alandır.
GEOHASH	text	Geohash	Enlem ve Boyamların Geohash Değeri Geohash uzunluğu 6’dır.
MINIMUM_SPEED	text	Asgari Hız	Verilen saatte ilgili geohash alanı için asgari hız (km/s cinsinden).
MAXIMUM_SPEED	text	Azami Hız	Verilen saatte ilgili geohash alanı için azami hız (km/s cinsinden).
AVERAGE_SPEED	text	Ortalama Hız	Verilen saatte ilgili geohash alanı için ortalama hız (km/s cinsinden).
NUMBER_OF_VEHICLES	text	Tekil Araç Sayısı	Verilen saatte ilgili geohash alanı içinde bulunan farklı araç sayısı.


3.2 Model ayarları

LSTM modelinde katman sayısı üzerinde test yapılarak en uygun katman sayısı iki olarak belirlenmiş ve iki katman kullanılmıştır. Derin öğrenme yöntemi kullanılarak yapılan çalışmada ise üç katman kullanılmıştır. Modelin içeriği ve yapısı şekil 3’te verilmiştir.




Şekil 3. Kullanılan derin öğrenme modeli yapısı

LSTM metodu ile çalışmada optimizasyon yöntemi olarak Adam algoritması kullanılmıştır. Adam, eğitim verilerine dayalı yinelemeli ağ ağırlıklarını güncellemek için klasik stokastik gradyan iniş prosedürü yerine kullanılabilen bir optimizasyon algoritmasıdır. Modellerin hata grafikleri Şekil 4 ve 5’te sunulmuştur. Şekil 4 ve Şekil 5’teki grafiklerden de görüldüğü üzere eğriler giderek birbirine yaklaştığından dolayı hem DL yöntemi hem de LSTM yöntemi eğitimleri başarılı olduğu rahatlıkla belirtilebilir.



Şekil 4. *sxk3r9* istasyonuna ait derin öğrenme model hatası.



Şekil 5. *sxk3r9* istasyonuna ait LSTM model hatası.

3. Bulgular


Klasik derin öğrenme ve LSTM yöntemlerinin deneysel değerlendirmeleri İBB'den alınan gerçek veriler kullanılarak yapılmıştır. Yöntemlerin başarımlarını irdelemek için değerlendirme kriteri ortalama hata kare kökü (RMSE) ve ortalama mutlak hata (MAE) değerleri kullanılmıştır. Deneysel değerlendirme yapılan istasyon bilgileri ve yöntemlerin değerleri Tablo 2'de sunulmuştur.

Deneysel değerlendirme sonuçları (Tablo 2) incelendiğinde LSTM yönteminin genellikle DL yöntemine kıyasla RMSE ve MAE değerlerinin daha düşük hata sonuçları vermiştir.


Tablo 2. Derin öğrenme ile LSTM yöntemlerinin karşılaştırılması.

İstasyon Geohash	Derin Öğrenme Yöntemi ile RMSE	LSTM Yöntemi ile RMSE	Derin Öğrenme Yöntemi ile MAE	LSTM Yöntemi ile MAE
sxk3q9	4.748	4.797	3.799	3.816
sxk3r9	37.584	20.580	29.115	15.152
sxk3rf	16.447	13.353	12.387	9.960
sxk3w2	6.165	5.405	4.883	4.282
sxk3w6	41.776	31.340	32.604	23.649
sxk90y	20.193	16.812	16.137	13.251
sxk91n	5.763	6.074	5.311	4.745
sxk91u	8.658	8.872	7.300	7.111
sxk91w	7.070	7.164	6.984	5.317
sxk92b	10.741	11.321	8.438	8.753
sxk92c	7.757	7.358	6.053	5.582
sxk92e	6.276	6.160	4.547	4.606
sxk92f	7.234	7.468	6.155	5.710
sxk92q	9.660	9.777	8.218	7.650
sxk93s	16.429	13.007	13.304	8.803
sxk966	6.577	7.261	5.696	5.532
sxk96e	7.934	6.706	5.193	5.118
sxk96h	31.072	21.894	24.022	17.577
sxk99b	9.885	9.834	7.279	7.291
sxk99y	14.418	8.205	8.745	6.225

Deney sonucunda çizdirilen kavşaklara ait tahmin edilen taşıt sayısı ve gerçekte olan taşıt sayısı grafikleri Şekil 6 ve Şekil 7’de verilmiştir. DL yönteminin çalışması sonucu çizdirilen (Şekil 6) tahmin değerleri ile gerçek değerler arasındaki yakınlıkta ufak sapmalar görülürken, LSTM yöntemine ait grafikte (Şekil 7) tahminlerin gerçek değerlere oldukça yaklaştığı görülmektedir.



Şekil 6. sxk3r9 istasyonu için *derin öğrenme yöntemiyle test ve tahmin verisi karşılaştırılması.*



Şekil 7. sxk3r9 istasyonu için *LSTM yöntemiyle test ve tahmin verisi karşılaştırılması.*

Sonuçlar

Günümüzde trafik sorunu insanların zamanının büyük bir kısmını almaktadır. Ayrıca nüfus yoğunluğunun fazla olduğu yerlerde trafik sistemlerinin yönetilmesi daha önemlidir. Trafik yoğunluğu sorunun üstesinden gelmek için Akıllı Ulaşım Sistemleri (AUS) kullanılmaktadır. AUS modellerinin en önemli bileşenlerinden bir tanesi trafik yoğunluğun önceden hesaplanabilmesidir. Bu amaçla Türkiye’de bulunan en kalabalık ve trafiği en yoğun olan İstanbul iline ait veriler üzerinde çalışılarak, trafikteki araç sayısının tespit edilebilmesi üzerine bir model önerilmiştir.

Trafik yoğunluğu tahmini için LSTM modeliyle derin öğrenme yaklaşımı önerilmiştir. LSTM, optimum zaman gecikmelerini otomatik olarak hesaplayabildiğinden ve daha uzun zaman aralıklı zaman serilerinin özelliklerini yakalayabildiğinden, trafik akış tahmininde daha yüksek performans sergilemiştir. Deney sonuçları incelendiğinde 20 kavşak için derin öğrenme yöntemi ile çıkan toplam RMSE değeri 276.387 iken LSTM yöntemi kullanılarak çıkan toplam RMSE değeri 223.388 çıkmıştır. Deneysel değerlendirmeler, LSTM tabanlı yöntemlerin klasik derin öğrenme yöntemine göre daha başarılı olduğunu göstermiştir.

Gelecekteki çalışmalar kapsamında, trafik yoğunluğu tahmini için diğer derin öğrenme algoritmalarının performanslarının araştırılması ve etkinliklerinin incelenmesi planlanmaktadır.

Teşekkür

Bu çalışma kapsamında kullanılan veri temininde saatlik trafik yoğunluk verilerini paylaştığı için İstanbul Büyükşehir Belediyesi'ne teşekkür ederiz.

Referanslar

- [1] D. Ravi, C. Wong, F. Deligianni, M. Berthelot; J. Andreu-Perez, B. Lo and G. Yanget, "Deep Learning for Health Informatics," in IEEE Journal of Biomedical and Health Informatics, vol. 21, no. 1, pp. 4-21, doi: 10.1109/JBHI.2016.2636665, Jan. 2017
- [2] T. Young, D. Hazarika, S. Poria and E. Cambria, "Recent Trends in Deep Learning Based Natural Language Processing [Review Article]," in IEEE Computational Intelligence Magazine, vol. 13, no. 3, pp. 55-75, doi: 10.1109/MCI.2018.2840738, Aug. 2018.
- [3] A. Şeker, B. Diri ve H. H. Balık, "Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme", Gazi Mühendislik Bilimleri Dergisi (GMBD), c. 3, sayı. 3, ss. 47-64, Aralık 2017
- [4] A. J. P. Samarawickrama, T. G. I. Fernando, "A recurrent neural network approach in predicting daily stock prices an application to the Sri Lankan stock market," 2017 IEEE International Conference on Industrial and Information Systems (ICIIS), pp. 1-6, doi: 10.1109/ICIINFS.2017.8300345, 2017
- [5] N. Buduma and N. Locascio, Fundamentals of Deep Learning. Designing Next-Generation Machine Intelligence Algorithms, O'Reilly Media, 172-217, 2017.
- [6] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," in Neural Computation, vol. 9, no. 8, pp. 1735-1780, 15 Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [7] X. Ma, Z. Tao, Y. Wang, H. Yu, and Y. Wang, "Long short-term memory neural network for traffic speed prediction using remote microwave sensor data" Transportation Research Part C: Emerging Technologies, 54, pp. 187–197, 2015.
- [8] Y. X. Tian and P. Li, "Predicting Short-term Traffic Flow by Long Short Term Memory Recurrent Neural Network", 2015 IEEE International Conference on Smart City/SocialCom/SustainCom (SmartCity), pp. 153-158, 2015.
- [9] R. Fu, Z. Zhang and L. Li, "Using LSTM and GRU neural network methods for traffic flow prediction", Youth Academic Annual Conference of Chinese Association of

- Automation (YAC), pp. 324-328, 2016.
- [10] TUIİK, Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları 2013, Türkiye İstatistik Kurumu Haber Bülteni, Sayı: 37210, 04.Şubat.2021.
- [11] TUIİK, “İllere göre motorlu kara taşıtları sayısı”, Available: <https://data.tuik.gov.tr/Bulten/Index?p=Road-Motor-Vehicles-December-2020-37410>, [Accessed Aralık, 2020].
- [12] K. Chakraborty, K. Mehrotra, C. K. Mohan and S. Ranka, “Forecasting The Behavior of Multivariate Time Series Using Neural Networks”, Neural Networks 5(6):961-970, 1992.
- [13] Y. Duan, Y. L.V. and F. Wang, "Travel time prediction with LSTM neural network," 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), 2016, pp. 1053-1058, doi: 10.1109/ITSC.2016.7795686, 2016.
- [14] F. A. Gers, J. Schmidhuber, F. A. Cummins, “Learning to forget: Continual prediction with LSTM” Neural Computation, 12 (10), pp. 2451-2471, 2000.
- [15] S. Samui, I. Chakrabarti, S.K. Ghosh, “Tensor-Train Long Short-Term Memory for Monaural Speech Enhancement” arXiv preprint arXiv:1812.10095, 2018
- [16] Ulaştırma Daire Başkanlığı, “Saatlik Trafik Yoğunluk Veri Seti, Ağustos 2020 Trafik Yoğunluk Verisi” 13 Aralık, 2020.

S-20 SEZGİSEL ALGORİTMALARLA TOPLAM POTANSİYEL ENERJİ OPTİMİZASYONU YÖNTEMİNİN YAPISAL ÇÖZÜMLEMEDE ÜSTÜNLÜKLERİ VE GELİŞMELER

Yusuf Cengiz TOKLU ^{1,*}, Gebrail BEKDAŞ ², Sinan Melih NİGDELİ ³

¹ İnşaat Mühendisliği, Beykent Üniversitesi, Türkiye, cengiztoklu@gmail.com

² İnşaat Mühendisliği, İstanbul Üniversitesi- Cerrahpaşa, Türkiye, bekdas@iuc.edu.tr

³ İnşaat Mühendisliği, İstanbul Üniversitesi- Cerrahpaşa, Türkiye, melihnig@iuc.edu.tr

Özet

Yapay zekâ optimizasyon algoritmaları olan Sezgisel Algoritmalar (SAlar) bilim ve mühendislik hayatına hızlı bir giriş yapmış olup sayıca ve kullanım alanı olarak büyük gelişmeler göstermektedir. Yapısal hesaplamalar alanında bu algoritmalar yapı optimizasyonunda yani tasarımda çokça kullanılmaktadır. Yapı analizi için ise çok sayıda analitik çözümler vardır, bu çözümler Sonlu Elemanlar Yöntemi (SEY) ile kolayca uygulanabilir hale gelmiş, özellik göstermeyen problemler için başka çözüm yöntemleri aranmasına gerek kalmamıştır. Ne var ki bu yöntem ancak belli sistemleri çözebilmektedir. Mesela çözümün tek olmadığı durumlarda, yapının labil ya da yetersiz bağlı olduğu durumlarda, ya da burkulma sonrasında SEY yetersiz kalmaktadır. Ayrıca malzemenin doğrusal olmadığı, büyük deformasyonlara gidildiği durumlarda da SEY ile çözüm elde edilmesi her uygulayıcı için mümkün olmamaktadır. Bu sorunlar yapının toplam potansiyel enerjisinin en küçüklenmesi prensibine dayanan ve en küçüklemeye SAlar kullanılmasını öngören “Sezgisel Algoritmalarla Toplam Potansiyel Enerji Optimizasyonu (SA/TPO)” yöntemi sayesinde ortadan kalkmaktadır. Bu çalışmada bu yöntemin üstünlükleri belirtilmiş ve düzlem gerilme problemi ile yapılmış örneklerin doğrusal olmayan durumlarına ait sonuçlar irdelenmiştir.

Anahtar Sözcükler: SA/TPO; yapısal analiz; Düzlem gerilme.

Abstract

Heuristic Algorithms (HAs), which are artificial intelligence optimization algorithms, have made a rapid entry into science and engineering life and show great developments in terms of number and usage area. In the field of structural calculations, these algorithms are widely used in structure optimization, that is, in design. There are many analytical solutions for structural analysis, these solutions have become easily applicable with the Finite Element Method (FEM), and there is no need to search for other solution methods for non-specific problems. However, this method can only solve certain systems. For example, in cases where the solution is not unique, the structure is labile or insufficiently connected, or after buckling, FEM is insufficient. In addition, it is not possible for every practitioner to obtain a solution with FEM in cases where the material is not linear and large deformations are made. These problems are eliminated thanks to the “Total Potential Energy Optimization (TPO/MA) with Heuristic Algorithms” method, which is based on the principle of minimizing the total potential energy of the structure and envisages the use of HAs for minimization. In this study,

the advantages of this method are stated and the results of the nonlinear cases of the samples made with the plane stress problem are examined.

Keywords: TPO/MA; structural analysis; Plane stress.

1. Giriş

Yapı analizinde kullanılan Toplam Potansiyel Enerji Optimizasyonu (TPO) yöntemi bilinen bir yöntemdir. Ancak bu yöntem, klasik monograflarda, özellikle burkulma problemlerine yönelik, birkaç küçük problemin çözülmesinin dışında [1] bir yöntem olarak kabul edilmemektedir. Sezgisel algoritmalar (SAlar), diğer alanlar dışında, İnşaat Mühendisliği problemlerinin optimizasyonunda da sıklıkla kullanılmaktadır. Bu algoritmalar yapı alanında ise genellikle maliyet enküçüklemesi ile tasarım değişkenlerinin optimizasyonu amaçlı kullanılmaktadır. Bu konuda, örneğin makasların ağırlık, şekil ya da biçim enküçüklemesi konusunda çok sayıda çalışma mevcuttur [2-9].

Son dönemlerde teknoloji alanındaki gelişmeler, yöntemi çok bilinen toplam potansiyel enerji optimizasyonu prensibi (TPO) ve yapay zeka optimizasyon algoritmaları olan sezgisel algoritmaları (SA) bir araya getirilerek yapısal analizlerde kullanılması fikrinin ortaya çıkmasını sağlamış ve bu konu üzerinde yapılan çalışmalar sonucunda SA/TPO yöntemi geliştirilmiştir [10-23]. Bu çalışmalarda makasların ve kablolu yapıların her türlü doğrusal ve doğrusal olmayan davranışlarının, hem büyük yer değiştirmeler, hem de her türlü doğrusal – doğrusal olmayan malzeme için, kullanıcı müdahalesine gerek kalmadan incelenebileceği görülmüştür. Ayrıca bu tip yapıların çatallaşma ötesi durumlarda birden fazla çözüm olması durumlarının da kolayca analiz edilebileceği de gösterilmiştir. Bu verilerin ve yapılan ön çalışmaların ışığında, SA/TPO yönteminin Çekme – Tümlleşik (ÇT) yapılar için de çok uygun bir analiz yöntemi olduğu kanısına varılmıştır [14]. Ayrıca düzlem gerilme elemanları kullanarak doğrusal ve doğrusal olmayan özgün gerilme-şekil değiştirme bağıntıları kullanarak tünel, istinat duvar, iç basınç maruz borular gibi her türlü sistemin çözümü mümkün olmuştur [17-24].

2. Amaç

Yapı mühendislerinin hesaplama alanında iki ana uğraşısı vardır. Bunlardan bir tanesi tasarım yani dizayn, diğeri ise analiz yani çözümlerdir. Esasında tasarım da çözümlmeyi içerir. Son zamanlarda tasarımın analiz dışında kalan kısmı, yani denenecek topoloji, şekil ve boyutların belirlenmesi için SAlar çokça kullanılır olmuştur. Bu uygulamalarla yapı optimizasyonunda büyük başarılar elde edilmiştir.

Çözümlemede ise hemen hemen tek yöntem sonlu elemanlar yöntemi (SEY) olarak görülmektedir. Yapı tasarımının çözümleme kısmı da bu yöntemle yapılagelmektedir. Ne var ki SEY yöntemi ve benzer matris yöntemleri her türlü yapı analizi problemini çözmekte maalesef başarısızdır. Bu problemlere verilebilecek örnekler çoktur:

- Aşırı gerilme ya da yapım hatası nedeniyle kopan, kırılan, etkinliğini kaybeden elemanlar dolayısıyla labil hale gelen makaslar ve daha genel yapılar,

- Aşırı gerilme ya da yapım hatası dolayısıyla etkinliğini kaybeden mesnetlerden dolayı eksik bağlı (under constrained) hale gelen yapılar,

- Aynı yük altında oluşan deformasyonun tek olmadığı yapılar,

- Yükün yön değiştirmesiyle ya da belli değerleri aşması sonunda üzerindeki etkiler çekmeden basınca dönüşen kablo tipi elemanlara sahip olan yapılar, mesela ÇT yapılar.

Bu örneklere SEY yönteminin büyük deformasyonlar ve doğrusal olmayan malzemeli yapılardaki başarı eksikliği ve kullanım zorluğu da eklenebilir. Bu problemlerin çözümü için normal SEY eğitiminin üstünde bir eğitim gereklidir. Ayrıca, uygulanan P-δ yönteminde uygulanan aralıkların başka uygulayıcılarca farklı seçilmesi durumunda aynı olmayan sonuçlara ulaşılması mümkün olmaktadır. Bunun yanında özel gerilme-şekil değiştirme bağıntıları olan sistemler direk bu yöntemle çözülememektedir. SA/TPO ise bu problemleri ilave bir yöntem ile birleştirmeye gerek duymadan çözebilmektedir.

2. Materyal ve Yöntem

SA/TPO'nun esası bilinmeyenleri deplasmanlar olarak almak, bunlar cinsinden toplam potansiyel enerjiyi veren bir fonksiyon yazmak, sonra da bir sezgisel algoritma yardımıyla toplam potansiyel enerjiyi en küçükleyecek deplasmanları bulmaktır.

Örneğin 3 çubuklu 4 düğüm noktalı sistemde bilinmeyenler vektörü 4 noktanın deplasmandan sonraki koordinatlarından ibarettir:

$$\mathbf{x}^T = [x_1, y_1, x_2, y_2, x_3, y_3, x_4, y_4] \quad (1)$$

Örneğin, mesnetlerden dolayı, x_1, y_1, x_4, y_4 değerleri sıfır olacağından bilinmeyenler vektörü aşağıdaki hale dönüşür:

$$\mathbf{x}^T = [0, 0, x_2, y_2, x_3, y_3, 0, 0] \quad (1)$$

Görüldüğü gibi bilinmeyenler vektöründeki bilinmeyenlerin sayısı 4'dür, bunlar da 3. ve 4. düğüm noktalarının yüklerin uygulanmasından sonra alacakları değerlerdir. Problem de toplam potansiyel enerjinin minimum olması için bu 4 değişkenin alacağı değerlerin bulunmasıdır.

Sezgisel algoritmalar, birden fazla vektörden oluşan bir sisteme dayalı olarak çalışır. Örneğin 5 vektör ile çalışılacaksa, rastgele olarak 5 başlangıç çözümü seçilir. Bunların aşağıdaki gibi yaratıldığını düşünelim:

$$\begin{aligned} \mathbf{x}_1^T &= [0, 0, 1.6, -0.7, 3.6, 7.9, 0, 0] \\ \mathbf{x}_2^T &= [0, 0, -7.2, -3.8, 2.5, 6.8, 0, 0] \\ \mathbf{x}_3^T &= [0, 0, 3.3, -3.9, -2.5, 7.1, 0, 0] \\ \mathbf{x}_4^T &= [0, 0, 7.3, 4.6, -7.5, 25, 0, 0] \\ \mathbf{x}_5^T &= [0, 0, 6.1, -7.3, -4.6, -8.9, 0, 0] \end{aligned} \quad (3)$$

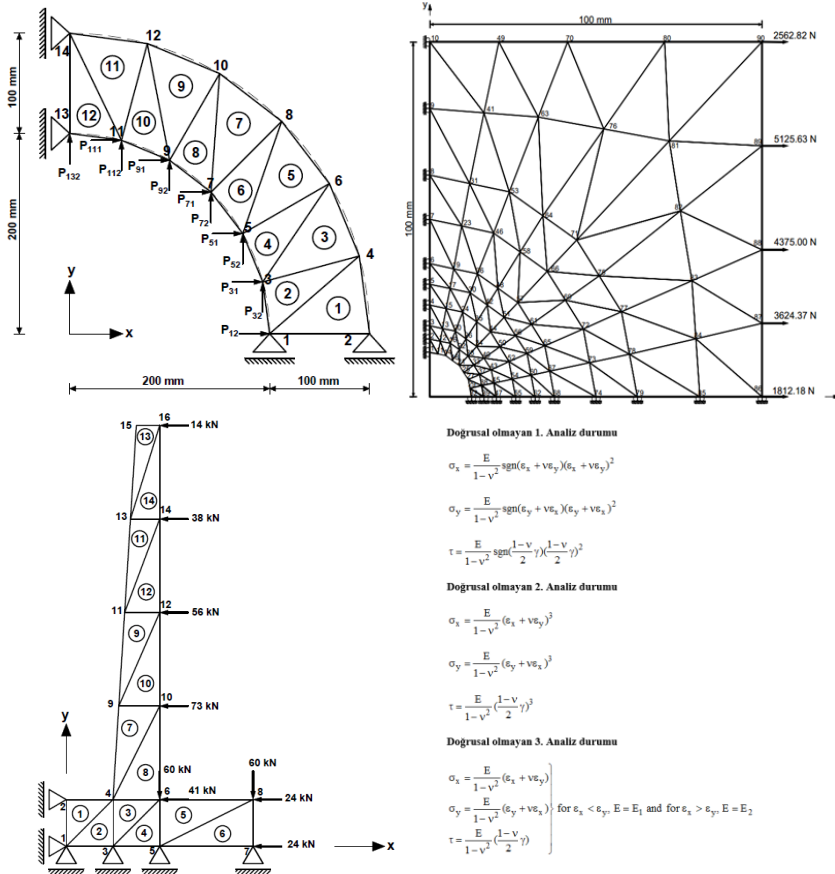
Bu 5 vektör deformasyonlardan sonra alabileceği 6 aday şekli gösterir. Bu aşamada akış diyagramının ilk aşaması tamamlanmış olmaktadır. Bundan sonra bu 5 konfigürasyon için sistemin toplam potansiyel enerjisi hesaplanarak akış diyagramının ilk değerlendirme aşaması tamamlanır.

Bu işlemten sonra SA kurallarına göre yeni aday deplasman değerleri türetilir ve sistemin toplam potansiyel enerjisi bu sonuçlar için daha az ise bu sonuçlar mevcut sonuçların yerini alır.

Yapılan çok sayıda döngü sonunda TP’lerde iyileşme görülmediği durumda sonuca ulaşıldığı düşünülerek döngüler durdurulur. Açıklanan yöntemin gelişimi ve metasezgisel yöntemler hakkında detaylı bilgi Toklu vd. [24] İçinde bulunabilir.

3. Bulgular

SA/TPO ile en son gelişmelerden olarak Şekil 1.’de görülen sistemler üçgen düzlem gerilme elemanları ile tanımlanmış ve aynı şekilde sunulmuş olan doğrusal olmayan gerilme-şekil değiştirme bağıntıları ile çözülmüştür [22]. Bu işlem için yonteme ek bir ilave yapılmamış, sadece toplam potansiyel enerjinin hesaplanmasını içeren denklemler kodlanmış ve optimizasyon algoritmalarının kodları ile entegre edilmiştir.



Şekil 1. Düzlem-gerilme elemanları ile doğrusal olmayan analizi yapılan sistemler ve denklemler.

4. Sonuçlar ve Öneriler

SA/TPO yöntemi başarı ile SEY ile ek bir iteratif yöntem kullanılmadan çözülemeyen yapısal sistemler kolaylıkla çözülmektedir. Ayrıca doğrusal olmayan gerilme-şekil değiştirme bağıntıları altında oldukça farklı çözümler elde edilmektedir. Örneğin çözülen istinat duvarı

örneğinin doğrusal durumda toplam potansiyel enerji değeri -0,032 kNm iken bu değer doğrusal olmayan durumlarda -7.726, -51.314 ve -48.744 kNm değerlerini almaktadır. Ayrıca, kullanılan algoritmanın başarımı için farklı algoritmalar ve modifiye edilmiş gelişmiş algoritmaların kullanımını sonuç hassasiyeti için tavsiye edilmektedir.

Teşekkür: Bu yayının İstanbul Üniversitesi - Cerrahpaşa Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir. Proje numarası: FYO-2019-32735

Referanslar

- [1] Timoshenko, S. P., Gere, J. M. 1961. “Theory of Elastic Stability”, 2nd. Edition McGraw-Hill.
- [2] Lee, K. S., Geem, Z. W. 2004. “A new structural optimization method based on the harmony search algorithm”, *Comput. Struct.* 82, 781–798..
- [3] Hatay, T. , Toklu Y. C. 2002. "Optimization of Trusses Using Simulated Annealing Method", 5th International Congress on Advances in Civil Engineering, Istanbul, Turkey, PALA, S., ILKI, A.(eds) ISBN 975-561-220-3, Vol.1, pp. 379-388.
- [4] Degertekin, S. O. 2008. “Harmony search algorithm for optimum design of steel frame structures: A comparative study with other optimization methods”, *Struct. Eng. Mech.*, 29(4), 391-410.
- [5] Degertekin, S. O., Hayalioglu, M. S., Gorgun, H. 2009. “Optimum Design of Geometrically Non-Linear Steel Frames With Semi-Rigid Connections Using A Harmony Search Algorithm”, *Steel Compos. Struct.*, 9(6), 535-555.
- [6] Erdal, F., Saka, M. P. 2009. “Harmony search based algorithm for the optimum design of grillage systems to LRFD-AISC”, *Struct. Multidiscip. O.*, 38, 25-41.
- [7] Erdal, F., Dogan, E., Saka, M. P. 2011. “Optimum Design Of Cellular Beams Using Harmony Search And Particle Swarm Optimizers”, *J. Constr. Steel Res.*, 67(2), 237-247. J. Smith, R. Jones, and K. Trello, “Adaptive filtering in data communications with self improved error reference,” In *Proc. IEEE International Conference on Wireless Communications '04*, 2004, pp. 65-68.
- [8] Hasancebi, O., Carbas, S., Dogan, E., Erdal, F., Saka, M. P. 2010. “Comparison of Non-Deterministic Search Techniques In The Optimum Design of Real Size Steel Frames”, *Comput. Struct.*, 88(17-18), 1033-1048.
- [9] Togan, V., Daloglu, A. T., Karadeniz, H. 2011. “Optimization of Trusses under Uncertainties with Harmony Search”, *Struct. Eng. Mech.*, 37(5), 543-560.
- [10] Toklu, Y. C. 2004. "Considerations on the Design of Space Structures - Active Design and Inclusion of Nonlinear Effects", 9th ASCE ASD International Conference- Earth & Space 2004, League City/Houston, Texas, USA, March 07-10, pp. 704-710.
- [11] Toklu, Y. C. 2004. “Nonlinear Analysis of Trusses Through Energy Minimization”, *Computers and Structures*, 82, 1581-1589.
- [12] Toklu, Y. C. 2004. “A New Technique For Nonlinear Analysis of Trusses”, 6th Int. Congress on Advances in Civil Engineering, Bogazici Univ., Istanbul, Turkey, pp.813-822.

- [13] Toklu, Y. C. 2009. "Optimization In Structural Analysis And Design", Struct. 2009 Congress, Texas, USA.
- [14] Toklu, Y. C., Uzun, F. 2016. "Analysis of Tensegric Structures by Total Potential Optimization Using Metaheuristic Algorithms", Journal of Aerospace Engineering, 29 (5), 04016023.
- [15] Toklu, Y. C., Kayabekir, A. E., Bekdaş, G., Nigdeli, S. M., & Yücel, M. (2020). Analysis of plane-stress systems via total potential optimization method considering nonlinear behavior. Journal of Structural Engineering, 146(11), 04020249.
- [16] Bekdaş G, Kayabekir AE, Nigdeli SM, Toklu YC. Advanced Energy Based Analyses of Trusses employing Hybrid Metaheuristics, The Structural Design of Tall and Special Buildings. 2019; 28(9):1-19, (e1609).
- [17] Kayabekir, A. E., Toklu, Y. C., Bekdaş, G., Nigdeli, S. M., Yücel, M., & Geem, Z. W. (2020). A novel hybrid harmony search approach for the analysis of plane stress systems via total potential optimization. Applied Sciences, 10(7), 2301.
- [18] Toklu, Y. C., Bekdaş, G., Kayabekir, A. E., Nigdeli, S. M., & Yücel, M. (2021). Total Potential Optimization Using Hybrid Metaheuristics: A Tunnel Problem Solved via Plane Stress Members. In Advances in Structural Engineering—Optimization (pp. 221-236). Springer, Cham.
- [19] Toklu, Y. C., Bekdaş, G., Kayabekir, A. E., Nigdeli, S. M., & Yücel, M. (2020, April). Total potential optimization using metaheuristics: analysis of cantilever beam via plane-stress members. In International Conference on Harmony Search Algorithm (pp. 127-138). Springer, Singapore.
- [20] Toklu, Y. C., Bekdaş, G., Yücel, M., Nigdeli, S. M., Kayabekir, A. E., Kim, S., & Geem, Z. W. (2021). Total Potential Optimization Using Metaheuristic Algorithms for Solving Nonlinear Plane Strain Systems. Applied Sciences, 11(7), 3220.
- [21] Toklu, Y. C., Bekdaş, G., Kayabekir, A. E., Nigdeli, S. M., & Yücel, M. (2021). Total Potential Optimization Using Hybrid Metaheuristics: A Tunnel Problem Solved via Plane Stress Members. In Advances in Structural Engineering—Optimization (pp. 221-236). Springer, Cham.
- [22] Toklu, Y. C., Kayabekir, A. E., Bekdaş, G., Nigdeli, S. M., & Yücel, M. (2020). Analysis of plane-stress systems via total potential optimization method considering nonlinear behavior. Journal of Structural Engineering, 146(11), 04020249.
- [23] Toklu, Y. C., Bekdaş, G., Kayabekir, A. E., Nigdeli, S. M., & Yücel, M. (2020, April). Total potential optimization using metaheuristics: analysis of cantilever beam via plane-stress members. In International Conference on Harmony Search Algorithm (pp. 127-138). Springer, Singapore.
- [24] Toklu, Y. C., Bekdas, G., & Nigdeli, S. M. (2021). Metaheuristics for Structural Design and Analysis. John Wiley & Sons

S-30 KARGO TESLİMAT VERİLERİ ÜZERİNDE ANOMALİ TESPİTİ

Sefa SARI¹, Selin BOSTAN¹, Ümit BOSTANCI¹, Cevher Nur SÖYLEMEZ², Fatma BOZYİĞİT^{2,*}

¹ Yurtiçi Kargo, Research&Development Department, TURKEY, {sefa.sari, selin.bostan, umit.bostanci}@yurticikargo.com.tr

² Computer Engineering, İzmir Bakırçay University, TURKEY, {cevhernur.soylemez, fatma.bozyigit}@bakircay.edu.tr

Özet

E-ticaret sitelerinde, müşteri memnuniyetini arttıran faktörlerden birisi kargo süreçlerinin sorunsuz bir şekilde yürütülmesidir. Dolayısı ile kargo firmalarının bu süreç yönetimine dahil olarak gerçekleştirilen alışverişin en iyi şekilde tamamlanmasına katkı vermesi önemli bir husustur. Bu çalışmada Türkiye’de kargo taşımacılığında hizmet veren Yurtiçi Kargo’nun ürün teslimatını oyunlaştırma tekniği üzerinde durulmaktadır. Bu doğrultuda kargo çalışanlarının mobil cihazlar üzerinden, teslimat detaylarını sisteme doğru ve eksiksiz bir biçimde girmesi ve müşterilere taşımacılığın her aşamasında geri bildirim sağlaması oyunun temel kuralıdır. Müşteri memnuniyetinin artırılmasının hedeflendiği bu yöntem ile kargo çalışanlarının puan toplayarak ve birbirleri ile yarışarak ödüller kazanabilmeleri sağlanmaktadır. Fakat her oyunda olduğu gibi bu sistemde de hile kaçınılmaz bir sorundur. YK-Game kapsamında ise ödüllendirme mekanizmasını çözen kuryeler bilerek ligden düşüp diğer ay çok daha fazla ödül toplamayı amaçlayan çalışanlar olduğu fark edilmiştir. Bu hilelerin yapılması oyunlaştırmada bir anomali oluşturmaktadır. Sonuç olarak çalışmamızda kargo taşımacılığında oyunlaştırma ile elde edilen verilerin analizi ve anomali tespiti hedeflenmiştir.

Anahtar Sözcükler: e-ticaret; müşteri sadakati, kargo süreçleri; oyunlaştırma, anomali tespiti.

Anomaly Detection Use Case in Cargo Delivery Domain

Abstract

In e-commerce sites, one of the factors that increase customer satisfaction is the smooth execution of cargo processes. Therefore, the cargo companies have a critical job to finalize the shopping processes in the best manner. In this study, the gamification for product delivery of Yurtiçi Kargo, which provides services in cargo transportation in Turkey, is focused on. In this respect, it is expected that cargo employees enter the delivery details into the system accurately and completely via mobile devices and provide feedback to customers at every stage of transportation. With this method, which aims to increase customer satisfaction, it is also ensured that cargo employees can win prizes by collecting points and competing. However, employees who solve the rewarding mechanism can cheat and purposely aim to drop from the league to collect more rewards next month. Performing this trick also creates an anomaly in gamification. This paper aims to analyze the data obtained by gamification in cargo transportation and detect anomalies within the scope of this paper.

Keywords: *e-commerce; customer loyalty; cargo transactions; gamification, anomaly detection.*

1. Giriş

Kargo taşımacılığında önemli konulardan birisi gönderi sahiplerine kargo durumunun doğru olarak bildirilmesidir. Gönderi sahibi kargonun bulunduğu şube ya da aktarım merkezini doğru olarak ve zamanında öğrenmek istemektedir. Müşteri memnuniyeti için de gerekli olan önemli bildirimlerden biri de kuryeler tarafından gönderinin dağıtımına çıkarıldığı bildirilmesidir. Tüm bu amaçlara erişmek ve müşteri memnuniyetini yüksek oranda karşılamak için kargo şirketleri barkodlama yöntemini kullanmaktadır. Bu yöntem, kargo çalışanlarının gönderinin ilerlemiş olduğu her adımda barkod ve diğer ilgili verileri sisteme girmesi ile yürütülmektedir.

Kargo çalışanlarının girdiği verilerin bütünlüğü, doğruluğu ve zamanlaması müşterilerin geri bildirimlerinin olumlu olmasını sağlamaktadır. Kargo taşımacılığında müşteri şikayetleri genellikle ölçümü ve izlenmesi kolaydır. Ancak, olumlu geri bildirimleri ya da memnuniyeti ölçmek ve zamanla değişimini kavrayabilmek kolay olmamaktadır. Yurtiçi Kargo Servisi A.Ş. Ar-Ge Merkezi kuryelerin verileri sisteme doğru, zamanında ve itinalı şekilde girmelerini sağlamak ve müşteri memnuniyetini ölçmek amaçlarına yönelik bir oyun geliştirmiştir. Bu oyuna YK-Game adı verilmiştir.

Oyun kuryeleri doğru ve itinalı iş yapmaya yönlendirirken diğer yandan da her oyunda olduğu gibi hilelerin yapılmasının da önünü açmıştır. Oyunda doğru ve zamanında bildirim yapan kurye ödül almaktadır. Alınan ödüllere göre de lig yükselip lig düşebilmektedirler. Ödüllendirme mekanizmasını çözen kuryeler bilerek ligden düşüp diğer ay çok daha fazla ödül toplamayı amaçlamaktadır. Bu hilenin yapılması da oyunlaştırmada bir anomali oluşturmaktadır. Çalışmamızda bu anomalinin tespiti için İzolasyon Ormanı [1] algoritması uygulanmış olup, firma tarafından fark edilememiş olan 2 adet kuryenin işlemleri ile oluşan anomali durumu tespit edilmiştir. İlerleyen aşamalarda Tek Sınıf Vektör Destek Makineleri [2] ve Yerel Aykırı Faktör [3] gibi farklı yöntemlerin de kullanılması ile elde edilen sonuçların değerlendirilmesi yapılacaktır.

Çalışmanın devamında, ikinci kısımda Materyal ve Yöntem kısmına değinilecektir. Üçüncü kısımda ise deneysel sonuçlar paylaşılır iken dördüncü bölümde sonuçlar ve gelecek çalışmalar hakkında bilgi paylaşımında bulunulacaktır.

2. Materyal ve Yöntem

Çalışmanın bu kısmında, ilk olarak Yurtiçi Kargo tarafından kargo süreçlerini daha başarılı bir şekilde yönetmeyi hedefleyen oyunlaştırma uygulamasına kısaca değinilecektir. Ardından deneysel çalışmalarda üzerinde veri bilimi yöntemleri uygulanacak olan veri seti hakkında bilgi verilecek olup, son olarak

2.1. Oyun Tasarımı

Oyun; kargo işlemlerini gerçekleştirmekte olan kuryelerin, bu işlemleri gerçekleştirirken kullandıkları mobil uygulamaya entegre olarak tasarlanmıştır. Böylelikle, oyuna katılan kuryenin mobil uygulama üzerinde kargo işlemlerini gerçekleştirirken, aynı zamanda oyun ekranları üzerinde ek işlem yapmasına ihtiyaç duyulmamaktadır.

Oyunda, kuryelerin ve bağlı çalıştıkları birimlerin dahil oldukları farklı ligler bulunmaktadır. Buradaki amaç, iş hacmi benzer olan kurye ve birimleri aynı liglerde yarıştırmaktır. Zira, kuryelerin başarılı bir performans göstermesine rağmen bağlı oldukları şubenin kapasitesi sebebiyle fazla puan toplamaları mümkün olmayabilmektedir. Performans ölçeklerine bağlı olarak oyuncuların üst liglere çıkışı veya alt liglere düşüşü yaşanabilir. Oyun, “Kurye Ligi” ve “Birim Ligi” olmak üzere iki ana bölümden oluşur. Kuryeler Kurye Liginde, birimler ise Birim Ligi’nde yarışmaktadır. Kurye liglerinde toplanan puanlar, kuryenin bağlı olduğu birim ligindeki sıralamasını belirlemektedir.

2.2. Veriseti

Çalışmada kullanılan veri setinde 2021 yılı boyunca kayıt altına alınmış gözlemleri içermektedir. Veri setinde yer alan öznitelikler Tablo 1 de yer almaktadır.

Özellik	Açıklama
sezon_no	Oyunun oynandığı dönem bilgisini tutar.
hafta_no	Oyunun oynandığı hafta bilgisini tutar.
calisan_no	Kuryelerin numaralarını tutar.
sube_no	Kuryelerin bağlı olduğu şube numaralarını tutar.
puan	Kuryelerin haftalık toplam puan bilgisini tutar.
sıra_no	Kuryelerin haftalık ligdeki puan sıralaması bilgisini tutar.
toplam_kupa	Kuryelerin ligdeki sıralamasına göre verilen kupa bilgisini tutar. Sezon ödülleri için total_cup özniteliği kullanılmaktadır. Bir kuryenin en düşük total_cup özniteliği değeri 0, en yüksek total_cup özniteliği değeri 15’tir.
lig_no	Kuryelerin lig bilgisini tutar. 1 ile 8 arasında değer alır. 1 eğitim ligini, 8 ise en yüksek ligi temsil eder.
league_count	Kuryelerin yarıştıkları lig sayılarının tutulduğu özniteliktir.
unique_league_count	Kuryelerin yarıştıkları benzersiz lig sayılarının tutulduğu özniteliktir.
league_variance	Kuryelerin yarıştıkları liglerin varyans değerlerinin tutulduğu özniteliktir.
sum_league_fall	Kuryelerin toplam lig düşme sayılarının tutulduğu özniteliktir.
total_prize	Kuryelerin kazandıkları toplam ödül bilgisinin tutulduğu özniteliktir.
point_variance	Kuryelerin puan varyans değerlerinin tutulduğu özniteliktir.

Kurye dağıtıcıların buldukları liglere ve aldıkları puanlar üzerinde varyans analizi yapılarak league_variance ve point_variance gibi özellikler veri setine sonradan dahil edilmiştir (Şekil 1).

emp_id	league_count	unique_league_count	leauge_variance	sum_league_fall	sum_league_rise	league_changings/playing_weeks	total_prize	point_variance	max_point	
0	10	2	2	0.25641	1	0	0.153846	0.0	144631.397436	2002
1	24	1	1	0.00000	0	0	0.076923	0.0	59287.192308	1627
2	61	1	1	0.00000	0	0	0.076923	0.0	4.923077	8
3	89	1	1	0.00000	0	0	0.076923	0.0	0.692308	3
4	102	1	1	0.00000	0	0	0.076923	0.0	0.000000	0

Şekil 1. Veri setine sonradan eklenen özellikler

2.3. İzolasyon Ormanı Yöntemi ile Anomali Tespiti

İzolasyon ormanı, karar ağacı tabanlı bir yöntem olup, veri kümesindeki her bir örneği öznitelik değerlerinde aralıklar belirleyerek diğer örneklerden ayırmaya (izole etmeye) çalışır. Anomaliye sebep olan örnekleri ayırmak nispeten daha az aralık belirleme işlemi gerektirmekte ve dolayısıyla daha kısa sürmektedir. Bu sebeple, izole etmesi kolay noktalar anomali olarak sınıflandırılmaktadır.

Birden fazla karar ağaçlarından oluşan İzolasyon Ormanı algoritması, rastgele gözlemler ve rastgele öznitelikler seçer daha sonrasında seçilen özniteliğin minimum ve maksimum değerleri arasında bir değer belirleyip gözlemleri bu değer altında veya üstünde olma durumuna göre dallara ayırır. Anomali durumda olan gözlemler veri setinden en yakın dallarda ayrılarak diğer gözlemlerden izole olurlar. İzolasyon ormanı algoritması, gözlemlerin anomali olma durumunun yanında anomali skoru da çıkartmaktadır. Model değerlendirme aşamasında genellikle modeldeki kümelerin birbirinden ne kadar iyi ayrıştığını ile ilgili bilgi veren Silhouette skoru kullanılmaktadır [4].

x kaydına ait anomali değeri, s , hesaplanmasına ilişkin denklem aşağıdaki gibi verilmiştir.

$$s(x, n) = 2 \frac{E(h(x))}{c(n)} \quad (1)$$

$h(x)$, x düğümüne kadar olan uzaklığı, $E(h(x))$ bir İzolasyon Ağaçları üzerindeki düğümlere ait $h(x)$ değerleri ortalamasını; $c(n)$ ise x düğümüne ulaşma aşamasında başarısız aramaların ortalama yol uzunluğudur.

3. Deneysel Sonuçlar


Deneysel çalışmalar kapsamında ilk olarak mevcut veri setinde keşifçi veri analizi yöntemleri uygulanmıştır. Bu doğrultuda yapılan işlemlerden biri kuryelerin tek seferde maksimum kaç lig düşüklerini incelemektir. Anomaliye sebep olacak seviyede lig düşen kuryelerin lig değişimleri

incelenmiştir. En keskin düşüşün, 8. ligden 2. lige düşen kurye tarafından gerçekleştirildiği gözlemlenmektedir (Şekil 1).

season_id	week_id	emp_id	unit_id	point	sequence_number	total_cup	league_id	
983	236245	41	42153	9160	28	9	3	8
10967	236245	42	42153	9160	8	7	5	8
21005	236245	43	42153	9160	8	7	5	8
31066	236245	44	42153	9160	8	7	5	8
41155	236245	45	42153	9160	8	8	4	8
61436	236245	47	42153	9160	803	6	4	8
71607	236245	48	42153	9160	2273	1	11	2
81840	236245	49	42153	9160	2624	2	10	6
92150	236245	50	42153	9160	3087	1	11	7
102477	236245	51	42153	9160	916	12	1	8
112839	236245	52	42153	9160	856	13	1	8
123241	236245	53	42153	9160	878	14	1	8

Şekil 2. 8. Ligde bulunan kuryelerin lig değişim gözlemleri

Şekil 3’ de gözlemlenen mavi renkli noktalar normal durumda olan kuryeler, sarı renkte olan kuryeler ise aykırı durumda olan kuryelerdir. Anomali skoru en yüksek olan kurye ($s=0,77$) incelendiğinde (kırmızı halka içine alınmış), kuryenin 8. ligde lig düşmeyi bekleyip 2. Lige düştüğü ve düştüğü ligde ödül aldığı gözlemlenmiştir.



Şekil 3. Anomali tespiti

Oyuna katılan kuryenin kullandığı mobil uygulama üzerinde yapılan işlemlerde herhangi bir uygunsuzluk, anomali ya da hile tespit edilmesi durumunda; üç farklı ceza uygulanır. Tespit sonucunda kuryeye “Sarı Kart” cezası verilirse kurye sözlü uyarı alır, “Kırmızı Kart” cezası verilirse kurye haftalık oyun dışı edilir, “Men” cezası alırsa kurye sezon boyunca oyun dışı edilir.

4. Sonuçlar

21. Yüzyılda milenyum nesli güç kazandıkça bu nesle yönelik uygulamalarda da çeşitlilik artmaya başlamıştır. Oyunlar daha önceki yıllarda sadece eğlence amaçlı olarak oynanmış olsa da oyunlardaki bu çeşitliliğin artması sonucunda eğitim, sağlık gibi birçok sektörde kullanılır duruma gelmiştir. Oyunların bu tip eğlence dışı alanlarda da kullanılmaya başlanması, oyunlardan farklı işlenebilir çıktılarının da elde edilebileceğini göstermiştir. Oyunlaştırma teknolojilerine olan ilgi akademik alanda da giderek yoğunlaşmaktadır. Ancak, araştırmalarımız sırasında kargo sektörü için benzer bir kullanımına rastlanmamıştır. Yurtiçi Kargo Servisi A.Ş. Ar-Ge Merkezi tarafından kuryelerin kargo süreçlerini içeren bilgileri sisteme doğru ve zamanında şekilde girmelerini sağlamak ve müşteri memnuniyetini arttırmak amacı ile geliştirilen YK-Game oyunundan elde edilen veriler üzerinde uygulanan veri bilimi uygulamaları sonucunda bazı anomalilere rastlandığı gözlemlenmiştir. Çalışanlar arasında gerçekleşen bu haksız rekabetin önüne geçmek için anomali bulma süreci bir web servise dönüştürülerek elde edilen sonuçlar ile kuryeler sürekli olarak bilgilendirilecektir.

Referanslar

- [1] F. T. Liu, K. M. Ting and Z. Zhou, "Isolation Forest," 2008 Eighth IEEE International Conference on Data Mining, 2008, pp. 413-422, doi: 10.1109/ICDM.2008.17.
- [2] R. Zhang, S. Zhang, Y. Lan and J. Jiang, "Network anomaly detection using one class support vector machine", Proc. Int. MultiConf. Eng. Comput. Scientists, vol. 1, pp. 1-5, 2008.
- [3] K. E. Elliott and C. M. Greene, "A local adaptive protocol," Argonne National Laboratory, Argonne, France, Tech. Report. 916-1010-BB, 7 Apr. 2007.
- [4] W. Wang and P. Lu, "An Efficient Switching Median Filter Based on Local Outlier Factor," in IEEE Signal Processing Letters, vol. 18, no. 10, pp. 551-554, Oct. 2011, doi: 10.1109/LSP.2011.2162583.
- [5] S. Aranganayagi and K. Thangavel, "Clustering Categorical Data Using Silhouette Coefficient as a Relocating Measure," International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007), 2007, pp. 13-17, doi: 10.1109/ICCIMA.2007.328.

S-36 STOCK PRICE PREDICTION USING DEEP LEARNING METHODS IN HIGH-FREQUENCY TRADING

Dr. Nurdan SARAN ¹, Emre ALBAYRAK ²

¹ Computer Engineering, Çankaya University, Turkey, buz@cankaya.edu.tr

² Computer Engineering, Çankaya University, Turkey, c1771010@student.cankaya.edu.tr

Özet

Borsa analizleri finansal, politik ve sosyal göstergeler göz önünde bulundurularak yapılırken, büyük veri ve derin öğrenme teknolojilerindeki önemli gelişmeler araştırmacı ve yatırımcıların dikkatini bilgisayar destekli analizlere yöneltmiştir. Bu çalışmada Uzun Kısa-Dönem Hafızalı(LSTM) ağlar, Kapı Özyinelemeli Geçitler (GRU) ve Uzun Kısa-Dönem Hafızalı ağlarda Dikkat Mekanizması modeli olmak üzere üç farklı model incelenmiştir. Borsa İstanbul verileriyle gerçekleştirilen çalışmada gün içi verileriyle tahminler gerçekleştirilmiştir. Yapılan test çalışmaları sonucunda Kapı Özyinelemeli Geçitler’in diğer modellere göre daha iyi sonuç verdiği görülmüştür.

Anahtar Sözcükler: *BIST, GRU, LSTM.*

Abstract

The stock market analysis examines and evaluates the stock market by considering the financial, political, and social indicators to make future predictions. Breakthrough results of advancements in big data and deep learning technologies attract the attention of researchers and traders to computer-assisted stock market analysis. There are several studies on stock market analysis using deep learning models. In this paper, we used three different models of recurrent neural networks: Long Short-Term Memory (LSTM) networks, Gated Recurrent Unit (GRU), and LSTM with an attention layer model. We compare the results and performance of three different models on Borsa Istanbul data while making intraday predictions. Even though the LSTM results are very close to the GRU model, GRU slightly outperforms the others.

Keywords: *BIST, GRU, LSTM.*

1. Introduction

Stock market analysis is one of today's most trending topics, along with cryptocurrencies, high-performance trading, etc. It can take the form of two methods: fundamental and technical analysis. Fundamental analysis merges a wide range of diverse data sources to harness data in the stock market analysis process. Data sources may vary from political news, government policies to insider information. Technical analysis relies on financial indicators such as stock charts, current market trends, trade volumes, etc. Technical analysis is used to understand short-term stock behavior, whereas fundamental analysis is used for long-term predictions [7].

Forecasting stock prices accurately is a challenging task due to its noisy, non-stationary, and highly volatile nature [9] [2]. Speculators and competitors are the factors that make it even harder to capture the stock price trends' complexity [8] [5]. The renaissance in artificial intelligence technology and the rapid domination of the field is enough to make them of interest to any data scientist. The complexity of predicting stock prices accurately and emerging big data and deep learning technologies have led to the use of computers in stock market analysis [1] [9].

This study uses Long Short Term Memory Networks, Gated Recurrent Units, and LSTM with Attention Mechanism to forecast the stock prices. Both LSTM and GRU are parts of RNNs.

1.1 Objectives

Our main objective is to study deep learning methods in high-frequency trading using Borsa İstanbul data in order to make intraday predictions. We use most popular and high-end deep learning methods such as LSTM with Attention mechanism with BIST data to come up with an comparative study.

2. Experimental Setup

2.1 Data Retrieval

The data is hourly data of 98 different stocks in Borsa Istanbul, and the data is acquired through the Matriks Information Delivery Services Inc. The data has a date range from 2001 to 2020 that results in 772533 lines in total.

Every file has five columns of data: datetime, open price, high price, low price, close price, and volume. The datetime column consists of the date and the hour. We preprocess the files as told above and shrink the size of the files accordingly. Then we create a list of technical indicators based on the hourly values of open, high, low, close, and volume data. There are 28 technical indicators we calculate during the preprocessing, and we have also added USD/TRY currency data. We have selected three different stocks from Borsa Istanbul considering the alphabetical order. The stocks are ASELS, AKBNK and AKENR.

2.2 LSTM

For deeper networks, issues can arise from backpropagation, sometimes called vanishing or exploding gradients. As we traverse back to the lower level layers or front layers closer to the input layers, gradients often get smaller, eventually causing neurons' weights to never change at these lower levels. A different activation function or batch normalization techniques might be proposed as solutions for vanishing gradient problems at a scale. However, due to the length of the sequence input, such as a long time-series data, these proposed solutions could slow down the training.

Another issue recurrent neural networks face is that the network will begin to "forget" the first inputs after a while, as information is lost at each step going through the RNN. At that point, a long-term memory solution is needed for recurrent neural networks. Long Short-Term Memory cell was created to help to address the vanishing gradient issue in 1997 [6].

LSTM cell was introduced with three different gates, input gate, forget gate, and output gate. Input gate to decide what to store in cell state, forget gate is where to determine what information is going to forget or throw away from the cell state, output gate is to decide what to update in the cell state [6] [3].

2.3 GRU

A variant of the LSTM cell is called the Gated Recurrent Unit (GRU) introduced in 2014 [4]. GRU simplifies the internal structure of LSTM by combining the forget and input gates into a single gate called "update gate". It also merges the cell state and hidden state.

The update gate is used to decide what information is to be passed, reset gate is used to determine what information is going to forget. These gates stand for the long term and short term memory, respectively.

2.4 Attention Mechanism

The attention mechanism in deep learning focuses on certain features of data during the training process. One of the most frequently use cases of attention mechanism is seq2seq models, also known as encoder-decoder model [4].

In this paper, we have used the Luong Attention mechanism, which is introduced in 2015 [10]. The attention mechanism mainly differs from the other models while assigning weights to the neurons in the network. It makes the network consider the key points of the data by adjusting the weights [10].

3. Results and Discussions

We have applied our models on three different stocks from BIST. The stocks are ASELS, AKBNK and AKENR. Different combinations of hyper parameters such as number of epochs, batch size, time step are taken into consideration during our test processes.

LSTM, GRU, and LSTM with an Attention mechanism. In the experiment with 50 epochs, GRU seems to give better results than the other models. LSTM with an attention layer cannot outperform the other models due to the long length of the data sequence. When we increase the number of epochs, error values are decreasing respectively. In LSTM model, RELU gives better results over sigmoid function and hyperbolic tangent function gives the best results. In this

paper, we have compared three models by considering the error values, and the GRU model seems to give the best results overall. The comparison of error values of all three models are in Table 1. LSTM and GRU results for ASELS stock are in the Figure 1 and Figure 2 respectively.

Table 1. Comparison Results for Stock ASELS.

Model	Epoch	Batch	Time Step	Optimizer	MSE	MAE
LSTM	50	20	30	ADAM	0.0014	0.0257
GRU	50	20	30	ADAM	0.0013	0.0267
ATTENTION	50	20	30	ADAM	0.0444	0.1724
LSTM	100	20	30	ADAM	0.0011	0.0227
GRU	100	20	30	ADAM	0.0010	0.0223
ATTENTION	100	20	30	ADAM	0.0430	0.1703
LSTM	150	20	30	ADAM	0.0009	0.0213
GRU	150	20	30	ADAM	0.0008	0.0205
ATTENTION	150	20	30	ADAM	0.0405	0.1670




Figure 1. Stock ASELS LSTM result figure for 150 epochs.




Figure 2. Stock ASELS GRU result figure for 150 epochs.

4. Conclusion

Our paper is one of the first papers which applies LSTM with Luong Attention Mechanism and hourly prediction of stock prices method to the Borsa Istanbul (BIST) data. We have gathered the data from the MATRIKS Inc. and we have used the 5 fundamental features of data for our analysis: Open, High, Low, Close, Volume. Then, we create a large number of technical indicators using the initial data. After the preprocessing operations, we fed our data to 3 different models: LSTM, GRU, LSTM with attention layer. We have compared three models for three different stocks and experimental results show GRU outperforms the other models in forecasting stock prices of BIST.

Acknowledgements

References

- [1] Borovkova, S. and Tsiamas, I. (2019). An ensemble of lstm neural networks for high-frequency stock market classification. *Journal of Forecasting*, 38(6):600–619.
- [2] Chen, Q., Zhang, W., and Lou, Y. (2020). Forecasting stock prices using a hybrid deep learning model integrating attention mechanism, multi-layer perceptron, and bidirectional long-short term memory neural network. *IEEE Access*, 8:117365–117376.
- [3] Chen, S. and Ge, L. (2019). Exploring the attention mechanism in lstm-based hongkong stock price movement prediction. *Quantitative Finance*, 19(9):1507–1515.
- [4] Cho, K., Merriënboer, B. V., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y. (2014). Learning phrase representations using rnn encoder–decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*.
- [5] Fischer, T. and Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2):654–

669.

- [6] Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., and Schmidhuber, J.(2017). Lstm: A search space odyssey.IEEE Transactions on Neural Networks and Learning Systems, 28(10):2222–2232.
- [7] Gunduz, H., Yaslan, Y., and Cataltepe, Z. (2017). Intraday prediction of borsaistanbul using convolutional neural networks and feature correlations.Knowledge-Based Systems, 137:138–148.
- [8] Nguyen, T.-T. and Yoon, S. (2019). A novel approach to short-term stock price movement prediction using transfer learning.Applied Sciences, 9(22):4745.
- [9] Qiu, J., Wang, B., and Zhou, C. (2020). Forecasting stock prices with long-short term memory neural network based on attention mechanism.PLOS ONE, 15(1):1–15.
- [10] Luong, T., Pham, H., and Manning, C. D. (2015). Effective approaches to attention-based neural machine translation.Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing.

S-54 SOSYAL MEDYADA FENOMENLER VE MÜŞTERİLERİ EŞLEYEN BİR ÇÖZÜM ÖNERİSİ

Fatih SOYGAZI¹, Özgür KAYA², Hilmi Can TAŞKIRAN¹, Muhammet Enes AYDOĞAN¹, Furkan ANŞİN¹

¹ Bilgisayar Mühendisliği Bölümü, Aydın Adnan Menderes Üniversitesi, Türkiye, fatih.soygazi@adu.edu.tr, {hilmicantaskiran, muhammetenesaydogan, furkanansinn}@gmail.com

² Fenomio Influencer Marketing, Türkiye, ozgur.kaya@fenomio.com

Özet

Sosyal medya platformları, reklamcılık sektörü için büyük önem arz etmektedir. Şirketler, reklamlara büyük bütçeler ayırarak ürünlerine en uygun fenomen/influencer/ünlüleri reklam yüzü olarak seçmeye çalışmaktadır. Her ürün, belirli segmentte kişilere hitap etmektedir. Bu kişilerin takip ettiği ünlüler/fenomenler tespit edildiği takdirde reklam şirketleri ilgili ürünler için bu kişiler ile iletişime geçmektedir. Bu çalışmanın amacı, şirketlerin bütçelerinin doğru şekilde kullanılmasını sağlamak için uygun ürüne ilgili fenomeni eşleştirerek reklam vermek isteyen şirketin işini kolaylaştırmaktır. Çalışmamızda sosyal medya fenomenlerinin Instagram hesabı üzerinden gerçek/sahte takipçi, cinsiyet ve takipçi yaş aralığı analizleri yapılmaktadır. Fenomeni takip eden bot hesaplar ayıklanarak gerçek hesaplar üzerinden cinsiyet ve yaş aralıkları tespit edilmesinin sağlanması üzerinde durulmuştur. Bot hesapların tespiti, gerçek ve bot hesaplara dair özniteliklerden yararlanan bir ikili sınıflandırma problemine dönüştürülmüştür. Cinsiyet tespiti için paylaşım yapan kişinin fotoğraflarından ve isminden beraberce yararlanarak yine bir ikili sınıflandırma çözümü sunulmuştur. Takipçi yaş aralığının tespitinde ise takipçilerin fotoğraflarından yola çıkarak önceden eğitilmiş bir derin öğrenme modeli ile yaş aralığının bulunması sağlanmıştır. Bahsi geçen üç durum göz önüne alınarak yapılan değerlendirmelerin fenomen/takipçi eşleşmesinde başarılı olduğu görülmüştür.

Anahtar Sözcükler: *Sosyal medya analizi; yapay öğrenme; derin öğrenme; sahte hesap tespiti; görüntü işleme*

Abstract

Social media platforms are so important for advertising industry. Companies have a huge amount of budget for advertisement and try to select an influencer as the face of their brand for these advertisements. Each brand is related with a specific segment of customers. When the true influencer that is followed by this segment, advertising companies contact with him/her. The objective of this work is to facilitate the job of advertising company by matching the brand and the influencer to use the budget of the advertising company in a appropriate way. Accordingly, our work makes analysis on real/fake account detection, gender and age range prediction of the influencer's followers. In this work, it is focused on the real accounts by eliminating the fake ones and the gender, age range prediction of these real accounts are determined. The detection of fake accounts are transformed to a binary classification problem by observing the features of real and fake accounts. Another binary

classification solution is presented for gender detection by checking the pictures of the account owners and their names together. A pretrained deep learning model for follower age range prediction is provided based on the pictures of these followers. The accuracy of the predictions are evaluated for each of the three situations and the success of our approach is observed for influencer/follower matching.

Keywords: *Social media analysis; machine learning; deep learning; fake account detection; image processing.*

1. Giriş

Sosyal medya üzerinden pazarlama ve satış güncel bir konu olarak karşımıza çıkmaktadır. Sosyal medya sitelerinde yapılan reklamların e-ticaretteki pazar paylarını nasıl değiştirdiği düşünüldüğünde özellikle Instagram’ın, kullanıcıların ürün alışkanlıklarını ciddi biçimde etkilediği göze çarpmaktadır. Bu değişimden yola çıkan reklam firmaları ürün satışlarını arttırabilmek için geleneksel pazarlama yöntemlerinden çok artık sosyal medya üzerinden satışlara ağırlık vermektedir. Influencer Marketing adı verilen bu yöntem, ürünler veya servislerin daha çok kullanıcıya ulaştırılması için ilgili fenomen/ünlü/influencer kişi veya kişilerle ilişki kurulup, ürün tanıtımlarının yapılma süreci ve bir içerik pazarlama stratejisidir. Bu doğrultuda sosyal medya üzerinden müşteri profili belirleme ve bu profildeki kişilere uygun ünlü/fenomenlerle ulaşmaya çalışma reklamın satış açısından başarısını arttıracığı için reklam yüzünün doğru biçimde seçilmesi ciddi önem taşımaktadır. Bu noktada reklam firmaları sosyal medya üzerinden analizler yapan uygulamalar yardımı ile en uygun fenomeni bulmaya çalışmaktadır.

Müşteri/fenomen eşleştirmesini yapma hedefi güden çalışmamız, Instagram takipçileri üzerine analiz yapan bir uygulamadır. Çalışmada bir Instagram fenomeninin takipçilerinin ne kadarlık kısmının sahte hesaplardan oluştuğunu, cinsiyetini ve demografik verisi tespit edilmektedir. Yapay öğrenme, görüntü işleme ve sınıflandırma algoritmaları kullanılarak %90’lık doğruluk oranıyla fenomen/müşteri eşleştirmesi yapılabilmektedir. Bu bildiride, bir instagram fenomeninin takipçilerinin yüzde kaçının gerçek kullanıcıdan oluştuğu, cinsiyet ve yaş dağılımının hesaplanması üzerinde durulmuştur. Bu sayede bir firma herhangi bir Instagram fenomenine reklam vermek istediği takdirde ürünlerindeki satışların hedefledikleri doğrultuda olup olmayacağı öngörülebilmektedir.

2. Önceki Çalışmalar

Sosyal medyada bot denilen otomatik olarak oluşturulan ve gerçek kimlik ifade etmeyen hesapların (sahte hesaplar) tespit edilmesi sosyal medyadaki gerçek davranışların anlaşılması açısından önemlidir. Akyon ve Kalfaoğlu [1] bot ve sahte hesaplardan meydana gelen iki adet veri kümesi oluşturmuştur. Bu veri kümeleri üzerinde denedikleri geleneksel yapay öğrenme yöntemleri ile gerçek olmayan hesapları 86% ve 96% oranlarında tespit etmişlerdir. Bu tespiti yaparken kullanıcının takip ettiği kişi sayısı, kullanıcıyı takip eden kişi sayısı, kullanıcı adının uzunluğu, kullanıcı adında bulunan nümerik değer sayısı gibi farklı özniteliklerden yola çıkarak eğitilmiş modeller elde etmişler ve gerçek hesapları tespit edebilmişlerdir.

Jeon ve arkadaşları [2], reklamcılık alanında kullanılmak amacıyla derin öğrenme yöntemleri ile kullanıcıların cinsiyet tespitini yapmayı amaçlamışlardır. 33752 Instagram paylaşımı üzerinden fotoğraf, metin paylaşımları ve günlük aktiviteler analiz edilerek cinsiyet tespiti yapılmıştır. Yapılan paylaşımlardan çıkarılan öznitelikler üzerinden F1-skoru 76% olmak üzere bir başarımlar elde edildiği ifade edilmiştir.

Han ve arkadaşları [3], gençlerin ve yetişkinlerin sosyal medyadaki davranışlarından yola çıkarak paylaşım yapan kişinin yaş aralığı hakkında tahminleme yapan bir yaklaşım geliştirmiştir. Kullanıcı profilleri ve bu profillerin etiketlerinden yararlanılarak elde edilen iki adet veri kümesinde kullanıcıların çevrimiçi davranış bilgileri saklanmıştır. Bu veri kümelerinden elde edilen eğitim sonuçlarında 82% doğruluk seviyesinde tahminleme yapıldığı ifade edilmiştir.

Influencer marketing ile ilgilenen firmalar çeşitli uygulamalardan [4], [5] yararlanmaktadır. Bu uygulamalar yapay zeka tabanlı yaklaşımlarla analizler yaparak profillere dair çeşitli bilgileri toplamakta ve reklam firmalarının en uyguna fenomen alternatiflerini sunmaktadır.

Farseev ve arkadaşları [6], SoMin adını verdikleri fenomen keşfine odaklı bir yapay zeka uygulaması geliştirmişlerdir. Çalışma, ilgili firmanın pazarındaki kullanıcı profilini çözümlenme ve bu profile uygun yakın veya uzak vadedeki fenomen eşleşmelerini bulma üzerinde durmaktadır. Ürünün bulunduğu pazara dair sosyal medya üzerinden yapılan tüm multimedya paylaşımları gözlemlenerek ürünü takip edecek kişilerin özniteliklerinin ne olacağını bulmak amacıyla “Individual User Profiling” olarak adlandırdıkları bir çözüm üretmişlerdir.

2. Materyal ve Yöntem

2.1. Sahte Hesap Tahmini

Sahte hesap tespitinde önceden hazırlanmış olduğumuz gerçek ve sahte kullanıcıların bilgilerini içeren bir veri seti oluşturulmuş ve bu veri seti ile model eğitimi gerçekleştirilmiştir. Sonrasında bir Instagram kullanıcısının gerçek takipçilerinin bilgileri toplanmış ve daha önce eğitilmiş olduğumuz modelde bu veriler ile tahminde bulunulmuştur. Sonuç olarak sahte olarak ifade ettiğimiz hesaplar tespit edilerek başarımlar ölçülmüştür. Model eğitimi esnasında Random Forest Classifier algoritması ile ikili sınıflandırma neticesinde sahte ve gerçek hesaplar birbirinden ayrıştırılmıştır.

Sahte hesap tahmini için kullandığımız özniteliklerden en önemlisinin kullanıcıyı takip eden kişi sayısının takip ettiği kişi sayısına oranı (FFR) olduğu gözlemlenmiştir.

$$\text{FFR} = \frac{\text{Takip edilen kişi sayısı}}{\text{Takip eden kişi sayısı}}$$

2.2. Cinsiyet Tahmini

Cinsiyet tahmini için iki farklı yöntem kullanılmıştır:

1. *Görüntü işleme ile cinsiyet tahmini:* Görüntü işleme algoritması olarak “DeepFace”¹ kütüphanesi kullanılmaktadır. DeepFace kütüphanesi ile kullanıcının Instagram profil resmi üzerinden cinsiyet ve yaşı tespit edilmektedir.
2. *İsim ile cinsiyet tahmini:* İsim ile cinsiyet tahmini için Python’un “gender_guesser”² modülü kullanılmaktadır. “gender_guesser” modülü ile kullanıcının Instagram profilinde vermiş olduğu isim üzerinden cinsiyet analizi yapılmaktadır.

Bu analizler yapıldıktan sonra iki farklı yöntemin sonuçları karşılaştırılarak aynı sonuçları alıp bu sonuçlar veri tabanına kaydedilmektedir. Böylelikle bir daha aynı kullanıcı için tekrarlı analiz yapılmayarak algoritmalarımızın daha hızlı çalışması sağlanmaktadır.

3. Testler ve Bulgular

Çalışmada kullanılan sahte hesap analiz yöntemi için ilk olarak Instagram fotoğraflarındaki beğeni, yorum sayısı ve hikaye görüntüleme sayısı ile tespit yapılması düşünülmüştür. Ancak beğeni sayısı, yorum sayısı ve hikaye görüntüleme gibi durumlar satın alınabilmektedir ve bu durum analizleri olumsuz etkilemektedir. Bu yüzden, önerdiğimiz yöntem ile fenomenin takipçilerinin bilgileri çözümlenerek sahte takipçi sayısı tespit edilmiştir.

3.1.Sahte Hesap Tahmini Testleri:

298 takipçisi bulunan bir hesap, 234 adet gerçek 64 adet sahte hesaplı takipçili biçimde bölünmüştür. Bu hesap üzerinde bot analiz algoritmalarımızla test işlemi gerçekleştirildikten sonra elde ettiğimiz sonuçlar neticesinde sahte hesap tespitinde 89.1%, gerçek hesap tespitinde 98.3% doğruluk oranı görülmüştür.

3.2. Cinsiyet ve Yaş Tespiti Testleri:

Cinsiyet tahmini işlem süreleri ve tespiti testlerimiz aşağıdaki tablolarda gösterilmektedir.

¹ <https://github.com/serengil/deepface>

² <https://pypi.org/project/gender-guesser/>

Tablo 2. DeepFace algoritması kullanarak elde edilen sonuçlar

Takipçi Sayısı	İşlem Süresi (sn)	Cinsiyet Tespiti Sayısı
100	141	33
250	316	101
500	736	189

Tablo 3. gender_guesser modülü kullanarak elde edilen sonuçlar

Takipçi Sayısı	İşlem Süresi (sn)	Cinsiyet Tespiti Sayısı
100	67	42
250	184	123
500	357	278

4. Sonuç ve İleriki Çalışmalar

Günümüzde birçok fenomenin profilinde sahte takipçilerin bulunduğu bilinmektedir. Aynı zamanda çoğu firma reklamlarını sosyal medya üzerinden fenomenler aracılığıyla yapmaktadır. Yapmış olduğumuz çalışma sayesinde firmaların doğru kişiler ile iş birliği yapıp verdikleri reklamların karşılığını almaları sağlanacaktır. Bu doğrultuda bildiride Instagramdaki takipçilerin sahte olup olmaması, cinsiyet ve yaş tespitine ait çalışmalar yapılmıştır.

İleriki çalışmalarda derin öğrenme modelleri çok çekirdekli yapıda çalıştırılarak fazla sayıda takipçisi olan fenomenlere dair analizlerin kabul edilebilir hızlarda yapılması üzerinde durulacaktır. Ayrıca benzeri ticari çalışmalarda önerilen “engagement_rate” gibi takipçi/fenomen arasındaki bağlantıyı ifade eden metrikler önerilerek bu metriklerin elimizdeki verisetine dair başarısı test edilecektir.

Referanslar

- [1] F. C. Akyon ve E. Kalfaoglu, “Instagram fake and automated account detection” In Proc. IEEE Innovations in Intelligent Systems and Applications Conference, 2019, pp. 1-7.
- [2] Y. Jeon, S.G. Jean ve K. Han, “Better targeting of consumers: Modeling multifactorial gender and biological sex from Instagram posts”, Journal of User Modeling and User-Adapted Interaction, 2020, vol. 30, pp. 833-866.

- [3] K. Han, S. Lee, J. Y. Jang, Y. Jung, ve D. Lee, “Teens are from mars, adults are from venus: analyzing and predicting age groups with behavioral characteristics in instagram.”, In Proceedings of the 8th ACM Conference on Web Science (WebSci '16), Association for Computing Machinery, 2016, pp. 35-44.
- [4] <https://hypeauditor.com/>
- [5] <https://analisa.io/>
- [6] A. Farseev, K. Lepikhin, H. Schwartz, E. K. Ang. , “SoMin.ai: social multimedia influencer discovery marketplace” In Proc. of the 26th ACM International Conference on Multimedia, 2018, pp. 1234-1236

S-03 SMART PARKING

Bilge Yılmaz

bilgeyilmazz@gmail.com

A. Özet

İstanbul'un kalbi Beyoğlu ilçemize her gün ortalama 15 bin araç giriyor. Bu nedenle, park yeri ararken meydana gelen fazladan trafik sıkışıklığına bir çözüm bulmamız gerektiğini düşündük. Bu sorundan yola çıkarak bir cep telefonu uygulaması tasarlamayı düşündük. Smart Parking adını verdiğimiz uygulamamız ile araçlar, otoparklarda doluluk oranını trafiğe girmeden görebilecek. Bu uygulama aynı zamanda kullanıcıların rezervasyon yapmasına da imkan verecek. Öğrenciler belirlenen problemin çözümü için doğru algoritmayı oluşturdular. Öğrenciler iki gruba ayrılarak bir otopark modeli tasarladılar. Bir grup, Tinker Cad uygulamasıyla modeli sayısallaştırdı. Diğer grup kartondan bir otopark modeli yaptı. İlk önce tasarladıkları bu otopark prototipleri üzerinde çalıştılar. Otopark prototipine bir görüntü işlemcisi yerleştirildi. Raspberry Pi kullanılarak kodlar oluşturulmuş ve otoparkta boş ve dolu alanların tespit edilmesi sağlanmıştır. Öğrenciler araçları türlerine göre sınıflandırmış ve dikdörtgen alan formüllerini kullanarak otoparka gelen bir aracın yaklaşık alanını hesapladılar. Üç boyutlu nesnelerin hacim formüllerinden dikdörtgen prizma hacim formülünü kullanarak bu araçların hacimlerini yaklaşık olarak hesapladılar. Yapılan hesaplamalar ile belli bir alana ve hacme sahip bir otoparka kaç aracın sığabileceğini buldular. Öğrenciler iki gruba ayrıldı, bir gruba distopya ve diğer gruba ütopya adı verildi. Bu sorunun gelecekteki dünyada nasıl görüneceğini hayal ettiler. Öğrenciler park sorunu hakkında distopya ve ütopya hikayeleri yazdılar. Yazılan hikayeler e-kitap haline getirildi. Yapay dilin tanımını öğrendiler. Teknolojinin ihtiyaçlarımız ve duygularımız üzerindeki etkisini, duygu ve ihtiyaçlarımızın teknoloji üzerindeki etkisini analiz ettiler. Yapay dillerin oluşumunda yaşam sorunlarına pratik çözümler getirmenin önemini anladılar. Bilim, teknoloji, mühendislik ve matematik alanlarında öngörülen yeni mesleklerin artık kodlama ve matematikle yakından ilişkili olduğunu fark ettiler.

Anahtar Kelimeler: Akıllı Şehirler, Görüntü İşlemciler, Akıllı Otopark, STEM, Yaratıcı Yazma, Akıllı Şehir Çözümleri, Distopya, Ütopya, Raspberry Pi, Algoritmalar, Tasarım Odaklı Düşünme

B. Giriş

Günümüzde kentler hızlı kentleşmeden dolayı yoğun göç alan ve kalabalık nüfusun biriktiği yaşam mekanları haline gelmiştir. Akıllı şehir teknolojileri, kente ait çeşitli sorunların rasyonel olarak çözülmesini sağlayabilen bir uygulama olarak ülkelerin gündemine girmiş bir kavramdır. (Akgül, 2013: 291) Bilgi ve iletişim teknolojilerinin kentlerin işleyişini iyileştirmektedir. Bilgi ve iletişim teknolojilerinin (BİT) bu kadar ileri derecede gelişmesi ve değişmesi, doğal olarak toplumu ve toplumun beklenti ve alışkanlıklarını da değiştirmiştir.

(Yılmaz, 2015: 3) Akıllı teknoloji uygulamalarının devreye girmesi ile istenilen verimlilikte çeşitli hizmet alanlarında tasarruf ve sürdürülebilir yaşam standartlarına ulaşılabileceği söylenebilir. (Varol, 2017: 43). Teknoloji platformları, yapay zekâ satıcıları, şehir yetkilileri ve bileşenleri ile ortaklaşa tasarlanan sistemler uzun vadede fark yaratabilir. Bunun için herkes sisteme ve özelliklerine aşina olmalı. Trafik her demografik gruptan insanı etkileyecek en önemli şehir problemlerinden biridir. Yapay zekâ teknolojilerini kullanan uygulamalar hepimizin hayatını kolaylaştıracak niteliklere sahiptirler.



Resim 1. Prototip örneği

C. Teknoloji Dersi Kazanımları

Belirlenen problemin çözümü için bir algoritma geliştirir. Akıllı Şehirler tasarımı kapsamında Akıllı Otopark algoritması oluşturur. Algoritma; Belirli bir sorunu çözmek veya belirli bir hedefe ulaşmak için tasarlanmış yol demektir. Bir başlangıç durumundan başlayıp açıkça tanımlanmış bir son durumda biten, matematik ve bilgisayar bilimlerinde bir iş yapmak için tanımlanan bir dizi sonlu işlemdir. Matematik ve bilgisayar bilimi arasındaki ilişkiyi tanımlar. Bilgisayarların akıllı davranış modellerini kullanma yollarını açıklar. Blok tabanlı programlama aracının ara yüzünü ve özelliklerini tanımlar. Blok tabanlı bir programlama aracında sunulan bir programın işlevlerini açıklar. Blok tabanlı programlama aracında sunulan bir programı verilen kriterlere göre geliştirerek düzenler. Karar yapısını içeren programlar oluşturur. Farklı programlama yapılarını kullanarak karmaşık sorunlara çözümler üretir. Döngü yapısını içeren programlar oluşturur. Bir algoritmayı uyarlamak için en uygun karar yapılarını

ilişisini anlar. Veri yapıları ve algoritmalar alanındaki sayıları, algoritmaları ve matris işlemlerini anlar. Algoritma analizi alanında algoritma analizi ve olasılık teorisini kullanır.



Resim 3. Mobil cihaz uygulaması

E. Edebiyat Dersi Kazanımları

Bilimsel araştırma yöntemlerini öğrenir ve uygular. Etkili bir sunum yapar. Distopya ve ütopya edebi türlerini tanır. Popüler distopik ütopyalardan birini seçerek bir sunum hazırlar. Sunumu hazırlarken web 2.0 araçlarını kullanmayı öğrenir. Kelime bulutu ve poster hazırlar. 6

şapka tekniği ile yaptığı araştırmalarda hayallerinin ülkesinin savunucusu olur. Bununla ilgili dramaya alışı. Yapılan çalışmalar sonucunda sınıf, araştırma konularının tersine göre altılı gruplara ayrılmıştır. Her grup kendi tarzında ütöpik ve distöpik bir dünya yaratır. Başlangıçta zihin haritalama gibi tekniklerle genel çerçeveyi alır ve ardından hayal gücünü yazar. Sistemler kurulduktan sonra her iki dünyanın sahipleri de kendi ülkelerindeki yaşamı yansıtan ürünler yaratırlar. Modeller hazırlayıp poster tasarlayabilirler. Güncel hikayelerini kitapçık şeklinde hazırlarlar. Hikaye Yazımı: Farklı hikayelerden tek bir hikaye oluşturulur. Farklı olasılıklar göz önüne alındığında, "Olmasaydı ne olurdu? Soruları cevaplayan bir hikaye yazılır. Yazılan hikaye canlandırılmıştır. Fantastik bir hikaye yazmak: Okunan veya dinlenen / izlenen bir masal kahramanının yeni bir hayali macerası yazılır. Farklı masal kahramanları tek bir masalda bir araya getirilir veya masal kahramanının maceraları günümüze uyarlanır. Öğrenciler yazdıkları hikayeleri çizgi romana dönüştürürler. Yazdıkları hikayeye dayanarak, bir gezegenin hayati özelliklerini korumak için neler yapılabileceğine dair çıkarımlar yaparlar. Ders konusu ile ilişkilendirilecek kelimeler sıralanır, bu kelimeler aracılığıyla süreçteki bilgileri derler ve sözlü olarak ifade ederler.



Resim 4. Uygulama sınıfı

Yazar Hakkında: Bilge Yılmaz, İstanbul'da Milli Eğitim Bakanlığı'na bağlı bir lisede matematik öğretmenidir. İstanbul eTwinning ve Scientix Elçisidir. Türkiye'de STEM eğitimi için bir model üzerinde üç yıl çalıştı. Bilişim Teknolojileri Rehber Öğretmenliği Eğitimi aldı. STEM, eTwinning, AB gençlik projeleri, Çevre ve Sosyal Sorumluluk projeleri, Matematik projeleri ve atölye çalışmaları yapıyor.

Kaynakça

1. AKGÜL, M. K. (2013), “Kentlerin E Dönüşümü: Akıllı Kentler”, Anahtar Dergisi, Mart, S.291, <http://anahtar.sanayi.gov.tr>, 12.10.2017.
2. VAROL, Ç. (2017). “Sürdürülebilir Gelişmede Akıllı Kent Yaklaşımı, 26 (1): 43
3. YILMAZ, Ö. (2015), “Akıllı Kentler ve Bilgi Toplumu Stratejisi”, T.C. Kalkınma Bakanlığı, Information Society Strategy and Action Plan (2015-2018) and Smart Cities, <https://www.csb.gov.tr/db/cbsgunu/webmenu/webmenu15780.pdf>, 17.10.2017.
4. <https://www.raspberrypi.org/help/what-%20is-a-raspberry-pi/>
5. <http://web.hitit.edu.tr/dosyalar/duyurular/mustafacosar@hititedutr070320157D4O6Y7A.pdf>
6. <https://medyaveiletisim.kulup.tau.edu.tr/yeni-dunyanin-dogusu-ve-sanattaki-yeri-distopya/>

S-22 PREDICTION OF COMPRESSIVE STRENGTH OF CONCRETE VIA MACHINE LEARNING METHODS

Aybike Özyüksel Çiftçioğlu

¹ Department of Civil Engineering, Manisa Celal Bayar University, Turkey,
aybike.ozyuksel@cbu.edu.tr

Abstract

Concrete has an important place in the construction industry as a material used in many structures nowadays. Engineers aim to raise the compression strength of concrete by accurately determining the factors affecting the strength in order to build robust and economical structures, as well as to predict its strength based on the amount of ingredients it contains. Therefore, in this research, the implementation of machine learning methods to forecast compressive strength of concrete is introduced. Four algorithms including random forest regressor support vector regressor, polynomial regressor, and decision tree regressor (DTR) are employed. The dataset of 1030 concrete samples of different ages is used, including different proportions of cement, blast furnace slag, fly ash, water, superplasticizer, coarse aggregate, and fine aggregate. Once the dataset is separated as training and testing data, four machine learning algorithms are trained. Subsequently, the estimated values obtained from the test data are compared with the actual values by plotting the distributions of the observed strength against the predicted strength of each model. The models are evaluated statistically, and the performances of the models are measured by showing the performance measurements for the test data set. RFR algorithm is the best performing model with an accuracy rate of 93%.

Keywords: compression strength; concrete; machine learning; regression.

1. Introduction

Concrete is a heterogeneous material consisting of cement, water, fine and coarse aggregates, and additives. It exhibits liquid-like properties in the first few hours and can be shaped easily. However, it is a material that gains strength over time with hydration. Moreover, concrete is one of the most important construction materials used today and continues to be the most used material in the designs of architects and engineers with its wide application area. The most important feature expected from the concrete used in buildings is its high compressive strength. Therefore, the properties affecting the strength and the estimation of the compressive strength of concrete samples with different property amounts are the subject that has been researched for many years [1], [2].

Machine learning (ML) is an artificial intelligence application that includes algorithms developed to find the model and parameters that best represent the available data [3], [4]. It provides the development of algorithms that can produce output from inputs that are not in the dataset, after learning the relationship between inputs and outputs by examining the data with various algorithms and methods. Some of these algorithms are used for regression (prediction) and some for classification [5]–[8].

In this study, it is tried to estimate the compressive strengths according to the ratios of the properties in the concrete with four different machine learning algorithms over 1030 concrete sample datasets with different properties. Besides, the performances of machine learning algorithms are compared with each other by various evaluation criteria.

2. Machine Learning Algorithms

2.1. Random Forest Regressor

Random forest regressor (RFR) is an algorithm proposed by Breiman [9] as a combination of decision trees, which can be used in both classification and regression problems. The algorithm creates a decision forest by randomly selecting more than one decision tree (subsets) from the data set it is connected to. Since the training takes place on different data sets in the RFR model, variance, in other words, overfitting, which is one of the biggest problems of decision trees, is reduced. In addition, with the bootstrap method, the probability of having outliers in the sub-datasets can be reduced.

2.2. Support Vector Regressor

Support vector regressor (SVR) is a machine learning algorithm introduced by Vapnik [10] for classification problems and adapted to regression problems by Smola et al [11]. SVR is effective in high-dimensional spaces where the number of specimens is less than the number of dimensions. It is versatile as many different kernel functions can be utilized for the decision function. In addition, “support vectors” (training points) are used in the decision function. Therefore, memory is used efficiently.

2.3. Polynomial Regressor

In real engineering problems, as in linear and multiple linear regression, there may not be a linear relationship between inputs and output. In such cases, one of the nonlinear regression models that can be optimized for the data by making changes in degree is the polynomial regressor (PR) model. PR is a specific case of multiple regression with only one independent variable x . The univariate PR model is explained by the following equation:

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \dots + \beta_n x_i^n$$

n is the degree of the polynomial as well as the model and i indicates the i^{th} data [12].

2.4. Decision Tree Regressor

Decision tree regressor (DTR) algorithm, which is preferred in solving classification and regression problems, transforms complex data into a phased form using a sequential approach and provides simple decision making. The algorithm creates decision rules by asking some questions about the data. Questions begin to be asked at the root node, which is the basic element of the tree structure, and thus the growth or branching of the tree continues until the leaves, which are the last element of the tree structure, are reached. It is a method that is easy to comprehend and appraise, necessities little data preparation but does not support missing values. Besides, it can process both numerical and categorical data and can be used in multi-

output problems. The negative aspects are that tree branching is not followed in the case of overly complicated trees that do not explain the dataset well, and the over-fitting problem may be encountered [13].

3. Data Processing

In this study, a dataset containing 1030 concrete samples from the UCI Machine Learning Repository [14] is used. The independent variables of the dataset are cement, blast furnace slag, fly ash, water, superplasticizer, coarse aggregate, fine aggregate, and age, where the dependent variable is compression strength. Statistical information about the variables of the dataset is introduced in Table 1.

Table 1. *Statistics of the dataset*

	Cement	Blast Furnace Slag	Fly Ash	Water	Superplasticizer	Coarse Aggregate	Fine Aggregate	Age	Compression Strength
min	102.00	0.00	0.00	121.75	0.00	801.00	594.00	1.00	2.33
max	540.00	359.40	200.10	247.00	32.20	1145.00	992.60	365.00	82.60
mean	281.17	73.90	54.19	181.57	6.20	972.92	773.58	45.66	35.82
std	104.46	86.24	63.97	21.35	5.97	77.72	80.14	63.14	16.70

The correlations of the variables are analyzed to gain more information about the interrelationship between all dependent and independent variables in the dataset. Figure 1 indicates the colormap correlation matrix of the features of the dataset. Dark blue illustrates a strong positive correlation and as opposed to it dark brown illustrates a strong negative correlation. As can be observed, the independent variables that have the strongest relationship with compressive strength are cement, superplasticizer, and age, respectively. Compression strength has the highest negative correlation with water. This is consistent with the general knowledge that the compressive strength of concrete will raise by increasing cement, superplasticizer, and age, whereas it will decrease with increasing water content.




Figure 1. Correlation matrix of features in dataset

4. Results and Discussion

Four ML regression models (RFR, SVR, PR, and DTR) were implemented to construct predictive models of compressive strength of concrete samples. Eight independent variables of the data set introduced in the third section were used as inputs for the regression models. The regression models have trained on 824 (80%) samples and the remaining 206 (20%) samples were used for validation. The training and validating process of ML models was implemented in Python 3.6. The random state parameter was set to zero when appropriate, to preserve randomness in the regression processes and reproducibility of the results.

Figure 2 shows the distribution of predicted and observed strength values for each ML model. A good model is one in which the points around the straight line with a slope of 45 degrees through the origin have a close distribution. Mean absolute error (MAE), root mean square error (RMSE), and coefficient of regression (R^2) were also used to assess the performance of the ML models. The model with the smaller RMSE and MAE values and the larger R^2 value is considered the best model to accurately forecast the compressive strength of concrete. The purpose of the regression models is that the MAE and RMSE values are close to 0 and the R^2 value is close to 1. MAE (Mpa), RMSE (Mpa), and R^2 were defined in Equation (2)-(4).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^p - y_i| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i^p - y_i)^2} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_i^p)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

where y_i , y_i^p , and \bar{y} represent the observed values, the predicted values, and the average of observed values respectively.

The calculated performance evaluation criteria of the four machine learning methods are presented in Table 2.

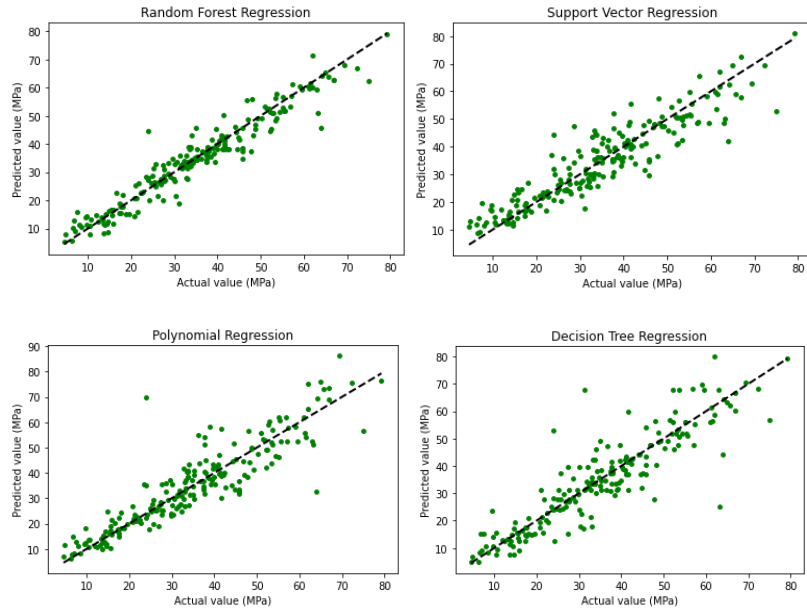


Figure 2. The distributions of the observed strength vs predicted strength.

Table 2. Performance measurements for test dataset.

ML method	RMSE	R ²	MAE
RFR	4.39	0.93	3.05
SVR	6.42	0.84	4.81
PR	7.15	0.81	4.82
DTR	7.36	0.79	4.59

The results of both Figure 2 and Table 2 reveal that RFR model is superior to other methods in the prediction of compression strength of concrete. It can be seen that the model has the lowest MAE (3.05) and RMSE (4.39) values shown in Table 2 for the testing data. Besides, it has the highest R^2 (0.93) value. Moreover, a good correlation is shown between the estimated and measured compressive strength values and all data points are close to the ideal fit from Figure 2.

When the methods are compared based on the accuracy of their predictions, it is seen that the SVR and PR models, respectively, perform relatively well after the RFR model. The DTR model shows the worst performance for this dataset.

References

- [1] Y. Murad, “Compressive strength prediction for concrete modified with nanomaterials,” *Case Stud. Constr. Mater.*, vol. 15, p. e00660, 2021, doi: <https://doi.org/10.1016/j.cscm.2021.e00660>.
- [2] X. Zhang, M. Z. Akber, and W. Zheng, “Prediction of seven-day compressive strength of field concrete,” *Constr. Build. Mater.*, vol. 305, p. 124604, 2021, doi: <https://doi.org/10.1016/j.conbuildmat.2021.124604>.
- [3] S. Khalilpourazari and S. H. R. Pasandideh, “Designing emergency flood evacuation plans using robust optimization and artificial intelligence,” *J. Comb. Optim.*, vol. 41, no. 3, pp. 640–677, 2021, doi: 10.1007/s10878-021-00699-0.
- [4] M. Bahaghighat, F. Abedini, Q. Xin, M. M. Zanjireh, and S. Mirjalili, “Using machine learning and computer vision to estimate the angular velocity of wind turbines in smart grids remotely,” *Energy Reports*, 2021, doi: <https://doi.org/10.1016/j.egy.2021.07.077>.
- [5] M. Z. Naser, “Mechanistically Informed Machine Learning and Artificial Intelligence in Fire Engineering and Sciences,” *Fire Technol.*, pp. 1–44, Jan. 2021, doi: 10.1007/s10694-020-01069-8.
- [6] A. Seitllari and M. Z. Naser, “Leveraging artificial intelligence to assess explosive spalling in fire-exposed RC columns,” *Comput. Concr.*, 2019, doi: 10.12989/cac.2019.24.3.271.
- [7] M. Z. Naser, “Observational Analysis of Fire-Induced Spalling of Concrete through Ensemble Machine Learning and Surrogate Modeling,” *J. Mater. Civ. Eng.*, vol. 33, no. 1, 2021, doi: 10.1061/(ASCE)MT.1943-5533.0003525.
- [8] S. A. Rather and P. S. Bala, *Analysis of Gravitation-Based Optimization Algorithms for Clustering and Classification*. IGI Global, 2020.
- [9] L. Breiman, “Random Forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [10] V. Vapnik, *The Nature of Statistical Learning Theory*. Newyork: Springer, 2000.
- [11] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Stat. Comput.*,

- vol. 14, no. 3, pp. 199–222, 2004, doi: 10.1023/B:STCO.0000035301.49549.88.
- [12] E. Ostertagová, “Modelling using polynomial regression,” *Procedia Eng.*, vol. 48, pp. 500–506, 2012, doi: 10.1016/j.proeng.2012.09.545.
- [13] S. K. Murthy, “Automatic Construction of Decision Trees from Data: A Multi-Disciplinary Survey,” *Data Min. Knowl. Discov.*, vol. 2, no. 4, pp. 345–389, 1998, doi: 10.1023/A:1009744630224.
- [14] I.-C. Yeh, “Concrete Compressive Strength Data Set,” *UCI Machine Learning Repository*, 1998.
<https://archive.ics.uci.edu/ml/datasets/Concrete+Compressive+Strength>.

S-48 REAL TIME FACE MASK DETECTION ON SURVEILLANCE CAMERAS IN EDGE DEVICES

Ahmet Emin YETKİN¹, İhsan KARATAŞ^{2*}, Hassan İMANİ³

¹ Biyomedikal Mühendisliği, Çözüm Makina, Türkiye, aeyetkin@cozum-makina.com

² Bilgisayar Mühendisliği, Çözüm Makina, Türkiye, ikaratas@cozum-makina.com

³ Bilgisayar Mühendisliği, Çözüm Makina, Türkiye, himani@cozum-makina.com

Özet

Milyarlarca insan 2019 Aralık'tan bu yana covid-19 salgınından mustarip şekilde hayatlarına devam etmeye çalışmaktadır. Yüz maskelerinin virüsün yayılmasını önlemedeki önemi pandeminin ilk aylarında kanıtlanmıştır. Ancak insanlar maske takmayı rahatsız edici bulmaktadırlar ve ilk fırsatta maskelerini çıkarmaya eğilimlidirler. Çözüm olarak, maske takmayan kişileri güvenlik kameraları görüntülerinde evrişimli sinir ağlarını kullanarak, tespit eden bir sistem önerilmektedir. Kamera akışlarını giriş olarak alan ve maskesiz bir kişi algılandığında anlık alarm veren bu sistem NVIDIA Jetson NX uç cihazında %95 doğruluk oranına ve toplamda 20 milisaniyelik çıkarım hızına sahiptir.

Anahtar Sözcükler: Covid-19; Evrişimsel Sinir Ağları; Uç Hesaplama; Yüz Maskesi Tespiti.

Abstract

Millions of people have been suffering from the covid-19 pandemic since December 2019. The importance of face masks on preventing the spread of the virus was proven in the early months of the pandemic. However, people find wearing masks uncomfortable and they tend to take off their masks. As a solution, a system that detects people who don't wear mask on surveillance camera streams instantly using convolutional neural networks is proposed. The system takes camera streams as input, and alarms instantly if a person without the mask is detected. The system achieved 95% accuracy and 20-millisecond total inference speed on NVIDIA Jetson NX.

Keywords: Covid-19; Convolutional neural networks; Edge computing; Face mask detection.

1. Introduction

In the last months of 2019, a member of the coronaviriade family, whose starting point is the city of Wuhan in China, met with the covid-19 virus. The virus spread rapidly all over the world. The epidemic was declared as a pandemic by the World Health Organization in March 2020. The effects are usually seen in the lower and upper respiratory tract. People infected with the virus often have severely damaged lungs [1]. The most common spread type of coronavirus is the airborne transmission.

Wearing a face mask plays a crucial role in alleviating the covid-19 virus, especially in closed areas [2]. Yet, most people find it hard to wear a mask even if they do not object to the benefit of wearing it. Therefore, local authorities and governments started to obligate people about wearing masks at the beginning of the pandemic. However, checking people whether wear a mask is not a scalable problem. It is hardly possible to control people in larger areas the whole time since it requires lots of labour force.

Convolutional neural networks (CNN) opened new doors to solve difficult computer vision problems [3]. For instance, classifying objects when backgrounds, light, object pose, and size are varied is a less challenging problem [11]. In this study, CNN was used to detect if a person does not wear a face mask on surveillance camera images. Although it may seem a trivial problem to classify faces with masks and without the mask, there are serious challenges on surveillance camera images. As it's supposed to be, surveillance cameras are positioned in high places and see people from above. In addition, they have low resolution to reduce hardware and data storage costs. These conditions make it difficult to detect and classify faces correctly. Using state-of-the-art deep networks might solve the classification problem if the system doesn't have to work in real-time.

In [5], a hybrid model was proposed. They used ResNet-50[4] as a feature extractor and used SVM for classification. Also, their training dataset mostly consisted of portrait face images and synthetically placed face masks. It's a practical solution yet little deceptive since synthetically placed object has a distinct edge that makes it easier to detect. In addition, a system that uses SVM followed by ResNet-50 is too much computational burden for edge devices. In [6], YoloV2[7] and ResNet-50 was used. Publicly available datasets were used for training and detector accuracy was reported as 0.81. Similar to [5], using these networks consecutively makes it harder to process real-time.

Our contributions can be listed as follows:

lightweight system that can operate on multiple surveillance camera streams in real time is developed.

A robust ResNet based model that detects face masks despite the disadvantages of surveillance cameras.

2. Material and Methods

2.1. System Topology

Acquired camera stream was first sent to face detector [9]. Output of the face detector is number and location of faces. Faces are cropped, resized to 96x96x3, and normalized around 0.485 mean and 0.229 standard deviation. Then, they are sent to classifier CNN. Since the system is supposed to run real-time on several cameras, computational cost must be minimized as much as possible. Therefore, lightweight models were preferred as classifier, such as Resnet-18 [4].



Figure 1. System Topology




Figure 2. ResNet-18 Architecture. Source: [10]

Resnet is a CNN architecture that is famous for its repetitive residual connections that preserves spatial data and increases the efficiency of back propagation of weight updates [4].

2.2. Dataset and Training

The model was trained on a custom dataset which was collected from our company’s CCTV cameras and annotated. It consists of 66910 images. Dataset was split as 75% train, 17% validation and 8% test. Our Resnet-18 backbone CNN model was trained to predict one of two classes which are with mask, without mask. During training, weights were not initialized randomly. Official pre-trained weights were used. All layers were frozen except last 2 fully connected layers that responsible for predictions.

Adam optimizer with binary cross entropy loss was used. Learning rate was 1×10^{-5} . Model was trained 30 epochs. Class weights were used since dataset that consists of following frames was unbalanced. That means most of the images in the dataset were repetitive images.

As data augmentation, images were randomly rotated by ± 30 degrees maximum, flipped images in Y axis with probability of 0.5, erased part of the images with probability of 0.5, maximum ratio to be erased to whole image is 0.3.

Pytorch [8] was used for training and inference. Pytorch is an open-source machine learning framework written in Python programming language. It has a CUDA support which provides tremendous speed both training and inference. Technical specifications of workstation that was used for training are as follows: Ubuntu 18.04 OS, AMD Ryzen Threadripper 3960X CPU, NVIDIA RTX 2080Ti GPU, 32 GB RAM, 1 TB SSD storage.

3. Results

Accuracy on test dataset which consists of roughly 4700 images was 0.95. Precision, recall, F1 and support metrics are also considered as evaluation criteria. During the training, these values were calculated at the end of each epoch and were analysed to prevent overfitting.

Table 1. Results

Evaluation Metrics				
Class Name	Precision	Recall	F1 Score	Support
With Mask	0.91	0.99	0.95	2309
Without Mask	0.99	0.91	0.95	2387

Accuracy	Support			
Macro Average	0.95	0.95	0.95	4696
Weighted Average	0.95	0.95	0.95	4696



Figure 3. Sample images on our test dataset that our model predicted correctly.

4. Discussion

Consistent face mask usage is important to prevent an airborne disease especially in indoor places. In this study, a system that takes the surveillance camera stream as input and alerts authorities when someone does not wear a mask was developed. To be able to do that, we needed to separate people precisely with masks from people without masks. When the face appears most of the input image with decent point of view, it's easy to tell whether the person wears a mask or not. It even may not require such an advanced method as CNN. Nonetheless it was mandatory to design a system that needs to work on surveillance videos. Naturally, in surveillance cameras, faces appear small and viewed from a steep angle. Camera distortions, low resolution, varieties in light conditions, and steep face angles were other challenges.

Image labelling was labour intensive task. Thus, creating a dataset that carries the characteristics of target domain was really helpful. As seen in Figure 3, images are ill posed and can be confusing.

A CNN that classifies faces as with mask, without the mask was trained. Adding the undefined class would be considered if face detection failures was frequent but face detector didn't send almost any non-face image to face mask classifier. In addition, adding a negative class without poisoning the learned representations is so hard since the undefined class would have wide borders.

In conclusion, tasks that has visual cues such as face mask usage can be tracked using CNNs. These systems helps quantizing the situation and makes it easier to track.

References

- [1] Yasar, Huseyin, and Murat Ceylan. "A new deep learning pipeline to detect Covid-19 on chest X-ray images using local binary pattern, dual tree complex wavelet transforms and convolutional neural networks." *Applied Intelligence* 51.5 (2021): 2740-2763.
- [2] Cheng, Yafang, et al. "Face masks effectively limit the probability of SARS-CoV-2 transmission." *Science* (2021).
- [3] LeCun, Yann, et al. "Gradient-based learning applied to document recognition." *Proceedings of the IEEE* 86.11 (1998): 2278-2324.
- [4] He, Kaiming, et al. "Deep residual learning for image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- [5] Loey, Mohamed, et al. "A hybrid deep transfer learning model with machine learning methods for face mask detection in the era of the COVID-19 pandemic." *Measurement* 167 (2021): 108288.
- [6] Loey, Mohamed, et al. "Fighting against COVID-19: A novel deep learning model based on YOLO-v2 with ResNet-50 for medical face mask detection." *Sustainable cities and society* 65 (2021): 102600.
- [7] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.

- [8] Paszke, Adam, et al. "Pytorch: An imperative style, high-performance deep learning library." *Advances in neural information processing systems* 32 (2019): 8026-8037.
- [9] Liu, Wei, et al. "Ssd: Single shot multibox detector." *European conference on computer vision*. Springer, Cham, 2016.
- [10] Ramzan, Farheen, et al. "A deep learning approach for automated diagnosis and multi-class classification of Alzheimer’s disease stages using resting-state fMRI and residual neural networks." *Journal of medical systems* 44.2 (2020): 1-16.
- [11] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems* 25 (2012): 1097-1105.

S-18 YAPAY SİNİR AĞLARI İLE STRONSIYUM-90 RADYOİZOTOPUNUN NÖTRON REAKSİYONLARININ TESİR KESİTİ TAHMİNLERİ

M.Mustafa ORHAN, Serkan AKKOYUN

Fizik Bölümü, Sivas Cumhuriyet Üniversitesi, Türkiye,
sakkoyun@cumhuriyet.edu.tr

Özet

Nükleer santrallerde nötronlar, nükleer reaksiyonları başlatmak için uranyum hedefinin bombardımanında kullanılır. Reaktör içerisinde sürekli olarak hızlı ve termal nötron akısı bulunmaktadır. Uranyum ürünlerinden bu süreçle, stronsiyum radyoizotopları oluşturulabilir. Nükleer reaktörlerde nükleer fisyon ürünü olan stronsiyum-90 (^{90}Sr) radyoizotopunun nükleer bataryalar içerisinde de kullanıldığı bilinmektedir. ^{90}Sr izotopunun, hedeflenen uzay araçları için yakıt olarak kullanılması da tartışılmaktadır. β^+ yayıcı olan ^{90}Sr , ek olarak nükleer atık olması sebebiyle de atık bertarafında sorun yaşanan radyoizotoptur. Nükleer reaksiyonlar için önemli parametrelerden birisi de reaksiyon tesir kesitidir. Bu çalışmada, reaktörlerin kullanımıyla ^{90}Sr radyoizotopunun nötronlarla bombardımanı sonrası gerçekleşmesi muhtemel reaksiyonların tesir kesiti verileri için TENDL-2019 kütüphanesindeki veriler kullanılmıştır. Tesir kesitlerinin tahmini ve modellenmesinde, yapay sinir ağı yöntemi, ^{90}Sr radyoizotopları üzerinde nötron kaynaklı olası reaksiyon tesir kesitlerini tahmin etmek üzere kullanılmıştır. Elde edilen sonuçlara göre, tesir kesiti bilgisinin bu yöntemle güvenle elde edilebileceği görülmüştür. Bilinmeyen bir enerji değerindeki nötron enerjileri için bu yöntemin, tesir kesitlerinin tahminine bir alternatif olarak kullanılabileceği sonucuna varılmıştır.

Anahtar Sözcükler: *Radyoizotop, Tesir Kesiti, Stronsiyum-90, Yapay Sinir Ağı, Nötron Reaksiyonları*


Abstract

In nuclear power plants, neutrons are used to bombard a uranium target to initiate nuclear reactions. There is always a fast and thermal neutron flux in the reactor. Strontium radioisotopes can be formed from uranium products by this process. It is known that the radioisotope of strontium-90 (^{90}Sr), which is a nuclear fission product in nuclear reactors, is also used in nuclear batteries. The use of ^{90}Sr as a fuel for targeted spacecraft is also discussed. ^{90}Sr , which is a β^+ emitter, is also a radioisotope that has problems in waste disposal because it is nuclear waste. One of the important parameters for nuclear reactions is the reaction cross section. In this study, the data in the TENDL-2019 library were used for the cross section data of possible reactions after the bombardment of the ^{90}Sr radioisotope with neutrons with the use of reactors. In the estimation and modeling of the cross sections, the artificial neural network method was used to predict neutron-induced reaction cross sections on the ^{90}Sr radioisotopes. According to the results obtained, it has been seen that cross section information can be obtained safely with this method. It is concluded that this method can be used as an alternative to the estimation of cross sections for neutron energies of an unknown energy value.

Keywords: Radioisotope, Cross Section, Strontium-90, Artificial Network, Neutron Reactions

1. GİRİŞ

Sr-90 saf haliyle, parlak bir gümüş metaldir, ancak havaya maruz kaldığında hızla sarıya döner. Madenden çıkarılan selestinin (SrSO₄) büyük bir kısmı iki işlemle karbonata dönüştürülür. Selestin doğrudan sodyum karbonat çözeltisi ile süzülür ya da sülfidi oluşturmak için selestin kömürle kavrulur. İkinci aşama, çoğunlukla stronsiyum sülfür içeren koyu renkli bir malzeme üretir. Bu sözde "kara kül" suda çözülür ve süzülür. Stronsiyum karbonat, stronsiyum sülfid çözeltisinden karbon dioksitin eklenmesiyle çökeltilir. Sülfat, karbotermik indirgeme ile sülfüre indirgenir [1,2].



Nükleer fisyon ürünlerinden olan stronsiyum (⁸⁹Sr ve ⁹⁰Sr), ²³⁵U'luk (sırasıyla 4.7 ve 5.8 atom/100 fisyon) yüksek fisyon verimi üretir. ⁹⁰Sr nispeten uzun bir yarı ömre (29 yıl) sahip olduğundan, uranyum ve plütonyumun en önemli fisyon ürünlerinden biridir.¹³⁷Cs ile (30 yıllık bir yarı ömre sahip). ⁸⁹Sr, ⁹⁰Sr'den daha radyoaktif olmasına rağmen, birincisi (50 günlük yarılanma ömrü ile) birkaç ay içinde bozunurken, ⁹⁰Sr çevrede kalır. Ek olarak, ⁹⁰Sr (son nokta enerjisi 0.54 MeV) çekirdeğinin potansiyel beta enerjileri çok yüksektir. ⁹⁰Sr kemikte biriktiğinde, uzun süreli beta radyasyonu ile iskelete ve çevre dokulara iletir[2]. ⁹⁰Sr'nin en çok kullanıldığı alanlar tıp ve tarımsal çalışmalardadır. Ayrıca olarak seyir fenerleri, uzay istasyonlarında, uzay araçları gibi uzak yerlerde kullanımı için güç kaynağı olarak kullanımıyla beraber endüstriyel kalınlık ölçümlerinde de kullanılmaktadır[3].

Bu çalışmada, ⁹⁰Sr radyoizotopu için farklı enerjilerdeki nötron reaksiyonlarının tesir kesitlerinin tahmini için yapay sinir ağı (YSA) yöntemi kullanılmıştır.⁹⁰Sr hedef malzeme olarak seçilmiş ve YSA tahminleri için veriler, TENDL-2019 kütüphanesinden alınmıştır. YSA, farklı katmanlarda fonksiyonel işlemler yapabilen yapay nöronlardan oluşmaktadır. Girdi değerinin analitik fonksiyonlarını ağırlık değerleriyle hesaplama yaparak kendi çıktılarını üretir. YSA, girdiler ve çıktılar arasında bir ilişkiye ihtiyaç duymaz. Bu nedenle doğrusal olmayan bir fonksiyonun tahminçisi olarak adlandırılır. Son yıllarda YSA nükleer fizikte birçok alanda kullanılmaktadır. Bunlara örnek olarak, nükleer kütle sistematığının geliştirilmesi[4], fisyon bariyer yüksekliklerinin elde edilmesi[5], nükleer yük yarıçaplarının elde edilmesi[6], beta bozunma enerjilerinin tahmini[7], Z bozununun tesir kesitlerinin yaklaştırılması[8-9], gama ışını açılal dağılımlarının belirlenmesi[10] ve soğuruculardaki elektronlar için radyasyon verimlerinin tahminleri [11].

2. METERYAL VE METOD

Yapay sinir ağları (YSA), standart tekniklerin başarısız olduğu durumlarda kullanılan çok güçlü bir matematiksel araçtır. Yapay sinir ağı, beyin işlevselliğini taklit eden matematiksel bir modeldir. Temelde üç farklı katmanda nöron adı verilen birkaç işlem biriminden oluşur[12]. En yaygın YSA türlerinden birinde, veri giriş katmanından çıkış katmanına ileri yönde akar. Bu nedenle bu çalışmada da kullanılan bu YSA türü, katmanlı ileri beslemeli YSA olarak

adlandırılmıştır. Yalnızca farklı katmanlardaki nöronlar, ağırlıklı bağlantılarla birbirine bağlanır. Bu iki katman arasında kara kutu olarak görülen gizli bir katman vardır. Girdi katmanındaki nöronlar verileri alır, veriler gizli katmanda işlendikten sonra çıktı katmanı nöronları sonucu verir. Problem değişkenlerine göre giriş ve çıkış katmanlarındaki nöron sayıları belirlenir. Ayrıca, gizli katmanın sayısı da 1'den daha önde gelen derin öğrenmeye değiştirilebilir[11]. Gizli katman ve nöron sayılarının belirlenmesinde herhangi bir kural yoktur. Problem için yapılan birçok denemeden sonra, istenen değerlere en yakın sonuçları veren gizli katman ve nöron sayıları dikkate alınabilir. YSA biri eğitim diğeri ise eğitim sonuçlarının test aşaması olmak üzere iki ana aşamadan oluşmaktadır. Problemin verileri genellikle %80 ve %20 olmak üzere iki kısma ayrılır ve %80'i YSA'nın eğitimi için ve %20'si YSA'nın testi için kullanılır. Eğitimde temel amaç, farklı katmanlardaki her bir nöron arasındaki bağlantıların ağırlık değerlerini belirlemektir. Bu çalışmanın eğitim aşamasında Levenberg-Marquardt[13,14] algoritması kullanılmıştır. En iyi sonucu veren ağırlık değerleri belirlendikten sonra oluşturulan ağ ile eğitim verilerinde istenilen değerler üretilmeye çalışılır. Ağın ürettiği çıktılar ile istenilen çıktılar arasındaki hata MSE tarafından belirlenir. MSE, istenen ve sinir ağı çıkış değerleri arasındaki farkın karelerinin ortalamasını verir. Ağın eğitim verileri üzerinde başarılı sonuçlar verdiğini görmek yeterli değildir. Ayrıca ağın bu tür veriler üzerinde genelleme yapıp yapamayacağı da belirlenmelidir. Bu, daha önce tahsis edilen %20'lik veri setinde yapılır. Oluşturulan ağ test verilerine uygulanarak ağın çıktıları istenilen çıktılarla karşılaştırılır. Test aşamasında da MSE değerleri istenilen seviyenin altında ise bu ağın verilen problemi çözmede başarılı olduğu söylenebilir.

Bu çalışmada, ^{90}Sr hedef çekirdeği üzerine gönderilen nötronlardan sonra gözlenen (n, g), (n, p), (n, d), (n, t) ve (n, a) reaksiyonlarına ait reaksiyon tesir kesitlerinin tahmini için, 271 veri kullanılmıştır. Nötron enerjisinin 1 MeV'den 200 MeV'ye kadar değerlerine karşılık gelen TENDL-2019 veri tabanındaki tesir kesiti verileri, rasgele olarak eğitim ve test aşamaları için ayrılmıştır. YSA'nın girdileri, reaksiyon tipi ve nötron gelme enerjisidir. Reaksiyon tipi değeri için, (n, g), (n, p), (n, d), (n, t) ve (n, a) reaksiyonları için sırasıyla, 0, 1, 2, 3 ve 4 değerleri kullanılmıştır. YSA'nın çıktısı ise tesir kesitidir. Tek gizli katmanın kullanıldığı hesaplamalarda, gizli katman nöron sayısı olarak 6, 10, 20 ve 30 kullanılmış ve sonuçları birbiriyle karşılaştırılmıştır.


3-SONUÇLAR VE TARTIŞMA

Reaksiyon tesir kesitlerini elde etmek üzere gerçekleştirdiğimiz bu çalışmada, farklı gizli katman nöron sayılarının (h) kullanımına ait istatistiksel değerler Tablo 1'de verilmiştir. Tablodan görüldüğü gibi, gizli katman sayısı arttıkça, MSE ve Maks. Hatanın azaldığı görüldü. Ancak h=10 YSA'da hatanın ve artışı burada istisnai durum oldu. En iyi değerleri ise eğitim ve test için h=30 olduğu görülmektedir.

Gizli Katman Nöron	Eğitim Seti		Test Seti	
	MSE	Maks. Hata	MSE	Maks. Hata
h=6	3,806	8,798	2,593	7,207
h=10	3,521	-9,196	5,930	-10,334
h=20	0,657	-3,490	0,452	-1,981
h=30	0,084	-1,395	0,109	-1,475


Tablo 1. Eğitim ve Test veri setlerinin MSE ve Maks. Hata verileri (Birimler mb cinsindedir)

Gizli katman nöron sayısının en düşük ve en yüksek olduğu hesaplamalara ait sonuçlar grafikler halinde sunulmuştur. Şekil 1’de eğitim verileri üzerinden YSA tahminleri görülmektedir. TENDL-2019 veri tabanındaki değerler ile YSA’nın ürettiği değerler arasındaki farkların çizildiği bu grafiklerde, h= 6 grafiğinde yaklaşık -4 ile 10 mb arasındaki dağılımı vardır. h=30’a ait dağılımın yaklaşık -1,5 ile 1 mb arasındadır. h=30 YSA daha iyi sonuçlar vermiş ve h=30 için eğitimin daha başarılı olduğu açıkça bellidir.



Şekil 1. YSA eğitim verilerinin dağılımı verilmiştir.

Şekil 2’de h=6 ve h=30 YSA test verileri görülmektedir. h=6 YSA yapısında bazı aralıklarda TENDL-2019’dan alınan verilere göre diğer bölgelere kıyasla daha büyük sapmalar vardır. Ancak h=30 yapısındaki YSA modelinde, önceden belirtilen aralıklardaki sapmalar, TENDL-2019’dan alınan verilerle arasındaki fark daha az ve kabul edilebilir düzeylerde olduğu görülmüştür. Sonuç olarak YSA’da nöron sayısı arttıkça sonuçların daha iyiye gittiği gözlemlenmiştir. h= 30 YSA modelinin ⁹⁰Sr hedefi üzerine gerçekleştirilecek olan (n, g), (n, p), (n, d), (n, t) ve (n, a) reaksiyonlarının istenilen enerji düzeyindeki tesir kesit tahminleri için kullanılabilir olduğu görülmüştür.



Şekil 2. YSA sonuçlarının TENDL-2019 verileri ile kıyaslanması.

KAYNAKÇA

- 1- Cdc.gov. 2021. *CDC Radiation Emergencies / Radioisotope Brief: Strontium-90 (Sr-90)*.
[online]Availableat:<<https://www.cdc.gov/nceh/radiation/emergencies/isotopes/strontium.htm>>[Accessed 26 October 2021].
- 2- Erdemoğlu, M. Aydoğan, S. and Canbazoğlu, M., 2007. A kinetic study on the conversion of celestite (SrSO₄) to SrCO₃ by mechanochemical processing. *Hydrometallurgy*, 86(1-2), pp.1-5.
- 3- Takagai, Y., Furukawa, M., Kameo, Y. and Suzuki, K., 2014. Sequential inductively coupled plasma quadrupole mass-spectrometric quantification of radioactive strontium-90 incorporating cascade separation steps for radioactive contamination rapid survey. *Anal. Methods*, 6(2), pp.355-362.
- 4- Akkoyun, S. and Bayram, T., 2014. Estimations of fission barrier heights for Ra, Ac, Rf and Db nuclei by neural networks. *International Journal of Modern Physics E*, 23(10), p.1450064.
- 5- Akkoyun, S. Bayram, T. Kara, S. and Sinan, A., 2013. An artificial neural network application on nuclear charge radii. *Journal of Physics G: Nuclear and Particle Physics*, 40(5), p.055106.
- 6- S. Akkoyun ve H. Kaya, "Estimations of Cross-Sections for Photonuclear Reaction on Calcium Isotopes by Artificial Neural Networks", *Sakarya University Journal of Science*, c. 24, sayı. 5, ss. 1115-1120, Eki. 2020, doi:10.16984/saufenbilder.694382
- 7- Akkoyun, S., Bayram, T. and Turker, T., 2014. Estimations of beta-decay energies through the nuclidic chart by using neural network. *Radiation Physics and Chemistry*, 96, pp.186-189.
- 8- Akkoyun, S. and Kara, S. 2013. An approximation to the cross sections of Z 1 boson production at CLIC by using neural Networks. *Open Physics*, Vol. 11 (Issue 3), pp345-349. <https://doi.org/10.2478/s11532-012-0168-y>

- 9- Kara, S. Akkoyun, S. and Bayram, T., 2014. Probing for leptophilic gauge boson Z_1 at ILC with $\sqrt{s} = 1\text{--}3\text{ TeV}$ by using ANN. *International Journal of Modern Physics A*, 29(30), p.1450171.
- 10- Yıldız, N., Akkoyun, S. and Kaya, H., 2018. Consistent Empirical Physical Formula Construction for Gamma Ray Angular Distribution Coefficients by Layered Feedforward Neural Network. *Cumhuriyet Science Journal*.
- 11- Haykin, S., 2008. *Neural Networks and Learning Machines*. 3. baskı. Hamilton, Ontario, Kanada: Pearson Prentice Hal, s.8-10.
- 12- Akkoyun, S. Bayram, T. 2021, “Production Cross-Section of ^{51}Cr Radioisotope Using Artificial Neural Networks” *Türk Fen ve Sağlık Dergisi*, 2, 133-138. <https://dergipark.org.tr/en/pub/tfsd/issue/60096/8282737-K>.
- 13- K. Levenberg, 1944. “A method for the solution of certain non-linear problems in least squares“, *Quart. Appl. Math.*, vol. 2, s. 164-168,.
- 14- D. Marquardt, D. 1963 “An Algorithm for LeastSquares Estimation of Nonlinear Parameters”, *SIAM J. Appl. Math.*, vol. 11, pp. 431-44

S-23 YENİLENEBİLİR ENERJİDE MAKİNE ÖĞRENİMİ YÖNTEMİ İLE TAHMİN

Zühre Aydın Yeniöglü

Bilgi İşlem Dairesi Başkanlığı, EPDK, Ankara, Türkiye,
zaydin@epdk.gov.tr

Özet

Bu çalışmanın temel amacı, yapay zekâ tekniklerinden makine öğrenimi algoritmalarının yenilenebilir enerji kaynaklarının gelecek tahminler için kısa vadede nasıl kullanılabileceğini ve karar verme süreçlerinde kullanılacak yöntemlerin ileri tahminler için önemini göstermektir. Makale, yenilenebilir enerji alanında makine öğreniminin nasıl çalıştığını örnek bir algoritma üzerinden sunmaktadır. Bu yazıda sunulan sonuçlar, yenilenebilir enerji alanında bir tahmin aracı olarak yapay zekânın potansiyelini kanıtlamaktadır.

Anahtar Kelimeler: Yenilenebilir enerji, Rüzgâr hızı tahmini, Makine öğrenimi, k -en yakın komşu algoritması, Denetimli öğrenme

Abstract

The main purpose of this study is to show how machine learning algorithms, one of the artificial intelligence techniques, can be used for future predictions of renewable energy sources and that the methods to be used in decision-making processes are important for renewable energy forecasting. The article presents how machine learning can be applied in the field of renewable energy through a sample algorithm. The results presented in this paper demonstrate the potential of artificial intelligence as a predictive tool in the field of renewable energy.

Keywords: Renewable energy forecasting, Wind speed prediction, Machine learning, k -nearest neighbor algorithm, Supervised learning

1. Giriş

Yapay Zekâ (YZ), en geniş anlamıyla, bir makinenin veya yapay nesnenin insan düşüncesini karakterize eden aynı tür işlevleri yerine getirme yeteneğini gösteren bir terimdir. YZ terimi, gerçek düşünce alanından uzak olsa da, basit programlamadan daha karmaşık görevleri gerçekleştirebilen bilgisayar sistemlerine ve programlarına uygulanmıştır.

Rüzgâr enerjisi kurulum maliyetleri düşük olan ve hızla büyüyen yenilenebilir enerji kaynağıdır. Rüzgâr enerjisi gibi değişken özelliklere sahip yenilenebilir enerji kaynaklarına olan ihtiyaçların doğru kararlarla belirlenmesi ve gelecek için potansiyellerinin tahmini, güç üretim birimlerinin kurulumu yönünden önemlidir. Yenilenebilir enerji sistemlerinin bilgi akışının ve performansının tahmini için analitik bilgisayar kodları sıklıkla kullanılır. Kullanılan algoritmalar genellikle diferansiyel denklemlerin çözümünü içeren karmaşıklığa sahiptir. Yenilenebilir enerji sistemlerinden gelen verilerin doğası gereği gürültülü olması, YZ kapsamında ele alınacak doğru problemler olduklarını gösterir. YZ analizi, bir sistemin genellikle gürültülü geçmiş verisine dayanır, bu nedenle diğer teorik ve ampirik yöntemlerden daha iyi analizler yapması ve tahminlerde bulunması normaldir.

Makine öğrenme algoritmaları, veri kümesinin davranışını, model girdi özelliklerini beklenen çıktıya ve model çıktı özelliklerinin tarihsel kayıtlarına göre tanımlamak için başarıyla

kullanılmaktadır. Makine öğrenimi algoritmaları, rüzgâr hızı verilerine dayalı olarak rüzgâr enerjisini tahmin etmede kullanılmaktadır.

Makalenin amacı, rüzgâr enerjisi için karar verme süreçlerinde rüzgâr hızı tahmininde, makine öğrenimi uygulama olanağını göstermektir. Bu çalışmada, makine öğrenimi K en yakın komşu (kNN-k Nearest Neighbor) algoritması uygulaması ile yapılacaktır. kNN, uygulamada basit ve kolay, öğrenme sürecinde güçlü ve kullanışlı olmasından dolayı sınıflandırmada yaygın biçimde kullanılmaktadır.

2. Literatür taraması

Yenilenebilir enerji alanında rüzgâr enerjisi tahminine dayanan çalışmalar kısa ve uzun vadeli enerji tahmini şeklinde iki kategoride araştırılır. Kısa vadeli gelecek enerji tahminleri zaman dilimini birkaç saat ya da birkaç gün gibi kısa zaman periyotlarında incelerken, uzun vadeli tahminler birkaç günden bir yıl sonrasına kadar dayanan uzun zaman periyotlarını tahmin etmeye çalışır. Bu kapsamda yenilenebilir enerji alanında rüzgâr enerjisi ve diğer bazı yenilenebilir enerji kaynaklarına ilişkin makine öğrenimi yöntemlerine dayalı olarak literatürde yürütülen çalışmalar aşağıda olduğu gibi incelenmiştir.

Makine öğrenme yöntemlerini kullanarak rüzgâr enerjisi tahminleriyle ilgili Khan vd. [1], rüzgâr gücünün uzun vadede sonuçlarını tahmin etmek için Kartezyen Genetik Programlama ve Yapay Sinir Ağları (YSA) üzerine çalışmışlardır. Zhang vd. [2], rüzgâr hızı tahmini için doğrusal regresyon, çok katmanlı algılayıcı ve destek vektör makinesi algoritmalarını kullanmışlardır. Wu vd. [3], rüzgâr enerjisi gelecek tahmini performansını artırmak için hibrit bir rüzgâr enerjisi üretim tahmin modeli önermiştir. Alencar vd. [4], YSA modelleri ve otoregresif hareketli ortalama ve (ARIMA) hibrit modellerini kullanarak, yapay zekâ tekniklerine dayalı ultra kısa, kısa, orta ve uzun vadeli rüzgâr hızı tahmin modelleri geliştirmiştir. Wang vd. [5], kısa vadede rüzgâr gücünü tahmin etmek için ARIMA modelini kullanmış ve sonuçlarında iyi performans gözlemlemiştir. Shi vd. [6], rüzgâr enerjisini tahmin etmek için uzun kısa süreli bellek tabanlı derin öğrenme mimarilerini kullanmışlardır. Wang vd. [7], yenilenebilir enerji kaynaklarının değişken doğası ve oluşan belirsizlik nedeniyle, belirsizliği azaltmaya bir önlem olarak yenilenebilir enerji tahmininin önemine değinmiş, yenilenebilir enerji potansiyelinin doğru bir şekilde tahmin edilmesi için, yapay zekâ tekniklerini ve hibrit teknikleri önermiştir. Maroufpoor vd. [8], meteorolojik değişkenler kullanarak rüzgâr hızı tahmini için sezgisel yapay zekâ algoritmasının kullanımını araştırmışlardır. Fan vd. [9], enerjide kısa vadeli yük tahmin modeli için kNN en yakın komşu algoritması ile kısa vadeli karar verme süreçlerinde fayda sağlanacağı üzerinde durmuştur. Pei vd. [10], ayrıştırma tabanlı rüzgâr tahmin yöntemlerinin kapsamlı bir incelemesini sunmuştur. Ayrıştırma tabanlı hibrit tahmin modelleri, ayrıştırma yöntemlerine göre dalgacık, ampirik mod ayrıştırma, mevsimsel düzeltme yöntemleri, değişken mod ayrıştırma, içsel zaman ölçeği ayrıştırma ve bernaola galvan algoritması gibi farklı gruplara ayrılır [10].

3. K-en yakın komşu algoritması

kNN örneği, örnek tabanlı tembel öğrenme yaklaşımını kullanan denetimli bir sınıflandırma algoritmasının klasik bir örneğidir. Örnek tabanlı öğrenme algoritmalarında, öğrenme işlemi eğitim setinde tutulan verilere dayalı olarak gerçekleştirilmektedir. Yeni karşılaşılan bir örnek, eğitim setinde yer alan örnekler ile arasındaki benzerliğe göre sınıflandırılmaktadır. kNN

algoritması Cover vd. [11] tarafından sunulmuştur. Bu makine öğrenimi örneğinde; her veri noktası, uzayda yer alan herhangi bir sayıda kategori veya sınıftan bir nokta olarak temsil edilir.

Değerlendirilen komşu noktaların sayısı bir k parametresi ile belirlenir. Veri tahmini için mevcut veri setindeki değerler ile aradaki uzaklık hesabı, ve k değerine en yakın komşulukları bulmak gerekir. $k=1$ durumunda en yakın veri seti elemanı ve sınıflandırma işlemi yapılırken, $k > 1$ durumunda en yakın elemanların listesi tutulur. Verinin yalnızca tahmin sırasında kullanılması tembel öğrenme yöntemi olmasının sebebidir. kNN algoritmasının adımları veriyi incelemek, k parametresini belirlemek, uzaklıkları hesaplamak, en yakın k birim uzaklıktaki komşuları belirlemek, seçilen sınıf için verileri tahmin yöntemiyle etiketlemek şeklindedir. Veri setine eklenecek verinin, diğer verilere uzaklığı genellikle “Euclidean”, “Manhattan”, “Minkowski” uzaklık fonksiyonlarıyla hesaplanıp, k sayıda yakın komşuluklar bulunur. Veri kümesindeki yeni etiketlenen verinin komşularını bulmak için, mesafe uzaklık fonksiyonu ile hesaplanır. Uzaklıklar ölçüldükten sonra, eğitim veri setindeki elemanların, etiketlenen yeni elemanlara olan uzaklıkları azalan sırada sıralanır ve en yakın komşular bulunur. Uygulamada, komşuluk fonksiyonu ile en yakın uzaklıklar listelenir, sıralanır ve komşular tespit edilir. Eğitim veri kümesinden toplanan en yakın komşular tahmin yapma amaçlı ilgili tahmin fonksiyonuyla bulunur.

4. Metodoloji

Bu bölümde kNN regresyon analizi algoritmasının Python üzerinde geliştirilen kodları ve sonuçları sunulacaktır. Bu algoritma; makine öğreniminde yaygın kullanımı, yenilenebilir enerjide rassallık ve tahmin için uygunluğu ve literatürde yüksek performans göstermesi nedenleriyle örnek uygulama için tercih edilmiştir.

4.1. Veri Seti

Bu çalışmada, kNN algoritmasının farklı nitelik türlerine ve veri değerlerine ilişkin sınıflandırma performansının incelenmesi için, dört farklı nitelik ve 646 örnek sayısından faydalanılmıştır. Çalışmanın amacı doğrultusunda rüzgâr hızı tahmini için veri setinin elde edildiği bölgeye ait nitelikler üzerinde çalışılmıştır. Uygulamada kullanılan veri seti, verilerin Dünya çapında binlerce kullanıcı ve kuruluş tarafından açık erişim ile sağlandığı <https://data.world/datasets/wind> bağlantısında yer alan 'boylam', 'enlem', 'zaman' ve 'rüzgâr hızı' niteliklerini içermektedir. Herhangi bir enlem ve boylam koordinatı için geçerli tarih ve saatte, rüzgâr hızı tahmin edilmiştir. İlgili veriler Python kodu sonucu olarak Şekil 1’ de sunulmuştur. Aşağıda yer alan şekilde Python sonuçları ile ekrana yansıtılan veri seti ve veri setinde yer alan verilerin değer alıp almadıkları, satır sayıları ve veri tipleri sunulmuştur.

```
Data columns (total 4 columns):
#  Column      Non-Null Count  Dtype
---  -
0  Boylam       646 non-null    float64
1  Enlem        646 non-null    float64
2  Zaman        646 non-null    float64
3  Ruzgar_hizi  646 non-null    int64
dtypes: float64(3), int64(1)
```

Şekil 1: Uygulamada kullanılan veri seti satır sayıları ve veri tipleri

4.2. Uygulama

Rüzgâr tahmini için geliştirilen kodun detayları aşağıda yer almaktadır.

Öncelikle veri setimizi analiz etmek için pandas, numpy, scikit-learn ve datetime modüllerinin kullanımı sağlanmıştır. Rüzgâr tahmini için ihtiyaç duyulan 'Boylam', 'Enlem', 'Zaman' özellikleri ve 'Ruzgar_hizi' hedef verisi aşağıdaki şekilde belirlenmiştir.

```
feature_col = ['Boylam', 'Enlem', 'Zaman']
target = ['Ruzgar_hizi']
```

X özellik veri kümesi değişkeni , y ise hedef veri kümesi değişkeni olarak atanmıştır. train_test_split fonksiyonu ile veriler eğitim ve test verileri kümelerine ayrılmıştır.

```
X_train, X_test, y_train, y_test = train_test_split(X, y, random_state = 1)
print(X_train.shape)
print(X_test.shape)
print(y_train.shape)
print(y_test.shape)
```

KNeighborsClassifier nesnesi ile ilk aşamada k en yakın komşu algoritması için k=1 seçilmiştir. Seçim sonrası modelin doğruluğu hesaplanmış ve %100 doğruluk bulunmuştur.

```
knn = KNeighborsClassifier(n_neighbors = 1)
knn.fit(X,y.values.ravel())
check_coord = [[11.79, 33.169998, 42368.149155]]
print(knn.predict(check_coord))
y_pred = knn.predict(X)
# modelin doğruluğunun ölçümü k=1
print(metrics.accuracy_score(y,y_pred))----sonuç 1
```


İkinci aşamada KNeighborsClassifier nesnesi ile algoritma için k=5 seçilmiş ve doğruluk testi tekrarlanmıştır. Bu testin sonucu %50' den düşük çıktığından k=1 doğru seçim olarak değerlendirilmiştir.

```
knn = KNeighborsClassifier(n_neighbors = 5)
knn.fit(X,y.values.ravel())
print(knn.predict(check_coord))
y_pred = knn.predict(X)
# modelin doğruluğunun ölçümü k=5
print(metrics.accuracy_score(y,y_pred))----sonuç 0,37
```

Sonraki aşamada, veri kümemizde bulunmayan rastgele koordinatların kontrolü için atamalar yapılmış, bu koordinatlar için rüzgâr hızı belirlemek amacıyla, datetime modülü yardımıyla currenttime kullanımı sağlanmıştır. Böylece rassal bir enlem ve boylam koordinatı için geçerli tarih ve saatte, rüzgâr hızı tahmin edilmiştir.

Geliştirme sırasında verilerin görselliğini sağlamak amacıyla seaborn veri görselleştirme modülü kullanılmıştır.

Elde edilen görseller aşağıda yer almaktadır.



Şekil 2: Rüzgar hızının öznelik veri setine göre değişimi ve tahmini

Şekil 2’ de görüldüğü gibi, rüzgâr hızı – zaman, rüzgâr hızı – boylam, rüzgâr hızı – enlem grafiğinde bazı farklılıklar görülmekle birlikte genel olarak veriler arasında tutarlı değişimler elde edilmiştir. Grafiklerde saniyeler içinde değişen değerler görülmektedir.

Son aşamada ise veri setimizde yer alan boylam, enlem ve zaman özellikleri, rüzgâr hızını belirlemek için doğruluk testine uygun şekilde ve $k=1$ seçilerek modele eklenmiştir. Sonuç olarak; kNN algoritmasının rüzgâr hızını %100 doğrulukla tahmin ettiği görülmüştür.

5. Sonuç

Bu çalışmada, kNN algoritmasının yenilenebilir enerji alanında kısa vadede karar verme için uygun olup olmadığı üzerinde durulmuştur. Veri setimize göre, saniyeler arasında rüzgâr tahmini yapmak için modelin nasıl eğitileceği, tahmin edilen çıktının nasıl doğrulanacağı, verilerin eğitim ve test veri kümelerine nasıl bölüneceği gösterilmiştir. Ayrıca, k değerinin uygun değerde seçilmesi performans açısından önem taşımaktadır. Uygulamada Öklid mesafesinde $k=1$ için en iyi, $k=5$ için en kötü tahmin performansı elde edilmiştir. k değeri büyüdükçe hesaplama zorluğu artacak, k değeri küçüldükçe algoritma gürültülü veriye karşı daha hassas davranacak, doğruluk oranında artış ve hız kazanacaktır. Bu nedenlerle; kNN algoritmasının; yenilenebilir enerjinin gelecekteki karakteristiklerinin tespitinde kullanılırken k değerine doğruluk ve güven açısından önem verilmesi, rassallığın göz önünde bulundurulması durumunda rahatlıkla uygulanabileceği çalışma kapsamında gösterilmiştir. Gelecek yenilenebilir enerji tahminlerinde; farklı özniteliklerin seçimi ve parametre optimizasyonu yapılarak makine öğreniminde sınıflandırma performansını artıracak çalışmalar yapılabilir.

Referanslar

- [1] G. M. Khan, , J. Ali and S. A. Mahmud, "Wind power forecasting - An application of machine learning in renewable energy", International Joint Conference on Neural Networks (IJCNN), Beijing, China, 06-11 July, 2014.
- [2] C. Zhang, H. Wei, , T. Zhu, K. Zhang, and , T. Liu, "Comparison of two multi-step ahead forecasting mechanisms for wind speed based on machine learning models", Chinese Control Conference, CCC. 2015, Hangzhou, China, 28-30 July, 2015.
- [3] Q. Wu, C. Peng, "Wind Power Generation Forecasting Using Least Squares Support Vector Machine Combined with Ensemble Empirical Mode Decomposition, Principal Component Analysis and a Bat Algorithm" Energies, 9(4), 261, 2016.
- [4] D. Alencar, D. B. De Mattos, A. C. De Oliveira, R. C. L. Rodríguez, J. L. M. Leite, J. C., and , J. C. R. Filho, "Different Models for Forecasting Wind Power Generation: Case Study", Energies 10, 1-27, 2017.
- [5] K. Wang, X. Qi, H. Liu and , J. Song, "Deep belief network based k-means cluster approach for short-term wind power forecasting", Energy 165(A), 840-852, 2018.
- [6] X. Shi, X. Lei, Q. Huang, S. Huang, K. Ren and Y. Hu, "Hourly day-ahead wind power prediction using the hybrid model of variational model decomposition and long short-term memory", Energies 11(11), 3227, 2018.
- [7] H. Wang, Z. Lei, X. Zhang, B. Zhou and, J. Peng, "A review of deep learning for renewable energy forecasting", Energy "Conversion and Management 198, 111799, 2019.

- [8] S. Maroufpoor, H. Sanikhani, O. Kisi, R. C. Deo and Z. M. Yaseen, "Long-term modelling of wind speeds using six different heuristic artificial intelligence approaches", *International Journal of Climatology* 39(8), 3543-3557, 2019.
- [9] G. F. Fan, Y. H. Guo, J.M. Zheng and W. C. Hong, “Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load Forecasting” *Energies*, 2019,12, 916
- [10] Y. Pei, H. Zareipour, N. Chen, “A review and discussion of decomposition-based hybrid models for wind energy forecasting applications”, *Applied Energy* 235:939-953, 2019.
- [11] T.M. Cover, and P.E. Hart, “Nearest neighbor pattern classification”. *IEEE Transactions on Information Theory*, IT13(1):21–27 ,1967.
- [12] <https://data.world/datasets/wind>

S-21 ANALYSIS OF KINEMATICALLY UNSTABLE TRUSSES WITH FINITE ELEMENT METHOD WITH ENERGY MINIMIZATION

Batuhan ŞANLI¹, Hakan ÖZBAŞARAN^{2,*}, Yusuf Cengiz TOKLU³

¹ Civil Engineering, Eskisehir Osmangazi University, Turkey, batuhansanli@gmail.com

² Civil Engineering, Eskisehir Osmangazi University, Turkey, ozbasaran@ogu.edu.tr

³ Civil Engineering, Beykent University, Turkey, cengiztoklu@gmail.com

Abstract

Trusses are structural systems that are constructed by connecting straight members to each other with pinned joints. They are preferred in many structure types such as factories, sport complexes, and transmission towers due to their low weight and high performance. As a common practice for all structural systems, the structural analysis of trusses under static loads are mostly performed with finite element method (FEM), which is a numerical method based on numerical solution of governing differential equations. Although classical FEM is a powerful method, it cannot deal with kinematic instabilities. However, it is certain that at least one equilibrium state is available for any structural system independent of its kinematic stability. The energy methods, which are based on the fact that any loaded structure takes the form that store the minimum total potential energy, are useful alternatives to deal with kinematically unstable structures. This paper evaluates the performance of a previously introduced method known as Finite Element Method with Energy Minimization (FEMEM) for the analysis of kinematically unstable truss systems over two numerical examples.

Keywords: *Truss; Kinematic Stability; Metaheuristics; Optimization; Artificial Intelligence*

1. Introduction

The finite element method (FEM) [1] is a powerful procedure for numerical solution of the governing equations of the problems found in nature. Contrary to the common misconception, the FEM is a general method to solve differential equations; it is not a method that is specifically designed for structural analysis. From the point-of-view of the structural engineer, the FEM is a Swiss army knife for computing the stresses, strains, internal forces, and displacements in a structure under a given set of loads. However, classical version of this powerful method fails in analysis of kinematically unstable structures (Figure 1).




Figure 1. *An externally kinematically unstable structure and its equilibrium state.*

The structure in Figure 1 is an “externally” kinematically unstable structure. The external kinematic instability refers to insufficient number of support reactions. On the other hand, a structure is internally kinematically unstable if it cannot maintain its form when disconnected from its supports. No matter if a structural system is kinematically stable or not, it will find an equilibrium state that renders the system to store minimum amount of potential energy under various loads. Such an equilibrium state is available for even internally unstable structural systems. The mentioned equilibrium state may not be similar to the shape of the unloaded structural system (the node displacements may be excessive), however, the topology of the system stays the same.

Toklu proposed the Total Potential Optimization (TPO) method [2] for the analysis of structures in 2004. The name of that method is later evolved to Finite Element Method with Energy Minimization (FEMEM). The mentioned method searches the node position configuration of the loaded system that stores the minimum total potential energy, which can be defined as an optimization problem. Since the mathematical modelling of the relation between the design variables (node displacements) and the objective value (total potential energy of the system) is not direct, the application of classical optimization methods is cumbersome. Therefore, metaheuristics will be useful in solving of this optimization problem.

This study evaluates the performance of the FEMEM in solving kinematically unstable planar trusses over two numerical examples.

2. Method

2.1. Platform

Python programming language is preferred to develop the solver used in this study. The Python language is popular due to its easy syntax and wide community. In addition, a huge number of libraries are available for Python. Visual Studio Code (VS Code) is used as Integrated Development Environment (IDE) which is a rich IDE developed by Microsoft.

2.2. Theory

The total potential energy stored in a deformed structural system is calculated by Eq. (1) [2].

$$U(\boldsymbol{\varepsilon}) = \int_V e(\boldsymbol{\varepsilon}) dV - \sum_{i=1}^{N_P} P_i \cdot u_i \quad (1)$$

$$e(\boldsymbol{\varepsilon}) = \int_0^{\boldsymbol{\varepsilon}} \boldsymbol{\sigma}(\boldsymbol{\varepsilon}) d\boldsymbol{\varepsilon} \quad (2)$$

In Eq. (1), V is the volume, P_i are the loads, u_i are the displacements, N_P is the number of the loads, and finally, U is the total potential energy stored in the system. In Eq. (2), e is the strain energy density, $\boldsymbol{\sigma}$ is the stress, and $\boldsymbol{\varepsilon}$ is the strain. The length of a deformed truss system member can be calculated with the expression given in Eq. (3).

$$L(\mathbf{c}) = ((x_j - x_i + u_j - u_i)^2 + (y_j - y_i + v_j - v_i)^2)^{1/2} \quad (3)$$

In Eq. (3), (x_i, y_i) and (x_j, y_j) are the start and end coordinates of the truss system member, respectively. And (u_i, v_i) and (u_j, v_j) show the start and end node displacements, respectively. The elongation of the considered member can be calculated by Eq. (4) and the strain can be expressed in terms of elongation as given in Eq. (5).

$$\Delta L(\mathbf{c}) = L(\mathbf{c}) - L(0) \quad (4)$$

$$\boldsymbol{\varepsilon}(\mathbf{c}) = \Delta L(\mathbf{c}) / L(0) \quad (5)$$

Since the materials are assumed to be linear elastic in this study, Eq. (1) can be simplified as Eq. (6) for the analysis of truss systems. The former part $(\sum_{j=1}^{N_m} e_j \cdot A_j \cdot L_j)$ of Eq. (6) is the strain energy, and the latter part $(\sum_{i=1}^{N_P} P_i \cdot u_i)$ is the work done by the external loads. Please note that the work done by external loads decrease the total potential of the structural system.

$$U(\boldsymbol{\varepsilon}) = \sum_{j=1}^{N_m} e_j \cdot A_j \cdot L_j - \sum_{i=1}^{N_P} P_i \cdot u_i \quad (6)$$

In Eq. (6), A_j and L_j are the cross-section area and length of the j^{th} member, respectively. N_m is the number of the truss system members. L_j is the cross-section area of the j^{th} member. The deformed shape of a truss system can be obtained by searching the node displacement components vector $\mathbf{c} = [u_1, v_1, \dots, u_N, v_N]$ that makes the value of Eq. (6) minimum. This can be performed by using a metaheuristic optimization algorithm. In this study the Jaya Algorithm (JA) [3] is preferred. The JA is a parameter-free metaheuristic with a single-line movement operator, which is successfully implemented in previous studies [4]–[8].

3. Numerical Examples

Both trusses in this part are examples of kinematically unstable structural systems. The Young's modulus of the material is 200 GPa and all members have the same cross section area of 0.1 m² in both examples.

3.1. Example 1




Figure 2. An internally and externally kinematically unstable planar truss.

The truss system in Figure 2 is both internally and externally unstable. The node 1 is restrained for displacement in x and y directions; the other nodes are free. Therefore, the number of support reactions are insufficient. On the other hand, the structure cannot maintain its form when it is disconnected from its only support, which makes it internally unstable, as well. The load acting at the node 5 is +10 kN in the x direction and the load acting at node 10 is +10 kN in the y direction. The initial (undeformed) and deformed states are drawn in gray and blue colors, respectively.

Starting with random solution candidates, the decrease in the total potential of the system by the iteration number is presented in Figure 3.




Figure 3. Iteration – total potential plot for the system given in Figure 2.

The minimum total potential energy is determined as -31.94 kNm for the loaded equilibrium state (drawn in blue color) given in Figure 2.

3.2. Example 2

The system in Figure 4 is internally stable. However, it has external instability due to its unfavorable restraint configuration (only the node 1 is restrained to move in x and y directions). The only load in the system is acting at node 6 in the y direction (+10 kN).




Figure 4. Two different but equivalent equilibrium states.

Both equilibrium states (drawn in blue color) given in Figure 4 stores the same amount of total potential energy as the minimum value that can be discovered by the authors. This means the undeformed system (drawn in gray color) may take both forms under the given load.

4. Conclusions

The method by Toklu is yet simple and effective method to determine deformed shape of structural systems. It is shown by the two examples introduced in this study that the analysis of truss systems with energy minimization can deal with both external and internal instabilities. This method can be extended to solve plates and solids with instability handling and multiple equilibrium state discovery features. The JA algorithm allowed to make a fair evaluation thanks to its parameter-free movement operator. On the other hand, the performance of the procedure may vary due to implemented optimization algorithm. Better results may be obtained by using more advanced algorithms [7]

References

- [1] O. C. Zienkiewicz, *The Finite Element Method*. London : McGraw-Hill, 1977, 1977.
- [2] Y. C. Toklu, “Nonlinear analysis of trusses through energy minimization,” *Comput. Struct.*, vol. 82, no. 20–21, pp. 1581–1589, 2004.
- [3] R. Venkata Rao, “Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems,” *Int. J. Ind. Eng. Comput.*, vol. 7, no. 1, pp. 19–34, 2016.

- [4] Y. C. Toklu, A. E. Kayabekir, G. Bekdaş, S. M. Nigdeli, and M. Yücel, “Analysis of Plane-Stress Systems via Total Potential Optimization Method Considering Nonlinear Behavior,” *J. Struct. Eng.*, vol. 146, no. 11, p. 04020249, 2020.
- [5] Y. C. Toklu, G. Bekdaş, A. E. Kayabekir, S. M. Nigdeli, and M. Yücel, “Total Potential Optimization Using Metaheuristics: Analysis of Cantilever Beam via Plane-Stress Members,” *Adv. Intell. Syst. Comput.*, vol. 1275, pp. 127–138, 2021.
- [6] Y. C. Toklu, G. Bekdas, and M. S. Nigdeli, *Metaheuristics for Structural Design and Analysis*. John Wiley & Sons, 2021.
- [7] H. I. Aytekin and H. Özbaşaran, “On the Road to Development of a Hyperheuristic: Experiments on a Size Optimization Problem,” *1st Int. Conf. Int. Conf. Interdiscip. Appl. Artif. Intell.*, vol. 1, pp. 12–13, 2021.
- [8] H. Özbaşaran, P. Ataş, B. Şanlı, and Y. E. Kaya, “Computer-Automated Design of RC Residential Buildings: First Thoughts and Initial Tests,” *1st Int. Conf. Int. Conf. Interdiscip. Appl. Artif. Intell.*, pp. 14–16, 2021.

S-15 VERİ MADENCİLİĞİ İLE RÜZGAR TÜRBİNLERİNİN GÜÇ TAHMİNİ

POWER PREDICTION OF WIND TURBINES WITH DATA MINING

Burcu KARAALI¹, Selma GÜRLER²

¹ Fen Bilimleri Enstitüsü, Dokuz Eylül Üniversitesi, Türkiye, burcugok28@gmail.com

² İstatistik Bölümü, Dokuz Eylül Üniversitesi, Türkiye, selma.erdogan@deu.edu.tr

Özet

Son yıllarda yaşanan teknolojik ve endüstriyel gelişmelerle birlikte tüm ülkelerin elektrik talebi her geçen gün artmaktadır. Elektrik ihtiyaçlarını karşılamak için ülkeler yenilenebilir enerji kaynaklarından verimli bir şekilde yararlanmanın yollarını aramaktadır. Bundan dolayı, rüzgar enerjisi önemli ve her yerde bulunan yenilenebilir bir enerji kaynağıdır. Rüzgar enerjisi sistemlerinin hızlı gelişim sürecinde rüzgar türbinlerinin performansı teknoloji ile birlikte sürekli gelişmeler göstermektedir. Rüzgar enerjisi üretimiyle ilişkili belirsizliği azaltmanın bir yolu, tahmin araçlarını kullanmaktır. Veri madenciliği yöntemleri rüzgar türbinlerinin ürettiği enerjinin tahmin edilmesi için ön plana çıkmaktadır. Bu çalışma, veri madenciliği yöntemleri kullanılarak Türkiye'nin İç Anadolu bölgesinde yer alan gerçek bir rüzgar santrali için rüzgar hızına bağlı olarak enerji üretim tahminini amaçlamaktadır. Elde edilen modeller çeşitli performans kriterleri kullanılarak karşılaştırılmıştır. Önerilen model hem maliyet hesabı hem de arıza ve bakım çalışmalarının planlanması aşamalarında karar vericilere yardımcı olacaktır.

Anahtar Sözcükler: *Rüzgar gücü, rüzgar gücü tahmini, veri madenciliği metotları.*

Abstract

The electricity demand of countries is increasing day by day with the technological and industrial developments experienced in recent years. Countries are looking for ways to use renewable energy sources efficiently to meet their electricity needs. Therefore, wind energy is an important renewable energy source. With the rapid development of wind energy systems, the performance of wind turbines shows continuous improvements with technology. One way to reduce uncertainty about wind power generation is to use forecasting tools. Data mining methods come into importance for estimating the energy produced by wind turbines. This study aims to estimate the power using wind speed for a real wind farm located in the Central Anatolia region of Turkey by data mining methods. Obtained models were compared using various performance criteria. The proposed model will help decision-makers in both cost calculation and planning of failure and maintenance work.

Keywords: *Data mining methods, wind power, wind power estimation.*

1. Giriş

Günümüzde enerji, dünyanın ve insanlığın en hayati ihtiyaçlarından biri haline gelmiştir. Artan talepler ve bu talepleri karşılamak için geliştirilen üretim süreçleri sebebiyle enerjiye ve enerji kullanımına olan ihtiyaç da artmaktadır. Enerji konusunda kalıcı çözümlerin bulunması için enerji problemlerinin doğru tanımlanması, uygulanabilecek çözümlerin bulunması, eski ve mevcut en iyi enerji teknolojileri arasında ayırım yapılması ve faydadan çok zarar veren eski

teknolojilerin kullanılmaması gerekmektedir. Teknolojik gelişmeler, sanayileşme ve yaşam standartlarının yükselmesiyle birlikte dünyadaki siyasi sürecin şekillenmesinde ülkelerin enerji kaynakları, bu enerji kaynaklarını nasıl kullandıkları, kullanım verimleri ve değerlendirme, denetleme ve geliştirebilme şekilleri de etkili olmaktadır. Ülkelerin enerji bağımsızlıkları siyasi olarak belirleyicilik katmaktadır. Tüm bu sebepler nedeniyle geleceğe yönelik oluşturulan üretim planlamalarında yenilenebilir enerji kaynaklarının kullanımının artırılmasına yönelik çalışmalar da hız kazanmaktadır [1].

Türkiye’de yenilenebilir enerji kaynakları önem kazanırken ülkenin sahip olduğu yüksek rüzgar enerjisi potansiyeli göz önünde bulundurulduğunda; rüzgarın, Türkiye’nin gelecekteki enerji üretiminde önemli bir rol oynayacağı öngörülmektedir. Rüzgar enerjisinde, Türkiye Rüzgar Enerjisi Birliği’nin (TÜREB) açıkladığı verilere göre 2020 yılının sonunda Türkiye’deki kurulu güç toplam 9.305 MW’a ulaşmıştır [2]. Genel olarak Türkiye’deki yedi coğrafi bölgenin değerlendirilmesiyle, rüzgar enerjisi sistemleri için en uygun bölgelerin Marmara, Ege ve Güneydoğu Anadolu bölgeleri olduğu sonucu çıkartılırken; Çanakkale, İzmir, Balıkesir, Hatay ve İstanbul’un rüzgar potansiyeli en yüksek iller olduğu belirtilmektedir [3].

Rüzgar enerjisi sistemlerinin hızlı gelişim sürecinde rüzgar türbinlerinin performansı teknoloji ile birlikte sürekli gelişmeler göstermektedir. Rüzgar enerjisi üretimiyle ilişkili belirsizliği azaltmanın bir yolu, tahmin araçlarını kullanmaktır. Bu tür araçların geliştirilmesi 15 yıldan fazla bir süredir devam etmektedir [4]. Rüzgar enerjisi aralıklı ve değişken bir yapıya sahip olduğundan farklı zaman ölçeklerinde rüzgar enerjisinin nerede, ne zaman ve ne kadar kullanılacağı belirlenmesi gerekmektedir. Ayrıca bir rüzgar türbinin gerçekleştireceği üretim miktarı; yerel ve bölgesel rüzgar trendleri, mevsimsel farklılıklar, çevredeki bitki örtüsü, yükseklik ve yakınında bulunan diğer türbinlere göre değişiklikler gösterebilmektedir. Böylelikle daha etkin ve verimli sistem kurulumları gerçekleştirilmektedir. Bu nedenlerden dolayı rüzgar türbinlerinin ürettiği rüzgar gücünün tahmin edilmesi gerekiyor ve bu aşamada doğru tahminler için veri madenciliği teknikleri ön plana çıkıyor. Bu çalışmada, veri madenciliği yöntemlerini kullanarak farklı modeller ve çeşitli yaklaşımlar ile bir rüzgar santralının üreteceği gücün RStudio uygulaması kullanılarak tahmin modelleri oluşturulmuştur. Modeller, bir rüzgar santralının SCADA (Denetleyici Kontrol ve Veri Toplama) sisteminden toplanan 2019 ve 2020 yıllarına ait veriler kullanılarak oluşturulmuştur.

Literatürde rüzgar gücünün tahminlenmesi üzerine pek çok çalışma bulunmaktadır. Kusiak ve ark. (2009) k-en yakın komşuluk algoritması ve temel bileşen analizi yöntemlerini kullanarak güç tahmini üzerine çalışmışlardır. Ayrıca, bir rüzgar santralının toplam güç çıktısını tahmin etmek için girdi olarak rüzgar hızını kullanan farklı modelleri karşılaştırmışlardır. Temel bileşen analizi yaklaşımıyla birleştirilen k-en yakın komşuluk modeli, bu çalışmada incelenen diğer modellerden daha iyi performans göstermiştir [5]. Başka bir çalışmada ise Kusiak ve Song (2010), güç çıktısını tahmin etmek için girdi olarak rüzgar hızı, rüzgar yönü, rotor hızı, jeneratör torku ve kanat dönme açısını kullanan farklı modelleri karşılaştırmışlardır. Bu modeller yapay sinir ağları, rassal ormanlar, destek vektör makinesi, k-en yakın komşuluk ve destek ağaçlarıdır. En iyi sonucu veren model ise yapay sinir ağları çıkmıştır [6]. 10 saniyelik rüzgar türbini verilerine dayanarak rüzgar hızı tahmin modellerini oluşturmak için üssel düzleştirme ve veri madenciliği algoritmaları kullanılmıştır. Kullanılan modellerin performans kıyaslaması hata

oranlarına göre analiz edilmiştir. Çolak ve ark. (2012) bu kapsamdaki çalışmalar hakkında geniş bir literatür incelemesi vermiştir. Literatürde tercih edilen diğer çalışmalara bazı örnekler [8], [9] ve [10] olarak verilebilir.

2. Materyal ve yöntem

Veri madenciliği, makine öğrenimi, örüntü tanıma, istatistik, veri tabanı yönetim sistemleri, akıllı sistemler ve veri görselleştirmenin kesişiminden oluşarak bu bağlamda gelişimini sürdürmektedir. Bu çalışmada, rüzgar güç üretimini tahmin etmek için veri madenciliği yöntemleri olan lineer regresyon, k-en yakın komşuluk regresyonu ve rassal ormanlar regresyonu modelleri kullanılmıştır. Bu çalışmada doğrusal, k-en yakın komşu ve rassal ormanlar regresyonlarının tahmin performansını karşılaştırmak için ortalama mutlak hata (MAE) ve belirtme katsayısı (R^2) ölçüleri karşılaştırılmıştır. Bu hata ölçüleri aşağıdaki gibi ifade edilir [11].

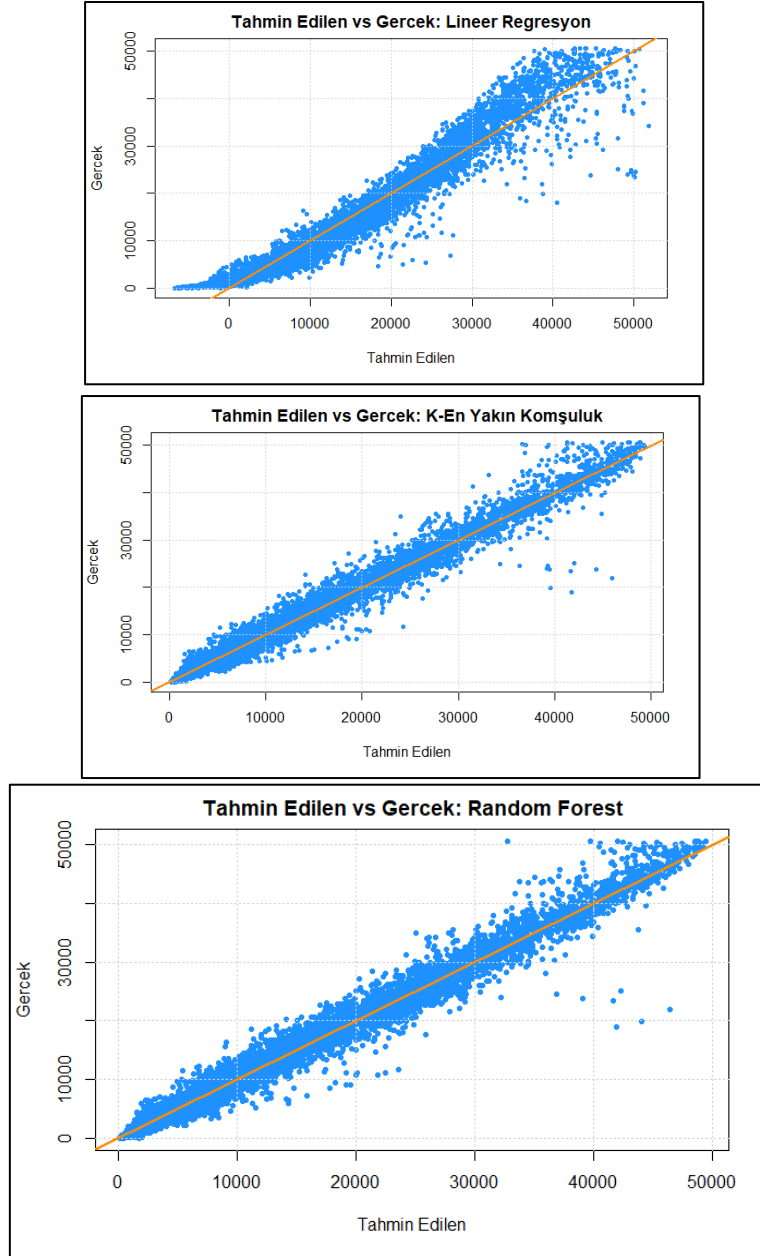
$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (1)$$

$$R^2 = \frac{\sum_{j=1}^n (\hat{y}_j - \bar{y})^2}{\sum_{j=1}^n (y_j - \bar{y})^2} \quad (2)$$

3. Bulgular

Bu çalışmada, 70 adet rüzgar türbininden SCADA sistemine işlenen veriler, İzmir’de kurulmuş uluslararası bir şirket olan ENERCON Servis Ltd. Şti. firması aracılığıyla sağlanmıştır. 2019 ve 2020 yıllarına ait günlük veriler SCADA sisteminden Excel csv formatında indirilmiş ve RStudio uygulamasına yüklenmiştir. Veri setinde veri temizleme işlemlerinden sonra veri kümesi %80 eğitim (train) ve %20 test (test) olarak ayrılmıştır. Modeldeki girdi değişkenleri rüzgar hızı, rotasyon hızı, kanat açısı ve makine dairesi pozisyonu iken çıktı ise enerji üretimidir. Kullanılan metotlar arasında lineer regresyon, k-en yakın komşuluk regresyonu, regresyon ağacı yöntemlerinden olan rassal ormanlar regresyonu yöntemleri, MAE ve R^2 bakımından karşılaştırılmıştır. Lineer regresyon modelinde çoklu doğrusal bağlantı problemi olduğu için modelden rotasyon hızı çıkarılmıştır. Model girdileri rüzgar hızı, kanat açısı ve makine dairesi pozisyonudur. Rassal ormanlar regresyonunda modele en önemli katkı sağlayan girdi değişkeni rüzgar hızı olarak belirlenmiştir.

Şekil 3.1’de görüldüğü gibi, doğrusal regresyon, k-en yakın komşu regresyon ve rassal ormanlar regresyon algoritmaları ile tahmin edilen rüzgar gücü değerleri ve gözlemlenen değerler arasındaki uyum gösterilmektedir.



Şekil 3.1 Tahminlenen ve gözlenen değerler

Şekil 3.1'de görüldüğü gibi, doğrusal regresyon, k-en yakın komşu regresyon ve rassal ormanlar regresyon algoritmaları ile tahmin edilen rüzgar gücü değerleri ve gözlemlenen değerler arasındaki uyum gösterilmektedir.

Tablo 3. Veri madenciliği yöntemleri ile hata ölçüm sonuçları

Algoritma	Hata ölçüm sonuçları	
	MAE	R^2
Lineer Regresyon	2199.64	0.94
K-En Yakın Komşuluk Regresyonu	1179.92	0.97
Rassal Ormanlar Regresyonu	1104.89	0.98

Bahsedilen veri madenciliği yöntemlerinin algoritmaları k-kat çapraz geçerlilik (k-fold cross validation) prosedürü ile tahmin edilmiştir. Çapraz geçerlilik prosedüründe k, 10 olarak seçilmiştir. Tahmin işlemi sonucunda, ortalama mutlak hata ve belirtme katsayısı R^2 değerleri Tablo 3'te verilmiştir. Tablo 3'de görüldüğü üzere rassal ormanlar regresyon yöntemi ile 0.98 R^2 'ye ulaşılmıştır. Kurulan üç model içerisinde en iyi sonucu rassal ormanlar regresyonu vermiştir. Buna göre bu yöntemde kurulan modelde en etkin değişkenin rüzgar hızı olduğu gözlenmiştir ve enerji üretim tahmini rüzgar hızına bağlı olarak yapılmıştır. Tablo 4'te üç farklı rüzgar hızı değeri için elde edilen günlük ortalama üretim tahmini değeri verilmiştir.

Tablo 4. Rüzgar hızına bağlı olarak enerji tahmini

Rüzgar hızı (m/sn)	Tahmin değeri (kW)
8.4	21860.54
10	32128.72
15.3	41233.61

4. Sonuç ve öneriler

Bu çalışmada, doğrusal regresyon, k-en yakın komşu regresyon ve rassal orman regresyon algoritmaları, rüzgar türbini günlük güç üretiminin tahmin performanslarını karşılaştırmak için kullanılmıştır. Ortalama mutlak hata ve belirtme katsayısının hata ölçüleri açısından rassal orman regresyonu algoritması, en yakın komşu regresyonu ve doğrusal regresyon algoritmalarına göre daha iyi tahmin performansı sağlamaktadır. Rüzgar güç çıktısını günlük tahminlemek, hem bakım maliyetlerini optimize etmek hem de son kullanıcı olan müşteriye öngörü sağlaması açısından yararlı olacaktır.

Referanslar

- [1] N. Karabağ, C. B. Ç. Kayıkcı and A. Öngen, "%100 Yenilenebilir Enerjiye Geçiş Yolunda Dünya ve Türkiye.," Avrupa Bilim ve Teknoloji Dergisi, pp. 230-240, 2021.
- [2] TÜREB, "TÜREB," 2020. [Online]. Available: <https://www.tureb.com.tr>.
- [3] C. İlkiliç, "Wind energy and assessment of wind energy potential in Turkey," Renewable and Sustainable Energy Reviews, no. 16, pp. 1165-1173, 2012.
- [4] G. Giebel, G. N. Kariniotakis and R. Brownsword, "The state-of-the-art in short term prediction of wind power from a danish perspective," 4th International Workshop on large scale integration of wind power and transmission networks for offshore wind farms, Oct. 2003.
- [5] A. Kusiak, H. Zheng and Z. Song, "Models for monitoring wind farm power," Renewable Energy An International Journal, pp. 583-590, 2009.
- [6] A. Kusiak and Z. Song, "Short-Horizon Prediction of Wind Power: A Data Driven Approach," IEEE Transactions on Energy Conversion, pp. 1112-1122, 2010.

- [7] İ. Çolak, Ş. Sağıroğlu and M. Yeşilbudak, "Data mining and wind power prediction: A literature review," *Renewable Energy an International Journal*, vol. 46, pp. 241-247, 2012.
- [8] K. YA, T. AG, G. PS and H. ND, "Improved wind power forecasting using a combined neuro-fuzzy and artificial neural network model," in *Advances in Artificial Intelligence-Lecture Notes in Computer Science*, pp. 105-15, 2006,
- [9] K. A, Z. H and S. Z, "Wind farm power prediction: a data mining approach," *Wind Energy*, vol. 3, no. 12, pp. 275-93, 2009.
- [10] K. A, Z. H and S. Z, "Short-term prediction of wind farm power: a data mining approach," *IEEE Transactions on Energy Conversion*, vol. 1, no. 24, pp. 125-36, 2009.
- [11] Ö. Eyecioğlu, B. Hangun, K. Kayışlı and M. Yeşilbudak, "Performance Comparison of Different Machine Learning Algorithms on the Prediction of the Wind Turbine Power Generation," in *8th International Conference on Renewable Energy Research and Applications*, Brasov, 2019.

S-52 ÇOK ALANLI CHATBOT MİMARİLERİNDE AVANTAJLI PERFORMANS VE BELLEK TAKASI

D. Emre TAŞAR¹, Şükrü OZAN², M. Fatih AKCA³, Oğuzhan ÖLMEZ⁴,
Semih GÜLÜM⁵, Seçilay KUTAL⁵, Ceren BELHAN⁶

¹ Big Data & Advanced Analytics Unit, Garanti BBVA, Türkiye,
emretasa@garantibbva.com.tr

² AdresGezini A.S., Ar-Ge Merkezi, Türkiye, sukruozan@adresgezini.com

³ Yönetim Bilişim Sistemleri, Sakarya Üniversitesi, Türkiye,
mehmet.akcal@ogr.sakarya.edu.tr

⁴ Yazılım Mühendisliği, Celal Bayar Üniversitesi, Türkiye, 172803041@ogr.cbu.edu.tr

⁵ Mekatronik Mühendisliği, Marmara Üniversitesi, Türkiye, semihgulum@marun.edu.tr,
secilaykotal@marun.edu.tr

⁶ Yazılım Mühendisliği, İzmir Ekonomi Üniversitesi, Türkiye, ceren.belhan@std.ieu.edu.tr

Özet

Doğal dil işleme alanında metin sınıflandırma problemi oldukça geniş bir çalışma alanıdır. Metin sınıflandırma problemi kısaca, verilen metnin daha öncesinde belirlenen sınıflardan hangisine ait olduğunun tespit edilmesidir. Geçmiş çalışmalarda bu alan özelinde başarılı çalışmalar gerçekleştirilmiştir. Bu çalışmada doğal dil işleme alanında metin sınıflandırma probleminin çözümü için sıklıkla tercih edilen bir metot olan Dönüştürücüler için Çift Yönlü Kodlayıcı Temsilleri (BERT - Bidirectional Encoder Representations for Transformers) kullanılmıştır. Bir canlı sohbet botu mimarisinde kullanılmak üzere, farklı sınıflandırma problemlerini özel olarak eğitilmiş tek bir model üzerinden çözerek, her bir sınıflandırma problemi için ayrı bir model eğitilerek gerçekleştirilecek bir çözüm yöntemi ile sunucu üzerinde oluşacak işlemci, rastgele erişimli hafıza ve depolama alanı ihtiyacının hafifletilmesi amaçlanmaktadır. Bu noktada birden fazla konuda sınıflandırma yapılabilmesi için oluşturulan tek bir BERT modelinin tahmini sırasında uygulanan maskeleyme yöntemi ile modelin tahmininin problem bazlı gerçekleştirilebilmesi sağlanmıştır. Birbirinden farklı alanları kapsayan üç ayrı veri seti, problemin zorlaştırılması adına çeşitli yöntemlerle bölünmüş ve alan olarak birbirine çok yakın olan sınıflandırma problemlerine de bu sayede yer verilmiştir. Bu şekilde kullanılan veri seti 154 sınıfa sahip beş sınıflandırma probleminden oluşmaktadır. Tüm sınıflandırma problemlerini içeren bir BERT modeli ile problemler özelinde eğitilen diğer BERT modelleri performans ve sunucuda kapladıkları yer açısından birbirleriyle karşılaştırılmıştır.

Anahtar Sözcükler: BERT; çoklu sınıf; doğal dil işleme; metin sınıflandırma.

Abstract

Text classification problem is a very broad field of study in the field of natural language processing. In short, the text classification problem is to determine which of the previously determined classes the given text belongs to. Successful studies have been carried out in this field in the past studies. In the study, Bidirectional Encoder Representations for Transformers (BERT), which is a frequently preferred method for solving the classification problem in the field of natural language processing, is used. By solving classification problems through a single model to be used in a chatbot architecture, it is aimed to alleviate the load on the server that will be created by more than one model used for solving more than one classification problem. At this point, with the masking method applied during the estimation of a single BERT model, which was created for classification in more than one subject, the estimation of the model was provided on a problem-based basis. Three separate data sets covering different fields from each other are divided by various methods in order to complicate the problem, and classification problems that are very close to each other in terms of field are also included in this way. The dataset used in this way consists of five classification problems with 154 classes. A BERT model containing all classification problems and other BERT models trained specifically for the problems were compared with each other in terms of performance and the space they occupied on the server.

Keywords: *BERT; multi-class; natural language processing; text classification.*

1. Giriş

Yapay zekanın alt dallarından biri olarak kabul edilen Doğal Dil İşleme; metin verileri üzerinde duygu sınıflandırma, özet bilgi çıkarma, metin sınıflandırılması gibi görevlerle ilgilenen bir alandır [1]. Günümüzde teknolojinin gelişmesi sayesinde doğal dil işleme alanında da gelişmeler meydana gelmektedir. Doğal dil işleme kullanılarak üretilen canlı sohbet botları teknolojinin de gelişmesiyle insansı bir davranış sergileyebilir hale gelmiştir.

Muangkammuen vd. tarafından yapılan çalışmada e-ticaret sektöründe sıkça sorulan soruları cevaplamak için LSTM tabanlı bir canlı sohbet botu modeli oluşturulmuştur. Oluşturulan LSTM modelinin doğruluk değeri %83 olarak hesaplanmıştır [2].

Ozan vd. gerçekleştirdikleri çalışmada çeşitli doğal dil işleme modellerinin kategorik sınıflandırma problemi üzerindeki performanslarını karşılaştırmışlardır. LSTM, BERT ve Doc2Vec modellerinin karşılaştırıldığı çalışmada en başarılı modelin %93 doğruluk seviyesiyle BERT modeli olduğu sonucuna varılmıştır [3]. Bu nedenle bu çalışmada BERT modeli üzerinden gerçekleştirilmiştir.

Tunç vd. tarafından yapılan çalışmada 16 kategorili bir veri setinde BERT modeli ile metin sınıflandırma yapılmıştır. Çalışmada %90 doğruluk değeri hedeflenmiş ancak %79 doğruluk değerine ulaşılmıştır. Modelin istenilen doğruluk seviyesine ulaşamamasının veri setinde yer alan cümlelerin, otomatik etiketleme yapılabilmesi için içerisinde net bilgi içermemesinden kaynaklı olduğu sonucuna varılmıştır [4].

Bahsedilen çalışmalar doğrultusunda gerçekleştirilen bu çalışmada ise, bir canlı sohbet botu mimarisinde kullanılmak üzere gelen isteğe göre önceden hazırlanmış yanıtlar arasından en uygununu seçebilen bir sistem kurgulanmıştır. Kurgulanan sistemde derin öğrenme metodolojisi olarak güncel teknolojiler arasında yer alan BERT modeli tercih edilmiştir [5].

Geliştirilen canlı sohbet botu mimarilerinde farklı firmalar ve projeler için oluşturulacak olan her bir model bellekte ayrı bir yer işgal etmektedir. Çözümü tek bir modele indirgeyebilmenin farklı firmalara hizmet veren şirketler için sistem kaynağı gereksinimi açısından etkili bir optimizasyon yöntemi olabileceği öngörülmektedir..

Öncelikle beş farklı veri seti kendi özelindeki BERT modelinin eğitimi ile gerçekleştirilen sınıflandırma işlemlerinin başarımları hesaplanmıştır. Daha sonra, bütün veri setlerinin birleştirilmesiyle oluşan toplamda 154 sınıflı bir veriyle tek bir BERT modelinin eğitilmesinin ardından gerçekleştirilen sınıflandırma işleminin başarımları hesaplanarak, elde edilen sonuçlar karşılaştırılmıştır. Bu sayede sunucuda tek bir model çalıştırılması ile daha az maliyetli bir BERT modelinin, ayrı ayrı ilgili konular özelinde eğitilen modellere yakın düzeyde başarılı olabileceği gösterilmiştir.

2. Materyal ve Yöntem

2.1. Kullanılan veri seti

Çalışmada “banka”, “firma” ve “covid” şeklinde adlandırılacak olan üç ayrı veri setine yer verilmiş, bu veri setleri çeşitli yöntemlerle bölünerek veri seti sayısı beşe çıkarılmıştır. Böylelikle tüm veri setlerini içeren modelin eğitimi sırasında benzer cümleler içeren alt veri setlerinin sınıflandırma esnasında birbiriyle karışma problemine de çalışmada yer verilmiştir.

Banka isimli veri seti, 77 sınıfa sahip, bir bankaya müşterileri tarafından yöneltilen sorular ve soruların kategori isimlerinden oluşmaktadır [6]. Huggingface veri setleri kütüphanesinden alınan bu veri seti öncelikle makine çevirisi ile Türkçe’ye çevrilmiş ve çevrilen cümlelerin çeviri kalitesi manuel olarak kontrol edilmiştir. Bu veri seti kategori sayısına göre ikiye bölünerek 38 ve 39 etikete sahip iki ayrı alt veri kümesi (Veri 1 ve Veri 2) elde edilmiştir.

Birbiriyle aynı veriler içeren iki ayrı veri seti elde edilmesi amacıyla Firma isimli 26 sınıflık veri setinde bulunan her bir sınıf, içerdiği veri sayılarına göre ikiye bölünmüştür. Böylelikle bu veri setinden 26 sınıfa sahip iki ayrı alt veri kümesi (Veri 3 ve Veri 4) elde edilmiştir.

Covid adlı veri seti (Veri 5) ise Covid-19 karantina yasakları kapsamında bakanlığa yöneltilen sorulardan ve soruların kapsadığı alanlardan oluşmaktadır. Bu veri seti T.C. İçişleri Bakanlığı’nın internet sitesi üzerindeki sıkça sorulan sorular ve yanıtları baz alınarak manuel olarak üretilmiştir.

Veri setinin tamamı 3-113 arasında kelime sayısına sahip uzun ve kısa cümlelerden oluşurken cümle uzunluklarına göre düzensiz bir dağılım sergilemektedir. Verinin sahip olduğu beş adet

alt küme veri seti, içerdiği etiket sayısına göre ve her bir etiketin sahip olduğu veri sayısına göre de düzensiz dağılıma sahiptir.

2.2. BERT yöntemi

Makalede sınıflandırma problemlerinin çözümü için Devlin vd. tarafından geliştirilen BERT modeli [7] kullanılmıştır. BERT yöntemi 12 dönüştürücü bloğu, 12 öz-dikkat başlığı ve 768 gizli katmandan oluşan çift yönlü bir dönüştürücü modelidir. Bu modelin eğitimi iki aşamadan meydana gelir. İlk aşama, yüksek boyutta veriler ile gerçekleştirilen ön eğitim aşamasıdır. Modelin bu aşamada dil yapısını kavraması beklenmektedir. İkinci aşama olan ince ayar ise problem bazlı kullanılacak veri seti ile modelin yeniden eğitilmesi işlemidir. Bu işlem ile model, probleme özgü bir dikkat mekanizması oluşturur ve probleme yönelik tahminlerini güçlendirir.

İnce ayar işlemi için seçilen ön eğitilmiş model, kategorik sınıflandırmada en yüksek başarımla elde edilen [8] lodos/bert-base-turkish-cased [9] modelidir. Bahsedilen model 200 GB boyutunda çeşitli Türkçe metinlerden oluşan bir veri setiyle ön eğitime tabi tutulmuş bir model olup çalışmada, beş veri seti ve ek olarak bu veri setlerinin tümünün birleşiminden oluşan veri seti ile birlikte toplamda altı veri seti, beş dönem (epoch) süresince eğitilerek ince ayar işlemi toplam altı kere gerçekleştirilmiştir.

Model başarımlarının değerlendirilmesi için çeşitli kriterler ele alınmıştır. Çoklu sınıflandırma problemlerinin değerlendirilmesi için genel olarak kullanılan doğruluk değeri ve hata düzeyinin (confusion matrix) yanı sıra sıklıkla tercih edilen F1 skoru ve makro F1 skoru kriterleri de göz önüne alınmıştır.


2.3. Tahminleme fonksiyonu ve alan tasarrufu

Çalışmada kullanılan BERT modeli, çok kategorili sınıflandırma görevinde ince ayara tabi tutulduğu için, kategori sayısı kadar etiket ile sınıflandırma modelini etiketleyebilme becerisine sahiptir. Fakat bu durumda BERT modelinin, farklı unsurlara hizmet edecek tek bir chatbot için üretilmiş olan bellek verimli BERT modelinde sorguya en yakın etiketleme işlemi ait olmadığı bir unsura yönlendirmesi sonucu modelin doğruluk değerlerinin %52'ye kadar düştüğü görülmüştür. Bu sorunu gidermek için BERT modelinin tahminlemesini, sadece o unsura ait olarak modelde bulunan kategoriler arasında yapmasını sağlayacak şekilde kısıtlayan bir fonksiyon yazılmıştır. Bu tahminleme kısıtlama fonksiyonu sayesinde modelin, her unsur özelinde başarı oranları tekrar %90'ın üzerine yükselmiştir.

3. Bulgular

İnce ayar yapılan toplamda 6 model üzerinden, oluşturulan tahminleme fonksiyonu yardımıyla tahmin yapılmış, sonuçları değerlendirmek için kayıp, doğruluk ve F1 skoru metriklerinden yararlanılmıştır. Doğruluk ve F1 skoru, eğitim ve test veri seti için ayrı ayrı hesaplanmıştır. Model dönem grafikleri Şekil 3'te paylaşılmıştır.

Modelin tahmini esnasında veri setlerine dair ön bilgi içeren ve bu sayede veri setine özgü bir tahmin yürütme imkanı sunan tahminleme fonksiyonunun modele katkısı incelenmiştir. Tüm veri seti ile eğitilmiş model, tahminleme fonksiyonu kullanılarak test edilmesinin yanı sıra ayrıca tahminleme fonksiyonu kullanılmadan da aynı test verisi üzerinden bir teste tabi tutulmuştur. Tahminleme fonksiyonu kullanılmadan gerçekleştirilen test ile elde edilen %52 doğruluk seviyesi, tahminleme fonksiyonu kullanıldığında %90 doğruluk seviyesine çıkmıştır. Her iki doğruluk değeri kıyaslandığında modelin tahmin fonksiyonu sayesinde başarı konusunda oldukça gelişim gösterdiği sonucuna varılabilmektedir.



Şekil 3. Eğitilen modellerin sonuç grafikleri

4.Sonuçlar ve Öneriler

Çalışmada, farklı firma verileri içeren ve tahmin yaptırılacak firmaya özgü sınıf aralıklarına dair ön bilgiye sahip tek bir BERT modelinin, her bir firma için o firmaya ait veri setiyle ince ayar yapılan diğer BERT modelleriyle başarıyı kıyaslanmış ve bulunan çözüm ile bellek alanından büyük oranda tasarruf sağlanması hedeflenmiştir. Modelin eğitimi esnasında birbirine çok yakın konularda sınıflandırma problemlerine (birbirinden ayrı veri setleri) yer verilerek problem kasıtlı olarak zorlaştırılmıştır.

Veri setinin tamamıyla eğitilmiş modelin sınıf tahmini esnasında doğruluğun artırılması için direkt olarak 154 sınıf arasından tahmin edilmesi yerine girdinin ait olduğu alt veri setinin sınıf aralıklarına dair ön bilgi verilmektedir. Bu sayede yalnızca veri setinin sahip olduğu sınıf aralığında tahmin yapılır. Kullanılan beş veri seti ile ayrı ayrı yapılan eğitimlerde test veri setleri ile ortalama %91,2 doğruluk değerine ulaşılmıştır. Buna ek olarak birçok sınıflandırma problemi içeren tek BERT modeli, veri setine ait ön bilgiye sahip olup olmamasına göre tahmin yapması sağlanarak sonuçlar incelenmiştir. Kullanılan alt veri setlerinin (firmaların) kapsadığı sınıflara dair bir ön bilgi içeren tahminleme fonksiyonu kullanılmadan test edilen modelde %52 doğruluk seviyesi elde edilmişken, tahminleme fonksiyonu kullanılarak %90 doğruluk değerine ulaşılmıştır. Başarım oranları arasındaki büyük farkın asıl sebebi modelin hangi aralıktan tahmin yapacağı ön bilgisine sahip olmasıdır.

Kullanılan ön eğitilmiş BERT modeline göre ince ayar edilmiş olan bir model bellekte 1.6 GB yer tutmaktadır. Bu durum göz önüne alındığında her bir veri seti özelinde eğitilmiş beş adet model 8 GB yer kaplarken, beş veri setiyle eğitilen tek bir model yalnızca tek bir model kadar (1.6 GB) yer kaplamaktadır. Sonuçlar göz önüne alındığında veri seti özelinde eğitilmiş çok sayıda modelden, kullanılan veri setlerinin tamamıyla eğitilmiş tek modele geçişte %1,2’lik doğruluk değeri kaybı olduğu gözlemlenirken oluşturulan yapı sayesinde bellek alanından yaklaşık %80 tasarruf edilmiştir.

Referanslar

- [1] Y. Santur, "Derin Öğrenme ve Aşağı Örnekleme Yaklaşımları Kullanılarak Duygu Sınıflandırma," Fırat Üniversitesi Mühendislik Bilimleri Dergisi, cilt 32, no. 2, pp. 561-570, 2020.
- [2] P. Muangkammuen, N. Intiruk ve K. R. Saikaew, "Automated Thai-FAQ Chatbot using RNN-LSTM," 2018 22nd International Computer Science and Engineering Conference (ICSEC), Chiang Mai, Thailand, 2018.
- [3] Ş. Ozan ve D. E. Taşar, "Kısa Konuşma Cümlelerinin Doğal Dil İşleme," 29. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Çevrimiçi, 2021.
- [4] A. Tunç, A. A. Altun ve Ş. Taşdemir, "Yapay Zeka Algoritmalarından Word2vec ile Müşteri Bildirimlerinin Kategorilendirilmesi : Categorizing Customer Notifications with an Artificial Intelligence Method Word2vec," 2020 5th International Conference on Computer Science and Engineering (UBMK), Diyarbakır, 2020.
- [5] Ş. Ozan ve E. Taşar, "Kısa Konuşma Cümlelerinin Doğal Dil İşleme Yöntemlerini Kullanarak Otomatik Etiketlenmesi," arXiv preprint arXiv:2106.04959., 2021.
- [6] I. Casanueva, T. Temcinas, D. Gerz, M. Henderson ve I. Vulic, "Efficient Intent Detection with Dual Sentence Encoders," 2020.
- [7] J. Devlin, M.-W. Chang, K. Lee ve K. Toutanova, "Bert: Pre-training of deep bidirectional transformers for language understanding," arXiv preprint arXiv:1810.04805, 2018.
- [8] D. E. Taşar, Ş. Ozan, U. Özdil, M. F. Akca, O. Ölmez, S. Gülüm, S. Kutal ve C. Belhan, "Auto-tagging of Short Conversational Sentences using Transformer Methods," arXiv preprint arXiv:2106.01735, 2021.
- [9] S. Schweter, BERTurk - BERT models for Turkish, 1.0.0 dü., Zenodo, 2020.

S-62 PROTOTYPE OF A DIGITAL TWIN MODEL: A CASE STUDY ON CARTESIAN AXES CNC WORKBENCH

Muhammet Raşit Cesur¹, Elif Cesur²

¹ Industrial Engineering, Istanbul Medeniyet University, Turkey,
rasit.cesur@medeniyet.edu.tr

² Industrial Engineering, Istanbul Medeniyet University, Turkey,
elif.karakaya@medeniyet.edu.tr

Özet

Endüstriyel dönüşümünün sonuçlarından biri olan kitlesel dönüşüm daha dinamik ve zeki üretim sistemlerinin uygulanmasını mecbur bırakmıştır. Diğer taraftan iletişim teknolojilerinde meydana gelen ilerlemeler ile gerçek üretim sistemlerinin Dijital İkiz'in (Dİ) yapılması hedeflenmiş ve bu şekilde gerçekte elde edilmesi beklenen sonuçların hesaplanabileceği gösterilmiştir. Bu çalışma kapsamında üretim sistemlerinde çoğunlukla kullanılmakta olan kartezyen eksenli CNC tezgâhlarının dijital ikizlerinin oluşturulması amaçlanmıştır. Oluşturulma aşamasında öncelikle CNC tezgâhın hareket komutlarını uygulama süresi ölçülerek veri toplanmıştır. Veri ön işlemede hareketli ortalama ile düzeltme yapılarak veri seti oluşturulmuştur. Oluşturulan veri seti ile regresyon ve yapay sinir ağı modelleri oluşturulmuştur. Çalışmada elde edilen sonuçlara değerlendirildiğinde doğrusal regresyon ile çok başarılı sonuçlar alınmış fakat hız parametresinin değişiminin modellenmesi aşamasında anlamlı bir başarı gözlemlenememiştir. Hız parametresinin de modellenmesi için çok katmanlı yapay sinir ağları kullanılmış ve başarılı sonuçlar elde edilmiştir.

Anahtar Sözcükler: Dijital İkiz, Yapay Zekâ, Akıllı Üretim

Abstract

Mass customization, which is one of the results of industrial transformation, has forced the implementation of more dynamic and intelligent production systems. On the other hand, with the advances in communication technologies, it was aimed to make a digital copy of real production systems and it was shown that the expected results could be calculated with the help of Digital Twin (DT). This study, it is aimed to create a digital twin of cartesian axis CNC workbench, which is mostly used in production systems. During the generating DT phase, data were collected by measuring the execution time of the CNC workbench's motion commands. In the data preprocessing step, the data set was produced by correcting with the moving average method. With the created data set, regression and artificial neural network models were performed. When the results were evaluated, very successful results were obtained with linear regression, but no significant success was observed in the modeling phase of the speed parameter. At this point, a multilayer perceptron is used to model the speed parameter and the results of neural networks were achieved.

Keywords: Digital Twin; Deep Neural Network; Smart Manufacturing

1. Introduction

Developing sensor and information and communication technology (ICT) leads the industry to a digital transformation. The digital transformation enables mass customization driving production systems to be more dynamic. Because of the dynamism, new generation production systems require more flexible planning & control algorithms. Thus, all combinations of states being able to occur in the production environment must be generated virtually by planning & control system, which behaves as a digital copy of real production system. Digital copy of real production system, called Digital Twin (DT), has the capability of simulating all states occurring in a real production environment and predicts outcomes of all transactions in the system. To achieve mentioned level of modeling, the DT model must have sub-models imitating the dynamics of a system.

Modeling dynamics of a system is possible in a couple of ways from a data science perspective, which are differential modeling, curve fitting, linear/non-linear/polynomial regression, machine learning methods, and artificial intelligence. These methods are possibly used for modeling all components of production systems. One of the essential components of production systems is workbenches, and most of the workbenches have cartesian axes to process parts. This study aims to propose a standardized set of procedures to generate DT models of cartesian axis CNC workbenches. DT model is considered to predict the processing time and energy consumption of every task that will be performed at the workbench. The DT model would consider the quality of the processed part whether ok or not. Finally, the DT model is expected to predict any breakdown or malfunction at the workbench. To achieve the goal of this study, model generation procedures of a DT model predicting execution time of linear motion commands of G-Code are proposed.

2. Literature Review

It is obviously seen that DI studies related to production systems in the literature are essentially located under 3 headings; 1) Production Planning and Scheduling, 2) Predictive Maintenance, 3) Modeling of production systems and subcomponents. In this context, when we look at the studies that contribute to the field of production by using the digital twin approach, the following examples can be given: [1] has worked on robust planning, [2] and [3] assembly line planning, [4] and [5] job shop planning. While [6] worked on predictive maintenance, [7] made specific studies on modeling the production system and [8] tried to create a simulation-based virtual factory. [9], on the other hand, proposed a digital twin-based prototype structure for the smart production system.

The methods and techniques utilized within the scope of DI studies are basically based on simulation, machine learning, and artificial intelligence. [6] used the Gray Relation method to analyze the failure risk in his study on predictive maintenance and stated that applying the deep learning method would also generate efficient results. [10] classified the availability of the required equipment problem by using the Support Vector Machine in the DI model. In another study, [11] matched the expected amount of displacement and the actual displacement measured with the help of sensors attached to the CNC head by using the sliding window method, and

thus the quality control of the produced product was carried out. When the results of the DI studies were evaluated separately, it was stated that the productivity in the field of production planning and the speed of decision making during production increased [5], and the rate of realization of the plans reached a very high level, such as 96%. [3] has contributed to the literature in this field by predicting the failures to occur at the rate of 90%. [6]

3. Theoretical Background

Several studies in scientific literature present DT models of CNC machine sub-systems predicting outcomes and performance indicators of tasks before beginning processing. [6] [10][11] DT models are developed via artificial intelligence (AI) or machine learning models in these studies. [6] used Gray Relations (GR) to analyze malfunction risk on the workbench, and emphasized Deep Learning (DL) would have more contribution to the proposed model. [10] used Support Vector Machine (SVM) algorithm to classify machine equipment as the level of availability. [11] studied quality control with DT via placing accelerometer and gyroscope to the tool-head of CNC. Sensor data is matched with solid model data by a sliding window algorithm. Matched data is analyzed by AI. The role of AI in mentioned studies, investigating to establish a DT model of production equipment, is to infer the working mechanism of the equipment and generate required outcomes.

In this study, we develop a DT model which predicts the execution time of linear motion commands (G0, G1) at cartesian axes CNC workbenches. The DT model aims to simulate any CNC adapter (driver card) by the proposed set of procedures. The first procedure is data collection; the second procedure is data pre-processing to train the AI model. The third procedure is AI training. The final procedure is the validation of the AI model as seen in Figure 1. The proposed procedures of DT model generation are determined parts as the framework of DT in many DT studies in scientific literature. However, this study aims to propose a DT model for practical applications designed for production systems. To propose a framework of the complete system, procedures to enable DT model generation for one element (workbenches) of the production system are considered.

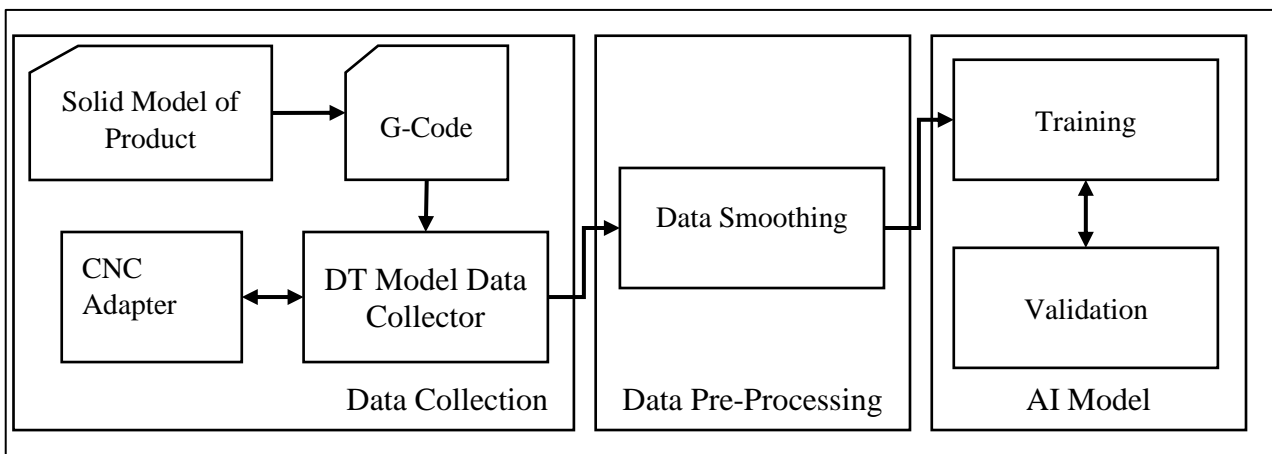


Figure 4: DT Generation Procedures

4. Methodology

The G-code file of the product planned to be produced on the workbench is uploaded to the DT model. DT model sends G-Code file to CNC adapter line by line, and measures duration of the process. The duration consists of five parts; the first is the duration of sending G-Code, the second is the duration of motor speeding up, the third is motor motion duration, the fourth is the duration of motor slowing down and the final duration is the duration of CNC adapter reply to notify DT model about the end of the process as seen in Figure 2. The second procedure is data pre-processing. Because of time delays in the data communication smoothing process is applied to time measures. Moving average is applied as a smoothing method. After data pre-processing, the DT model is tried to be generated both using linear/power regression and multilayer perceptron. One hidden layer is preferred in multilayer perceptron. Backpropagation is chosen as a learning algorithm and hyperbolic tangent function is used as activation function.

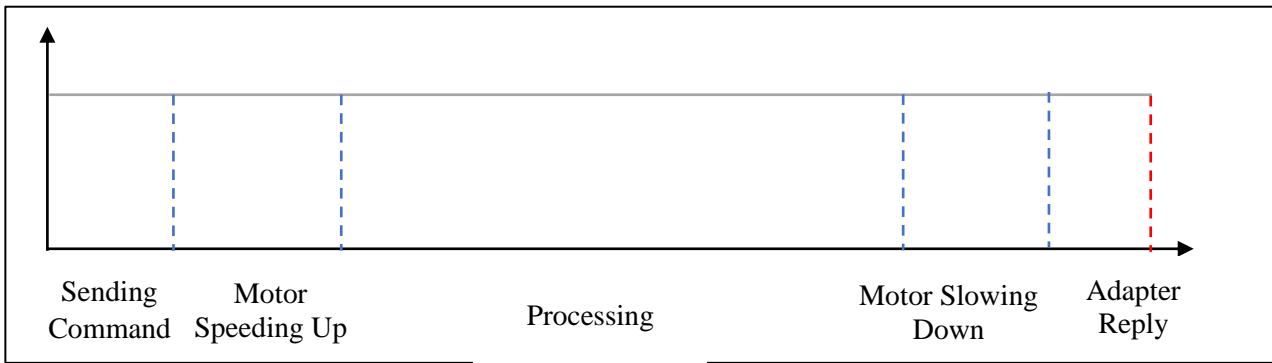


Figure 5: Processing Duration

5. Case Study

Proposed DT model generation procedures are applied to generate DT of a GRBL compatible CNC adapter. At the first step processing duration of linear motion, commands are measured for different speed and motion distance combinations. At the second step, duration data is smoothed with moving average as seen in Figure 3. At the final step, 3 DT models are developed. The first model is linear regression which performed magnificent performance with G0 command or G1 command at constant working speed with 0.99 R^2 and 6.83×10^{-5} mean absolute percentage error (MAPE). However, the linear model does not perform well when speed parameters become dynamic. In that case, a power regression model is tried to be established. The power regression model is established with 0.98 R^2 and predicts processing duration 10.62% MAPE level. Although the performance of the power regression model is better than linear regression the level of error must be decreased to achieve the DT goal.




Figure 3: Processing Duration of different speeds and amount of motion

Finally, a multilayer perceptron model with Adams Optimizer via TensorFlow. Because there is a need of developing a DT model with a small data learning rate is set as 0.01. The model consists of an input layer, a 15 neuron fully-connected hidden layer, and an output layer. Speed, amount of displacement, and the ratio of total displacement to speed are bound to the input layer. “Relu” activation function is used for the hidden layer and the “Linear” activation function is used for the output layer. Sum of Squared Error is used as loss function, also Mean Absolute Error is used as another optimization metric. The model is trained for 7500 epocs, which is the optimal number of epocs for learning against under-fitting or over-fitting. The value of the loss function is decreased from 0.112 to 2.31×10^{-7} on training data, and decreased from 0.305 to 0.0032 on test data, as seen in Figure 4. As the result, the model is established with $0.99 R^2$ and 2.656×10^{-2} MAPE.




Figure 4: Loss function

6. Conclusion

DT approach has been started to utilize during the industrial revolution to achieve a dynamic and flexible production system. However, there are not enough theoretical and practical applications available in both the literature and manufacturing sectors. At this point, this study aims to provide an initial study of a digital twin of a Cartesian axis of CNC workbench which

is mostly used in manufacturing sides. Firstly, in the data preprocessing stage, the obtained data from the G Code of CNC workbenches are smoothed by using moving average methods. Then, processing durations are tried to predict various speeds of motions and the number of motions. Two methods are utilized to discover the completion time of the task 1) Regression method 2) Multilayer Artificial Neural Network. It is so clear that the regression method is enough to calculate operation durations under constant speed conditions, however, when the model is expanded to operate under different speed values, regression has no reasonable outcomes. Thus an original model should be developed by using multilayer perceptron to predict the linear motion duration of a CNC workbench.

7. References

- [1] H. Zhang, Q. Yan, and Z. Wen, “Information modeling for cyber-physical production system based on digital twin and AutomationML,” *Int. J. Adv. Manuf. Technol.*, vol. 107, no. 3–4, pp. 1927–1945, 2020.
- [2] C. Zhuang, J. Liu, and H. Xiong, “Digital twin-based smart production management and control framework for the complex product assembly shop-floor,” *Int. J. Adv. Manuf. Technol.*, vol. 96, no. 1–4, pp. 1149–1163, 2018.
- [3] Y. H. Son, K. T. Park, D. Lee, S. W. Jeon, and S. Do Noh, “Digital twin-based cyber-physical system for automotive body production lines,” *Int. J. Adv. Manuf. Technol.*, vol. 115, no. 1–2, pp. 291–310, 2021.
- [4] J. Ma *et al.*, “A digital twin-driven production management system for production workshop,” *Int. J. Adv. Manuf. Technol.*, vol. 110, no. 5–6, pp. 1385–1397, 2020.
- [5] K. T. Park, D. Lee, and S. Do Noh, “Operation Procedures of a Work-Center-Level Digital Twin for Sustainable and Smart Manufacturing,” *Int. J. Precis. Eng. Manuf. - Green Technol.*, vol. 7, no. 3, pp. 791–814, 2020.
- [6] Y. Wang, W. Ren, Y. Li, and C. Zhang, “Complex product manufacturing and operation and maintenance integration based on digital twin,” *Int. J. Adv. Manuf. Technol.*, 2021.
- [7] K. T. Park, J. Lee, H. J. Kim, and S. Do Noh, “Digital twin-based cyber-physical production system architectural framework for personalized production,” *Int. J. Adv. Manuf. Technol.*, vol. 106, no. 5–6, pp. 1787–1810, 2020.
- [8] E. Yildiz, C. Møller, and A. Bilberg, “Demonstration and evaluation of a digital twin-based virtual factory,” *Int. J. Adv. Manuf. Technol.*, vol. 114, no. 1–2, pp. 185–203, 2021.
- [9] H. Zhang, G. Zhang, and Q. Yan, “Digital twin-driven cyber-physical production system towards smart shop-floor,” *J. Ambient Intell. Humanize. Comput.*, vol. 10, no. 11, pp. 4439–4453, 2019.
- [10] R. B. Roy *et al.*, “Digital twin: current scenario and a case study on a manufacturing process,” *Int. J. Adv. Manuf. Technol.*, vol. 107, no. 9–10, pp. 3691–3714, 2020.
- [11] S. Liu, S. Lu, J. Li, X. Sun, Y. Lu, and J. Bao, “Machining process-oriented monitoring method based on digital twin via augmented reality,” *Int. J. Adv. Manuf. Technol.*, vol. 113, no. 11–12, pp. 3491–3508, 2021.

S-11 USING ENSEMBLE LEARNING METHODS FOR PREDICTING SUCCESSFULNESS OF STARTUP BUSINESS

Farid BAGHERI ¹, Derya EREN AKYOL ^{2,*},

¹ Industrial Engineering, Dokuz Eylul University, Turkey, farid.bagheri@ogr.deu.edu.tr

² Industrial Engineering, Dokuz Eylul University, Turkey, derya.eren@deu.edu.tr

ABSTRACT

The goal of this paper is to develop a credible model for predicting startup business's success by using ensemble learning methods. Previous studies have concentrated on the accuracy of various algorithms without exploring the true influence of risk and success variables, or on understanding the effects of successful factors. In this paper we consider the successful factors and also analyze them from different point of view.

Keywords: *Ensemble Learning Methods; Data Science; Machine Learning; Predicting; startup businesses*

1. Introduction

As stated by Huang[1], a startup business is successful if it is accrued, IPO, or has a net worth of more than \$1B(unicorn). There are two primary exit paths for a profitable start-up. The business can go through an Initial Public Offering or it can be sold to an existing corporation via an acquisition. Under an IPO, the enterprise receives a stock market listing, which enables the business to access more finance for its projects and permits executives to eventually sell their shares to the public. According to the dictionary in Old English, the root of business is bisignes "Care, anxiety, occupation," from bisig "Careful, anxious, busy, occupied, diligent" and Krishna[2] et al. In this paper, it is considered as a successful company that returns invested money to investors consequently, we look from an investor's perspective in this project that allows them to make the right decision before starting a business.

2. Model Framework

This research utilizes mostly data from Crunchbase, an online network created to connect startups and investors; Crunchbase is a complete database about startups in the market. For this reason, most of the researches about the subject utilize it. The Crunchbase database contains data from over 100k startups of diverse industries and locations across the globe, dataset contains information about startups' condition and also the database restricts to startups founded before 2012. According to that, we have 4 conditions: 1- Operating, 2- Closed, 3- IPO, 4- M&A by using different features, we try to predict the outcome of a new startup business. In this paper, we will show the results by 0 and 1 which indicate 0 for a failed business and 1 for a successful business. I divided the dataset into 2 pieces: 70% of the dataset as a training set and the rest of it as a test set. The main goal of this paper is to fit training data and test data into machine learning methods and compare their performance. There is a list of machine learning

methods that will be trained and tested by dataset: 1-Random Forest , 2-XGBoosting , 3-Gradient Boosting ,4-AdaBoost

2.1 Target variable

The target or dependent variable is "Successful startup - likely to generate a return to the investors." The steps to create the binary (0 and 1) target variable are:

-Startups under status "Closed" are classified as a failure "0".

-Startups with a successful exit (IPO or Acquired) are classified as successful "1".

2.2 Independent variables

Most the features in crunchbase dataset Other than business status are considered as Independent variables such as milestones and number of founding and etc. Some of these variables are Qualitative Data and some of them are Quantitative Data. to use these Quantitative Data in machine learning methods we have change these features to numerical features which are suitable to methods.

3.Transformations

Some transformations are necessary to address collinearity among variables and correct any possible non-linear behavior of any variable alone or group of variables.Following the transformations that I tried and the intuition behind them.The second issue is that some variables may not have a linear effect on startup success, so I tried to add a second squared term of each. Because intuitively they may present a decreasing return per scale.

4. Model Estimation And Results

As explained in the previous sections, this model utilizes the one of the Ensemble learning methods as the benchmark technique for variable selection, because this method has a straightforward interpretation and statistical approach, it is possible to compare the estimated effect and the statistical significance of each risk factor.To accomplish the objective of this research, I need to be sure that the final model is predictive and that the estimated coefficients reflect the real impact on startup success.For this reason, it is fundamental to check whether all the variables are well specified.After validating the variables and the reliability of the model, this research tests the predictability, comparing its accuracy with it of other well-known methods.

4.1 Model performance metrics

The performance metrics are the following Accuracy, Confusion Matrix.

4.2 Model selection

The model selection consists of the process of determining the combination of variables from the candidate pool that generates an output consistent with the economic intuition of the variables and presents a good out-of-sample performance

5. Conclusion

This research develops a systematic model using ensemble learning methods to predict startups that will potentially succeed, consequently applying other statistical and machine learning algorithms to test the adequacy and applicability of Ensemble Learning Methods. The data selection is based on statistical and logical approaches to ensure that the model correctly specifies the dependent and independent variables, such that the results can be interpreted, satisfying the economic intuition regarding the effects of the independent variables on startup outcome. All variables in the final model are both economic and statistically significant. According to this study Ensemble learning methods has better performance in comparisons with other machine learning methods and they are faster. The only difference between this paper and previous study is that we try to predict the successfulness of the start up business from different point of view by using features which are not used in other studies. This paper shows that by utilizing better features and methods we can get more accurate results.

References

- [1]Huang, B. G. (2016). Predict startup success using network analysis and machine learning techniques. CS224 Stanford University.
- [2] Krishna, A., Agrawal, A., and Choudhary, A. (2016). Predicting the outcome of startups: less failure, more success. In 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW), pages 798805. IEEE.
- [3] Bento, F. R. d. S. R. (2018). Predicting start-up success with machine learning. PhD thesis
- [4] Ünal, C. (2019). Searching for a unicorn: A machine learning approach towards startup success prediction. Master's thesis, Humboldt-Universität zu Berlin.
- [5] Shah, V. M. (2019). Predicting the sucess of a startup company, 3878-2019. Oklahoma State University.

S-47 TAŞINMAZ MAL DEĞERİ KESTİRİMİNDE TOPLULUK ALGORİTMALARININ DOĞRULUK ANALİZİ

Muzaffer Can İBAN¹

¹ Harita Mühendisliği Bölümü, Mersin Üniversitesi, Türkiye, caniban@mersin.edu.tr

Özet

Açık erişimli Melbourne kenti taşınmaz mal veri seti üzerinde topluluk yapay öğrenme algoritmalarından rastgele orman, adaboost ve gradyan artırma algoritmaları ile tahmin çalışmaları yürütülmüştür. Uygun hiper-parametre ve bağımsız değişken seçimlerinin ardından, bu üç algoritma ile Python Scikit-learn kütüphanesi kullanılarak tahmin edici modeller geliştirilmiştir. Üretilen modellerin eğitim doğruluğu ve test doğruluğuna bakıldığında, rastgele orman ve gradyan artırma bağlanımının kabul edilebilir doğruluk ürettiği, ancak gradyan artırmanın biraz daha yüksek ve umut verici bir performans gösterdiği tespit edilmiştir. Her iki modelde de tahmin doğruluğu %90'ın üzerindedir ve diğer doğruluk kriterleri Uluslararası Değerlemeciler Derneği'nin oransal standartlarına uygundur. Bunun yanı sıra, kullanılan veri seti üzerinde adaboost bağlanımı doğruluğu uygun bir model oluşturamamıştır.

Anahtar Sözcükler: taşınmaz mal değerlendirme, topluluk algoritmaları, rastgele orman, gradyan artırma, adaboost.

Abstract

Real estate value prediction studies were carried out with open access Melbourne City real estate data set, using three ensemble learning algorithms: random forest, adaboost and gradient boosting regression. After optimizing hyper-parameters and selecting independent variables, predictive models were developed in Python Scikit-learn library. Considering the training and test accuracy of the developed models, it was determined that random forest and gradient boosting regressions resulted acceptable; however, gradient boosting showed more accurate and promising performance. The prediction accuracy of both models was over 90% and other accuracy metrics are in compliance with the ratio standards of International Association of Assessing Officers. Moreover, adaboost regression could not form a model with a suitable accuracy on the data set used.

Keywords: real estate valuation, ensemble algorithms, random forests, gradient boosting, adaboost.

1. Giriş

Taşınmaz malların değerlendirilmesi ve vergilendirilmesi, arazi yönetiminin önemli bir bileşeni olup, ülkelerin sürdürülebilir kalkınma amaçlarını gerçekleştirebilmesi için sahip olması gereken önemli araçlardan biridir. Taşınmaz malların doğru ve adil bir şekilde değerlendirilmesinin yapılması, o ülkedeki taşınmaz mal piyasasının canlanmasını, mülkiyet ve ona bağlı hakların güvence altına alınmasını, doğru bir şekilde vergilendirilmesini, hem kamunun hem de özel

sektörün ilgilendiği taşınmaz mallara ilişkin uygulamaların başarılmasını (kentsel dönüşüm, imar uygulamaları, kamulaştırma vb.) da beraberinde getirmektedir [1].

Genel olarak tüm ülkelerde taşınmaz mal değerlemesi için parsel özellikleri, yapı özellikleri ve yapının bulunduğu konumun özellikleri dikkate alınmaktadır [2]. Gelişmiş ülkelerde özel ve kamu sektörünün taşınmaz mal piyasasına ilişkin veri setlerini elinde bulundurduğu ve bu konuda veri biliminden faydalanan çalışmaların yoğunluğu dikkat çekicidir. Ancak, Türkiye gibi gelişmekte olan ve taşınmaz mal bileşenini kadastralarında kapsamlı olarak henüz barındıramayan ülkeler, taşınmaz mal değerlemesi çalışmalarında veri bilimi ve yapay öğrenme uygulamalarını kısıtlı ve kişisel olanaklarla elde edilmiş veri setleri üzerinden gerçekleştirmektedir.

Kurumumuzda Mersin kentine özgü bir taşınmaz mal değerlendirme tahmini sisteminin kurulmasına yönelik sahadan veri toplama çalışmaları devam etmektedir. Veri toplama çalışmalarına paralel olarak, kullanılacak olan tahmin modellerinin geliştirilmesine yönelik ön fizibilite çalışmaları da yapılmaktadır. Bu bağlamda, Kaggle üzerinden erişilebilecek olan Avustralya Melbourne kentine ait konut değerleri veri seti kullanılarak, ülkemizde de oluşturulmaya çalışılan modelin algoritmik tasarımı yönünden bir ön inceleme yapılarak, elde edilen çıkarımlar bu bildiride sunulmaktadır. Kullanılan veri seti üzerinde üç adet topluluk algoritmasının (rastgele orman, gradyan artırma, adaboost) tahmin performansı değerlendirilmiştir.

2. Yöntem ve Materyal

2.1. Materyal

Bu çalışmada, Kaggle web sitesinden indirilen açık erişimli Melbourne konut piyasası veri seti kullanılmıştır [3]. Veri setinin ham dosyasında 34857 satır gözlem ve 21 adet farklı değişken (sütun) bulunmaktadır. Her bir gözlem, 2016-2018 tarihleri arasında Melbourne kentinde kayıt altına alınan satış işlemlerinden derlenmiştir. Taşınmaz mal değerinin tahmin sonucu, sürekli bir değer olan fiyattır. Fiyatı tahmin edebilmek için de sayısal ve kategorik bağımsız değişkenlerden faydalanmak gerekmektedir.

Veri setinin ön işleme için ilk olarak eksik verilerin araştırılması yapılmıştır. Çok fazla sayıda değer eksikliği barındıran sütunlar ve eksik değer içeren fiyat sütununa ait satırlar ham veriden çıkarılmıştır. Az sayıda eksik değer içeren sayısal değişken satırları ise bu sütuna ait medyan değerleri ile doldurulmuştur. Bu işlemlerin ardından, çalışmada verimli bir şekilde kullanılabilen 15 sütun ve 6858 satırdan oluşan işlenmiş veri seti hazırlanmıştır (Tablo 1).

Tablo 1. Kullanılan Veri Setine Ait Değişkenler ve Türleri

Değişken İsmi	Türü	Değişken İsmi	Türü	Değişken İsmi	Türü
Mahalle	Kategorik	Arac_Parki_Sayisi	Sayısal	Insaat_Yili	Sayısal
Oda_Sayisi	Sayısal	Parsel_Buyuklugu	Sayısal	Enlem	Sayısal
Fiyat	Sayısal	Yapi_Taban_Alan_i	Sayısal	Boylam	Sayısal
Uzaklik	Sayısal	Yatak_Odasi_Sayi	Sayısal	Bolge	Kategorik
Posta_Kodu	Sayısal	Banyo_Sayisi	Sayısal	Mahalledeki_Mulk_Sayisi	Sayısal

2.2. Yöntem

Taşınmaz mal değerini tahmin edebilmek için yapay öğrenme tekniklerinden iki şekilde yararlanılmıştır. İlki, taşınmaz mal piyasası endeksini tarihsel ilerleme içerisinde tüm ekonomik faktörleri göz önünde bulundurarak tahmin etme ve tüm taşınmaz malların değerlerinin bu yıllık ortalama indeks ile yeniden hesaplanmasını içermektedir. İkincisi ise, çeşitli algoritmalar kullanarak belirli bölgedeki taşınmaz malların mevcut değerlerinden eğitilmiş model oluşturmayı kapsamaktadır. [4].

Her bir taşınmazın değerini tahmin etmeye yönelik yapay öğrenme çalışmaları genellikle çoklu lineer bağlantı, rastgele orman, destek vektör makineleri ve yapay sinir ağları gibi denetimli yapay öğrenme algoritmalarını kullanmıştır [5, 6, 7]. Kullanılan veri setinin doğasına uygun olarak farklı doğruluklarda sonuç veren bu algoritmalar arasında en iyisini ilan etmek oldukça güçtür. Ancak ülkemizdeki akademik uygulamalarda ve piyasada taşınmaz mal değeri tahmini yapan özel sektör firmalarının uygulamalarında rastgele orman algoritmasının, çoklu doğrusal bağlantı algoritmasına göre daha başarılı sonuçlar verdiği gözlemlenmiştir [7].

Rastgele orman algoritması, topluluk algoritmalarından biridir. Ancak, rastgele orman dışında da farklı topluluk algoritmaları bulunmaktadır. Taşınmaz mal değeri tahmin çalışmalarında, matematiksel kökenleri birbirinden farklı olan bağlantı algoritmalarını karşılaştırmak daha yaygın bir tutum olmuştur. Buna karşın, aynı grupta tasniflenebilecek algoritmaların kendi içerisindeki performans karşılaştırmasından genellikle uzak durulmuştur. Bu çalışmada, sadece topluluk algoritmalarından üç örneğin performansı karşılaştırılmıştır.

Topluluk algoritmalarının amacı, tek bir tahminci üzerinde modelin genellebilirliğini ve sağlamlığını geliştirmek için birden fazla tahmincinin tahmin ettiği değerleri toplayıp, en iyi tahmini sunabilmektir. Rastgele orman gibi algoritmalar birkaç tahminciyi bağımsız olarak


oluşturup, ardından tahminlerin ortalamasını almayı ilke edinmektedir [8]. Adaboost ve gradyan artırma gibi algoritmalar ise sıralı olarak tahmin ediciyi oluşturur ve bunların birleşimiyle güçlü bir model geliştirmeyi amaçlar [9].

Bu üç algoritmanın kullanımından elde edilen modellerin eğitim ve test verileri üzerindeki doğruluğu R^2 bağlanım skoru, modellerin tüm veri seti üzerindeki tahmin doğruluğu ise Pearson Korelasyon Katsayısı (r) ve Kök Karesel Ortalama Hata (KKOH) ile irdelenmiştir. Aynı zamanda, tahmin edilen değerler ile gerçek değerleri eksenlere yerleştiren grafikler çizilmiş ve bağlanım doğru denklemi hesaplanmıştır.

3. Yapılan Çalışmalar

3.1. Kullanılan Değişkenler

Veri seti içerisinde kullanılan ve Tablo 1’de adı geçen değişkenlerin korelasyon matrisi Şekil 1’de gösterilmektedir. Bu bağlamda, fiyat bağımlı değişkeni, bağımsız değişkenlerle mükemmel bir korelasyona sahip değildir. Fiyat değişkeni, oda sayısı, yatak odası sayısı, banyo sayısı ve taban alanı değişkenleri ile diğer değişkenlere oranla daha fazla ilişkilidir.



Şekil 1. Melbourne Konut Veri Seti Değişkenlerine Ait Korelasyon Matrisi

3.2. Eğitim ve Test Verisinin Oluşturulması

Veri seti eğitim ve test verileri olarak ikiye ayrılmıştır. Bu ayırım, veri satırları arasında rastgele seçimle gerçekleştirilmiş olup, herhangi bir kural uygulanmamıştır. Bu çalışmada 5 katlı çapraz doğrulama yöntemi kullanılarak, veri setinin %80’lik kısmı modeli eğitmek için, kalan %20’lik kısmı da modelin çıktı değerlerini orijinal veri ile karşılaştırarak test etmek için ayrılmıştır.

3.3. Hiper-parametrelerin Uyumlandırılması

Yapay öğrenme algoritmalarının doğruluğu, modelin eğitildiği hiper-parametreler ile doğrudan ilişkilidir. Kullanılan üç algoritma için Python Scikit-learn kütüphanesinde GridSearchCV

modülü ile hiper-parametre uyumlandırılmasını yapmak olanaklıdır. Hiper-parametrelerin seçiminde kütüphanenin sabit başlangıç değerlerini kullanmak yerine, en yüksek doğruluğu sağlayan değerlerin belirlenmesi için iteratif deneme-yanılma yolu kullanılmıştır. En yüksek doğruluğu sağlayan hiper-parametreler kombinasyonu, tahmin edici modelin kurulması esnasında fonksiyon girdisi olmuştur.

3.4. Tahmin Modellerinin Geliştirilmesi

Gerekli ön işleme süreçlerinin ardından, tüm tahmin modelleri Python Scikit-learn kütüphanesinde geliştirilmiştir. Yapay öğrenme kütüphanelerinden biri olan Scikit-learn, yapay öğrenme süreçlerinin uygulanması için zengin bir ortam sağlamasının yanı sıra, daha iyi bir kullanıcı ara yüzüne sahip olmasıyla öne çıkmaktadır. Scikit-learn kütüphanesinde esas alınan nesne, bir girdi veri dizisi üzerinde model oluşturan tahmin edici (regresör) algoritmalarıdır.

4. Bulgular

4.1. Rastgele Orman Bağlanımı


Rastgele orman bağlanımı algoritması ile eğitilen modelin, eğitim verileri üzerinde %81.72, test verileri üzerinde %77.50 doğruluk sağladığı gözlemlenmiştir. Eğitilen modelin tüm veri seti üzerindeki tahmininde ise Pearson korelasyon katsayısı $r = 0.9066$ olarak hesaplanmış olup, dağılım katsayısı (Coefficient of Dispersion – COD) 14.7, fiyata ilişkin diferansiyel (Price-Related Differential - PRD) ise 1.030 olarak bulunmuştur. Veri setindeki gerçek fiyat değerleri ile modelin tahmin ettiği fiyat değerleri arasındaki bağlanım grafiği Şekil 2a'da gösterilmektedir.

4.2. Gradyan Artırma Bağlanımı

Gradyan artırma bağlanımı algoritması ile eğitilen modelin, eğitim verileri üzerinde %98.41, test verileri üzerinde %81.45 doğruluk sağladığı gözlemlenmiştir. Eğitilen modelin tüm veri seti üzerindeki tahmininde ise Pearson korelasyon katsayısı $r = 0.9781$ olarak hesaplanmış olup, COD değeri 13.2, PRD değeri ise 1.022 olarak bulunmuştur. Veri setindeki gerçek fiyat değerleri ile modelin tahmin ettiği fiyat değerleri arasındaki bağlanım grafiği Şekil 2b'de gösterilmektedir.

4.3. Adaboost Bağlanımı

Adaboost bağlanımı algoritması ile eğitilen modelin, eğitim verileri üzerinde %21.12, test verileri üzerinde %15.84 doğruluk sağladığı gözlemlenmiştir. Eğitilen modelin tüm veri seti üzerinde herhangi bir tahmin yapabilecek doğruluğu bulunmamıştır.



Şekil 2. (a) Solda Rastgele Orman Bağlanımı Grafiği (b) Sağda Gradyan Artırma Bağlanımı Grafiği

5. Tartışma ve Sonuç

Yapılan çalışmada uygun hiper-parametreler ve bağımsız değişkenlerle eğitilmiş gradyan artırma bağlanımının, standart rastgele orman bağlanımına göre daha güçlü ve doğru sonuçlar verdiği, taşınmaz mal değeri tahmin çalışmalarında daha kapsamlı bir kullanımının olabileceği tespit edilmiştir. Yerel sahada toplanacak veri seti üzerinde de gradyan artırma bağlanımının kullanımı özendirilecektir. Adaboost bağlanımı ise kullanılan veri seti üzerinde bir model oluşturmada başarıdan uzaktır. Bunun sebebi olarak, modelin aşırı öğrenmesi ya da veri setindeki aykırı değerlerin fazla olması öne sürülebilir. Kullanılan ve uygun görülen regresyon algoritmalarının ürettiği COD ve PRD değerleri, Uluslararası Değerlemeciler Derneği'nin (IAAO) oransal standartlar rehberine göre kabul edilebilir değerlerde bulunmuştur.

Referanslar

- [1] Williamson, I., Enemark, S., Wallace, J., and Rajabifard A., “Land administration for sustainable development”. Redlands, CA: ESRI Press Academic, 2010.
- [2] Kara, A., Çağdaş, V., Lemmen, C., Işıkdag, Ü., van Oosterom, P., and Stubkjær, E., "Supporting fiscal aspect of land administration through a LADM-based valuation information model." in Land Governance in an interconnected World: 19th Annual World Bank Conference on Land and Poverty, 2018.
- [3] Pino, A., “Melbourne Housing Market data”. Kaggle, 2018 [online] Available: <https://www.kaggle.com/anthonypino/melbourne-housing-market> [Accessed Aug. 29, 2021].
- [4] Gupta, R., Kabundi, A. and Miller, S. M., "Forecasting the US real house price index: Structural and non-structural models with and without fundamentals", Economic Modelling, vol. 28, no. 4, pp. 2013-2021, 2011.
- [5] Gu, J., Zhu, M. and Jiang, L., "Housing price forecasting based on genetic algorithm and support vector machine", Expert Systems with Applications, vol. 38, no. 4, pp. 3383-3386, 2011.
- [6] Aiyin, W. and Yanmei, X., "Multiple Linear Regression Analysis of Real Estate Price," 2018 International Conference on Robots & Intelligent System (ICRIS), pp. 564-

568, 2018.

- [7] Yilmazer, S., and Kocaman S., "A mass appraisal assessment study using machine learning based on multiple regression and random forest.", *Land Use Policy* 99 – 104889, 2020.
- [8] Breiman, L., “Random forests”, *Machine learning*, 45(1), pp. 5-32, 2001.
- [9] Drucker, H., "Improving regressors using boosting techniques." in *ICML*, vol. 97, pp. 107-115, 1997.

S-31 BİR MINİBAR İÇERİSİNDE FASTER R-CNN EVRİŞİMSSEL SİNİR AĞI ÜZERİNDE GELİŞTİRİLEN MODELİN NESNE TANIMA BAŞARISINA TANIMA ORANI VE ARKA PLANIN ETKİSİNİN ARAŞTIRILMASI

Furkan İZMİRLİ^{1,*}, Uğur PEHLİVANOĞLU², Mert ÖNDEROĞLU³

¹Tasarım Merkezi, ISM Makine Elektrik San. ve Tic. A.Ş., Manisa, TÜRKİYE, fizmirli@ismas.com.tr

²Tasarım Merkezi, ISM Makine Elektrik San. ve Tic. A.Ş., Manisa, TÜRKİYE, upehlivanoglu@ismas.com.tr

³Tasarım Merkezi, ISM Makine Elektrik San. ve Tic. A.Ş., Manisa, TÜRKİYE, monderoglu@ismas.com.tr

Özet

Bilgisayarların görüntüler ve videolardaki nesnelere ya da kişileri tanımlamasını ve anlamasını amaçlayan bir bilgisayar bilimi alanı olan görüntü işleme teknolojisi, günümüzde birçok teknolojik alanda geniş bir uygulama alanına sahiptir. Bu görüntüleme işleme yöntemleri kullanılarak, resim ve videolarda çeşitli analizler farklı amaçlara yönelik olarak gerçekleştirilebilmekte ve anlamlı bilgiler ortaya çıkarılabilmektedir. Son yıllarda derin öğrenme algoritmaları yapay zekâ alanında bir devrim yaratmıştır. Derin öğrenme algoritmalarının, görüntü işleme teknikleriyle eş zamanlı olarak kullanılması başarılı sonuçlar alınmasını sağlamaktadır. Minibar içerisinde nesnelere otomatik olarak tanımlanması ve tüketim bilgilerinin doğru bir şekilde resepsiyona iletilmesiyle ilgili yapılan bu çalışmanın amacı olarak tanıma oranı ve arka planın, yapay zeka başarı oranına etkileri incelenmiştir. Çalışma yöntemi olarak, derin öğrenme ile nesne tanıma için Google’ın açık kaynak kodlu makine öğrenmesi kütüphanesi olan TensorFlow ve Region Based Convolutional Networks kütüphanesinden Faster R-CNN modeli kullanılmıştır. Tanıma oranının etkisini ortaya koymak amacıyla, minibar içerisinde 11 farklı ürüne ait 945 kombinasyonlu görüntüden oluşan veri seti 26.000 adım boyunca eğitilmiştir ve yine minibar içerisinde, eğitim aşamasında kullanılmayan kombinasyonlu görüntülerden oluşan 6 minibara ait toplam 600 görüntü ile %60 ve %95 tanıma oranlarında test edilmiştir. %60 tanıma oranı kullanıldığında ortalama başarı oranı %84,25 iken %95 tanıma oranı kullanıldığında ortalama başarı oranı %89,82 olarak tespit edilmiştir. Arka planın etkisi için, minibar dışında 5 farklı ürüne ait 111 kombinasyonsuz görüntüden oluşan veri seti 17.000 adım eğitilmiştir ve yine minibar dışında, eğitim aşamasında kullanılmayan kombinasyonsuz görüntülerden oluşan toplam 34 görüntü ile %99,70 tanıma oranı kullanıldığında başarı oranı %100 olarak tespit edilmiştir ancak minibar içerisinde başarı sağlanamamıştır.

Anahtar Sözcükler: Başarı Oranı; Faster R-CNN; Nesne Tanıma; Tanıma Oranı, Tensorflow.

Abstract

Image processing technology, which is a field of computer science that aims for computers to identify and understand objects or people in images and videos, has a wide range of applications in many technological fields today. By using these imaging processing methods, various analyzes on pictures and videos can be performed for different purposes and useful information can be revealed. In recent years, deep learning algorithms have revolutionized the field of artificial intelligence. The use of deep learning algorithms simultaneously with image processing techniques provides successful results. As the aim of this study, which was carried out on the automatic identification of objects in the minibar and the accurate transmission of consumption information to the reception, the effects of recognition rate and background on the success rate of artificial intelligence were examined. As the study method, TensorFlow, Google's open source machine learning library, and Faster R-CNN model from the Region Based Convolutional Networks library were used for object recognition with deep learning. In order to reveal the effect of recognition rate, the dataset consisting of 945 combination images of 11 different products in the minibar was trained for 26,000 steps. In addition, the data set was tested with a total of 600 images of 6 minibars, which were not used in the training phase, at 60% and 95% recognition rates. While the average success rate was 84.25% when 60% recognition rate was used, the average success rate was 89.82% when 95% recognition rate was used. For the effect of the background, the dataset consisting of 111 uncombined images of 5 different products, except the minibar, was trained for 17,000 steps. The success rate was found to be 100% when the recognition rate of 99.70% was used with a total of 34 images consisting of uncombined images that were not used in the training phase outside the minibar however there was no success rate inside the minibar.

Keywords: Success Rate; Faster R-CNN; Object Recognition; Recognition Rate, Tensorflow.

1. GİRİŞ

Derin öğrenme, makine öğreniminin bir alt kolu olup, bu bilişimsel alanın temelini Yapay Sinir Ağları (YSA) oluşturmaktadır. Derin öğrenme, sunulan bir veri setinden yararlanılarak bir analize yönelik sonuçları tahmin eden birden fazla katmanlı bir mimariye sahip olan bir makine öğrenme yöntemi olarak ifade edilebilmektedir. Bu çalışmada ise derin öğrenme teknikleri, otellerde yaygın bir şekilde kullanılan minibarların içerisinde ürün takibinin yapılabilmesi ve geliştirilmesi amacıyla tercih edilmiştir.

Yapılan çalışmada kullanılan Faster R-CNN (Faster Region Based Convolutional Networks) modeli Faster R-CNN Inception Resnet V2 Atrous Coco'dur. Diğer Faster R-CNN modelleri ile karşılaştırıldığında en yavaş çalışan 2. model olmasına karşılık, aynı zamanda başarı oranı en yüksek olan 2. modeldir. Bu modelde yapılan eğitimde kullanılan kombinasyonlu görüntüler, ürünlerin tekli ve diğer ürünlerle beraber farklı açılar ve konumlarda kullanıldığı anlamına gelmektedir. Her ürünün yapay zekâ tarafından tespitinin yapılabilmesi için minimum bir eşik değeri bulunmakta olup, ürünler bu değer üzerinden

tespit edilir, bu değer tanıma oranı olarak ifade edilmektedir. Birbirlerine geometrik açıdan çok benzer ürünler kullanılması, bu ürünlerin tanıma oranı değerlerinin birbirlerine çok yakın çıkması ile sonuçlanmaktadır. Bunun bir sonucu olarak, bir ürün, birden çok farklı ürün olarak algılanabilmekte ve bu durum olumsuzluk yaratabilmektedir. Dolayısıyla söz konusu çalışmada birbirlerine benzer olmayan farklı ürünlerin kullanılması tercih edilmiş ve tanıma oranı %60 ile %95 oranlarında incelenmiştir. Yapay zekâ eğitimi yapılacak ortam ve test edilecek ortamın aynı olması gerekmektedir. Bu gerekliliğin sağlanamaması durumunda, bir ürün farklı bir ortamda yapay zekâ tarafından hiç tanınamayabilir ya da bambaşka bir ürün olarak tespit edilebilir. Söz konusu çalışmada elde edilen bilgi birikimi sayesinde otel sektöründe minibar tüketim ve dolun işleyişinin rahatlaması, farklı projelerde kullanılabilmesi ve bu alanda faaliyet gösteren kurum ve kuruluşlara ışık tutması hedeflenmiştir [1-3].

Söz konusu teknoloji ile ilgili literatürde yer alan çalışmalarda 10 farklı model arabaya ait çekilen 20.000 fotoğrafın eğitilmesi sonucu başarı oranı %94,40, 11 farklı balina türüne ait çekilen 200 fotoğrafın eğitilmesi sonucu başarı oranı %94 ve 111 farklı kelebek türüne ait 5.695 fotoğrafın eğitilmesi sonucu %70,40 başarı tespit edildiği gözlemlenmiştir. Yapılan bu çalışmada, araştırmanın kapsamı gereği derin öğrenme çatısı altında kullanılan ve optimum sonuçları sağlayan 3 farklı yöntem araştırılmış ve bunlar sırasıyla Tensorflow, Keras ve Pytorch kütüphaneleri olarak belirlenmiştir [1-3].

Tensorflow kütüphanesi birçok farklı uygulama alanında tercih edilmekte olan bir kütüphane olup, genel kullanım amacı nesne tanımadır. Yüksek başarı ile hızlı tahminleme sağlayan bu kütüphane C, C++, Java ve Python programlama dilleriyle birlikte kullanılabilir. Keras kütüphanesi, yapay zeka öğrenimine yeni başlamış kullanıcılar, öğrenciler ve iş hayatında küçük projelerde prototip yapmak isteyen çalışanlar tarafından tercih edilmektedir. Küçük veri kümeleri ile eğitim yapılabilirdiğinden dolayı düşük başarı ve yavaş tahminleme yeteneğine sahiptir. Pytorch kütüphanesi, müşteri hizmetleri sağlayan sanal asistan gibi doğal dil işleme alanlarında kullanılmakta ve orta donanıma sahip bilgisayar ile orta düzeyde performans sağlamaktadır. Minibar içerisindeki ürünlerin nesne tanıma başarısına, tanıma ve arka planın etkisini ortaya koymak amacıyla gerçekleştirilen bu çalışmada, yüksek başarı ile hızlı tahminleme sağlamak amacıyla Tensorflow kütüphanesi tercih edilmiştir. Derin öğrenmeyi kapsayan ve algoritmaların performansının artırılması amacıyla kullanılan makine öğrenmesi çatısı altındaki 3 farklı yöntem araştırılmıştır. Bu yöntemler sırasıyla, gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenmedir. Gözetimli öğrenmede, veri kümesinde mevcut olan etiketli nesnelere kullanılmakta ve tahmin edilmesi istenen nesne, etiketleri veriler arasından seçilmektedir. Gözetimsiz öğrenmede, veri kümesinde mevcut olan etiketsiz nesnelere kullanılmakta olup, algoritmalar, nesnelere arasında bir takım anlamlı gruplamalar yapmaktadırlar. Pekiştirmeli öğrenmede ise, bir veri kümesi olmadan makine deneme yanımıyla yöntemi ile karmaşık bir ortamda hedefe ulaşmayı amaçlar [4,5].

2. MATERYAL VE METOD

İlgili çalışmada, istenilen sonuç yani makinenin tam olarak neyi tahmin etmesi gerektiği bilinmektedir ve bu sebeple gözetimli öğrenme tercih edilmiştir. Nesne tanımada kullanılan

en önemli 2 kütüphane incelenmiştir. İncelenen kütüphaneler, Faster R- CNN ve SSD (Single Shot Multibox algorithm) kütüphaneleri olarak belirlenmiştir. Sadece hız ve gerçek zamanlı nesne tespiti yapılacaksa SSD'nin tercih edilmesinin gerektiği bilinmektedir. Bu sebeple, Faster R-CNN tercih edilmiştir. Yapılan bu çalışmada, derin öğrenme yöntemlerinden Tensorflow kütüphanesi, makine öğrenmesi yöntemlerinden gözetimli öğrenme ve nesne tanıma için Faster R-CNN modellerinden, Faster R-CNN Inception Resnet V2 modeli kullanılmıştır.



Şekil 1. Peltier Minibar

Gerçekleştirilen çalışmada, tanıma oranının başarı oranına etkisi için, minibar içerisinde 11 farklı ürüne ait 945 kombinasyonlu görüntüden oluşan veri seti 26.000 adım eğitilmiştir ve yine minibar içerisinde, eğitim aşamasında kullanılmayan kombinasyonlu görüntülerden oluşan 6 minibara ait toplam 600 görüntü ile %60 ve %95 tanıma oranlarında test edilmiştir. Tanıma oranı ve arka planın, yapay zekâ başarı oranına etkisinin araştırılması için 40 litre hacime sahip peltier minibar tercih edilmiştir. Bu çalışmada ele alınan peltier minibarın genel görüntüsü Şekil 1’de verilmiştir. Gerçekleştirilen bu çalışma için, özel raf tasarımı ve minibar kapağı arkasına nesne tanıma amaçlı görüntü alınabilmesi amacıyla 2 kameralı özel bir düzenek oluşturulmuştur. Ayrıca arka planın etkisinin araştırılması amacıyla Şekil 2’deki düzenek yapılmıştır.




Şekil 2. Arka planın etkisinin araştırılması için hazırlanan

Yapay zekâ eğitiminde kullanılacak görüntülerde nesnelere etiketlenmesi için LabelImg programı kullanılmıştır. Programlama sırasında kullanılan kod sistemine Şekil 3’te yer verilmiştir. Eğitim yapılacak ortam, kullanılan nesne sayısı ve birbirleriyle konumlarına bağlı olarak tanıma oranı ile deneme yapılmış ve en uygun başarı oranının elde edilmesi üzerine çalışılmıştır [6].

```
def visualize_boxes_and_labels_on_image_array(  
    image,  
    boxes,  
    classes,  
    scores,  
    category_index,  
    list_for_return,  
    instance_masks=None,  
    instance_boundaries=None,  
    keypoints=None,  
    use_normalized_coordinates=False,  
    max_boxes_to_draw=20,  
    min_score_thresh=.6, min_score_thresh=.6 → TANIMA ORANI  
    agnostic_mode=False,  
    line_thickness=4,  
    groundtruth_box_visualization_color='black',  
    skip_scores=False,  
    skip_labels=False):
```

Şekil 3. Kod sistemi

Başarı oranının hesaplanması amacıyla doğru tanınan ürün sayısı, toplam ürün sayısına bölünerek bir başarı oranı hesaplanmıştır. Söz konusu denklem kullanılarak İlgili görsel için gerçekleştirilen hesaplamalar sonucunda başarı oranı %92,86 olarak hesaplanmıştır. Geliştirilen tanıma sisteminin minibar içerisindeki görüntüsü Şekil 4’te görülebilmektedir.



Şekil 4. Minibar içerisinde tanıma sistemi

3. BULGULAR

Başarı oranlarının hesaplanması sonucunda elde edilen tanıma oranı değerlerine ilişkin verileri Tablo 1’de sunulmuştur. Buna göre, farklı tanıma oranlarında görüntüler üzerinde gerçekleştirilen testler sonucunda, %60 tanıma oranı kullanıldığında farklı odalara ait minibarlarda sırasıyla %75,21, %84,64, %94,05, %85,30, %80,67, %85,63 başarı oranları ve ortalama başarı oranı %84,25 olarak tespit edilmiştir. %95 tanıma oranı kullanıldığında farklı odalara ait minibarlarda sırasıyla %99,92, %96,96, %86,69, %92, %72,78, %89,69 başarı oranları ve ortalama başarı oranı %89,67 olarak tespit edilmiştir. Bu bulgulara dayanarak, tanıma oranının artması ile başarı oranının arttırıldığı sonucuna ulaşılmıştır.

Yapılan çalışmada arka planın etkisini ortaya koyabilmek amacıyla minibar dışında 5 farklı ürüne ait 111 kombinasyonsuz görüntüden oluşan veri seti 17.000 adım eğitilmiştir ve yine minibar dışında, eğitim aşamasında kullanılmayan kombinasyonsuz görüntülerden oluşan toplam 34 görüntü ile %99,70 tanıma oranı kullanıldığında başarı oranı %100 olarak tespit edilmiştir ancak minibar içerisinde herhangi bir başarı sağlanamamıştır. Bu sebeple, nesnelerin doğru tanınabilmesi için gerçek ortamında eğitilip test edilmesi gerektiği gözlemlenmiştir. Arka planın yapay zekâ eğitimine etkisi için A3 kâğıdı önüne kurulan tek kameralı düzeek oluşturulmuştur.

Tablo 2. Başarı oranlarının hesaplanması

%60,00		%95,00	
Minibar	Başarı Oranı	Minibar	Başarı Oranı
1	%75,21	1	%99,92
2	%84,64	2	%96,96
3	%94,05	3	%86,69
4	%85,30	4	%92,00
5	%80,67	5	%72,78
6	%85,63	6	%89,69
Ortalama	%84,25	Ortalama	%89,67

4. SONUÇ

Minibar donanımı aynı olmasına rağmen, üretim kaynaklı milimetrik farklardan dolayı yapay zekâ başarı oranı da farklılık göstermektedir. Yapılan bu çalışmada 6 farklı minibara ait farklı tanıma oranlarında farklı başarı oranları tespit edilmiştir. Genel başarı oranını arttırmak için tanıma oranını arttırmak bir yöntemdir. Nesne tespiti yapılacak ürünler için yapay zekâ eğitimi kendi ortamında yapılmalıdır. İlgili çalışmada, istenen nesne tespitleri minibar içerisinde yapılmak istendiğinden yapay zekâ eğitimi minibar içerisinde yapılmıştır. Minibar dışarısında yapılan eğitim ve minibar içerisindeki test sonucunda hiçbir başarı oranı sağlanamamıştır. Yapılan çalışma sonucunda nesne tanıma alanında çalışmalar yapmak isteyen kurum ve kuruluşlara önerilen yapay zekâ eğitimi yapılacak ortam projenin gerçek hayatta kullanılacağı ortam olmalıdır. Nesne tespiti yapılması istenen ürünler dikkatli seçilmelidir ve olabildiğince birbirlerinden farklı ürünler olmalıdır. Her bir ürünün yapay zekâ tarafından tespiti farklı gerçekleşeceğinden tanıma oranı parametresi ile deneme yanılma yaparak en yüksek başarı oranı sağlanan tanıma oranı parametresi seçilmelidir.

Referanslar

- [1] Z. Tan, “Derin öğrenme yardımıyla araç sınıflandırma,” Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ, 2019.
- [2] A. Öztürk, M. Karatekin, İ. A. Saylar, N. B. Bardakçı, “Recognition of sign language letters using image processing and deep learning methods,” *Journal of Intelligent Systems: Theory and Applications*, vol. 4, no. 1, p. 17-23, 2021.
- [3] R. Zhao, C. Li, S. Ye, X. Fang, “Butterfly Recognition Based on Faster R-CNN,” *IOP Conf. Series: Journal of Physics: Conf. Series*, p. 1176, 2019.
- [4] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, “Tensorflow: A system for large-scale machine learning,” In *12th Symposium on Operating Systems Design and Implementation*, 2016.
- [5] H. Li, Y. Huang, Z. Zhang, “An Improved Faster R-CNN for Same Object Retrieval,” *Access IEEE*, vol. 5, p. 13665-13676, 2017.
- [6] Tzutalin, *LabelImg Free Software*, MIT License, 2015.

S-09 SOCIOLOGICAL DIMENSIONS OF ALGORITHMS

Emin Baki ADAŞ¹, Borabay ERBAY²,

¹ Department of Sociology, Aydın Adnan Menderes University, Turkey,
eminadas@gmail.com

² Department of Sociology, İzmir University of Economics, Turkey,
borabayerbay@gmail.com

Abstract

Technology, from simple tools to complex machinery, has always been inevitable part of human existence. Today, the ever-expanding and penetrating technologies such as artificial intelligence and algorithms present us strong challenge to demonstrate how politics in its widest sense operate in the realm of artificial intelligence both in its production and its uses. It is common to think technology in general and artificial intelligence in particular as neutral technical problem. However, in this paper we argue that algorithms are not neutral, or technical things, but intrinsically social and political phenomenon. Algorithms, which consist the essence of artificial intelligence, make, filter and suggest decisions for humans, thus they have potential to manipulate human action. In this regard, algorithms are not simply a technical problem but must be considered as a sociological problem as well.

Introduction: Is Technology Neutral?

We tend to take sociology into account in our everyday life regarding its function. More often we, as human beings, focus on the effects of technology that makes our lives easier and we expect it to substantiate these with minimum error. As long as technological products function with minimum error, we diverge from thinking their effects on our lives. These ideas and practices are closely linked to how modern technology presents itself to us. Ideas on technology, particularly with the emergence of modern technology, bear the notion of efficiency in their cores [1]. This way of thinking [and the ideas arise from it] is something that conceals the effects of technology on social life and social nature of technology. That is where sociology of technology comes in and tries to comprehend both positive and negative effects on social life in cause-and-effect relationships. One of the main questions asked in this process of comprehension is whether technology is neutral or not. Conventional ways of thinking and ideas tend to take technology into account as a neutral phenomenon. The idea of technology as a neutral phenomenon finds its foundations on three axioms stated by Romero Moñivas [2]:

- a) Technology is a means.
- b) Therefore, the technology cannot be morally good or evil.
- c) The uses of technological products or the technology itself is not intrinsic.

This way of thinking highlights human domination over technology but in the meantime, it reduces the technology to a simple means, a simple tool which human has full control on.

Social theory has tried [and still does] to comprehend technology in various ways such as its uses in economy [3], its effect on concealing the truth by its substance [4], its participation as a non-human actor in social process [5]. All these various approaches may differ in many different areas such as epistemology, ontology and even methodology but, in a sense, their point of arrival is the same. Whether technology is being used as a means by the ruling classes to dominate their opponents, or potential rivals, or it has a substance that can manipulate the world appeared to humans, or it is something that allows human to act and thus becomes the actor itself, technology is not neutral. On the contrary, it is a political phenomenon. The idea that technology as a neutral phenomenon neglects the political dimension of its production and its uses. This negligence constructs a gap between those who develop technology and those who consume it. It puts the developers and consumers in different planes and it confines the developers of technology in their own as an isolated realm which consists of only developers and nothing else [6]. Such a view perceives the developers not as social beings but neutral professionals whose social existence have no impacts on their technological products. However, the engineers or scientists who develop and design new technologies are social beings and they inevitably put their ideas, thoughts and cultural biases into technology and technological products [7] [8]. Hence, isolating technology from its social and cultural bases disguises social and political nature of technology and technological products.

Algorithms as Social and Political Things

Algorithms are the main essence of the artificial intelligence. Basically, an algorithm can be defined as the part of a code which charts a path for a computer, or machine to follow in order to reach designed or desirable purposes [9]. This definition might suggest what an algorithm is but it is not sufficient to capture its true essence. From a sociological perspective, algorithms can be defined as the purpose-setter of the data [10], as the decision-making part of the code [11], or as the ‘digital doppelgänger’ of human beings [9]. What all these definitions have in common is that algorithms carry some agency and built-in intentions such as suggesting, organizing and filtering the data and they interact with human beings, or the way they function has social consequences [12].

In sociological studies there are two broader perspectives on algorithms. One set of sociological studies on algorithms focuses on material interventions which analyzes the manipulations of algorithms on everyday life, which consists of the effects of algorithms on people’s choices and decisions [12]. Studies in this field are built upon the idea that algorithms carry different forms of agency. Hence, sociologists analyze these forms of agency and their effects on human action. Studies in this context can be described as twofold. First of them focuses on the question whether algorithms can truly be neutral. Even though algorithms present themselves as a neutral technological phenomena, the engineers and scientists who code algorithms are social beings with emotions and values. Since the algorithms are modeled after social world, thus they cannot be value-neutral, on the contrary, they are value-laden [13] which makes algorithms not neutral but active enough to have a part in reproducing social inequalities existing in societies [14]. Hence, algorithms as technological things built upon and reflects social classifications existing in the social and culture world. Some scholars, on the other hand, analyze algorithms as filter

bubbles which limit cultural and social contact and expose people to same news, same people, same experiences and same culture [15]. By doing that these studies and scholars impute an agency to algorithms with almost full-autonomy. Other studies regard algorithms not as a bearer of social power in themselves but associations and situations they operate in grant them this power [16]. These studies tend to distribute agency to both human agent and machine agent. Further critical studies analyze the role of algorithms in reproducing various social inequalities in various areas [17] [18] [19]. The concealment of the roles of algorithms, which decide and suggest what we see, what we hear and who we meet, hence penetrate our daily lives in various areas (Beer, 2017:6), is achieved through a technocratic view that regards algorithms as not accessible to lay people but only to those who mastered the art of algorithmic techniques. Hence such a view creates a black box society which runs through unquestionable algorithms [10]. Sociological perspective on the other hand, argue that developing algorithms require finance and data to coders and hence we need to consider the questions of where, how and most importantly, for whom the algorithms are being developed for [13]. A second and a newer approach on algorithms claims that the foundational questions sociology must ask on algorithms are how the concept of algorithm is used, how it is framed and how the truth is constructed within this framework which disguises the social power that algorithms truly bear [12]. From a Foucauldian perspective, Beer claims that the material interventions that algorithms have on social life such as deciding, suggesting and ordering things find their foundational power through the discourse of technological trustworthiness, which rests upon the idea of mechanical efficiency and neutrality [12]. In other words, the social circulation and framing of algorithms propose a reliability and trustworthiness, which conceal their manipulative effects on human action in social processes. That makes up a “code of normalization” in terms of Foucault [20] which makes human action and the way we think vulnerable to algorithmic manipulation by normalizing the notion of algorithm as something natural in social life. This process of normalization is run through the discursive practices which construct the notion of algorithm as objective and trustworthy [12].

All these sociological approaches on algorithms may differ on their understanding on agency, they may offer different forms of cause-and-effect relationships. But all of them have a common point which can be summed up as follows: algorithms as technological products are not value-neutral but whether it is caused by their own agency or the bearers of some form of agency of the coders who bring them into existence, they have social effects and they take part in social processes. That makes algorithms social phenomenon as well as technological, thus sociology must have a stake on the production and use of the algorithms used in artificial intelligence.

Conclusion

Although a product of human action, technological phenomena, technological products, hence the technology itself is capable of affecting human life and action. It is not essential for sociology to debate on if technology is morally good or evil in itself in order to assess if it is value-neutral or not. The effect of technology on social world not solely depends on the effect of technological products or things but the use and perception of the notion of technology in social world, hence the idea of technology as a neutral phenomenon conceals its social effects.

To exceed the boundaries created by this idea, sociology not only concerns with the social effects of value-laden nature of technology, with that it concerns with which social processes make technology value-laden. Thus, technological products, their uses and technology as a social power are both enters the field of interest of sociology.

Algorithms are and will be a part of our social existence. We can see the undeniable effects of algorithms on the choices we make, things we see, music we listen to, people we meet, hence in almost every social and cultural interactions in society. Algorithms carry a political character and makes them as much of a concern of social sciences as computer sciences. Sociology approaches to algorithms in various ways such as their effects on the reproduction of social inequalities and the effect of non-human agency on social processes. In this regard it has become a priority of sociology to understand the manipulative effects algorithms have on human action and society. The construction of algorithms mostly rely on technological neutrality, technical efficiency and trustworthiness which conceals their social nature and manipulative power, thus making their effects unquestionable. However, sociology lifts the” technical veil” that makes algorithms unquestionable, unspoken, thus unanalyzable and expose the political and social nature of algorithms and artificial intelligence both at its production and consumption levels.

Bibliography

- [1] Y. Tao and S Daojin, “Technology Neutrality”, *Studies in Sociology of Science*, vol. 6, no. 3, pp. 13-19, 2015.
- [2] J. Romero Moñivas, “The Problem and Sociopolitical Confusion of ‘Technological Neutrality’: The Case of the Observatorio de Neutralidad Tecnologica in Spain”, *Current Sociology*, vol. 59, no. 3, pp. 310-327, 2011.
- [3] K. Marx, *Capital: A Critique of Political Economy Volume I*, NY: Penguin Books, 1992.
- [4]. M. Heidegger, *The Question Concerning Technology and other Essays*, NY: Grand Publishing, 1977.
- [5] B. Latour, *We Have Never Been Modern*, Massachusetts: Harvard University Press, 1993.
- [6]. M. Berg, “The Politics of Technology: On Bringing Social Theory into Technological Design”, *Science, Technology & Human Values*, vol. 23, no. 4, pp. 456-490, 1998.
- [7] R. Eynon & E. Young, “Methodology, Legend, and Rhetoric: The Constructions of AI by Academia, Industry, And Policy Groups for Lifelong Learning”, *Science, Technology, & Human Values*, vol. 46, no. 1, pp. 166–191, 2021.
- [8] S. Šabanović, “Inventing Japan's ‘Robotics Culture’: The Repeated Assembly of Science, Technology, and Culture in Social Robotics”, *Social Studies of Science*, vol. 44, no. 3, pp. 342–367, 2014.
- [9] D. Lupton, *Digital Sociology*, NY: Routledge, 2015.
- [10]. F. Pasquale, *The Black Box Society: The Secret Algorithms That Control Money and Information*, Massachusetts: Harvard University Press, 2016.

- [11]. D. Beer, *Popular Culture and New Media: The Politics of Circulation*, Basingstoke: Palgrave Macmillan.
- [12] D. Beer, “The Social Power of Algorithms”, *Information, Communication & Society*, vol. 20, no. 1, pp. 1-13, 2017.
- [13] K. Joyce, L. Smith-Doerr, S. Alegria, S. Bell, T. Cruz, S. G. Hoffman, S. U. Noble and B. Shestakofsky, “Toward a Sociology of Artificial Intelligence: A Call for Research on Inequalities and Structural Change”, *Socius: Sociological Research for a Dynamic World*, vol. 7, pp. 1-11, 2021.
- [14] M. Broussard, *Artificial Unintelligence: How Computers Misunderstand the World*. Massachusetts: The MIT Press, 2018.
- [15] E. Pariser, *The Filter Bubble: What the Internet is Hiding from You*, London: Viking Books, 2011.
- [16] D. Neyland and N. Möllers, “Algorithmic IF ... THEN Rules and the Conditions and Consequences of Power”, *Information, Communication & Society*, vol. 20, no. 1, pp. 45-62, 2017.
- [17] S. Barocas and A. D. Selbst, “Big Data’s Disparate Impact”, *California Law Review*, vol. 104, no. 3, pp. 671-732, 2016.
- [18] C. O’Neill, *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*, NY: Broadway, 2016.
- [19] R. Benjamin, *Race After Technology: Abolitionist Tools for the New Jim Code*, Massachusetts: Polity Press, 2019.
- [20] M. Foucault, *Society Must be Defended: Lectures at the Collège de France, 1975-1976*, London: Penguin Books, 2004.

S-33 İŞ SAĞLIĞI VE GÜVENLİĞİ ALANINDA YAPAY ZEKA UYGULAMALARI

Öyküm AKAR

İş Sağlığı ve Güvenliği Koordinatörlüğü, Muğla Sıtkı Koçman Üniversitesi, Türkiye,
oykumakar@outlook.com

Özet

Tüm dünyada olduğu üzere ülkemizde her gün çok sayıda çalışan, iş kazaları ve meslek hastalıklarından dolayı ruhsal veya bedensel kayıplar yaşamaktadır. İş sağlığı ve güvenliği (İSG) profesyonellerinin temel hedefi güvenli çalışma ortamının sağlanmasına katkıda bulunarak; olası iş kazaları ve meslek hastalıklarından dolayı yaşanacak kayıpları ortadan kaldırmak ya da asgari düzeye indirmektedir. Bu amaçla son yıllarda İSG alanında teknolojik gelişmelerle birlikte yeni önlem alma yaklaşımları da tartışılmaya başlanmıştır. Bu yaklaşımlardan biri de yapay zekanın (YZ) iş sağlığı ve güvenliği alanında kullanılmasıdır. YZ desteği ile birlikte geliştirilen iş sağlığı ve güvenliği teknolojileri, iş süreçlerinin güvenli yönetimine katkı sağlayarak risk faktörlerinin belirlenmesi ve ortadan kaldırılması açısından büyük önem taşımaktadır. İSG profesyonellerinin, farklı lokasyonlarda sorumlu oldukları alanda, eş zamanlı olarak; birçok alanı görmesi ve o alanlara erişmesi neredeyse imkansızdır. Bu sınırlı görüş çerçevesinde; görüş alanını artıran, müdahale olasılığını yükselten, görülmeyen alanlardan görüntü ve veri paylaşabilen görüntü işleme teknolojileri İSG açısından oldukça etkili çözümler olarak karşımıza çıkmaktadır. İSG'nin dijital dönüşümüyle birlikte, video analizi aracılığıyla tehlikeli alanlarda bulunan; çalışanların, nesnelere, tehlikeli hareketlerin ve tehlikeli durumların tespiti, etiketle kilitle emniyetinde insan odaklı risklerin minimize edilmesi, kişisel koruyucu ekipmanların otomatik kontrolü, ergonomi ve davranış analizi, yangın algılama, kimyasal döküntü ve sızıntı tespiti, yaya yolu ve forklift alanları emniyeti gibi konularda İSG profesyonellerine destek sağlayabilecek YZ uygulamaları geliştirilmiştir. Bu çalışma ile YZ teknolojilerinin, İSG alanındaki etkinliğinin belirlenmesi amaçlanmıştır. YZ teknolojileri ile İSG profesyonellerinin eş zamanlı birçok alana ve çalışana ulaşım, proaktif yaklaşımla güvenli çalışma ortamı oluşumuna katkı sağlaması beklenmektedir.

Anahtar Sözcükler: İş sağlığı ve güvenliği; nesnelere interneti; makine öğrenmesi; veri görselleştirme; yapay zeka.

Abstract

As in the rest of the world, many employees in our country experience mental or physical losses every day due to work accidents and occupational diseases. A main goal of occupational health and safety professionals is to eliminate or minimize losses due to possible work accidents and occupational diseases by contributing to the provision of a safe working environment. For this purpose, in recent years, new approaches to taking precautions have been started to be discussed along with technological developments in the field of Occupational Health and Safety (OHS).

OHS technologies developed with the support of artificial intelligence (AI) in terms of identifying and eliminating risk factors by contributing to the safe management of business processes. It's impossible for OHS professionals to see and access the different areas they're responsible for at the same time. Under these constraints, image processing technologies that increase the field of view, increase the possibility of intervention, share images and data from areas of responsibility appear as effective solutions in terms of OHS. With the digital transformation of OHS, some applications have been developed, such as the detection of employees, objects, dangerous movements and situations in dangerous areas through video analysis in order to minimize human-oriented risks. AI applications have been developed that can provide support to OHS professionals in areas such as automatic control of personal protective equipment, ergonomics, fire detection, chemical spill and leak detection, pedestrian and forklift areas safety. With this study, it's aimed to determine the effectiveness of AI technologies in the field of OHS. With AI technologies, OHS professionals are expected to reach many areas and employees simultaneously and contribute to the creation of a safe working environment with a proactive approach.

Keywords: Artificial intelligence; data visualization; internet of things; machine learning; occupational health and safety.

1. Giriş

İş sağlığı ve güvenliği; çalışma ortamı ve çalışan ile sınırlanmaksızın, işletme tarafından gerçekleştirilen tüm faaliyetlerden etkilenen insanların; hem sağlığını hem de güvenliğini tehlikeye atan etkenlerin tespit edilerek ortadan kaldırılması veya azaltılması çalışmalarıdır[1]. İSG uygulamalarının multidisipliner bir alanı kapsamaması nedeniyle; iş yerlerinde iş sağlığı ve güvenliğinin sağlanması tek başına bir bilim dalı tarafından gerçekleştirilmesi olası değildir. Bu uygulamalar; İşyeri hekimlerinin, iş güvenliği uzmanlarının, mühendislerin, ergonomistlerin ve çalışanın kendisinin de içinde olduğu bir farkındalık ortamı yaratılarak yapılan uygulamalar olmalıdır. Endüstriyel alanda robotik süreç ve otomasyonların büyük ilerleme kaydetmesi, İSG anlamında da teknolojik gelişme ihtiyacını açığa çıkartmıştır. İSG alanında gerçekleşen dijital gelişmelerle birlikte, çalışanların eş zamanlı izlenebilmesi mümkündür. Bu sayede, gerçekleşebilecek kazalar belirlenerek proaktif yaklaşımlarla gerekli önlemler alınabilmektedir. Sahada kullanılabilen; Radyo Frekanslı Tanıma (RFID), Nesnelerin İnterneti (IoT), 3D Modelleme, Bulut Sistemi (Cloud), Gerçek Zamanlı Konum Belirleme (RTLS), Makine Öğrenmesi, M2M (machine to machine) takip sistemleri, Sanal Gerçeklik (VR) ve Artırılmış Gerçeklik (AR), Akıllı Kişisel Koruyucu Ekipmanlar, Entegre Yazılımlar, Büyük Veri Analitiği ve Yapay zeka (YZ) gibi gelişmekte olan dijital teknolojiler yardımıyla çalışma ortamını daha güvenli bir konuma taşımak mümkündür. Bilgiyi toplayıp algılayabilen, uyarı ve ikaz vererek otonom kontrol sağlayan teknolojiler ile sensörlerle donatılmış akıllı giysiler, İSG süreçlerinin güvenli bir şekilde yürütülmesi, risk durumlarının belirlenmesi ve bertaraf edilmesine katkıda bulunarak iş kazalarını önlemeye, yüksek risk içeren çalışma ortamlarında güvenli çalışma koşullarının oluşumuna yardımcı olmaktadır[2].

2. Amaç

Bu çalışma iş yerlerinde güvenliğin artırılması kapsamında; İSG alanında yapay zeka uygulamaları derlenerek alanda yapılacak çalışmalara katkı sağlamayı ve bu uygulamaların kullanım örneklerini aktarmayı amaçlamıştır.


3. Materyal ve Yöntem

Bu çalışmada; “yapay zeka, makine öğrenmesi, iş güvenliği, veri görselleştirme, nesnelerin interneti” anahtar kelimeleri kullanılarak literatür taranmış ve yapılan çalışmalar derlenmiştir. Son 10 yıl içerisinde İSG alanında kullanılan YZ teknolojilerini içeren çalışmaları kapsayacak şekilde çalışma sınırlandırılmıştır. Ülkemizde ve dünya genelinde İSG profesyonelleri tarafından geliştirilen YZ uygulamaları temel olarak incelenmiştir.

4. Bulgular

YZ'nin endüstriyel alanda uygulanması Dördüncü Sanayi Devrimi olarak tanımlanmıştır[3]. Teknoloji ve dijitalleşmenin endüstriyel alana entegrasyonu ile birlikte, İSG alanında da dijitalleşme ihtiyacı ortaya çıkmıştır. İSG kapsamında YZ uygulamaları endüstriyel alanda gelişmekteyken, literatürde de bu alandaki yayınların sayısı gittikçe artmaktadır. YZ uygulamaları ile birlikte iş yerinde karşılaşılabilecek risklerin analizi, proaktif yaklaşımla önleyici tedbirlerin belirlenmesi, kaza verilerinin analizi ile iş kazalarının ve meslek hastalıklarının önlenmesi beklenmektedir[4]. Çalışma hayatında karşılaşılabilecek riskler üzerine YZ ile oluşturulan senaryolar; sanal gerçeklik gözlükleri, akıllı cihazlar ve sensörler aracılığıyla simülasyona dönüştürülüp İSG eğitimlerinde uygulanmaktadır. IoT ve YZ ile entegre edilen cihazlar veri bulutuna bilgi aktarımı ile durum analizi yaparak çalışanları, İSG profesyonellerini ve yönetimi uyararak kazaların önlenmesinde oldukça etkili sistemler olarak karşımıza çıkmaktadır[2]. Bu uygulamalar çalışan sağlığı ve güvenliğinin izlenmesinde yeni bir boyut oluşturmuştur.

Günümüzde; teknolojik gelişmeler, dijitalleşme, çalışma alanındaki yenilikler hakkında güncel bilgi ve materyallere erişebilmek için çevrimiçi arama motorları birçok insan tarafından kullanılmaktadır. Son dönemde büyük veri analizi daha fazla önem kazanarak, sıklıkla kullanılabilir hale gelmiştir. Bu bağlamda yeni bir veri kaynağı olan Google Trends; kullanıcıların erişim zamanına, coğrafi konumuna ve anahtar kelimeye göre arama sıklığının belirlenmesine imkan tanıyan en popüler arama motoru olan Google arama motoru özelliğidir[5]. 2011-2021 yılları arasında yaklaşık 10 yıllık süreci kapsayan dünya genelinde taranan Google Trends verileri analizi sonucunda; derin öğrenme, makine öğrenmesi, nesnelerin interneti, veri görselleştirme, yapay zeka arama terimleri ile yapılan çalışmalar mevcuttur.



Şekil 1. Google Arama İstatistiği[6]

Yukarıdaki grafikte özellikle makine öğrenmesi ve yapay zeka konusunda göze çarpan artış trendi, yapay zekanın endüstriyel alanda gelişmekte olduğunun göstergesidir. Gelişen teknoloji ile birlikte YZ' nin uygulama alanlarına İSG çalışmaları da eklenmiştir. Makine öğrenmesi; mevcut problemi, problem verilerine göre modelleyen bilgisayar algoritmalarıdır[7]. İSG alanında makine öğrenmesi destekli video analitiği ile mevcut kamera görüntüleri yapay zeka algoritmaları ile işlenerek veri analizi ve gerçek zamanlı video içerik analizi yapılabilmektedir. Endüstriyel IoT (IIoT) ile tüm süreçler izlenebilmektedir. Giyilebilir cihazlarla eşleştirilen IoT teknolojilerinde tüm donanımlar birbirine bağlanarak kablosuz sensörler aracılığıyla veri paylaşımı yapmaktadır. Alınan veriler ile akıllı üretim ve akıllı güvenlik sistemleri oluşturulabilmektedir. Çalışanların sağlık durumları ve yaralanmalara yol açabilecek riskli aktiviteler izlenebilmektedir. Giyilebilir cihazlardan alınan verilerle ortamda anomali tespiti yapılarak, olası kaza durumunda hızlı bir şekilde aksiyon alınması sağlanmaktadır. Aynı zamanda bu veriler toplanarak veri analizi yapılır ve bulut sistemine kaydedilir[8]. Bu sürecin takibi ve izlenmesi için Endüstriyel IoT sistemleriyle birlikte RFID kullanılmaktadır. RFID (Radyo Frekansı ile Tanımlama) teknolojisi, kablosuz iletişim teknolojilerinde hızla gelişmekte olan ve birçok sektörde uygulanabilen bir teknolojidir. Bu teknoloji okuyucu, etiket ve bunlara bağlı antenler olmak üzere 3 temel bileşenden oluşmaktadır[9]. RFID sistemi İSG alanında mesafe uyarıları sistemleri ile birlikte çarpışma ve düşme önlemleri için kullanılabilir. Aynı zamanda çalışma ortamına yetkisiz kişilerin erişimini ve sorumlu personel dışında makine-ekipman kullanımını da önleyebilmektedir[2]. RTLS (Gerçek Zamanlı Konum Takip Sistemleri) endüstriyel alanda optimizasyonu artırarak verimliliğin sağlanmasında kullanılmaktadır. Bu sistemler aracılığıyla çalışanlar ve çalışma ortamında bulunan nesnelerin konumları otomatik olarak tespit edilmektedir. Çalışan için hareketsizlik bildirimi, acil durumlarda toplanma bölgesinde hızlı sayım, riskli bölge girişlerinde bildirim oluşturmaktadır[10].

İSG alanında kullanılan diğer teknolojiler ise artırılmış gerçeklik ve sanal gerçekliktir. AR; gerçek dünya ile bağlantısını devam ettirerek, veri ve görüntülerin gerçek dünya görüntülerine

entegre edilebilen, sanal ve gerçek nesnelerin aynı ortamda beraber algılanmasını sağlayan bir teknolojidir. VR ise; bilgisayar kaynaklı üç boyutlu oyunlarda karşılaşılan, kullanıcının bu ortama girdiğinde dünya ile ilişkisinin kesildiği bir teknolojidir[11]. Bu teknolojiler aracılığıyla gerçek çalışma ortamı üç boyutlu ve dinamik bir görüntüyle eşleştirilebilmektedir. Çalışanın duruşuna göre otonom ayarlanan görüntü açısı, ortamdaki sesler ve vücut sensörleri gibi eklentiler ile duyuşal olarak gerçek ortamda hissedilmesine yardımcı olmaktadır. Bu sayede farklı kaza senaryoları oluşturularak, oluşabilecek tehlike ve risk simülasyonlarıyla mevcut güvenlik önlemleri değerlendirilmekte ve İSG eğitimlerinde kullanılmaktadır.

Sahada kullanılabilen giyilebilir akıllı cihazlar ise İSG alanına yeni bir boyut kazandırmıştır. Bu teknolojiler ile kişisel nedenlerden kaynaklanan tehlikeli hareketler önlenilmekte ve tespitinde çalışana uyarı vermektedir. "Giyilebilir teknoloji", "giyilebilir cihaz" ve "giyilebilir sensör" terimleri vücuda rahatlıkla giyilebilen kıyafetleri ve takılabilen aksesuarları temsil eden elektronik ya da bilgisayar teknolojileridir. Saatler, gözlükler, lensler, bileklikler, tekstil ürünleri, baret, ayakkabı, işitme cihazı gibi kişisel donanımlar giyilebilir cihazlara örnek verilebilir[12]. Bu cihazlar yardımıyla çalışanların kalp atışı, vücut ısısı, solunum hızı, kandaki insulin oranı, tansiyon gibi değerler hakkında eş zamanlı veri toplanarak, bu veriler İSG profesyonelleriyle paylaşılabilir.

5. Sonuç ve Öneriler

Geleceğin iş yerindeki yapay zeka uygulamaları, ekonomik ve sosyal yapılar üzerinde küresel olarak dönüştürücü bir etkiye sahip olacağından, İSG alanında da önemli gelişmeleri beraberinde getirecektir. İSG uygulamaları günümüzde YZ'nın ön saflarında yer alması da, ilerleyen aşamalarda YZ'nın çalışan sağlığı ve güvenliği açısından büyük etki yaratacağı öngörülmektedir. YZ mesleki araştırmalarla birlikte iş yeri uygulamaları hakkında stratejik öngöründe bulunarak, reaktif duruştan proaktif duruşt geçişin sağlanmasına katkıda bulunacaktır.

YZ uygulamaları ile İş Sağlığı ve Güvenliği çözümleri;

- Kişisel koruyucu ekipman kontrolü sağlanabilir,
- Riskli makinelerin çalıştığı alanlara çalışan giriş yaptığında sistem otomatik kapatılabilir,
- Tehlikeli işlerin yapıldığı alanlarda yalnız çalışan personel durumu tespit edilebilir,
- Mesafe kontrolü sağlanabilir,
- İş makinasının system üzerinden takibi yapılabilir,
- İş makinasının çalışana yaklaşması sırasında erken uyarı sistemi verilebilir ve hız kesilebilir,
- Kör nokta geçişlerinde uyarı mekanizması ile muhtemel kazalar önlenilebilir,
- Yangın algılama erken uyarı sistemleri geliştirilebilir.

Geleceğin iş yeri için YZ'nın olanaklarını ve zorluklarını araştırmak, YZ uygulamalarının çalışan sağlığı ve güvenliğinde karşılaşılabilecek negatif yönleri azaltmaya yardımcı olacaktır.

YZ ile kullanılan sensörler, robotlar, ML algoritmaları üretkenliği artırarak, çalışan sağlığı ve güvenliği açısından potansiyel olarak iyileştirme sağlayabilmektedir. Çalışanların güvenliğini sağlamanın yanı sıra, tehlikeli ortamlardaki güvenlik sorunları bu teknolojilerle proaktif bir şekilde değerlendirilmektedir.

Nihai olarak bu çalışma İSG sektöründe YZ'nin uygulanabilirliğini göstermektedir. Gelecek çalışmalarda farklı optimizasyon teknikleri ile makine öğrenmesi algoritmaları sentezlenerek İSG alanında daha iyi sonuçlar üretilebileceği düşünülmektedir.

Referanslar

- [1] İ. Kılıkış, İş Sağlığı ve Güvenliği, Bursa: Dora, 2018.
- [2] İ.Ekmekçi and A.B.Ekmekçi, “Endüstri 4.0 Ve İş Sağlığı Ve Güvenliğinde Yeni Teknolojiler: İsg 4.0” in *Sektörlerin ve Mesleklerin Geleceği*, 2020.
- [3] K. Schwab, “The Fourth Industrial Revolution; Currency.” Redfern, NSW, Australia, 2017.
- [4] G. Fu, X. Xie, Q. Jia, Z. Li, S. Chen, Y. Ge, “The development history of accident causation models in the past 100 years: 24Model, a more modern accident causation model”, *Process Safety and Environmental Protection*, vol. 134, pp. 47–82, 2020.
- [5] T. Bulut, “Google Trendler İle COVID-19’un Analiz Edilmesi: Türkiye ve Dünya Vaka Örnekleri: Analyzing COVID-19 with Google Trends”, *Sağlık Bilimlerinde Yapay Zeka Dergisi (Journal of Artificial Intelligence in Health Sciences)*, vol.1, no.2, pp. 8-13,2021.
- [6] “Google Trends,” *Google.com*. [Online]. Available: <https://www.google.com/trends>. [Accessed: 26-Aug-2021].
- [7] M. Atalay and E. Çelik, “Büyük Veri Analizinde Yapay Zekâ Ve Makine Öğrenmesi Uygulamaları - Artificial Intelligence And Machine Learning Applications In Big Data Analysis,” *Mehmet akif ersoy üniv. sos. bilim. enst. derg.*, pp. 155–172, 2017.
- [8] B. Shiklo, “IoT in manufacturing: The ultimate guide,” *ScienceSoft*, 25-Dec-2018. [Online]. Available: <https://www.scnsoft.com/blog/iot-in-manufacturing>. [Accessed: 27-Aug-2021].
- [9] F. Maraşlı and M. Çibuk, “RFID Teknolojisi ve Kullanım Alanları,” *Bitlis Eren Üniv. Fen Bilim. Derg.*, vol. 4, no. 2, 2015.
- [10] “RTLS Teknolojisinin Endüstriyel Kullanım Alanları Neler? - Trio Mobil,” *Triomobil.com*. [Online]. Available: <https://www.triomobil.com/tr/blog/rtls-teknolojisinin-endustriyel-kullanim-alanlari-nelerdir>. [Accessed: 27-Aug-2021].
- [11] T. İçten, and B. A. L. Güngör. "Artırılmış gerçeklik üzerine son gelişmelerin ve uygulamaların incelenmesi." *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji* 5.2, pp. 111-136, 2017.
- [12] EA. Sağbaş, S. Ballı, and T. Yıldız. "Giyilebilir Akıllı Cihazlar: Dünü, Bugünü ve Geleceği." *Akademik Bilişim*, 2016.

S-05 YAPAY ZEKÂ VE TOPLUMSAL CİNSİYET İLİŞKİSİNİN MESLEKLER BAĞLAMINDA İNCELENMESİ

Öğr. Gör. Büşra Sedef ÇİFCİ^{1*}, Prof. Dr. Çiğdem ŞAHİN
BAŞFIRINCI²

¹Tıbbi Tanıtım ve Pazarlama Bölümü, Bitlis Eren Üniversitesi, Türkiye,
bscifci@beu.edu.tr.

²Halkla İlişkiler ve Reklamcılık Bölümü, Trabzon Üniversitesi, Türkiye,
cbasfirinci@trabzon.edu.tr.

*Bu bildiri, Büşra Sedef Çifci'nin “Yapay Zekâ Konusunun Toplumsal Cinsiyet Kapsamında İncelenmesi” adlı makalesinden üretilmiştir.

Özet

Bu araştırmanın yapılmasındaki temel gaye, yapay zekâ ve robotik uygulamalarının, toplumsal yapı içerisindeki cinsiyet eşitsizliği algısının güçlenmesine sebep olup olmadığını araştırmaktır. Araştırmanın sorusuna meslekler bağlamında cevap bulunmaya çalışılmıştır. Araştırma bağlamında senaryo tekniğine kullanılmıştır. Araştırma verileri anket yoluyla elde edilmiştir. Hipotezlerin test edilmesinde tek örneklem ve bağımsız örneklem t testleri kullanılmıştır. Düşünüldüğü gibi katılımcılar, meslek robotlarını hem cinsiyet hem de kişilik kriterleri yönünden cinsiyetçi algılama yönünde eğilim göstermişlerdir. Araştırma kapsamında yapılan literatür taraması neticesinde yapay zekâ/robotik gelişmeler ve toplumsal cinsiyet ilişkisi kapsamında Türkiye bağlamında yapılan bir araştırmaya rastlanmaması bu çalışmanın özgün değerini oluşturmaktadır.

Anahtar Sözcükler: *Sözcük 1; Yapay Zekâ Sözcük 2; Toplumsal Cinsiyet Sözcük 3; Robotlar.*

Examining the Relationship between Artificial Intelligence and Gender in the Context of Professions

Abstract

The main purpose of this research is to investigate whether artificial intelligence and robotic applications cause the perception of gender inequality in the social structure to be strengthened. It has been tried to find an answer to the research question in the context of professions. In the context of the research, the scenario technique was used. Research data were obtained through a questionnaire. Single sample and independent sample t tests were used to test the hypotheses. As it is thought, the participants showed a tendency to perceive occupational robots as sexist in terms of both gender and personality criteria. As a result of the literature review conducted within the scope of the research, the fact that there is no research conducted in the context of artificial intelligence/robotic developments and gender relations in the context of Turkey constitutes the original value of this study.

Keywords: Keyword 1; Artificial Intelligence Keyword 2; Gender Keyword 3; Robots.

1. Giriş

Yapay zekâ ve robotik teknolojilerinin gelişimi ve robotların günlük yaşantıda daha fazla yer almaya başlamasıyla beraber, tasarlanan robotların sosyal yapı içerisine daha hızlı entegre olabilmeleri adına robotistlerin, bu robotları insan özelliklerine en yakın boyut ve formlarda üretmeye başladıkları görülmektedir. Fakat bu durumun sosyal yapı içerisindeki cinsiyet eşitsizliklerini nasıl bir etkiye bulunacağı konusu soru işaretleri içermektedir. Bu anlamda araştırmaya ilk olarak kavramsal açıdan kısaca değinmek gerekirse cinsiyet kavramını tanımlayarak başlamak uygun olacaktır. Cinsiyet kavramı; bir bireyin yaratılış farklılıklarını açıklamak gayesiyle kadın ve erkek olmanın biyolojik boyutuna vurgu yapmak, kadın ve erkeğin yaratılış farklılıklarını anlatmak için kullanılır. Toplumsal cinsiyet kavramı ise toplumun kadın ve erkek için belirlediği ve uygun gördüğü bazı rolleri ifade eder. Bu roller erkeklerin ve kadınların toplumsal yapı içerisindeki faaliyet alanlarını kısıtlayan toplumsal beklentileri ifade etmektedir (Kalan, 2010, s. 77). Bu beklentiler çocukluk dönemlerinde bireylere aktarılmaya başlanır ve bireylerin bu toplumsal beklentilere göre davranışları öğretilir. Bu anlamda kadınlara ev ile ilgili işleri yapmaları kazandırılırken/öğretilirken (yemek yapmak, temizlik, çocuk bakımı vb.) erkeklere ise dışarıya (para kazanmak, ailesini geçindirmek vb.) dair sorumluluklar yüklenmiştir. Hâlbuki bu roller zamanımızın modern toplumlarının yapısını anlamada/açıklamada yetersiz kalmaktadır. Buna rağmen geçmişten günümüze gelen ve zamanla öğrenilen kalıp yargılar sebebiyle roller üzerinden inşa edilen bu toplumsal beklentiler bireylerin mesleki kararlarında büyük oranda etkili olmaktadır. Mesleki kararları etkileyen bu cinsiyet rolleri çok erken dönemlerden itibaren kalıp yargılar yoluyla bireyler tarafından içselleştirilir. Örneğin, kadınlar toplumsal bakış açısına göre daha uygun görülen öğretmen, temizlik görevlisi, hemşire ve bakıcı gibi mesleklere teşvik edilirken erkekler ise zekâ, güç ve cesaret isteyen inşaat mühendisliği, mimarlık, doktorluk, güvenlik görevlisi gibi mesleklere yönlendirilmektedir. Bu süreçlerin neticesi olarak da toplumsal cinsiyete dair kalıp yargılar ve algılar hayatın her aşamasında görüldüğü gibi, meslek kararlarında da bireye bir yol çizmekte ve toplumun kendisinden beklediği şekilde hareket etmesini istemektedir (White and White, 2006, p. 219).

2. Geçmiş Araştırmalar

Alanda yapılan araştırmalar göstermektedir ki erkekler, robotlarla alakalı pozitif bir algıya sahiptirler ve robotların toplumsal hayattaki mevcudiyetlerini benimseme konusunda daha heveslidirler. Kadınlar ise ekseriyetle robotların sebep olabileceği tehlikelere yoğunlaşmakta ve robotların varlığını kabullenme/benimseme noktasında direnç göstermektedirler (Showkat, 2018; Yan, 2014; Hung, 2012; Kuo vd., 2009; Nomura vd., 2006). Bunun yanı sıra erkek katılımcıların kadın robotlar ile kadın katılımcıların ise erkek robotlar ile daha başarılı bir iletişim sürdürdükleri görülmektedir (Aimi vd., 2018; Emma vd., 2014; Siegel vd., 2009). Buna ilaveten hem kadınlar hem de erkekler, internette sanal hizmet veren kadın robot asistanlar ile iletişim kurarken kendilerini daha rahat hissetmekte, kadın asistanlara daha fazla güven duymaktadırlar (Aimi vd., 2018; Niculescu vd., 2010).

Araştırma kapsamında yapılan literatür taraması neticesinde görülmektedir ki Türkiye’de yapay zekâ ve toplumsal cinsiyet arasındaki ilişkiyi inceleyen bir çalışma yer almamaktadır. Tüm bu veriler ışığında gerçekleştirilen bu araştırmanın amaçları; araştırma kapsamında belirlenen on farklı meslek robotuna yönelik toplumsal cinsiyete dair algıların var olup olmadığını ölçmek, bu algıların katılımcıların cinsiyetlerine göre farklılık gösterip göstermediğini belirlemek ve meslek robotlarının belirlenen kişilik kriterleri yönünden değerlendirilmesi durumunda da toplumsal cinsiyetçi bir algının var olup olmadığını ortaya koymaktır. Bu amaçlar bağlamında ele alınan bu araştırmanın üç temel hipotezi bulunmaktadır.

- *H₁: Meslek robotlarına yönelik toplumsal cinsiyet düşüncesi/algısı vardır.*
- *H₂: Kadınlarla erkeklerin belirlenen robot mesleklerine dair toplumsal cinsiyet algıları birbirinden farklıdır.*
- *H₃: Meslek robotlarının kişilik kriterlerine dair toplumsal cinsiyet düşüncesi/algısı vardır.*

3. Yöntem

Bu çalışma bağlamında kantitatif/nicel yöntemden faydalanılmıştır. Meslek robotlarına dair toplumsal cinsiyetçi bir algının var olup olmadığını ölçebilmek için senaryo tekniğinden yararlanılmıştır. Araştırmadan elde edilen veriler anket yoluyla toplanmıştır. Hipotezlerin test edilmesi noktasında tek örneklem ve bağımsız örneklem t testleri kullanılmıştır. Araştırmanın örneklem grubunu Trabzon Üniversitesi ve Karadeniz Teknik Üniversitesi’nde aktif olarak öğrenim görmekte olan öğrenciler oluşturmaktadır. Örneklem grubu, kolayda örneklem yöntemiyle belirlenmiştir. Örneklem grubunda toplamda 1023 katılımcı yer almaktadır. Anket bağlamında katılımcılara 10 farklı meslek robotunun her birini ne oranda kadınsı ya da erkeksi algıladıklarını belirtmeleri için 5’li Likert ölçeği sunulmuştur. Araştırma kapsamında katılımcılara sunulan robot meslekleri, *eczacı, aşçı, cerrah, banka müdür, savcı, hemşire, makine mühendisi, güvenlik görevlisi, sekreter ve anaokulu öğretmeni* olarak belirlenmiştir. İkinci grupta ise katılımcılara 11 farklı kişilik kriteri sunulmuş ve kendilerinden, her 10 robot mesleği için ayrı ayrı olacak şekilde uygun olduğunu düşündükleri bu kişilik kriterlerini işaretlemeleri istenmiştir. Belirlenen kişilik kriterleri erkeksi; *zeki, lider, baskın, özgüvenli, dayanıklı, iddialı* ve kadınsı; *mütevazı, geleneksel, hassas, kibar, duygusal* olarak sunulmuştur. Araştırma kapsamında belirlenen meslek kategorilerinin ve kişilik özelliklerinin seçiminde literatürde yer alan önceki araştırmalardan faydalanılmıştır (Woods, 2018; Eyssel ve Hegel 2012; Gustavsson, 2005; Karabekmez, 2018; Benedict, 2014; Gustavsson, 2005).

4. Bulgular

Bu çalışmanın H₁ hipotezi bağlamında yapılan t testinden elde edilen bulgulara göre meslek robotlarının (eczacı, aşçı, cerrah, banka müdür, savcı, hemşire, makine mühendisi, güvenlik görevlisi, sekreter ve anaokulu öğretmeni) tamamı için toplumsal cinsiyet algılamaları sıfır noktasından anlamlı düzeyde farklı bulunmuştur. Bir başka deyişle H₁

hipotezi 10 farklı meslek robotunun her biri için tek tek kabul edilmiştir. H₂ hipotezi bağlamında ise 10 meslek robotundan (*eczacı, aşçı, cerrah, banka müdür, savcı, hemşire, makine mühendisi, güvenlik görevlisi, sekreter ve anaokulu öğretmeni*) 9’una yönelik toplumsal cinsiyete dair algılamaların, katılımcıların cinsiyetlerine göre değişkenlik gösterdiği görülmüştür. *Aşçı* meslek robotu kapsamında ise kadınların ve erkeklerin toplumsal cinsiyete dair algılarının farklılık göstermediğine yönelik bulgular elde edilmiştir. H₃ hipotezi bağlamında, meslek robotları belirlenen kişilik kriterleri yönünden ele alındığında da toplumsal cinsiyete dair algıların güçlü şekilde ortaya çıktığı görülmektedir. Başka bir ifadeyle H₃ hipotezi 10 meslek robotunun her biri için tek tek kabul edilmiştir, kişilik kriterleri bağlamında bu mesleklere dair belirli bir toplumsal cinsiyet düşüncesinin/algısının var olduğu belirlenmiştir.

5. Sonuç ve Öneriler

Beklendiği gibi, bu araştırmanın verileri, araştırma kapsamında belirlenen meslek robotlarına dair cinsiyetçi bir algının varlığını, bu algıların kadınlarda ve erkeklerde farklılık gösterdiğini ve istatistiksel olarak da anlamlı düzeyde farklılıkların yer aldığını ve kişilik kriterleri noktasında ele alındığında da cinsiyetçi düşüncelerin/algıların varlığını açık bir şekilde ortaya koymaktadır. Araştırma kapsamında elde edilen bu veriler, literatürde yer alan yurt dışı kaynaklı araştırmaların sonuçlarıyla da paralellik göstermektedir (Showkat 2018; Aimi vd., 2018; Guo ve He, 2015; Yan, 2014; Emma vd., 2014; Hung, 2012; Willbourn ve Kee, 2010; Kuo vd., 2009; Siegel vd., 2009; Nomura vd., 2006; (Karabekmez, 2018; Benedict, 2014; Gustavsson, 2005; Shinar, 1975). Bu bağlamda *sekreter, eczacı, hemşire, aşçı ve anaokulu öğretmeni*, meslek robotları kadınsı; *güvenlik görevlisi, makine mühendisi, savcı, banka müdürü ve cerrah*, meslek robotları ise erkeksi olarak düşünülmüş/algılanmıştır. Araştırmadan sağlanan bu veriler literatürde yer alan araştırmaların bulguları ve toplumsal zihniyetteki algılar ve kalıp yargılar ile de paralellik göstermektedir (Karabekmez, 2018; Gustavsson, 2005; Benedict, 2014). Buna ilaveten Eagly’in (1987), sosyal rol teorisini de desteklemektedir. Toplumsal cinsiyete dair algının en düşük olduğu meslek robotları ise banka müdürü ve aşçı meslek robotları olarak bulunmuştur.

H₂ hipotezine göre *anaokulu öğretmeni, hemşire, eczacı ve sekreter* meslek robotlarını hem kadınlar hem de erkekler, kadın olarak algılamalarına/değerlendirmelerine rağmen, erkek katılımcılar bu robot mesleklerini daha yüksek düzeyde kadınsı olarak değerlendirmektedir. Buna benzer olarak *güvenlik görevlisi, makine mühendisi ve cerrah* meslek robotları hem erkekler hem de kadınlar, erkek olarak değerlendirilmelerine rağmen, erkekler bu meslek robotlarını daha erkeksi olarak değerlendirmektedir. H₂ hipotezi (katılımcıların cinsiyetlerine göre toplumsal cinsiyet algıları) bağlamında *savcı ve banka müdürü* meslek robotlarını kadınlar kadınsı olarak, erkekler ise erkeksi olarak algılamışlardır. H₂ hipotezinin kabul edilmediği tek meslek *aşçılık*tır. Her iki cinsiyet grubu da *aşçı* robotu kadınsı olarak değerlendirmişlerdir ve aralarında anlamlı bir fark bulunamamıştır.

Robotlar kişilik kriterleri noktasından değerlendirildiğinde de toplumsal cinsiyete yönelik algıların baskın düzeyde var olduğu görülmektedir. Keza H₃ hipotezi 10 meslek robotunun tümü için doğrulanmıştır. Buna göre kişilik kriterleri noktasında yapılan bir değerlendirmede banka müdürü, güvenlik görevlisi, savcı, cerrah ve makine mühendisi kadınsı; anaokulu öğretmeni, hemşire, eczacı, sekreter ve aşçı erkeksi algılanmaktadır.

Tablo 1. Meslek Robotlarına Yönelik Cinsiyetçi Değerlendirmelerin Karşılaştırmalı Tablosu

Robot Meslekleri	H₁ Hipotezi Meslek Robotları İçin Algılanan Toplumsal Cinsiyet	H₂ Hipotez Katılımcıların Cinsiyetlerine Göre Toplumsal Cinsiyet Algıları		H₃ Hipotezi Meslek Robotlarının Kişilik Özelliklerine Yönelik Toplumsal Cinsiyet Algıları
<i>A. Öğr.</i>	K	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		E
<i>Hem.</i>	K	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		E
<i>Sek.</i>	K	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		E
<i>Ecz.</i>	K	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		E
<i>Aşçı</i>	K	Hem kadınlar hem de erkekler için kadınsı.		E
<i>Banka Müd.</i>	E	Kadınlara göre kadınsı	Erkeklere göre erkeksi	K
<i>Savcı</i>	E	Kadınlara göre kadınsı	Erkeklere göre erkeksi	K
<i>Cerrah</i>	E	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		K
<i>Makine Müh.</i>	E	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		K
<i>Güvenlik Gör.</i>	E	Hem kadınlar hem de erkekler için kadınsı ancak erkek katılımcıların algıları bağlamında daha kadınsı.		K

Güvenlik görevlisi, makine mühendisi ve cerrah meslek robotları, (H1) ve (H2) bağlamında değerlendirildiğinde erkek olarak algılanmakta ancak kişilik kriterleri (H3) noktasında değerlendirildiğinde ise her üç meslek robotu da kadınsı olarak algılanmaktadır. Buna benzer olarak, *hemşire, eczacı, sekreter, aşçı ve anaokulu öğretmeni* robot meslekleri de hem (H1) hem de (H2) yönünden değerlendirildiğinde kadın olarak algılanmakta ancak kişilik kriterleri (H3) yönünden bakıldığında ise beş robot mesleğinin tümünün erkeksi yönde algılandığı görülmektedir. Diğer meslek robotları ise - *banka müdürü ve savcı* - (H1) hipotezi bağlamında erkeksi olarak algılanırken (H3) hipotezi noktasında ise kadınsı olarak algılanmaktadır.

H₁ ve H₃ hipotezleri kapsamında, taban tabana zıt olarak elde edilen veriler, bireylerin kültürel değerler ve toplumsal yapı tarafından şekillenen algıları ile gerçekte benimsemiş oldukları düşüncelerinin ve algılarının farklılığını/çatışmasını göstermektedir. Jessel ve Beymer (1992)'in de belirtmiş olduğu gibi bireylere doğrudan meslek isimleri verildiğinde cinsiyetçi bir algı kolayca oluşmaktadır. Fakat bireylere, mesleğin adı değil, yapılacak işin/görevin tanımı verildiğinde ise güçlü ve bariz bir toplumsal cinsiyet algısı oluşmamaktadır. Bütün bu verilerden yola çıkarak, robotların meslek dünyasında/yaşantısında daha kolay kabul görebilmesi ve sosyal yaşantıya daha hızlı ve rahat dahil olabilmeleri için bu robotların sosyal yaşantı içerisindeki cinsiyet kodlarına uygun şekilde üretileceği/tasarlanacağı öngörülebilmektedir. Bu öngörü yapay zekâ alanında yaşanan gelişmelerin bir uzantısı olarak robotların, var olan toplumsal cinsiyet algılarının yeniden inşa edilmesinde bir araç rolü üstleneceğine işaret etmektedir.

Bu çalışma, toplumsal cinsiyet ve robotik sistemler/yapay zekâ ilişkisine dair *Türk toplum yapısı* hakkında bilgi veren, veri sunan ilk çalışmadır. Bu bağlamda, ileride yapılacak araştırmalara öncülük edeceği düşünülmektedir. Gelecekte yapılacak araştırmalarda, verilerin kapsayıcılığını arttırmak ve konuyu daha sistematik bir yaklaşımla değerlendirebilmek için *tesadüfi örneklem* yöntemiyle, *farklı bir sosyal sınıf, farklı yaş aralıkları ve farklı meslek grupları ile çalışılabilir*. Bununun yanı sıra ileride yapılacak araştırmalarda mesleklere yönelik toplumsal cinsiyet algısı prestij konusu bağlamında ele alınabilir.

Referanslar

- [1] Aimi Shazwani, G. vd. (2018). Effect of robots characteristics and gender in persuasive human robot interaction. *Frontiers in Robotic and AI, Vol 5; No:73*, 1-20.
- [2] Alexander, E. vd. (2014). Asking for help from a gendered robot. *In Proceedings of the Annual Meeting of the Cognitive Science Society, Vol 36; No:36*, 48-75.
- [3] Eagly, A. H. vd. (2000). Social role theory of sex differences and similarities: a current appraisal. *The Development Social Psychology of Gender, Vol 12*, 123-174.
- [4] Friederike, E. and Frank, H. (2012). (S)he's got the look: gender stereotyping of robots. *Journal of Applied Social Psychology, Vol 42; No:9*, 2213-2230.

- [5] Guo, Y. and He, X. (2015). A stereotypic explanatory bias study of college students occupational gender stereotype. *Canadian Social Science*, Vol 11; No:3, 141-145.
- [6] Gustavsson, E. (2005). Virtual servants: Stereotyping female front-office employees on the internet. *Blackwell Publishing Ltd*, Vol 12; No:5, 401- 419.
- [7] Jessell, J. and Beymer, L. (1992). The effects of job title vs. job description on occupational sex typing. *Sex Roles*, Vol 27; No:1, 73-83.
- [8] Kalan Gündüz, Ö. (2010). Reklamda çocuğun toplumsal cinsiyet teorisi bağlamında konumlandırılışı: kinder reklam filmleri üzerine bir inceleme. *İletişim Fakültesi Dergisi*, Vol 1; Sayı: 38, 75-89.
- [9] Karabekmez, S. vd. (2018). Okul öncesi dönem çocuklarının mesleklere yönelik toplumsal cinsiyet algılarının incelenmesi. *Bilim Eğitim Sanat ve Teknoloji Dergisi*, Vol 2; Sayı:1, 51-70.
- [10] Kuo, I. vd. (2009). Age and gender factors in user acceptance of healthcare robots. Proceedings of the 18th IEEE International Symposium On Robot And Human Interactive Communication içinde 214-219. Toyama: Japan,
- [11] Lin, C. H., vd. (2012). Exploring Parents’ Perceptions towards educational robots: Gender and socioeconomic differences. *Br J Educ Technol*, Vol 43, 31-34.
- [12] Niculescu, A. vd. (2010). How the agent’s gender influence users’ evaluation of a qa system. Proceedings Of The International Conference On User Science And Engineering, NJ: IEEE, Vol 13; No:15, 16-20.
- [13] Nomura, T. vd. (2006). Experimental investigation into influence of negative attitudes toward robots on human–robot interaction. *AI and Society*, Vol 20; No:2, 138-150.
- [14] Shinar, E. (1975). Sexual stereotypes of occupations. *Journal of Vocational Behavior*, Vol 7, 99-111.
- [15] Showkat, D. (2018). Gender Differences in Robot Teleoperation, Yayınlanmamış Yüksek Lisans Tezi, Oregon State University.
- [16] Siegel, M. vd. (2009). Persuasive robotics: The influence of robot gender on human behavior. *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2563-2568.
- [17] Tay, B. vd. (2014). When stereotypes meet robots: The double-edge sword of robot gender and personality in human–robot interaction. *Computers in Human Behavior*, Vol 38, 75-84.
- [18] Wang, Y. (2014). Gendering human-robot interaction: Exploring how a person’s gender impacts attitudes toward and interaction with robots. Yayınlanmamış Yüksek Lisans Tezi, Manitoba University, Kanada.

[19] Wilbourn, M. P. and Kee, D. W. (2010). Henry the nurse is a doctor too: implicitly examining children’s gender stereotypes for male and female occupational roles. *Sex Roles*, Vol 62, 670-683.

[20] Woods, H. S. (2018). Asking more of siri and alexa: Feminine persona in service of surveillance capitalism. *Critical Studies in Media Communication*, Vol 35; No:4, 334-349.

S-08 GERÇEK YAPAY ZEKÂNIN ÖNÜNDEKİ ENGEL BİLİNÇ MİDİR?

Ferhat ONUR

Karadeniz Teknik Üniversitesi, Sosyoloji Bölümü, ferhatonur@ktu.edu.tr

Özet

Yapay zekâ araştırmaları doğrudan etkilerini gördüğümüz sayısız uygulamayla birlikte tüm hızıyla sürüyor. Ancak bu araştırmaların nihai amacı hayatımızı kolaylaştıran teknolojiler üretmekten ziyade insanın sahip olduğu türden bir zekâyı, genel yapay zekâyı, hatta daha fazlasını elde etmektir. Yapay zekânın sadece bir satranç ustası olmasını, araç kullanmasını veya asistanlık yapmasını değil, anlamlı iletişim kurabilmesini, yaratıcı fikirler ortaya koyabilmesini, sağduyu sahibi olabilmesini, dünya hakkında düşünebilmesini istiyoruz. Böyle bir zekânın olabilirliği üzerine konuşulduğunda felsefi problemler baş gösteriyor. Bunlardan öne çıkanı yapay zekânın insanlar gibi gerçek bir zekâyı sahip olup olmadığını nasıl bilebileceğimiz ile ilgili epistemolojik problemidir. Bu noktada zekânın belirtisini sergilenen davranışlarda arayan davranışçı yaklaşım haklı görülebilir ancak bunun bir koşulu vardır: Yapay zekâ bizi kendisinin gerçekten de genel bir zekâyı sahip olduğuna ikna etmelidir. Bilincin bu ikna girişiminde bir rol oynuyor olabilmesi yapay zekâ ve bilincin sanılandan daha güçlü bir şekilde birbirine bağlı olduğunu imleyecektir. Daha otonom bir varlık/birey olma hedefinde yapay zekânın yolu bilincin varlığı ile kesişiyor olabilir.

Anahtar Kelimeler: *Bilinç, derin öğrenme, genel yapay zekâ, Turing testi.*

Abstract

(Is Consciousness an Obstacle to Real Artificial Intelligence?)

Artificial intelligence research continues at full speed with countless applications which we directly see its effects. However, the ultimate goal of these researches is not to produce technologies that make our lives easier, but to obtain the kind of intelligence that humans have, namely the general artificial intelligence and even more. We want AI to not only be a chess master, drive a car or be an assistant, but also be able to make meaningful communication, come up with creative ideas, have common sense and think about the world. When talking about the possibility of such an intelligence, philosophical problems arise. Prominent among these is the epistemological problem of how we can know whether AI has the real intelligence like humans have. At this point, the behaviorist approach, which looks for the signs of intelligence in the behaviors exhibited, may be justified, but there is a requirement for this. AI should convince us that it does indeed have general intelligence. The fact that consciousness could play a role in this attempt at persuasion would imply that AI and consciousness are more strongly interconnected than previously thought. In the goal of becoming a more autonomous being/individual, the path of AI may intersect with the existence of consciousness.

Key Words: *Consciousness, deep learning, general artificial intelligence, the Turing test.*

1. Giriş

Yapay zekânın gelişim aşamaları genellikle üç dönemle karakterize edilir³. 1950’lerden 90’lara kadar yapay zekâ araştırmalarının başat yöntemi olmuş ve John Haugeland’ın (1985: 112) “eski moda yapay zekâ (GOFAI)” olarak adlandırdığı birinci dönemde, programcılar belli bir problemin nasıl çözüleceğini keşfetmekte ve söz konusu keşfi problemin sembolik bir temsili aracılığıyla kodlara dönüştürmektedirler. Ortaya çıkan program kural temellidir ve insan bilgisini bu kurallar üzerinden temsil etmeye odaklıdır, bundan dolayı bu tür sistemlerin “el yapımı bilgi (*handcrafted knowledge*)” ürettiği söylenir. 2010’lardan günümüze uzanan yapay zekânın ikinci dalgasında kural temelli, sembolik temsil yerini istatistiksel öğrenmeye bırakır. “Derin öğrenme/düşünme” adı da verilen bir tür *makine öğrenmesinin* gerçekleştirildiği bu ikinci dönemin ayırt edici özelliği makinelerin kendi kendilerini programlamalarını olanaklı kılmış olmasıdır. Programcılar belli problem alanları için istatistiksel modeller oluşturarak onları *büyük veri* kümelerine maruz bırakırlar. Makineler bu modelleri kullanarak verileri yorumlayıp bilgilerini genişletebilir ve öngörülerde bulunup karar verebilir hale gelirler. Sanal asistanlar, sohbet robotları, sürücüsüz araçlar, özelleştirilmiş deneyimler, yüz tanıma, renklendirme, çeviri, bilgisayar destekli hastalık teşhisi gibi uygulamalarla günümüz yapay zekâ teknolojileri ikinci dalgayı örneklemektedir. Henüz daha başlarında olduğumuz üçüncü dalga, bizleri yapay zekâ sistemlerini sadece insanların programladığı kuralları uygulayan (birinci dalga) veya insanların düzenlediği veri dizilerinden genellemeler yapan (ikinci dalga) araçlar olmaktan daha fazlası olarak görmeye, onları insan benzeri iletişim ve akıl yürütme becerilerini elde etmiş ortaklar olarak düşünmeye davet etmektedir (Kersting, 2020: 435). Bu aşamada yapay zekânın yüz yüze geldiği olay ve durumlar karşısında kararlar almakla kalmayıp “bağlama uyumlu (*contextual adaptation*)” bir şekilde aldığı kararları açıklaması, bunların nedenlerini ortaya koyması, böylece doğal iletişimin önünün açılmasıyla problemlere insanlarla birlikte çözüm önerileri getirmesi beklenmektedir. Bununla birlikte, üçüncü dönem veya dalga başarıyla tamamlansa bile kimilerine göre yapay zekâda amaçlanan sonuca ulaşılmış olunmayacaktır.

Yapay zekâ araştırmalarının nihai hedefi *genel yapay zekâ* (GYZ) veya *güçlü yapay zekâ*⁴. Günümüzde düşünebilen makineler geliştirme araştırmalarının büyük çoğunluğu *zayıf* veya *dar yapay zekâ*ya (belli problemleri çözmek üzere tasarlanmış programlar) odaklanmıştır. Buna karşın genel yapay zekâ bir insanın gerçekleştirdiği *bütün* entelektüel işleri ve belki daha fazlasını yapabilecek yetkinlikte olacaktır (Walsh, 2018; Sabouret, 2021). Günlük yaşamında bir insanın düşünsel aktivitesi dünya hakkında sahip olduğu muazzam sayıda bilgiye dayanır. Bu bilginin bir kısmı rasyonel ve hesaplıysa da büyük bir bölümü sağduyusal (*common sense*) ve sezgiseldir. Sağduyusal ve sezgisel bilgi formel bir şekilde ifade edilemediğinden yapay zekâ

³ Bu sınıflama ABD Savunma Bakanlığı’na bağlı bir devlet kurumu olan ve teknoloji alanında birçok yeniliğe imza atmış *Savunma İleri Araştırma Projeleri Ajansı* (DARPA) tarafından yapılmış ve hüristik açıdan faydalı bulunduğundan çoğu araştırmacının onayını almıştır. DARPA’nın John Launchbury tarafından yapılan konu hakkındaki sunumuna <https://www.darpa.mil/about-us/darpa-perspective-on-ai> adresinden ulaşılabilir.

⁴ Bazı yazarlar genel yapay zekâ ve güçlü yapay zekâ arasında bir ayırım yapsalar da burada bu iki terimle kastedilen şey en genel anlamıyla “insan-benzeri bilişsel bir kapasite” olduğundan söz konusu ayırım konumuz açısından bir önem arz etmemektedir. Ayrıca yapay zekâ araştırmalarının nihai hedefinin “bilimsel yaratıcılık, genel bilgelik ve sosyal beceriler de dahil olmak üzere her alanda en iyi insan beyinlerinden daha akıllı olan bir zekâ” olarak tanımlanan (Bostrom, 2006) *süper yapay zekâ* olduğu da ileri sürülebilir. Ancak böylesi hipotetik bir zekânın varlığı da yazının argümanı bakımından bir farklılık yaratmadığı için göz ardı edilmesinde sakınca yoktur.

için en önemli zorluklardan biri bu informel bilginin bilgisayarlarda nasıl yaratılacağıdır (Goodfellow vd., 2016: 2). Bu problem çok önceleri yapay zekânın babası sayılan Alan Turing (1912-1954) tarafından *Computing Machinery and Intelligence* adlı ünlü makalesinde yapay zekâyâ karşı getirilen dokuz argümandan biri olarak ele alınmıştır. Turing’in “Davranışın İformelliği Argümanı” adıyla sunduğu bu argümana göre, “kişinin düşünülecek her koşulda ne yapacağını tanımlayan bir dizi kural oluşturmak mümkün değildir.” (1950: 452) Turing her olasılığı kapsayan davranış kuralları sağlamanın imkânsız görüldüğünü kabul eder ancak bunun bizlerin birer makine olamayacağımız düşüncesinin onanması anlamına gelmediğini de ekler. O, insanın gerçekten de bir makine olmasından şüpheleniyordu. Şayet insan bir makine idiyse makineler de bir gün düşünebilirdi: “Bu yüzyılın [20. yy] sonunda kelimelerin kullanımı ve genel eğitilmiş kanaat o kadar değişmiş olacak ki, kişinin çelişkiye düşmeyi beklemeden makinelerin düşünmesinden bahsedebileceğine inanıyorum.” (1950: 442) Turing için olduğu gibi GYZ programı için de makinelerin düşündüğünün ikrarı sadece bir zaman meselesidir. Turing’in kehaneti gerçekleşmedi. Henüz makinelerin düşündüğünden bahsetmiyoruz. O halde yanlış giden neydi? Hâlâ bu bir zaman meselesi midir, yoksa başka bir engel mi söz konusu?

2. Makineler Düşünebilir mi?

Bir makinenin düşündüğünü söyleyebilmemiz için gereken koşul veya kriter nedir? Turing geliştirdiği “taklit oyunu” ile bir kriter ortaya koyduğunu düşünüyordu. “Turing testi” de denilen bu oyuna göre, eğer bir makine belli koşullar altında, kendisine yöneltilen sorulara onu bir insandan ayırt edemeyeceğimiz şekilde iyi cevaplar verebiliyorsa, o makinenin düşündüğünü söylemeliyiz. Buna göre, Turing’in kullandığı kriter davranışçıdır; yani o düşünmenin tespiti için oyuncuların yapıldıkları malzemelerle (biyolojik veya sentetik) veya içinde buldukları hallerle (zihinsel veya fiziksel) ilgilenmemekte fakat sadece uyarılara (sorulara) verdikleri tepkileri (cevapları) dikkate almaktadır. Turing ve diğer davranışçıların böyle düşünmelerinin nedeni basittir: Herhangi bir varlığa düşünce ve diğer zihinsel özellikleri atfedebilmemizin başka bir yolu yoktur. Yaşamın var olduğunu keşfettiğimiz bir gezegene iniş yaptığımızı ve o gezegenin bizimle iletişim kurmaya çalışan ve bize benzemeyen bazı yaşam formları tarafından karşılandığımızı farz edelim. İletişimimizin sağlıklı olduğunu, söylediklerimizi anladıklarını nasıl bilebiliriz? Elbette verdikleri cevapların sorularımıza olan uygunluğundan veya kurduğumuz diyalogda olması gereken karşılıkları vermelerinden biliriz. Aslına bakılırsa bir başka insanın da düşündüğünü ve bir zihne sahip olduğunu sergilediği sözel veya bedensel davranışlardan anlarız. Bazı bilim kurgu filmlerine konu olan bir olay gerçekleşse, görünüşleri ve sergiledikleri davranışlar itibarıyla bizlere benzeyen dünya dışı varlıklar aramızda dolaşıyor olsaydı, sadece görünüşleri ve davranışlarına bakarak onları insanlardan ayırt etmemizin imkânı olmazdı. O halde Turing testini geçen bir makinenin de gerçekten bizi anladığını, düşündüğünü, iletişim kurduğunu neden söylemeyelim? Her felsefi problemde olduğu gibi meselenin bu kadar kolay çözülemeyeceğini bildiren itirazlar ve argümanlar ileri sürülmüştür. İlk ciddi itiraz enformasyon teorisinin babası olarak kabul edilen Claude Shannon (1916-2001) ve “yapay zekâ” terimini ortaya atan kişi olan bilgisayar bilimci John McCarthy’den (1927-2011) gelmiştir:

Turing’in düşünme tanımının bir dezavantajı, tüm mümkün girdi uyarılarına karşı keyfi olarak seçilmiş cevaplar bütününe içeren bir makine tasarlanmasının prensipte ihtimal dahilinde olmasıdır... Böyle bir makine, bir anlamda, verilen her girdi durumuna (geçmiş de dahil) uygun cevap için adeta bir ‘sözlüğe’ bakar. Böyle bir makine, uygun bir sözlükle Turing’in tanımını pek tabii yerine getirir fakat bizim olağan sezgisel düşünme kavramımızı yansıtmaz (1956: v-vi).

Yıllar sonra benzeri bir eleştiriyi filozof John Searle yapar. Searle (1980), “Çin Odası” adını verdiği düşünce deneyinde düşünce kavramının makineler için kullanılamayacağını göstermeye çalışır. Buna göre, bilgisayarların (akıllı cihazların) yaptığı şey, Çince bilmeyen bir kişinin kapalı bir odada kendisine uzatılan soruları bir kural kitabına bakarak cevaplamasına benzetilebilir. Kişi Çinceye ilişkin hiçbir şey bilmemesine ve anlamamasına karşın belli yönergeleri takip ederek sorulara cevap verebilmekte, bir diyalogu yürütebilmektedir. Aynı şekilde bir bilgisayar da sahip olduğu programlarda içerilen talimatlara uymak koşuluyla kullanıcısının komutlarını yerine getirmekte ancak bu komutların ne işe yaradığını bilmemektedir. Searle’ün deyişiyle bilgisayar sadece sembolleri manipüle etmekte, insan zihni gibi anlam üretmemektedir. Bu itirazlar belki birinci dalga GOFAI sistemler için geçerli olabilir. Peki ya ikinci dalga öğrenen makineler için de aynı şeyi söyleyebilir miyiz? Ne de olsa onlar birinci dönem yapay zekâ sistemleri gibi kural temelli değildirler. Başka bir deyişle, komutları/girdileri bir “sözlüğe” veya “kural kitabına” bakarak işlememekte, fakat bunları istatistiksel modellemelere tabi tutarak önceden tayin edilmemiş sonuçlar üretebilmektedirler. Beklenen atılım gerçekleşirse ve kendimizi ikinci dalganın sınırlılıklarını aşan (örneğin herhangi bir nesneyi tanımlamakla kalmayıp neden öyle tanımladığını açıklayan veya herhangi bir alanda öğrendiği bilgiyi başka bir alana uygulayarak soyutlama yapan) üçüncü dalga sistemlerinin içinde bulursak bu sistemlerin de yine düşünmediklerini, bir zekâyâ sahip olmadıklarını söyleyecek miyiz? Doğal ve yapay zekâ arasında radikal bir farklılık var mıdır?

3. Yapay Zekâ ve Bilinç

Her ne kadar yapay zekâ çalışmaları bu amaçla yürütülmüyor olmasa da şu ana kadar Turing testini geçen bir makine olmadı. Shannon, McCarthy ve Searle gibi düşünen yazarlar için test geçilse dahi bunun bir önemi olmazdı. Zira makine bize düşünüyormuş gibi görünür, fakat *gerçekte* düşünmüyor olurdu.⁵ Bu görünüş-gerçeklik ayrımının yapay zekâ hakkındaki felsefi mülahazaların temelinde yer aldığını söyleyebiliriz. Davranışçılar açısından bu ayrımın meşru olmadığını gördük. Bununla birlikte, davranışçıları bütünüyle haklı görmemizi, dolayısıyla sadece görünüşe dayanarak insanı da bir makine ilan etmemizi engelleyecek bir husus vardır: Makineyi yapan insandır, insanı yaparsa milyonlarca yıllık evrim sürecidir. İster kural temelli olsun ister istatistiksel modellemelere dayansın, isterse üçüncü dalga yeni bir yaklaşımın ürünü olsun, yapay zekâ teknolojilerinin en nihayetinde ne kadar zarif ve karmaşık olsa dahi birtakım algoritmalara dayandığını biliyoruz. Buna karşın insan zihninin algoritmik olup olmadığını veya ne ölçüde algoritmik olduğunu bilmiyoruz. Nörobiyolojiyi önemseyen yapay zekâ uzmanları GYZ hedefinde beynin özünde algoritmalara dayanan bir sistem olduğu varsayımıyla hareket ediyorlar ve içerdiği gizli algoritmaların keşfedildiği takdirde insanı

⁵ Bu yorumu yaparken Shannon ve McCarthy’nin yapay zekâ hakkındaki genel düşüncelerini değil, Turing’e verdikleri cevabı dikkate alıyoruz.

makinelere yolunun açılacağını düşünüyorlar. Ne var ki bu girişimin veya projenin sonuç verememe ihtimali vardır. Nitekim Turing’in bahsettiği informel bilgi problemini gündeme getiren, evrimin bizlere bahsettiği içgüdüsel/sezgisel davranış biçimleri ile dünyayla etkileşimimizden ve öznel deneyimlerimizden doğan sağduyusal bilginin bir hesaplama meselesi olmadığını, zekânın GYZ’ye giden yolda anlaşılması gereken bu yönü için bir algoritmanın tasavvur edilemediğini ve mevcut yaklaşımlarla yakın zamanda da edilemeyeceğini bildiren görüşler ileri sürülmüştür (Dreyfus, 1992; Smith, 2019; Roitblat, 2020; Larson, 2021). Zekânın tam olarak ne olduğu veya neleri kapsadığı kendi başına bir problem olmakla birlikte (Cycleback, 2018: 19-20) en azından bilgi ve yeteneğin problemlerin çözümünde veya bir amaca ulaşılmasında efektif bir şekilde kullanılmasını, zorluklar karşısında doğru ve yerinde kararlar alabilme becerisini içerdiğini söyleyebiliriz (Lee, 2020). Makine zekâsının günümüzdeki zayıf versiyonundan güçlü versiyona taşınması spesifik problem çözümlerinin genel problem çözümlere dönüştürülmesi veya yerini onlara bırakması anlamına geldiğinden ve sezgisel-sağduyusal davranışın insanlar gibi genel problem çözümlerinin temel bir özelliği olmasından ötürü buna ilişkin bilginin olası GYZ sistemlerine entegre edilmesinin bir yolunun bulunması gerekmektedir gibidir. Sezgisel davranış evrimsel geçmişe dayanmaktadır. Dolayısıyla sezgisel bilgi için girişilecek algoritma arayışı evrimsel süreçte aktarılan genetik enformasyonun ve bu enformasyona ihtiyaç duyan yaşamın algoritmik olduğunu imleyecektir. Diğer taraftan sağduyusal davranış büyük ölçüde öznenin dünyayı deneyimlemesine bağlıdır. O halde bir makineye sağduyu kazandırmak için ona bir beden vererek dünyaya yerleştirmeli, çevresiyle etkileşerek öğrenmesine, inançlar oluşturmaya ve çeşitli bilişsel beceriler edinmesine imkân tanımalıyız.⁶ Bu noktada yapay zekâ-bilinç ilişkisini irdelemek gerekmektedir. Zira bilincin kendi zekâlarını geliştiren sistemlerin ayrılmaz bir parçası olduğu iddia edilebilir (Henning, 2021). Basitçe söylersek, insan büyüme sürecinde bir zihin geliştirir, bilinç ve zekâ ise bütüncül bir fenomen olarak karşımıza çıkan bu zihnin tamamlayıcı unsurlarıdır. Bilinçli olmayan zeki bir insan görmediğimiz gibi zekâyâ sahip olmayan bilinçli bir insan da görmüyoruz. Bunun yanında bilinç insanın dünyaya açılan kapısıdır. Bilincin yokluğunda dünyanın deneyimlenmesi de mümkün olmazdı. Buna göre zekânın bilinç ile hiçbir ilgisi olmadığını ileri süren birinin öznel deneyimin kişinin bilişsel gelişimine hiçbir katkısı olmadığını savunması gerekecektir ki bu da çoğu kimsenin üstlenmek isteyeceği bir görev değildir. Nitekim bir bebeğin gelişimini izlemek bile bu iddianın aksi yönünde güçlü kanıtlar sunmaktadır.

Elbette davranışçı bir pozisyon almayı sürdürerek makine-insan benzetmesini yapısal değil davranışsal ve işlevsel olarak düşünebiliriz. Buna göre insan zihninin algoritmik olup olmaması GYZ hedefinde bir değişiklik yaratmayacaktır. İnsanın sahip olduğu düzeyde bilişsel bir kapasiteye sahip olduğunu gösterir davranışlar sergileyen yapay zekâ sistemleri oluşturabildiğimiz takdirde hedefimize ulaşmışız demektir. Ancak bu durumda dahi bilinci dikkate almak zorunda olabiliriz. Çin Odası’na tekrar dönelim. Odadaki kişiye diyalogu yürütmesine karşın düşünce atfedemiyor oluşumuzun sebebi, diyalogun öğelerine (kelimeler,

⁶ Bu yaklaşım yapay zekâ felsefesinde “yerleşik yapay zekâ (*situated ai*)” adıyla bilinmektedir (Brooks, 1995). Alan Turing sözünü ettiğimiz makalesinde bu yaklaşımı belli entelektüel aktivitelerde (örneğin, satranç oynama veya bilgi yarışması gibi) uzmanlaşmaya yoğunlaşan geleneksel yapay zekâ yaklaşımına bir alternatif olarak sunmuş ve yapay zekânın gelişiminin “bir çocuğun öğrenme sürecini takip edebileceğini” önermiştir (1950: 460).

cümleler, deyimler, ifadeler, vs.) ilişkin hiçbir şey anlamamasıydı. Anlama edimi düşünce sürecinin *farkında olmayı* gerektirir ve bir şeyin farkında olmak o şeyin bilincinde olmak demektir. Başka bir deyişle, farkındalık için bilinç elzemdir. Eğer anlama zekânın belirteçlerinden biri olarak görülürse, bilinçsiz bir makinenin GYZ’ye erişebilmesi beklenmez. Bir davranışçı bu argümana şöyle karşı çıkabilir: Bir insanın içsel halleri bize kapalı olduğu gibi makineninki de kapalıdır. Bundan dolayı makinenin *gerçekten* anlamasının, dolayısıyla bilinçli olmasının bir önemi yoktur. Anlıyormuş veya bilinçliymiş gibi görünmesi yeterlidir. Ünlü fütürist Ray Kurzweil son kitabında (2012) bu noktayı şöyle dile getiriyor: “Biyolojik olmayan antiteler, duygusal tepkilerinde tamamıyla ikna edici olurlarsa onları bilinçli kişiler olarak kabul edeceğim ve öngörüm toplumda da bu yönde bir uzlaşma oluşacağı şeklindedir.” Kurzweil haklı olabilir ancak bunun gerçekleşmesi için onun da dediği gibi makineler “tamamıyla ikna edici” olmalıdır. Fakat makinenin hiçbir şey hissetmeksizin nasıl *tamamıyla* ikna edici olacağı belirsizdir. Hisleri taklit etmenin tek yolu ise yine bilinçli olmaktan geçmektedir. O halde bilince sahip olmayan bir makinenin bizleri tamamıyla ikna edecek şekilde bilinçliymiş gibi görünmesi için bilinçlenmesi gerekecektir! Bilinç, sahtesi yapılabilecek en son fenomendir ve eğer zekânın varlığı bir şekilde bilinci gerektiriyorsa bilinçli makineler yaratmadan gerçek bir yapay zekâyı elde etme hayalimiz gerçekleşmeyebilir.

4. Sonuç

Geniş bir perspektiften ele alındığında yapay zekânın geliştirilmesine yönelik iki ana yaklaşımdan bahsetmek mümkündür. Halihazırda uygulamalarını gördüğümüz geleneksel yaklaşım beynin zekâyâ nasıl sahip olabildiğiyle pek fazla ilgilenmeden problem çözme kabiliyetleri gittikçe artan ve belli alanlarda zeki davranışlar sergileyen derinlikli algoritmalar yaratmayı istiyor. Ancak bu algoritmaların genel yapay zekâyı verecek algoritma veya algoritmalara nasıl evrileceği konusu açıklığa kavuşturulmuş değildir. Öte yandan alternatif yaklaşım insan beyninin zekâ üretimini ciddiye alıyor ve insanın edindiği yaşam deneyimlerinin genel zekâyâ erişmesinde kilit bir öneme sahip olduğunu düşünerek GYZ için benzeri bir süreci yapay zekâ sistemlerinin de geçirmesi gerektiğini ileri sürüyor. Ne var ki, tüm yönleriyle zekânın gelişimi göz önüne alındığında insanın evrimsel geçmişi bu sürecin dışında bırakılmayacağından alternatif yaklaşım canlılığın başlangıcına gidip yaşamın ilk algoritmalarını deşifre etmek gibi bir güçlük yüzleşmek zorunda kalabilir. Her iki yaklaşım için de bilinç bir sorun teşkil etmekte gibidir. İnsan söz konusu olduğunda yaşam deneyimi onun bilinçli olmasıyla doğrudan ilgilidir. Bir makinenin de belki duyumsadığını, algıladığını ve düşündüğünü söyleyebiliriz ancak makine bunları insanın aksine belli bir farkındalıkla gerçekleştirmediği için onun *gerçekten* bunlara sahip olduğuna inanmakta güçlük çekebiliriz. Yine de makinenin bilinçle iç içe geçmiş gerçek bir zekâyâ sahip olmasa da bizi sahip olduğuna tamamıyla ikna edebilme olasılığı vardır. Ancak hissetmenin (ister insan eliyle isterse makine aracılığıyla) algoritmasını yazmanın bir yolu bulunmadığı müddetçe bu olasılık son derece düşük görünmektedir. Eğer umulmayan gerçekleşir de makineler bir şekilde bizi kandırmayı başarırlarsa zaten görünüş-gerçeklik ayırımı anlamını yitirecek ve makine haklarını konuşmaya başlamış olacağız.

Referanslar

- Bostrom, N. (2006). “How Long Before Superintelligence?” *Linguistic and Philosophical Investigations*, 5(1): 11-30.
- Brooks, R. (1995). “Intelligence without Reason.” *The Artificial Life Route to Artificial Intelligence: Building Embodied, Situated Agents* içinde, Luc Steels ve Rodney Brooks (Der.), New Jersey: Lawrence Erlbaum Associates, s. 25-81.
- Cycleback, D. (2018). *Philosophy of Artificial Intelligence*. London: Bookboon.
- Dreyfus, H. L. (1992). *What Computers Still Can't Do: A Critique of Artificial Reason*. Cambridge: MIT Press.
- Goodfellow, I., Bengio, Y. ve Courville, A. (2016). *Deep Learning*. Cambridge: MIT Press.
- Haugeland, J. (1985). *Artificial Intelligence: The Very Idea*. Cambridge: MIT Press.
- Henning, K. (2021). *Gamechanger AI: How Artificial Intelligence is Transforming our World*. Cham: Springer.
- Kersting, K. (2020). “Rethinking Computer Science Through AI.” *KI – Künstliche Intelligenz*, 34: 435-437.
- Kurzweil, R. (2012). *How to Create a Mind: The Secret of Human Thought Revealed*. New York: Viking Penguin.
- Larson, E. J. (2021). *The Myth of Artificial Intelligence: Why Computers Can't Think the Way We Do*. Cambridge: Harvard University Press.
- Lee, D. (2020). *Birth of Intelligence: From RNA to Artificial Intelligence*. New York: Oxford University Press.
- Roitblat, H. L. (2020). *Algorithms Are Not Enough: Creating General Artificial Intelligence*. Cambridge: MIT Press.
- Sabouret, N. (2021). *Understanding Artificial Intelligence*. Boca Raton: CRC Press.
- Searle, J. (1980). “Minds, Brains and Programs.” *The Behavioral and Brain Sciences*, 3: 417-424.
- Shannon, C. ve McCarthy, J. (1956). “Preface.” *Automata Studies* içinde, Claude E. Shannon ve John McCarthy (Der.), Princeton: Princeton University Press, s. v-viii.
- Smith, B. C. (2019). *The Promise of Artificial Intelligence: Reckoning and Judgment*. Cambridge: MIT Press.
- Turing, A. M. (1950). “Computing Machinery and Intelligence.” *Mind*, 49: 433-460.
- Walsh, T. (2018). *Machines That Think: The Future of Artificial Intelligence*. New York: Prometheus Books.

S-06 YAPAY ZEKÂ ETKİSİNDE İÇ MİMARLIĞIN GELECEĞİ

Burcu YILDIRIM¹, Doç. Dr. Sibel DEMİRARSLAN²

¹ İç Mimarlık Anasanat Dalı, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Türkiye,
burcuyldrm3@hotmail.com

² İnşaat Bölümü İnşaat Teknolojisi Programı, Kocaeli Üniversitesi Kocaeli Meslek Yüksek
Okulu, Türkiye, sdarslan@kocaeli.edu.tr

Özet

Yakın geçmişte, endüstriyel devrimlerin gelişimi üssel bir biçimde meydana gelen teknolojik ilerlemeler ve yenilikler getirmiştir. Bunun bir sonucu olarak, son yıllarda insan yaşantısına farkına bile varılmadan adapte olan yeni araç ve sistemler ortaya çıkmıştır. Bu araç ve sistemlerin tasarlanması, üretimi, kullanılması ve denetlenmesi gibi gereklilikler farklı meslek disiplinlerinin meydana gelmesine yol açmıştır. Diğer taraftan, halihazırda var olan meslekler geliştirilen teknolojilerin etkisi altında kalmış ve bu teknolojileri kendi disiplinler süreçlerine entegre etme yoluna gitmişlerdir. İç mimarlık da bu meslek kollarından biridir. Teknoloji etkisiyle geliştirilen yeni tasarım araç ve yöntemlerinin yanında, teknolojilerin önerdiği yeni üretim biçimleri iç mimarlık disiplininin işleyiş sürecinde değişikliklere yol açmıştır. Bahsi geçen teknolojilerle üretilen ürünlere artan toplumsal talep doğrultusunda meslek, zanaat ağırlıklı bir üretimden teknoloji ağırlıklı bir üretime yönelmiştir. İçinde bulunduğumuz süreçte ise meydana gelen teknolojik gelişmeler ağırlıklı olarak yapay zekâ alanına işaret etmektedir. İnsan zekâsı aracılığıyla gerçekleştirilen çeşitli bilişsel işlerin yapay bir sistem aracılığıyla gerçekleştirilmesi gayesi olarak nitelendirilebilecek yapay zekâ alanı, tıpkı sanayi devrimlerinde olduğu gibi yeni meslek kolları yaratmasının yanı sıra var olan meslek kollarını da etkisi altına almış ve değişime uğratmıştır. Bu değişimlerin iç mimarlık disiplini çerçevesinde incelenmesinin amaçlandığı çalışmada karma yöntem yaklaşımından faydalanılmaktadır. Araştırma, yapay zekânın disipline güncel etkilerini tespit etme, mesleğe sunduğu faydalar doğrultusunda iç mimarlıkta etkin kullanımına dair bir yöntem önerisi meydana getirme ve çalışmalardan elde edilen bulgular doğrultusunda yapay zekâ-iç mimarlık ilişkisine dair gelecek öngörülerinde bulunabilme gayesindedir. Çalışmanın yapay zekâ-iç mimarlık ilişkisini araştıran araştırmacılar için kaynak teşkil etmesi hedeflenmektedir.

Anahtar Sözcükler: Yapay zekâ; iç mimarlık; teknoloji; dijital tasarım; dijital üretim.

Abstract

Recently, the development of industrial revolutions has brought technological advancements and innovations that exponential occur. As a result of this, new devices and systems that adapt to human life are without notice have emerged in recent years. Requirements such as design, production, use and control of these devices and systems brought about different professions. On the other hand, existing professions were under the influence of developed technologies and started to integrate these technologies into their disciplinary processes. Interior architecture is one of these professions. In addition to the new design devices and methods that develop under the influence of technology, new production methods are proposed by these technologies led to changes in the function of the interior architecture discipline. Due

to the increasing social demand for the products is created using these technologies, the profession has been shifted from craft-based production to technology-based production. Lately, technological developments mainly have indicated the artificial intelligence field. The field of artificial intelligence that can be defined as the purpose of realizing various cognitive functions of human intelligence through an artificial system has been influenced and changed the existing professions just as industrial revolutions created new professions. The study, which aims to examine these changes within the framework of the discipline of interior architecture uses the mixed-method approach. The aim of the study, to determine the current effects of artificial intelligence on the discipline, to propose a method for its effective use in interior architecture within the scope of the utilities it offers to the profession, and through the findings to make future predictions about the relationship between artificial intelligence and interior architecture. This study presents a written resource for researchers investigating the relationship between artificial intelligence-interior architecture.

Keywords: Artificial intelligence; interior architecture; technology; digital design; digital production.

1. Giriş

“İlkel toplumlarda her birey, diğer üyelere eşdeğerdir. Yani bir bakıma ihtiyaç duyulan her konuda yeterlidirler. Ancak standartlar yükseldikçe herkesin hemen her şeyi öğrenmesi olasılığı ortadan kalkmıştır” [1, s. 135]. İnsanlığın çeşitli alanlarda bilimsel ve pratik yollarla elde ettikleri bilgi birikimi arttıkça bu durumun bir getirisi olarak meslek kolları ve uzmanlaşma alanları ortaya çıkmıştır. Bilgi artışı ve mesleki uzmanlaşma arasındaki doğrudan ilişki günümüzde halen geçerliliğini korumaktadır. Elde edilen her yeni bilgi ve bulgu; yeni bilim dalları, çalışma alanları ve meslek disiplinleri meydana getirmektedir. Yapay zekâ da bu disiplinlerden biridir.

Genel bir tanımlamayla ifade edilecek olursa yapay zekâ: “Doğal sistemlerin yapabildiği (zekice olsun veya olmasın) her bilişsel etkinliği (gerekirse bedenleri olan) yapay sistemlere, daha da yüksek başarımlı düzeylerinde nasıl yaptırabileceğimizi inceleyen bilim dalıdır” [2, s. 83]. Başlangıçta insanın bilişsel etkinliklerini yerine getirme amacı taşıyan bu bilim dalı günümüzde; ruh, duyarlılık ve duygusallık gibi insana atfedilen kavramlarla birlikte anılmaya başlamıştır. Bu nedenle yapay zekânın amacı, kapsam ve sınırlılıkları bugün sıklıkla çeşitli bilim çevrelerince ve araştırmacılarca sorgulanmaktadır. Cevaplar teorik ve uygulamalı yöntemlerle aranmaktadır. Diğer taraftan yapay zekânın mevcuttaki meslek kollarıyla etkileşim düzeyi her geçen gün artış göstermeye devam etmektedir. Bu mesleki disiplinlerden biri de iç mimarlıktır.

Ünlü mimar Louis Kahn: “Mimarlık, mekânı düşüncede yaratmaktır” [3, s. 8] demiştir. Buradan anlaşılmaktadır ki mekân tasarımı işi zihinsel bir etkinliktir. İç mimarlık özeline gelindiğinde ise; disiplinin nesnel bilgiye dayalı çeşitli iş kalemleri ve süreçleri olduğu bilinmekle birlikte oldukça öznel, tasarlama sürecinin duygularını, düşüncelerini temel alan taraflar içerdiğini de ifade etmek gerekmektedir. Örneğin disiplinin tasarım süreci ele alındığında “Tasarlama süreci ve tasarım için her tasarımcının kendine özgü bir yöntemi bulunabilir. Ancak, gözden kaçmaması

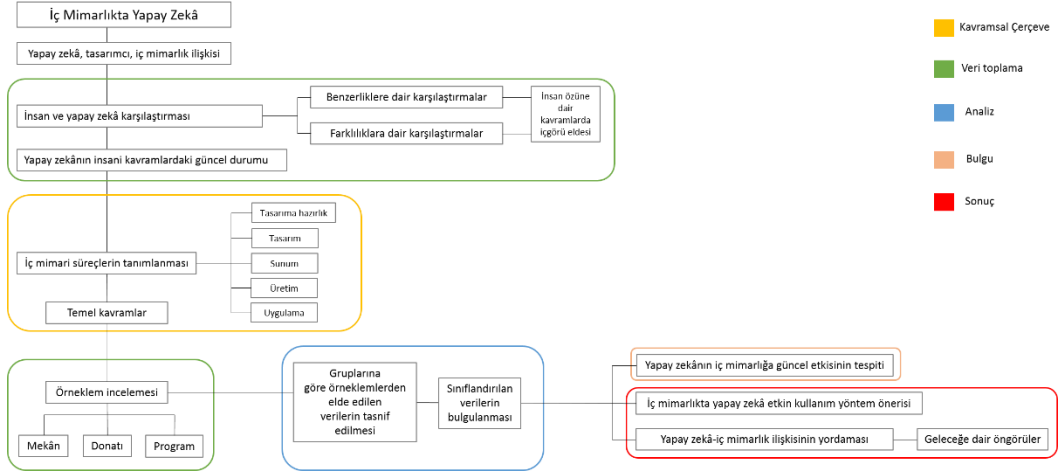
gereken, tasarım yöntemlerinin çokluğuna ve çeşitliliğine rağmen, tasarımın duygu ile düşünceyi birleştirmeye çalışması ve ürüne dönüştürmesidir” [4, s. 54]. Günümüz tasarım nesnesinin değeri ki bu nesne ister bir obje olsun ister bir mekân veya yapı, bu duygu ve düşünceyi birleştirme işlevi ile ölçülmektedir. Yapay zekâ ve iç mimarlık arasındaki ayrım bu noktada başlamaktadır. Bu nedenle de nesnel görevleri insanlardan çok daha başarılı bir biçimde yerine getirebilen yapay zekânın; iç mimarlık disiplininin hangi süreçlerine fayda sağladığı, hangi süreçlerinde yetersiz kaldığı, disiplini nasıl etkilediği, sahada ne derece karşılık bulduğu merak konusudur.

2. Amaç

İç mimarlık: “İnsanların gereksinimlerini karşılamak amacıyla belirlenmiş mekânları pratik, estetik ve sembolik işlev açılarından ele alan, insanların fiziksel ve ruhsal özellikleri ve eylemlerine uygun olarak mekânları biçimlendiren bir meslek alanıdır” [5, s. 95]. Yapay zekâ sistem ve tekniklerinin iç mimarlık alanında günümüzdeki kullanımları incelendiğinde, birçoğunun disiplinin uygulamalı alanlarında karşılık bulduğu gözlemlenmektedir. İç mimarlık ve yapay zekâ arasında kurulan bu ortaklığın; tasarımcıya, kullanıcıya ve uygulayıcıya iç mimari hizmet sürecinde sunduğu avantajlar dolayısıyla yapay zekâ teknolojilerinin mevcut disiplinler sürece entegre edilmesi ve yapay zekâ sistemleriyle “iç mimarlığı” tasarlamak günümüz tasarımcılarının gündemindedir. Alanda çalışan araştırmacıların temel amacı; yapay zekâ yardımı ile daha işlevsel, kullanıcı ihtiyaçlarına göre optimize edilmiş, kullanıcıyı tanıyan, sınıflandıran ve anlayan bir süreç organize etmektir. Bu bağlamda çalışmanın sorunsalı; yapay zekânın iç mimarlığa güncel etkilerinin değerlendirilmesi yoluyla mesleğe dair bir gelecek öngörüsü tablosu çizmek, meslekte yapay zekânın etkin kullanımına dair bir yöntem önerisi geliştirebilmek ve yapay zekâ-iç mimarlık ilişkisinin yakın ve uzak geleceğine dair öngörülerde bulunabilmektir.

3. Materyal ve Yöntem

Sorunsalı farklı boyutlarıyla ele alabilmek adına çalışmada karma yöntemden faydalanılmaktadır. Karma yöntem: “Araştırmacının, araştırma problemlerini anlamak için hem nicel veriler (kapalı uçlu) hem de nitel veriler (açık uçlu) topladığı, iki veri setini birbiriyle bütünleştirdiği ve daha sonra bu iki veri setini bütünleştirmenin avantajlarını kullanarak sonuçlar çıkardığı” [6, s. 2] araştırma biçimidir. Karma yöntemin birleştirme (çeşitleme) deseninden faydalanılarak çalışmanın araştırma deseni meydana getirilmiştir (Şekil 1).



Şekil 1. Araştırma Deseni.

Araştırmada iç mimarlıkta yapay zekâ konusu: yapay zekâ, tasarımcı, iç mimarlık ilişkisi kapsamında değerlendirilmektedir. Bu amaçla insan ve yapay zekâ arasındaki benzerlikler ve farklılıklar literatür araştırması aracılığıyla benzerliklere dair karşılaştırmalar ve farklılıklara dair karşılaştırmalar olarak iki ayrı sınıfta ele alınmaktadır. Bu karşılaştırmalardan elde edilen bulgular aracılığıyla yapay zekâ-insan ayrımını oluşturacağı düşünülen insan özüne dair kavramlara yönelik bir içgörü elde etmek ve yapay zekânın insani kavramlardaki güncel durumunu tespit etmek hedeflenmektedir. Bir sonraki adımda iç mimari süreçler: tasarıma hazırlık, tasarım, sunum, üretim ve uygulama alt başlıklarında ifade edilmekte ve yapay zekâ-iç mimarlık ilişkisine ait konu ve temel kavramlar tanımlanmaktadır. Bu yolla çalışmanın kavramsal çerçevesi elde edilmektedir. Kavramsal çerçeve aracılığıyla mekân, donatı ve program alt başlıklarında örneklem incelemeleri gerçekleştirilmektedir. Örneklemden elde edilen veriler sınıflandırılarak bulgulanmaktadır. Elde edilen bulgularla yapay zekânın iç mimarlığa güncel etkisinin tespiti, iç mimarlıkta güncel olarak yapay zekânın etkin kullanılabilmesine dair yöntem önerisi eldesi ve yapay zekâ iç mimarlık ilişkisinin yordaması gerçekleştirilerek bu ilişkinin yakın ve uzak gelecekteki durumu için öngörüler ifade edilmektedir.

4. Bulgular

Yapay zekânın iç mimarlıkta etkin kullanımına dair yöntem önerisi senaryosunda, iç mimarın hizmet sunduğu her işveren/proje verilerine dair meta verilerin ve verilerin analizi yoluyla elde edilecek veri setleri sistem altyapısını besleyecek ve yeni kullanıcılar için daha kısa sürelerde daha doğru tasarımsal tahmin ve öneriler gerçekleştirebilecektir. Böylelikle daha doğru ve memnuniyet düzeyi yüksek iç mimari hizmet sunumu yapay zekâ kullanımıyla mümkün hale gelecektir. Projeler ve kullanıcı kitlelerine dair bilgileri analiz ederek anlamlı biçimlerde sınıflandıran yapay zekâ varlığının hizmet sürecini hızlandırarak iç mimar için disiplinin yaratıcılık gerektiren kısımlarına daha fazla zaman yaratacağı öngörülmektedir.

Yapay zekânın disiplin içerisindeki rolü yalnızca tasarım iyileştirici bir unsur olmak değildir. Yapay zekâ mekânın tasarlanma ve üretim aşamalarında rol alabileceği gibi, tasarlanan

mekânın içerisinde mekânın bir unsuru olarak da yer alabilir. Bu noktada yapay zekâ içeren mekânların gündelik hayata entegrasyonu için gerekli teknolojik altyapının mekân içerisinde bulunması gerekliliği ortaya çıkmaktadır. Bu durum konut bazında ele alınacak olunursa; nasıl ki gelişen teknoloji elektrik tesisatı, internet altyapısı, su tesisatı gibi unsurları konutların vazgeçilmez gereklilikleri haline getirdiyse, yapay zekâ kullanımı ile ilgili sistemler de bu unsurlar arasına girmeye başlamıştır. Bu noktada paydaş meslek olarak mimarlık disiplininin yapı tasarımında bu altyapısal gerekliliği göz önünde bulundurması beklenmektedir. Böylece iç mimar bu altyapıya sahip mekânlarda yapay zekâ içeren mekân kurguları gerçekleştirebilecektir. Aksi takdirde yapay zekâ kullanımı aracılığıyla disiplinin tasarım sürecinde kazanılan zaman, üretim ve uygulama süreçlerinde kaybedilecektir.

Yapay zekâ olgusu sıklıkla insan işgücüne dair bir risk altında olma durumu ile bağdaştırılmaktadır. Fakat düşünülenin aksine yapay zekâ mesleklere farklı profesyonel açılımlar sağlama potansiyeline sahiptir. Yapay zekânın dâhil olduğu meslek disiplinlerinde, yapay zekâ donanımına sahip cihazların mesleki yeterlilik sahibi kişilerce komuta edilmesi gerekliliği bu duruma örnek olarak verilebilir.

5. Sonuçlar ve Öneriler

İnsanlık eski çağlardan günümüze değin uyum sağlama yeteneği ile hayatta kalabilmiş ve yaşamını sürdürebilmiştir. Değişen iklim koşullarına, gıda problemlerine, yırtıcı hayvan saldırılarına karşı çözüm üretebilen nesillerin kültürleri kuşaktan kuşağa aktarılmıştır. Yerleşik hayata geçilmesiyle birlikte insanın doğaya karşı savaşı sona ererken baş edilmesi gereken başka problemler ortaya çıkmıştır. Günümüzde ise insanlık geliştirmekte olan teknolojileri, özellikle sürekli kendisi ile karşılaştırılan ve yarıştıran yapay zekâyı bir tehdit olarak algılamaktadır. Fakat bu hatalı bir tutumdur. Özellikle insanlığın doğaya verdiği zararın boyutlarının tüm dünyada oldukça sert bir biçimde hissedilmeye başladığı bugünlerde fonksiyonellik, sürdürülebilirlik, verimlilik, enerji etkin kullanımı gibi konseptler ön plana çıkmaktadır. İnsanlık bu durumda nesnel hesaplama ve görevleri kendisinden çok daha üstün bir biçimde yerine getirebilen yapay zekânın yaşama dair her alanda faydalarının ayırdaında olmak durumundadır.

Yapay zekâ uygulamaları, kişiselleştirilmiş hizmet alanına vurgu yapmaktadır. Bu durum iç mimarlık disiplininin de temel gayelerinden biridir. Yapay zekânın günümüzdeki gelişimi izlendiğinde, gelişen teknoloji ile kullanıcının talep ve ihtiyaçlarını doğru bir biçimde analiz eden yapay zekâ uygulamalarının zamanla geliştirilebileceği öngörülebilmektedir. Böylelikle iç mekân tasarımı süreci iletişim hususunda gelişim gösterebilecektir. Bunun yanında böyle bir sistem için yapay zekâ aracılığı ile sosyal medya paylaşımları ve beğenilerinin incelenerek tasarıma dair müşteri/kullanıcı kişiliğinin analiz edilmesi, buna dair bir profil oluşturulması (dijital ayak izlerinin takibi) mesleğe yeni açılımlar sağlanmasına yol açacaktır. Diğer taraftan, yapay zekânın iç mimarlıkta kullanımı, yeni nesil kullanıcı profiline deneyimlemekten hoşnut kalacağı dijital temelli bir tasarım-danışmanlık hizmeti oluşturulabilmesine olanak vermesi anlamında da yapay zekânın disipline getireceği faydalardan biridir.

İç mimarlık hizmet sürecinde kullanılacak yapay zekâ sisteminin, sisteme kayıtlı müşterilerin data ve meta dataları aracılığıyla toplumların kültürel ve etik unsurlarına dair tasarım verilerini arşivlemesi ve bu bilgilerden yola çıkarak genel tasarım tercihlerini sınıflandırması mümkün olacaktır. Böylece iç mimarın tasarım sürecinde kullanıcıya dair erişmesi gereken bilgileri güncel tutan canlı bir sistem meydana gelmiş olacak ve sistem bu bilgilerden yola çıkarak tasarım sürecinin başlangıcında kullanıcı ile eşleşen tasarım önerilerinde bulunabilecektir.

İç mimarlık alanında yapay zekâ kullanımının müşteri ve iç mimar açısından memnuniyet sağlaması ve bu durumun da kalite ve güvenilirlik artışı olarak görülmesi sonucu getireceği avantajlar ortadadır. İç mimarlıkta yapay zekâ kullanımı, disiplin kapsamındaki işlerin ve hizmetlerin daha kontrollü, hızlı yani zaman verimli, doğru yorumlanmış, sıfır hata hedefli ve kalite kavramı dâhilinde başarı ile ele alınabilir nitelikte olmasını sağlayacaktır. Bu durumun bir sonucu olarak iç mimarlıkta yapay zekâ kullanımı mesleği destekleyecek, mesleğe duyulan saygının ve mesleki disiplinin daha ileriye götürülmesine olanak sağlayacaktır.

Referanslar

- [1] E. M. Esin, “Yapay Zekânın Sosyal ve Teknik Temelleri,” içinde *Yapay Zekâ ve Gelecek*, G. Telli, Ed. İstanbul: Doğu Kitabevi, 2019, ss. 110-138.
- [2] C. Say, *50 Soruda Yapay Zekâ*, 9. baskı. İstanbul: Bilim ve Gelecek Kitaplığı, 2018.
- [3] M. Frederick, *Mimarlık Okulunda Öğrendiğim 101 Şey*, 2. baskı. İstanbul: YEM Yayın, 2009.
- [4] D. Demirarslan ve O. Demirarslan, *Tasarım ve Tasarım Süreci*, Ankara: İksad Yayınevi, 2020.
- [5] B. B. Kaptan, *Kültür ve İçmimarlık*, Ankara: Seçkin Yayıncılık, 2013.
- [6] J. W. Creswell, *Karma Yöntem Araştırmalarına Giriş*, 3. baskı. Ankara: Pegem Akademi, 2021.

S-14 ARTIFICIAL INTELLIGENCE APPLICATIONS IN RENEWABLE ENERGY

Füsun S. TUT HAKLIDIR

¹ İstanbul Bilgi University, Department of Energy Engineering Systems, Turkey,
fusun.tut@bilgi.edu.tr

Abstract

While investments in renewable energy systems are becoming widespread throughout the world, the importance of controlling greenhouse gas concentrations points to the importance of using clean energy production options every day. Although these clean energy options offer important solutions for a better world, the energy efficiency of most renewable energy systems is still not competitive with other energy sources and systems need to be improved. More effective use of artificial intelligence technologies in renewable energy systems is seen as a good solution to increase the efficiency of these systems.

This study focuses on revealing the benefits of using artificial intelligence technologies in different renewable energy systems.

Keywords: renewable energy, artificial intelligence, energy production, optimization, efficiency

1. Introduction

The world population has reached eight billion and the need for food, water and energy is increasing rapidly worldwide while energy needed is increasing more with the developing technology.

While energy demand increases fastly, the greenhouse gases such as CO₂, CH₄ which mainly develop due to the use of fossil fuels and cause global warming and sudden climate change, adversely affect the living conditions and lead humanity to use renewable energy sources more in the world.

Renewable energy sources such as; solar, wind, geothermal, hydro, biomass have been started to attractive after the first oil crisis in 1973 and the world has started to understand the importance of energy independence for future. These energy sources are called sustainable and their negative impact on environment much less than fossil fuels and require new technologies to increase energy efficiencies in these systems. Beside improvement of technical equipment, using energy storage and hybrid energy systems, prediction of electricity production, optimization and controlling of these systems are quite essential actions to increase energy efficiencies of renewable energy systems. Because especially solar, wind and hydropower systems directly depend on meteorological conditions and these conditions directly reduce the capacity factors of the energy systems.

Artificial intelligence (AI) technologies have been used at different industries and also started to use in energy systems in recent years. AI algorithms are mainly designed to take decisions using real-time data which are taken by different sensors in a system. All digital data or inputs combine with each other and analyze the data and provide prediction, optimization or an act in the system. The role of AI Technologies in the energy systems are varies but the main requirements are; power prediction, possible system/equipment failure prediction (predictive maintenance), controlling and optimising of energy systems and all these acts directly provide time and cost saving.

The study focused on showing the purposes for which artificial intelligence technologies are used in renewable energy systems.

2. The Status of Renewable Energy Power Plants and The Green Deal Act Effect

Renewable energy sources can be mainly used for electricity production, district heating and cooling purposes. Renewable energy power generation capacity reached to 2799 GWe at the end of the 2020¹ (Figure 1). Decarbonization goals of countries and renewable energy support mechanisms of governments keep to support new renewable energy capacities in the world. Based on the IEA, 2020 report²; renewable energy sector was the showing growth during the 2020 pandemic on the contrary other energy sectors.

Although it continues to grow, it still needs some technological developments in order to use renewable energy effectively. With new technological applications, energy supply is tried to be directed towards progress in harmony with each other according to the changing priorities in the World (Figure 2). Economic trends, decarbonization goals, renewable energy support mechanism of the countries directly affect the growing usage of renewable energy in the world³. New approaches such as; artificial intelligence technologies provide new opportunities to increase energy efficiency at these systems.




Figure 1. Renewable power capacity growth between 2016-2020¹

Beside all, 2050 European Green Deal Act has declared by the EU and the target is to be climate neutral Europe in 2050⁴. The act supports; environmentally- friendly technologies, innovative technologies, decarbonising the energy sector, energy efficient building and improve glonal environmental standarts of international partners of EU countries such as Turkey.

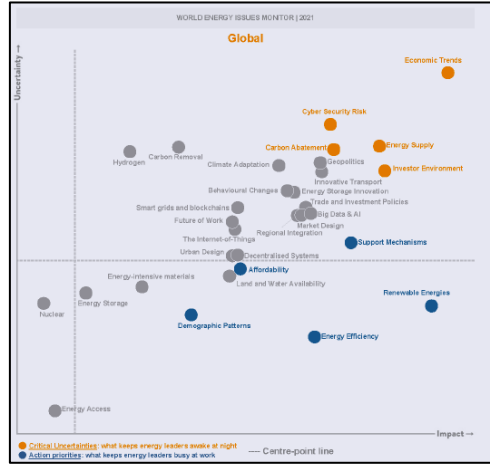


Figure 2. World Energy Issues Monitor 2021³

3. Renewable Energy Systems and Benefits of Using AI Technologies

The power industry is undergoing a major transformation with the increased usage of renewable energy such as, solar, wind, geothermal, hydro and biomass technologies and to increase the efficiencies of these energy systems, using AI technologies provide benefits to this sector.

AI based developments allow for a larger number of automatically controllable resources and minimize to an operator-based problems in energy sector. This can give permission unlocked by usage of big data in renewable energy area. AI based solutions can provide fast and intelligent decision making to increase grid flexibility and integration of variable renewable energy technologies and this will help to reach clean energy access all around the world. AI technologies can be used for energy efficiency, reliability, optimization of verified renewable energy (VRE) systems³ (Figure 3). This new approach also provides to use digital twin to remote controlling of the systems and give chance to operational costs of the power plants.

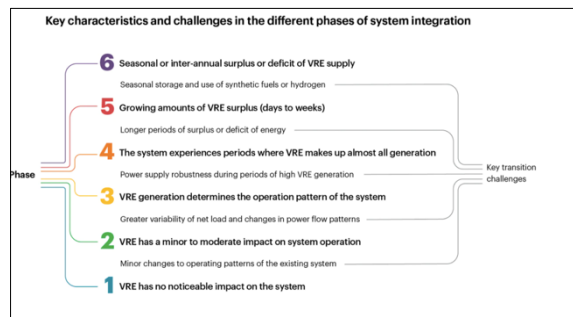


Figure 3. Key characteristics and challenges in the different phases of system integration²

3.1 Implementation of AI technologies in Renewable Energy Systems

Each renewable energy source has different characteristics and technical challenges has been changed based on the source.

Generally, AI technologies can also be used to maximize performance of renewable energy power plants with analyze data—region, system, slopes, humidity, irradiance, manufacturer—to recognize anomalies or issues that a human may not.

As an example, from solar power systems; AI technologies can be use in weather forecasting and for prediction of global solar radiation on horizontal surfaces. Large volumes of historical and real-time data from satellites and weather stations can be analyzed by machine learning techniques to recognize patterns and predict weather condition, solar inverter conditions that could impact solar production AI can be used for predictive maintenance purposes by machine learning algorithms to spot inconsistencies and determine when a panel or an inverter fails^{5,6,7}.

AI technologies can predict wind power production for hours and days ago in a site before actual power generation. Using AI technologies such as machine learning algorithms, provides possible to accurately evaluate the potential downtime of components. It gives chance to be part of a smart grid system⁵.

In geothermal power systems, AI approaches have been used in both underground and surface conditions at geothermal systems. Controlling of a geothermal well, reservoir modeling, reservoir temperature prediction, controlling of chemical inhibitor systems and optimization inhibitor dosages, well and production management in a geothermal field are some applications for underground^{8,9}. Predictive maintenance application is a good choice to check the system control overall in a geothermal power plant.

For bioenergy systems, optimum design of the supply chain, detection of unwanted component like H₂S gas, estimation of the methane concentration, performance estimation of biodiesel engine is some of the probable AI implementation areas.

Although hydroelectric systems provide the highest-level power among renewable energy sources, these systems have been affected by sudden climate change and drought and the energy balance has been sharply changed in the in most of country. Climate change and dryness prediction are quite two parameters to provide energy balance especially in summers and AI technologies give chance to understand the future perspective and take some precautions such

as installation of secondary energy system as hybrid like photovoltaic systems for hydropower systems.

Results and Recommendation

Some of renewable energy system' such as solar PV and wind capacity factors still change 25-40 %. Using new approaches such as AI in renewable energy will increase system efficiencies and provide more energy efficient system during the power generation. These technologies will also helpfully to predict energy production and energy demands in any case.

Using renewable energy more in the world, help to reduce carbon and methane emissions. It will positively affect to international trade due to some obligation in the European Green Deal Act.

References

- [1] IRENA, 2021. Renewable Capacity Highlights (31.03.2021); https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2021/Apr/IRENA_-_RE_Capacity_Highlights_2021.pdf?la=en&hash=1E133689564BC40C2392E85026F71A0D7A9C0B91
- [2] IEA 2020. Introduction to System Integration of Renewables; <https://www.iea.org/reports/introduction-to-system-integration-of-renewables?mode=overview>
- [3] World Energy Council, 2021. World Energy Issues Monitor. <https://www.worldenergy.org/publications/entry/world-energy-issues-monitor-2021-humanising-energy>
- [4] EU Green Deal Act; https://ec.europa.eu/info/strategy/priorities-2019-2024/european-green-deal_en
- [5] Jha, S.K., Bilalović, J., Jha, A., Patel, N., Zhang, H. 2017. Renewable energy: Present research and future scope of Artificial Intelligence. Renewable and Sustainable Energy Reviews 77: 297-317.
- [6] IRENA 2019. Artificial Intelligence and Big Data. <https://www.irena.org/publications/2019/Sep/Artificial-Intelligence-and-Big-Data>
- [7] Özenç M. and Uluhanşın O. 2021. Solar Power Production by Machine Learning. BSc. Thesis in Istanbul Bilgi University, Department of Energy Systems Engineering.

[8] Haklıdır Tut, F.S. 2020. The importance of long-term well management in geothermal power systems using fuzzy control: A.

Western Anatolia (Turkey) case study. *Energy*, 213:118817

[9] Haklıdır Tut, F.S., Haklıdır, M. 2019. Prediction of Reservoir Temperatures Using Hydrogeochemical Data, Western Anatolia

Geothermal Systems (Turkey): A Machine Learning Approach. *Natural Resources Research*, 1-14

S-58 DERİN ÖĞRENMEYE DAYALI İKİLİ KODLAR İLE VERİMLİ VE HIZLI İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİ

Enver AKBACAK

Mühendislik Fakültesi, Haliç Üniversitesi, Türkiye, enver.akbacak@gmail.com

Özet

İçerik tabanlı görüntü erişimi, görüntülerin sorgu olarak kullanılması ve sorguya en çok benzeyen görüntülerin bir veritabanından elde edilmesidir. Popülerliği giderek artmaktadır. Tıbbi görüntüleme arama motorlarına, güvenlikten elektronik ticarete kadar geniş kullanım alanları bulunmaktadır. Ancak anahtar kelimelerle arama yapmaya nazaran bir takım zorlukları bulunmaktadır. Çünkü görüntüler iki boyutlu uzaysal alanda yüksek miktarda veri taşırlar ve işlenmeleri güçlü bilgisayar işlemleri gerektirir. Bu da görüntüye erişim zamanının hızlı olmasını önemli bir hale getirmektedir. Diğer taraftan erişim doğruluğunun tatmin edilir bir seviyenin üzerinde olması da önemlidir. Görüntülerin ikili kod özellikleri ile gerçekleştirilen görüntü erişim metodları bilinen en hızlı metodlardır. Derin öğrenmeye dayalı olarak elde edilen ikili görüntü kodları ise bilinen en verimli yöntemlerden biridir. Bu çalışmada görüntülerin ikili kodlarını derin öğrenme tabanlı bir ağ ile elde eden orjinal bir yöntem sunulmuştur. Bu yüzden yöntem hem hızlıdır hem de verimlidir. Görüntü erişim metodlarının test edilmesinde kullanılan veri setlerinin çoğu tek etiketli görüntüleri barındırır. O yüzden çoğu çalışmanın başarımları yüksek değerlerle yayınlanır. Halbuki gerçek hayatta görüntülerin çoğu çoklu etiketlere sahiptir. Bu çalışmanın performansı, günlük hayattaki görüntüler gibi çok etiketli bir görüntü veri tabanı üzerinde test edilmiştir. Test için kullanılan görüntüler ise derin ağın eğitilmesinde kullanılan görüntülerin dışından ayrıca hazırlanmıştır. Yöntemin başarımları tatmin edici olup pratik uygulamalar için uygundur. Önerilen yöntemin tüm kaynak kodları internette herkese açıktır.

Anahtar Sözcükler: İçerik tabanlı görüntü erişimi; görüntü ikili kodları; derin öğrenme.

Abstract

In content-based image retrieval studies, images are used as a query. Then, images most resemble a query are retrieved. Recently it is become more popular and spread to many domains. It has broad usage fields from medical imaging to search engines, from defense applications to electronic commerce. However, it has some challenges compared to searching with keywords. Since images carry a high amount of data in two-dimensional spatial space, the processing of those data requires high computing costs. Thus, reducing the retrieval time becomes an important issue. In addition, it is also important the retrieval accuracy be over an acceptable level. Hashing-based methods are one of the best solutions for fast image retrieval. On the other hand, deep learning-based image retrieval methods are known to be the most efficient. In this study, an original deep learning-based image hashing method has been proposed. Thus, the method is both fast and efficient. Most of the image datasets used for evaluating content-based image retrieval studies are single-labeled.

Therefore, the performance evaluation of most studies is quite high. In real life, however, most images are inherently multilabel. The performance of this study has been tested on a multilabel image database. The test images have been prepared separately from outside the database and not included in the training phase. The method's performance is satisfactory and it is suitable for practical applications. All source codes of the proposed method are publicly available on the Internet.

Keywords: *Content-based image retrieval; image hashing; deep learning.*


1. Giriş

İçerik tabanlı görüntü erişim çalışmalarında, görüntüler sorgu olarak kullanılır ve veritabanından sorgu görüntüsünün içeriğine en çok benzeyen görüntüler elde edilirler. Kullanım alanı oldukça geniştir ve her geçen gün daha da popüler olmaktadır. Başta google gibi arama motorları olmak üzere bazı alışveriş sitelerinde bile kullanılmaya başlayan ve ingilizce adı “reverse image search” olarak bilinen görüntü erişim hizmetlerinin son kullanıcılara kadar gelmiş olması hız ve görüntü erişim verimliliğinde erişilen seviyeden kaynaklanmaktadır.

Görüntü erişiminin gerçekleştirilebilmesi için, görüntüleri temsil eden sayısal özniteliklerin çıkarılması gerekir. SIFT [1] ve HoG [2], yakın zamana kadar yaygın olarak kullanılan yöntemlerdir. Tamamen gerçek sayılardan oluşan tu tür özniteliklerin bazı dezavantajları bulunmaktadır. İlki, sorgu ile tüm veritabanı arasında benzerlik ölçütü olarak kullanılan Öklid veya herhangi bir mesafe metriği, veritabanı boyutunun büyük olması durumunda çok yoğun bir hesaplama yükü getirerek görüntü erişim zamanını arttırır. Diğerisi ise, özniteliklerin görüntü içeriğini temsil etmelerinde zaman zaman karşılaşılan yetersizliklerdir. Dahası bu özniteliklerin elde edilmesi görüntü erişim yönteminden bağımsızdır. Yani görüntü erişim yöntemlerinden önce ayrıca elde edilerek daha sonra giriş olarak kullanılmaları gerekir. Halbuki son yıllarda çeşitli derin öğrenme yöntemlerine dayalı görüntü erişim metodlarının diğer metodlara göre verimliliği pek çok çalışma ile kanıtlanmıştır [3-6]. Üstelik derin öğrenmeye dayalı metodlar görüntü özniteliklerini de aynı mimari üzerinde çıkarabilmektedirler. Diğer taraftan görüntü erişim zamanını önemli ölçüde azaltan görüntü ikili kodları son yıllarda oldukça popülerdir. Bu da gösteriyor ki derin öğrenme ve görüntü ikili kodları ile gerçekleştirilen metodlar hem hız hem de verimlilik bakımından üstündürler.

Bu çalışmada, görüntülerin ikili kodlarını derin bir ağ üzerinde elde eden orijinal bir yöntem önerilmiştir. Yöntem görüntü sınıflandırma mimarisi üzerine kuruludur. Elde edilen görüntü ikili kodları ile sorgu ve veritabanı öğeleri arasındaki benzerlik XOR işlemi ile oldukça hızlı bir şekilde elde edilmiştir. Yöntemin başarımı çok etiketli bir görüntü veri seti üzerinde test edilmiş ve başarılı sonuçlar elde edilmiştir. Bu çalışma ile ilgili tüm kaynak kodlar internette herkese açık olup başarımı test edilebilir ⁷.

7 <https://github.com/enverakacak/EIR>



Şekil 1. Önerilen yöntemin genel mimarisi.

2. Görüntü İkili Kodları

2.1. Temel bilgiler

Sorgu ile görüntü veritabanı arasındaki benzerlikleri elde etmek için gerçekleştirilen mesafe hesaplamaları yüksek bilgisayar hesaplaması gerektirir, özellikle büyük boyutlu görüntü veritabanlarında. Görüntü ikili kodları, diğer adıyla hash kodları, bu zorluğun üstesinden gelmek için en iyi çözümlerden biridir. Bu yöntemlerde, yüksek boyutlu ve sayısal olan görüntü öznitelikleri düşük boyutlu hash kodlara dönüştürülür. Dönüştürülen uzaya hash uzayı denir. Öznitelik uzayındaki benzerlikler, hash dönüşümünden sonra da korunmalıdır. Hash uzayındaki tipik bir benzerlik kriteri Hamming mesafesidir. Hamming mesafesi iki hash kod arasında bitsel XOR işlemi ile oldukça hızlı bir şekilde elde edilebilir. Böylece, görüntü erişim süresi önemli ölçüde azalır.

En basit hashing metodları görüntülerin ikili kodlarını elde ederken, görüntüleri birbirinden doğrusal yöntemlerle ayırt ederler. Halbuki görüntü sınıfları arasındaki bağımlılıklar genelde lineer olmadığı için bu tür yöntemler verimli değildirler. Derin öğrenmeye dayalı yöntemler sayesinde, aynı mimari üzerinde hem görüntü öznitelikleri hem de hash kodları lineer olmayan dönüşümlerle verimli bir şekilde elde edilirler.

2.2. Hashing tabanlı görüntü erişim yöntemi

Önerilen yöntem derin bir CNN tabanlı çok etiketli görüntü sınıflandırma mimarisi üzerine kurulmuştur. Yöntemin genel mimarisi Şekil-1’de sunulmuştur. Yöntemin giriş bloğu, ImageNet görüntü veriseti üzerinde eğitilmiş yüksek sınıflandırma başarımı olan EfficientNet-B0 ağıdır [4]. Bu ağın çıkışından elde edilen vektörler 1280 kanallı 7x7 boyutlu görüntü çerçeveleridir. Yani EfficientNet-B0’a giren her bir görüntü için 7x7x1280 boyutlu sayısal değerlerden oluşan bir vektör elde edilir. Bu öznitelikler Düzleştirme (Flatten) olarak bilinen katman ile tek boyutlu bir vektöre dönüştürülür. Boyutu oldukça yüksek olan bu vektör, birbiri ardısıra gelen iki Dense katmanından geçirilir. İlk Dense katmanının boyutu 2048 olup herhangi

bir aktivasyon fonksiyonuna sahip değildir. Yani bu katmanın görevi yüksek boyutlu olan görüntü özniteliklerinin boyutunu azaltmaktır. İkinci Dense katmanı ise öznitelik ve hash kodlarının üretildiği katmandır. Bu katmanın çıkış aktivasyon fonksiyonu hiperbolik tanjant'tır. Hiperbolik tanjant aslında sigmoid aktivasyonunun bir varyantıdır. Hiperbolik tanjant sayesinde bu katmanın çıkış değerleri 1 ile +1 arasında sınırlandırılır. Bu katmanın boyutunun seçimi (K) ise keyfidir. Eğer 64 adet çıkış olacak şekilde seçilirse, elde edilen görüntü hash kodları 64-Bit olarak elde edilecektir. Kullanacağımız görüntü veritabanı çok etiketli görüntülerden oluştuğu için, sınıflandırma katmanı üzerindeki maliyet fonksiyonu binary cross entropy olarak seçilmek durumundadır. Softmax sınıflandırma maliyet fonksiyonundan farklı olarak, sınıflandırma katmanı üzerindeki her bir çıkışın hata değeri birbirinden bağımsız olarak hesaplanır. Bu sayede bir görüntü birden fazla etikete sahip olabilir. Çok etiketli görüntüler için binary cross entropy maliyet fonksiyonu aşağıdaki gibi tanımlanır,

$$M_1(a, \bar{a}) = \frac{-1}{S} \sum_{i=1}^S [a_i \log \bar{a}_i + (1 - a_i) \log (1 - \bar{a}_i)],$$

(1)

bu denklemde a görüntülerin sınıflarını temsil eden vektörü, \bar{a} ise sınıflandırma katmanından elde edilen görüntü sınıflarının tahminleridir. S değeri veritabanındaki tekil görüntü sınıflarının sayısıdır. Bu maliyet fonksiyonu, tamamen veya kısmen aynı sınıflarda yer alan görüntülerin aynı veya benzer hash kodlara, birbiri ile tamamen farklı sınıflarda yer alan görüntülerinde farklı hash kodlara sahip olmalarını sağlar. Şekil 1'de ilk Dense katmanının N adet çıkışlarını $x \in R^N$ ile ifade edelim. ikinci Dense katmanının çıkış sayısı ise K olsun. Bu durumda her iki Dense katmanı arasındaki bağlantıları ifade eden ağırlık matrisi, $W \in R^{N \times K}$ boyutlu olur. Çıkış aktivasyon fonksiyonu tanjant hiperbolik olan ikinci Dense katmanından elde edilen görüntü öznitelikleri, $H = \tanh(Wx + b)$ olarak elde edilir. Bu denklemde b değeri, derin ağlarda ağırlık değerlerine ilave olarak eklenen ve adı bias olan reel bir vektördür, $b \in R^K$. İkinci Dense katmanından elde edilen görüntü öznitelikleri aşağıdaki denklem ile hash kodlara dönüştürülür.

$$B = H > 0.$$

(2)

Ancak görüntü özniteliklerinin ikili kodlara dönüştürülmesi bilgi kaybına neden olur. Bilgi kaybını verimli bir şekilde azaltmak için, sınıflandırma performansına hanel getirmeden ikinci Dense katmanında da bir maliyet fonksiyonu tanımladık. Bu sayede öznitelikler ve hash kodlar arasındaki entropi farkı en aza indirilir. Böylece elde edilen öznitelikler ya oldukça -1'e yakın olur ya da 1'e. Yani özniteliklerin sayısal ikili kodlara dönüştürülmesinden kaynaklı bilgi kaybı en aza indirilir. Bu maliyet fonksiyonunu da bir binary cross entropy olup aşağıdaki gibidir,

$$M_2(h, z) = \frac{-1}{K} \sum_{i=1}^K [h_i \log z_i + (1 - h_i) \log (1 - z_i)],$$

(3)

bu denklemde h ve z sırasıyla ikinci Dense katmanından elde edilen hash kodları ve öznitelikleri temsil eden vektörlerdir. Böylece önerilen derin ağ, eğitimi sırasında iki amaç

fonksiyonunu da en aza indirmeye çalışır. Toplam amaç fonksiyonu her iki amaç fonksiyonunun toplamı olarak aşağıdaki gibi elde edilir.

$$(4) \quad M = M_1 + M_2.$$

Entropi’ye dayalı maliyet fonksiyonlarının en büyük avantajı, karesel farklara dayalı maliyet fonksiyonlarında zaman zaman görülen fonksiyon türevinin tanımsız olduğu bölgelere sahip olmamalarıdır. Çünkü ağı eğitimi sırasında geri yayılım algoritması çalışırken, maliyeti azaltmak için, maliyet fonksiyonunun türevleri kullanılır. Entropy fonksiyonlarında kullanılan logaritmaların türevleri yine bir logaritma tabanlı olup süreklidirler. Lütfen unutulmasın, maliyet fonksiyonları sadece derin ağı eğitilmesi sırasında kullanılırlar. Ağ eğitilip parametreler sabitlendikten sonra Denklem 2’ye uygun olarak nihai hash kodlar elde edilirler.

Önerilen yöntem Keras derin öğrenme kütüphanesi ve python3 kullanılarak gerçekleştirilmiştir. Derin ağ, *sgd* optimizasyonu kullanılarak 50 adımda eğitilmiştir. Eğitim, ikinci Dense katmanının 16,32 ve 64 tane çıkış durumu için tekrarlanmış ve eğitimden sonra bu katmandan elde edilen öznitelikler Denklem (2)’ye uygun olarak 16,32 ve 64 bit hash kodlara dönüştürülmüşlerdir.

3. Deneyler

3.1. Performans ölçütleri

Kesinlik (p), ortalama kesinlik (ap) ve genel ortalama kesinlik (map) ölçütleri kullanılmıştır. Erişilen bir görüntü, sorgu ile tamamen aynı sınıfa/sınıflara üye ise gerçek pozitif (tp), değilse yanlış negatif (fn) olarak değerlendirilir. Sorgu sonucu k tane görüntü’ye erişildiğini varsayalım. Bu durumda p skoru aşağıdaki gibi,

$$(5) \quad p@k = \frac{tp@k}{tp@k+fp@k}$$

ap skoru ise aşağıdaki gibi elde edilir,

$$(6) \quad ap@k = \frac{1}{R_k} \sum_{s=1}^k p_s \alpha_s ,$$

bu denklemde R_k erişilen görüntüler içerisinde sorgu ile aynı sınıfta olan görüntülerin sayısı, α ise, erişilen görüntü sorgu ile aynı etiketli ise 1, değilse 0 olan bir faktördür. Erişim performansının eldesinde bir sorgu grubu kullanılır. *map* skoru, birbiri ardısıra gerçekleştirilen sorgular (q) ile elde edilem *ap* skorlarının ortalamasıdır. Yani,

$$map@k = \frac{1}{q} \sum_{i=1}^q ap_i ,$$

(7)

3.2. Deney sonuçları

Bu çalışmanın performansını irdelemek için, Lamda görüntü veritabanı kullanılmıştır⁸. Test sorguları ise google arama motorundan ayrıca elde edilmişlerdir. Sorgu hash kodları ile veritabanındaki her bir öge arasındaki benzerlik, bitset XOR işlemi ile yani Hamming mesafeleri ile elde edilmiştir. Bir sorguya en çok benzeyen ilk 5,10,15,20 görüntüler elde edilmiştir. Elde edilen görüntüler, sorgu ile aralarındaki Öklit mesafelerine göre yeniden sıralanmışlardır. Öklit mesafeleri için öznitelik vektörleri kullanılmıştır. Ardından sıralanan görüntülerin *ap* skorları elde edilmiştir. Sonrasında 40 adet test sorgusu için bir adet *map* soru elde edilmiştir. Deneyler 16,32 ve 64 bit hash kod için tekrarlanmıştır. *map* skorları için MATLAB kullanılmıştır. Erişime açık kaynak kodlar ile bu deneylerin sonucu herkes tarafından doğrulanabilir. Deney sonuçları Tablo 1’de sunulmuştur.

Tablo 1. *Sorgu grubu ile elde edilen ortalama kesinlik (map) skorları.*

Hash Code	map@5	map@10	map@15	map@20
16 Bit	0.6841	0.7028	0.6987	0.6992
32 Bit	0.65	0.6522	0.65	0.6420
64 Bit	0.6922	0.6818	0.6857	0.6787

⁸ <https://github.com/enverakbacak/EIR>

Referanslar

- [1] Lowe, D.G., 2004. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2), pp.91-110.
- [2] Dalal, N. and Triggs, B., 2005, June. Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)* (Vol. 1, pp. 886-893). Ieee.
- [3] Wang, J., Zhang, T., Sebe, N. and Shen, H.T., 2017. A survey on learning to hash. *IEEE transactions on pattern analysis and machine intelligence*, 40(4), pp.769-790.
- [4] Rodrigues, J., Cristo, M. and Colonna, J.G., 2020. Deep hashing for multi-label image retrieval: a survey. *Artificial Intelligence Review*, 53(7), pp.5261-5307.
- [5] Dubey, S.R., 2021. A decade survey of content based image retrieval using deep learning. *IEEE Transactions on Circuits and Systems for Video Technology*.
- [6] Tan, M. and Le, Q., 2019, May. Efficientnet: Rethinking model scaling for convolutional neural networks. In *International Conference on Machine Learning* (pp. 6105-6114). PMLR.

S-59 HİBRİT YÜZ TANIMLAMA ALGORİTMASI GELİŞTİRİLMESİ VE MEVCUT MODELLERLE KARŞILAŞTIRILMASI

Hasan AKYOL¹, Mustafa ERŞAHİN²

¹ Web Front End Team, Commencis A.Ş, Türkiye, hasan.akyol@commencis.com

² Web Front End Team, Commencis A.Ş, Türkiye, mustafa.ersahin@commencis.com

Özet

Her türlü verinin büyük anlam kazandığı günümüzde dijital ortamda kişilerin tüm hareketleri anonim olarak çeşitli araçlar ile toplanmakta ve anlamlandırılmaktadır. Elde edilen bu veriler ticari alanda müşterileri tanımak, geleceğe yönelik tahminlerde bulunmak ve hatta müşterilere kişiselleştirilmiş deneyimler sunarak müşteri memnuniyeti ve bağlılığını artırmak için kritik önem taşır. Dijital ortamlardaki verinin toplanması günümüzde oldukça kolaydır. Fakat fiziki hayattaki verinin toplanması için farklı çözümler olsa da bu yöntemler daha zor ve zahmetlidir. Dijital olmayan insan davranışlarının takibinde kullanılan popüler yöntemlerden biri de görüntü işleme ve anlamlandırma teknikleridir. Bu teknikler ile insanların yüzleri fotoğraflarından bağımsız olarak matematiksel bir şekilde modellenerek saklanır ve tekrar görüldüklerinde bu saklanan model aracılığı ile tanınmış olur. Bu sayede insanların fiziksel mekanlardaki davranışları takip edilebilir. Bu alanda kullanılacak açık kaynaklı çözümler olduğu gibi Amazon, Google gibi büyük şirketlerin ticari amaçlı çözümleri mevcuttur. Çalışmamızda geliştirdiğimiz hibrit yüz tanıma algoritmamız mevcut açık kaynak kodlu algoritmaların hem açık kaynak veri setlerinde hem de kurumsal veri setleri üzerinde %4 ile %8 oranında daha başarılı sonuçlar elde etmiştir. Bulut tabanlı sistemlerin yetkinliklerini ve başarısını da paylaştığımız bu çalışmada, teknik detaylarına ulaşabildiğimiz algoritmalara göre daha yüksek başarılı bir algoritma geliştirilmiştir.

Anahtar Sözcükler: *hibrit yüz tanıma, görüntü işleme, açık kaynak.*

Abstract

Nowadays all types of data which is gathered from the users anonymously by means of different tools has great importance. The existing data is used for identifying the customer and predicting the future. As well, it is essential for improving customer pleasure and loyalty by offering specialized experiences to the customers. Today, collecting the data from the Internet is quite easy but it is more difficult in everyday life although there are alternative methods. One of the methods used for the tracking of people's behaviour is image recognition. In this technique, faces of people are saved modelled as mathematically and they are recognized when they are appeared. Through, people's attitudes and movements can be tracked in the physical places. There are some open-source tools and also commercial solutions provided by the large companies like Amazon and Google. It is more practical using these ready methods instead of developing new methods for big data. Proposed hybrid face detection algorithm has promising results on experiments which are already tested in

both well-known datasets and corporate datasets. The hybrid algorithm performs %4 to %8 better than all the other open-source face detection algorithms.

Keywords: *hybrid face detection, image processing, open source.*

1. Giriş

Yüz insanları birbirinden ayırt emenin en hızlı ve verimli yoludur. İnsan beyni bu tanıma işlemini çok kısa bir sürede ve gerçek zamanlı olarak yapabilmektedir. Kameralar ile dijitalleştirilen görüntüler yapay sinir ağı modelleri aracılığı ile anlamlı sayı dizileri şeklinde kodlanarak hafızada saklanır. Bu işlem insan beyninin bir cismi ilk defa gördüğünde yaptığı işleme benzer. Daha sonrasında ise kameralardan gelen görüntüler hafızada tutulan kodlanmış veriler ile karşılaştırılarak benzerlikleri ölçülür ve yeterince birbirine benzeyen bir görüntü yakalandığında ilgili obje tanınmış olur. Yüz tanımlama işlemi insan yüzündeki kaş, göz, burun, ağız ve çene gibi karakteristik noktaların belirlenmesi ve bu noktaların birbirleri ile olan uzaklıklarının oranları ile mümkündür. Yüz tanımlama ve karşılaştırma işlemi yüzden alınan bu görsel geometri verileri aracılığı ile olduğundan yüzün fotoğrafının saklanmasına ihtiyaç yoktur. Bu da veri gizliliği açısından büyük bir sorumluluktan kurtulmak anlamına gelir.

1.1.Hazır bulut çözümleri

Yüz tanımlama ve kişi takibi için kullanılacak en basit ve en hızlı uygulanabilecek yol Amazon, Microsoft gibi firmaların sunduğu bulut çözümleridir. Bu sistemler tüm işlemleri arka planda hallederek kullanıcıya basit API veya SDK’lar aracılığı ile kolay kullanım sağlarlar. Bu sayede kullanıcının planlaması gereken tek şey verinin nasıl buluta iletileceği ve geri dönen anlamlı verinin nasıl kullanılacağı olur.

Amazon Rekognition yüz tanımlama alanında başarısı, kullanım kolaylığı ve diğer hizmetleri ile uyumlu çalışmasından dolayı güçlü oyuncuların birisidir. Yüz tanımlamanın yanında, yüz analizi, metin okuma, obje etiketleme ve videodan nesne takibi gibi gelişmiş özelliklere sahiptir. Amazon’un bu hizmeti yapılan API çağrısı başına ücretlendirilir. 1, 10 ve 100 milyonuncu isteklerden sonra birim fiyatı düşen bir ücretlendirme modeli ile çalışır.

Tablo 1. *Haziran 2020 tarihli amazon rekognition fiyatlandırması.*

Ücret türü	Fiyatlandırma	1.000 görüntü başına fiyat	Ücret türü	Fiyatlandırma
0-1M	0,001 \$	1,00 \$	0-1M	0,001 \$
1M-10M	0,0008 \$	0,80 \$	1M-10M	0,0008 \$
10M-100M	0,0006 \$	0,60 \$	10M-100M	0,0006 \$
+100M	0,0004 \$	0,40 \$	+100M	0,0004 \$

1.2.Açık Kaynaklı Yüz Tanımlama Modelleri

Yüz tanımlama uygulamalarında bulut servislerine alternatif oluşturabilecek bir diğer çözümler ise önceden eğitilmiş veri modelleridir. Bu modellerin de yardımı ile “one-shot learning” denilen teknik kullanılarak bir kişinin tek bir fotoğrafı ile o kişi daha sonrası için tanınabilir bir hale gelir.

VGG-Face[1], Oxford Üniversitesindeki Visual Geometry Group isimli araştırma grubu tarafından oluşturulan popüler yüz tanımlama modelidir. Modelin oluşturulmasında 2622 farklı kişiden oluşan 2.6 milyon fotoğraf kullanılmıştır. Çalışma Creative Commons Attribution License ile lisanslandığı için ticari amaçlı kullanıma uygun değildir.

FaceNet[2], Google araştırmacıları tarafından geliştirilmiş bir açık kaynak yüz tanımlama projesidir. Çalışmamızda TensorFlow implementasyonu kullanılmıştır. Güncel hali ile CASIA-WebFace ve VGGFace2 olarak iki farklı veri seti ile önceden eğitilmiş model sunmaktadır. Çalışmamızda VGGFace2 veri seti ile eğitilen model kullanılmıştır. Bu model yaklaşık 9000 farklı kişinin 3,3 milyon pozunu içermektedir.

DeepFace[3], Facebook AI Research ve Tel Aviv Üniversitesi ortaklığı ile gerçekleştirilmiş bir çalışmadır. Orijinal çalışma 4000 farklı kişiden toplam 4 milyon pozun bulunduğu bir eğitim verisi ile eğitilmiş bir modeldir.

OpenFace[4], Ulusal Bilim Vakfı (NSF) tarafından desteklenen ve Intel Corporation, Google, Vodafone, NVIDIA ve Conklin Kistler aile fonu gibi kuruluşlarca fonlanan açık kaynaklı bir yüz tanımlama projesidir. Eğitimi için en büyük yüz tanımlama veri setlerinden olan CASIA-WebFace ve FaceScrub’in birleştirilmiş hali kullanılmıştır. Apache License 2.0 lisansı ile lisanslandığı için ticari kullanıma da olanak tanır.

face_recognition[5], Adam Geitgey tarafından MIT lisansı altında geliştirilen açık kaynaklı bir yüz tanıma API’idir. Python dlib kütüphanesi kullanılarak geliştirilmiştir.

2. Yöntem

Önerilen çalışmada kullanılan yüz verileri kurumsal şirket çalışanları tarafından sağlanmıştır. İki farklı ofiste ortak alana çıkan kapılara yerleştirilen kameralar sayesinde kişilerin doğal yaşamındaki görüntüleri kayda geçirilmiştir. Kameralardan elde edilen görüntüler gerçek zamanlı olarak raspberry pi 4 cihazı üzerinde face_recognition kütüphanesi kullanılarak işlenmiş ve yüz verileri kaydedilmiştir. Elde edilen yüz fotoğraflarından 10 kişiye ait 50’şer örnek insan gözü ile seçilmiş ve veri seti nihai halini almıştır.

Çalışmada kullanılan tüm çözümler aynı yapı içerisinde python programlama dili ile kullanılmıştır. Girdi olarak verilen görselde tespit edilen yüz eđik ise açısı hesaplanıp hizalanır. Hizalanmış yüzün görsel geometri bilgileri tanımlanır. Tanımlanmış yüz önceden kaydedilmiş yüzler ile kosinüs benzerliği yöntemi kullanılarak birbirlerine olan yakınlıkları hesaplanır. Böylece daha önceden kaydedilmiş yüzler arasından en yakın yüz tespit edilmiş olur. Eğer bulunan en benzer yüz belirlenen eşik değeri kadar benziyor ise sisteme giren poz benzetilen kişi ile isimlendirilir. Eğer eşik değeri altında bir benzerlik elde edilir ise de sisteme giren bu poz ilk defa gelen bir kişi olarak nitelendirilip ona bundan sonra tanınması için bir isim verilerek kaydedilir.

2.1. Başarıyı Arttıran Yöntemler

2.1.1. Yeniden Tanımlama

Başarımı arttırmanın en basit yollarında biri kişinin birden fazla açıdan ve farklı ışıklar altında elde edilmiş yüz verilerini saklamasıdır. Böylece sonradan yakalan bir pozun o kişi ile ilişkilendirilmesi ihtimali arttırılmış olur. Bu yöntem tanınması beklenen kişilerin önceden manuel olarak tanımlandığı bir uygulamada kesin bir başarı artışı sağlar. Fakat manuel olarak tanımlama yapılamayan durumlarda sistemin hatalı eşleşme sonucu tanımlama yapma ihtimali risk oluşturur. Bu durum tanımlama veri setinin bozulmasını yol açabilir.

2.1.2. Modellerin Hibrit Kullanımı

Kullanılan modeller aynı görseller üzerinde çalışırken her zaman aynı doğrultuda sonuçlar üretmeyebilirler. Bu nedenle bir kişinin eşleştirilmesi için birden fazla model kullanılarak özellikle yeniden tanımlama için daha iyi bir başarıml elde edilebilir.

Çalışmamızda hibrit model yöntemi face_recognition’ un temel model, FaceNet ve VGG-Face’ in de destek modeller olduğu bir yapı ile uygulanmıştır. face_recognition ile normal akış işlerken face_recognition’ ın benzer olarak bulduğu yüz diğer iki destek modeli ile de tanımlanıp karşılaştırılır. İki poz arasındaki toplam üç modelden alınan benzerlik oranları birleştirilerek yeniden tanımlama için kullanılır.

2.2. Sistemin Sınanması

Kullanılan yüz tanımlama modellerini sınamak için kurumsal şirketten elde edilen veri setindeki her bir yüz, kişinin tespit edildiği kameradan geçtiği zamana göre sıralanarak işleme alınmıştır. LFW(Labeled Faces in the Wild)[6] veri seti ile sınama yapmak için ise her bir poza rastgele bir numara atanmış ve kayıtlar bu numaraya göre sıralanarak işleme alınmıştır. Bu sayede modellerin gerçek hayattaki davranışları taklit edilerek başarımları sınanmıştır. Test sistemi yüzler gelmeye başladığında yüzü önce daha önceden tanımlanıp tanımlanmadığını kontrol eder. Eğer tanımlanmış bir kişi ise o pozunu da aynı isim ile veri tabanına kaydeder. Eğer daha önce tanımlanmamış bir kişi olduğunu kararı verilirse ise pozunu “face-123” şeklinde benzersiz bir isim ile veri tabanına kaydeder. Başarım kriteri olarak model tarafından tahminleri yapıp belirlenmiş kişiler poz eşleşmesi sayısına göre sıralanmıştır. Sistemin eşleştirdiği her bir kişi için ne kadarının gerçekten bir kişi olduğu oranı(doğruluk) ve o kişinin veri setindeki pozlarının ne kadarının bir araya getirildiği oranı(eşleşme) hesaplanmıştır. Elde edilen bu değerlerin ilk 10 sırasının ortalamaları alınarak da modelin genel başarımlı elde edilmiştir. Bu iki başarımlın ayrı olarak hesaplanması sayesinde modelin kişileri birbirleri ile karıştırmaya mı yatkın yoksa kişinin pozlarını eşleştirememeye mi yatkın olduğu durumları gözlemlenebilir. Modeller için kullanılan en düşük benzerlik eşikleri ve tekrar tanımlama benzerlik eşikleri doğru ve yanlış benzetimlerdeki yakınlık değerleri Grid Search[7] yöntemi ile belirlenmiştir. Bu eşikler veri setindeki pozların genel kalitesine göre daha iyi sonuçlar elde edebilmek için değiştirilebilir. Örneğin iyi ışık almış keskin ve dik açılı pozlarda doğru benzetimlerdeki yakınlık değeri çok düşük, yanlış benzetimlerde de çok yüksektir. Bu durumda benzerlik ve yeniden tanımlama eşikleri aşağılara çekilebilir. Aksi durumlarda ise. Daha yüksek seviyelerde tutulmak zorunda kalınır. Bu durum da başarımlı olumsuz yönde etkiler.

3. Bulgular

Araştırmada kullanılan tüm modellerin tamamı ideal şartlarda iki yüzü karşılaştırırken yüksek doğrulukla çalışmaktadır. Düşük ışık, kötü yüz açısı ve düşük çözünürlük gibi yüz hatlarının tahminini zorlaştıran etmenler modellerin başarımlarını düşürür. Yapılan testlerin ardından gerçek dünya şartlarında bu modellerin nasıl tepki verdikleri ve zor koşullarda hangi modelin ne kadar tolere edebildiği Tablo 2’de gösterilmiştir.

Tablo 2. 10x10 Kurumsal veri seti eşleştirme sonuçları.

Yüz Tanımlayıcı	Benzerlik Eşiği	Tekrar Tanımlama Eşiği	Eşleşme	Doğruluk
face_recognition	0,5	-	82,0	97,2
Vgg-face	0,25	-	75,0	97,1
FaceNet	0,55	-	81,0	92,5
OpenFace	0,2	-	26,0	63,3
DeepFace	0,4	-	33,0	62,4

Tablo 3. 10x10 kurumsal veri seti tekrar tanımlama ile eşleştirme sonuçları.

Yüz Tanımlayıcı	Benzerlik Eşiği	Tekrar Tanımlama Eşiği	Eşleşme	Doğruluk
face_recognition	0,5	0,4	87,0	96,5
Vgg-face	0,25	0,15	81,8	98,2
FaceNet	0,55	0,2	81,0	92,9
OpenFace	0,2	0,1	26,0	62,0
DeepFace	0,4	0,3	34,0	75,3

Modellerin farklı özelliklerde veri setleri ile sınamaları sonucunda AWS Rekognition’ın yüksek başarısı gözlemlenmiştir. Nihayetinde Amazon’un bu servisi bitmiş bir ürün iken diğer çözümler geliştirilecek bir sistemde kullanılacak hazır parçalardır.

Amazon’un bu başarısının ardından face_recognition kütüphanesi ve Vgg-face ile FaceNet modellerinin kullanılabilir sonuçlar ürettikleri gözlemlenmiştir. Özellikle LFW veri setindeki sonuçları ile face_recognition ve FaceNet kaliteli pozlar alındığında doğruluk %100 seviyesinde kalmıştır. Bu sonuç da kişilerin birbirleri ile karıştırılmayacağını gösterir. Bu sonuçlara göre sadece tekrar tanımlama işlemi ile doğruluktan kaybedilmeden eşleşme oranları %4 ile %8 oranında artırılmıştır. 10x10 kurumsal veri setinde de başarımlar büyük ölçüde korunsa da pozların kalitesindeki düşüş sebebi ile özellikle eşleşme oranlarında düşmeler görülmektedir. Asıl düşüş ise 10x50 kurumsal veri setinde görülmüştür. Bu veri setinde her

kişinin 50 pozunu bulduğu için eşleştirme sırasında yapılan bir hata sonraki eşleşmeleri de olumsuz yönde etkilemektedir. Bu sebeple bir kişinin toplamdaki 50 pozunu birden fazla parçaya bölünüp eşleşme oranlarını düşürmektedir. Bu da poz sayısının arttıkça eşleşme değerini düşeceğini göstermiştir.

Başarımı arttırmak için kullandığımız hibrit model yaklaşımı tekrar tanımlama işlemindeki poz seçimi sırasında birden fazla modelden faydalanır. Bu sayede yeniden tanımlamadaki hata oranı azaltılmaktadır. Ayrıca temel modelin benzer olarak bulunduğu yüz ile aranan yüz arasındaki benzerlik destekleyici modeller tarafından da kontrol edilir. Böylece benzer olarak tespit edilen yüzün doğruluğundan emin olunur. Hibrit model kullanılarak eşleşme başarımında tüm modellerin tekrar tanımlama ile elde edilen en iyi sonuçlarının üzerine 4 puana kadar artış olduğu gözlemlenmiştir.

Tablo 4. Hibrit model karşılaştırması.

Yüz Tanımlayıcı	10X10 LFW	10X10 Kurumsal	10X50 Kurumsal
face_recognition	92,0 / 100,0	87,0 / 96,5	70,6 / 92,7
Vgg-face	69,0 / 94,6	81,8 / 98,2	65,6 / 94,8
FaceNet	94,0 / 100,0	81,0 / 92,9	63,8 / 88,8
Hibrit	96,0 / 98,2	90,0 / 96,5	73,4 / 92,5

4. Sonuç ve Tartışma

Çalışmamız kapsamında önerilen hibrit model ile elde edilen çıktılar ışığında insanların doğal davrandıkları koşullarda dahi yakalanan pozları ile doğru bir şekilde tanımlanıp sınıflandırılabilmesi gözlemlenmiştir. Bir bulut çözümü olan Amazon Recognition'ın bu tür bir sistemde doğrudan kullanılmaya hazır olduğu görülmüştür. Fakat maliyetleri de göz önünde bulundurulduğunda bir bulut çözümü yerine açık kaynaklı çözümler de kullanılabilir. Açık kaynaklı yüz tanıma algoritmaları ve modelleri üzerinde yaptığımız testler sonucunda elde edilen doğru sınıflandırma başarısını arttırmak hedefiyle geliştirdiğimiz hibrit model bize kullanılan araçlara göre %4 ile %8 arasında bir başarı artışı sağlamıştır.

Referanslar

- [1] O. M. Parkhi, A. Vedaldi, A. Zisserman, Deep Face Recognition, 2015.
- [2] F. Schroff, D. Kalenichenko, J. Philbin, FaceNet: A Unified Embedding for Face Recognition and Clustering, 2015.
- [3] Y. Taigman, M. Yang, M. Ranzato, L. Wolf, DeepFace: Closing the Gap to Human-Level Performance in Face Verification, 2014.
- [4] B. Amos, B. Ludwiczuk, M. Satyanarayanan, OpenFace: A general-purpose face recognition library with mobile applications, 2016.
- [5] “face_recognition Github”, 2020; https://github.com/ageitgey/face_recognition.
- [6] “Labeled Faces in the Wild”, 2020; <http://vis-www.cs.umass.edu/lfw/>

- [7] Thristed R.A, Elements of statistical computing: Numerical computation, Newyork, USA, 1988
- [8] Amazon Rekognition, 2020; <https://aws.amazon.com/tr/rekognition>

S-02 AKILLI SULAMA SİSTEM TASARIMI: İZMİR KATİP ÇELEBİ ÜNİVERSİTESİ ÖRNEĞİ

Hasan Ali OK¹, Furkan ŞAHİN², Aysegul ALAYBEYOGLU³

¹ Yazılım Mühendisliği, İzmir Katip Çelebi Üniversitesi ,İzmir, Türkiye,
Y200237015@ogr.ikcu.edu.tr

² Yazılım Mühendisliği, İzmir Katip Çelebi Üniversitesi , İzmir, Türkiye,
Y200237010@ogr.ikcu.edu.tr

³ Bilgisayar Mühendisliği, Yapay Zeka ve Veri Bilimi Uyg. Arş. Mrz., İzmir, Türkiye,
aysegul.alaybeyoglu@ikcu.edu.tr

Özet

Bu çalışmanın amacı su tüketimin en etkin bir şekilde kullanımı, fazla sulamanın bitkiye ve toprağa verdiği zararın önlenmesi, gereksiz insan gücü kullanımından ve zamandan tasarruf sağlanması için yapay zeka teknolojileri kullanılarak akıllı bir sulama sisteminin geliştirilmesidir. Geliştirilecek olan Akıllı Sulama Sistem yazılımı ile bitkinin sulama zamanı ve miktarı yazılım tarafından belirlenecek olup, sistem insan müdahalesi olmadan otomatik olarak çalışmaya başlayacaktır. Böylece bitki ihtiyaç duyduğu zamanda ve miktarda sulanmış olacaktır. Bu durum hem bitkinin canlılığını arttıracak hem suyun etkin bir şekilde tüketimini sağlayacak hem de otomatik çalışacak sistem sayesinde gereksiz insan gücü kullanımını ortadan kaldıracaktır. Ayrıca akıllı sulama sisteminin uygulanması sonucunda yeşillik alanlardaki değişimin, su tüketimindeki farkın ve sosyal çevreye yansımalarının istatistiksel analizlerinin yapılması hedeflenmektedir. Gerçekleştirilmesi planlanan proje İzmir Kâtip Çelebi Üniversitesi kampüsünde uygulanacak olup, akıllı sulama sisteminin kampüste uygulanması yönüyle ülkemizde bir ilk olacaktır.

Anahtar Sözcükler: LoRawan; Yapay Zeka; Gömülü Sistem; Makine Öğrenmesi

Abstract

The aim of this study is to develop a smart irrigation system by using artificial intelligence technologies in order to use water in the most effective way, to prevent the damage of over irrigation to plants and soil, to save unnecessary manpower and time. With the Smart Irrigation System software to be developed, the irrigation time and amount of the plant will be determined by the software, and the system will start to work automatically without human intervention. Thus, the plant will be watered at the time and amount it needs. This will both increase the vitality of the plant, ensure the efficient consumption of water, and eliminate the use of unnecessary manpower thanks to the automatic system. In addition, it is aimed to make statistical analyzes of the change in green areas, the difference in water consumption and its reflection on the social environment as a result of the implementation of the smart irrigation system. The project that is planned to be realized will be implemented

on the campus of İzmir Katip Çelebi University and will be a first in our country in terms of implementing the smart irrigation system on campus.

Keywords: *LoRawan; Artificial Intelligence; Embedded System; Machine Learning*

1. Giriş

Küresel ısınma, bilinçsiz tüketim ve iklim değişiklikleri gibi faktörler gelecekte yaşanabilecek su sorunlarına sebep olarak öne çıkmaktadır. Bu durumun, özellikle yağışların azaldığı dönemlerde su kaynaklarını bulmayı zorlaştıran, ekolojik dengeyi tehdit eden bir hal alması öngörülen bir tehlikedir. Su kaynaklarının erken tükenmesine sebep olan bir başka durum ise tarım alanlarının yanlış sulanmasıdır. Toprağın salma sulama denilen yöntem ile sulanması toprak verimini düşüren, su israfını ise arttıran bir durumdur. Yanlış sulamanın bitkiye ve toprağa verdiği zarar da su israfına ek olarak düşünülmesi gereken bir durumdur. Bu sebeplerle su kullanımının verimli hale getirilmesi ve su havzalarının korunmasının önemi her geçen gün artmaktadır. Günümüzde suyun etkin kullanımına ilişkin çeşitli çözümler araştırılmakta ve teknolojinin de bu alandaki rolü giderek etkin hale gelmektedir.

Tarımda sulama sistemlerinin geliştirilmesinde teknolojilerin kullanımı son zamanlarda araştırmacıların dikkatini çekmiş, bu alanda çalışmaların yapılmasında motive edici olmuştur. [1]'de suyun uygun şekilde kullanılması için uygun yerlerde sıcaklık ve nem sensörünün kullanıldığı bir sistem önerilmiştir. [2]'de sıcaklık ve toprak nemi eşik değerleriyle geliştirilen bir algoritma, su miktarını kontrol etmek için mikro denetleyici tabanlı bir ağ geçidine programlanmıştır. Sistem, fotovoltaik panellerle çalıştırılmış olup, bir web sayfası aracılığıyla veri inceleme ve sulama planlamasının programlanmasına olanak tanıyan bir hücresel-İnternet arayüzüne dayalı çift yönlü bir iletişim bağlantısına sahiptir. [3]'te Kablosuz Sensör Ağları hassas tarımda sera parametresinin izlenmesinde ve kontrolünde kullanılmıştır. [4]'te minimum su kullanımıyla üretkenliği en üst düzeye çıkarmak için değişken oranlı sulamayı, tarla algılamada gerçek zamanlı, sahaya özgü hassas doğrusal hareketli sulama sistemini kontrol etmeyi amaçlayan dağıtılmış kablosuz sensör ağı kullanan bir uzaktan algılama ve kontrol sulama sistemi geliştirilmiştir. [5]'te patatesten hassas damla sulama programlarının yapılmasında toprak nem sensörlerinin kullanılması gerçekleştirilmiştir. Çalışmada farklı toprak nem ölçüm cihazları, siltli tınlı toprakta, hassas sulama programı yapılmasında test edilmişlerdir. Nötron problemler, frekans domain problemler, tansiyometreler ve granüler matrix sensörler birbirleriyle mukayese edilmiştir. Granüler matrix sensörlerin okunması, otomatik olarak data toplayıcılar ve manuel olarak elde taşınır okuyucu ile yapılmıştır. [6]'da yapay zeka ve nesnelerin interneti konusunun tarım alanında uygulanması konularında çalışılmıştır. [7]'de bulut bilişim, IoT ve veri madenciliği tekniklerini içeren çeşitli entegre platformlar incelenerek tarım uygulamaları için yeni bir sistem önerilmiştir.

Belirtilen mevcut çalışmalarda tarım alanlarında kullanılmak üzere yapay zekâ teknolojilerinden faydalanılmaktadır. Bu proje akıllı sulama sisteminin bir üniversite kampüsünde uygulanacak olması ve ileride de birçok kamu alanlarında da uyarlanabilir

nitelikte olması yönleriyle su ve insan gücü kullanımı tasarrufları ile bitki toprak verimliliği konularında katkı sağlayacak bir çalışma olduğu düşünülmektedir.

2. Akıllı Sulama Sistem Tasarımı

Bu bölümde Akıllı Sulama Sistem Mimarisi tanıtılmaktadır.

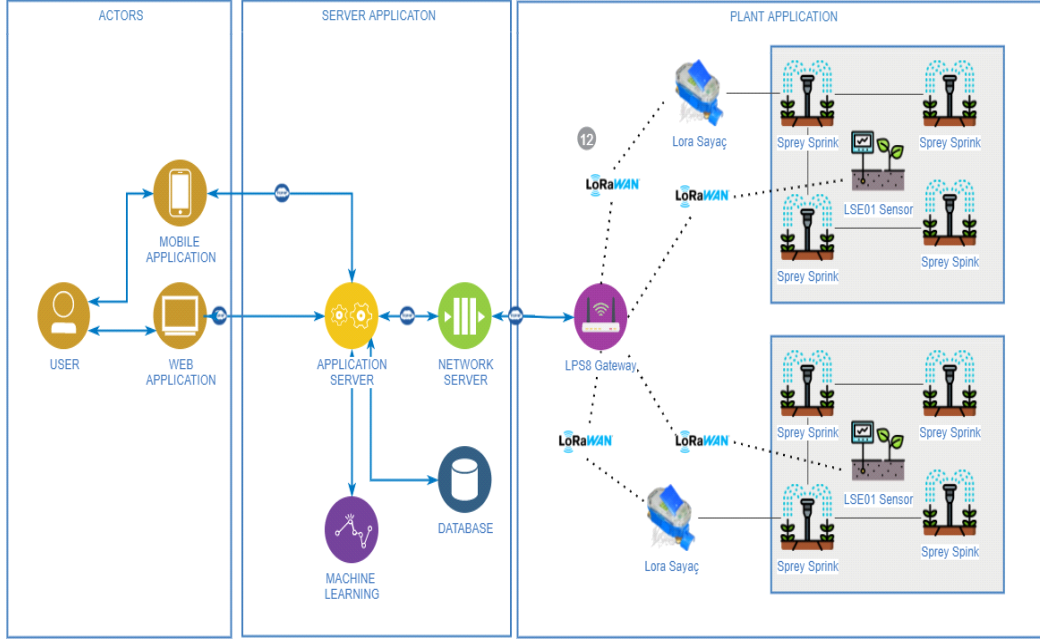
2.1 Genel Fikir

Bu çalışma kapsamında; üniversitemizde seçilen pilot bir bölgeye, sulama sistemi ve LoRa kablosuz haberleşme protokolüne sahip ultrasonik vanalı su sayacı ve toprak nem sensörleri yerleştirilecektir. Seçilen toprak nem sensörleri aracılığı ile toprağın nem, sıcaklık ve iletkenlik bilgileri hassas bir şekilde ölçülerek sunucuya iletilecektir. Yapay zekâ algoritmaları kullanılarak bu bilgiler analiz edilecek ve toprağın su ihtiyacına bağlı olarak sulama sistemi otomatik olarak çalışmaya başlayacaktır. Sensörlerden elde edilen veriler arttıkça, Yapay zekâ algoritmaları kullanılarak toprağın yapısını öğrenen ve en verimli şekilde sulamayı yapabilen akıllı bir sistemin gerçekleştirilmesi hedeflenmektedir.

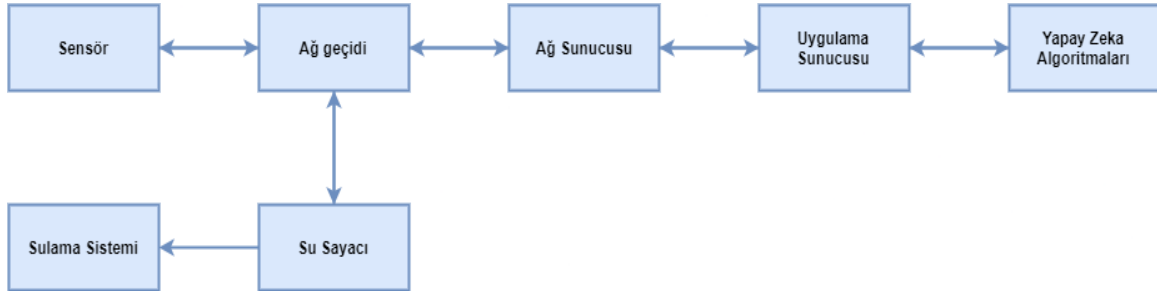
2.2 Sistem Mimarisi

Dünyada tatlı su kaynakları küresel ısınma, kirlilik, yanlış kullanım gibi sebeplerden dolayı zarar görmekte ve azalmaktadır. Akıllı sulama sistemi sayesinde yanlış kullanım oranının azaltılarak suyun en verimli şekilde kullanılması amaçlanmaktadır.

Tarlalar, seralar, parklar ve bahçeler gibi sulama yapılan alanlar geniş bir alanı kapsamaktadır. Geniş alanlarda akıllı sistemler kurulması istendiğinde temel veriler olan toprak nemi, sıcaklığı gibi verileri okumak ve sulama sistemini yönetmek yüksek iş yükü ve kablolu masrafı gibi engeller çıkmaktadır. Akıllı sulama sistemlerinde bu verilerin kablosuz bir şekilde yönetilebilmesi, sensörlerin dağıtık ve dinamik bir şekilde yerleştirilmesi, sensörlerin pil tüketiminin az ve uzun mesafelerde veri göndermesi, sisteme yeni bir sensör veya sulama sisteminin kolayca adapte edilmesi veya çıkarılması, sistemlerin başka sistemler ile (çöp takibi, su sayaç okuması vb) birlikte çalışabilmesi maliyetinin düşük olması büyük bir avantaj sağlayacaktır.



(a)



(b)

Şekil 1 . Akıllı Sulama Sistem Mimarisi

Şekil 1’de sahada uygulaması yapılacak olan Akıllı Sulama Sistem Mimarisi sunulmuştur.

2.3 Sulama Yapılacak Bölge Tespiti

Sulama sistemi projelendirilecek çalışma alanı olarak İzmir Katip Çelebi Üniversitesi kampüsünde yer alan 9776 m2 hacime sahip sol bahçe alanı seçilmiş ve bu alanda farklı çalışmaların kıyaslama ve performans analizlerini yapabilmek adına 5 bölüme ayrılması planlanmaktadır. Şekil 2’de İzmir Katip Çelebi Üniversitesi Kampüs alanı içerisinde ki seçilen bölge ve bölümler görülmektedir.



Şekil 2. Sulama Projesi Yapılacak Alan ve Bölümler

Seçilen bölüm ile ilgili topografik olarak inceleme yapılmamış olsa da, yerinde yapılan incelemelerde arazinin düz yapıda olduğu tespit edilmiştir.

3. Montaj ve Kurulum Aşamaları

Kurulum Aşamasında; üniversitede belirlenmiş olan bölgelerde sulama sistemine su sayaçları bağlanacaktır. Böylece sulama sırasında ne kadar su tüketimi yapıldığı takip edilecektir. Ayrıca sunucu tarafından su sayacın vanası yönetilerek sulama işlemleri yapılacaktır. Su sayacına sulama işlemi için fiskiye sistemi bağlanacaktır. Fiskiye sisteminin sulama bölgesini eşit bir şekilde sulayacak şekilde yerleştirilecektir. Çalışma alanlarının sulama suyu ihtiyacının belirlenmesi aşamasında; bitki su tüketimi, gerçekleşen bitki su tüketimi ve kısa boylu bitki esaslı referans bitki su tüketimi değerleri referans alınacaktır. Devamında; başlık seçimi, düzeni ve yağmurlama hızının belirlenmesi gerçekleştirilecektir. LoRawan Gateway Kurulumu, Web Arayüz Altyapısı, ve Makine Öğrenmesinin Sisteme Entegrasyonu aşamaları da tamamlandıktan sonra, sistemin test aşamasına geçilecektir.

4. Sonuç

Bu çalışmada İzmir Katip Çelebi Üniversitesi Kampüs alanında uygulanması planlanan Akıllı Sulama Sistem Mimarisi hakkında bilgiler sunulmuştur. Sistemi oluşturan temel bileşenler hakkında bilgi verilmiş olup, sistemin saha çalışması aşamasında gerçekleştirilecek temel adımlara değinilmiştir. Gelecek çalışmalarda, bu çalışmada mimarisi sunulan sistemin saha çalışmasına geçilecek ve performans ölçümleri yapılacaktır.

Bilgilendirme

Bu proje İzmir Katip Çelebi Üniversitesi ile BAYLAN firması ortaklığı ile Sanayi Projesi kapsamında gerçekleştirilmektedir.

Referanslar

- [1] S. R. Nandurkar, V. R. Thool, R. C. Thool, “Design and Development of Precision Agriculture System Using Wireless Sensor Network”, IEEE International Conference on Automation, Control, Energy and Systems (ACES), 2014

- [2] Joaquín Gutiérrez, Juan Francisco Villa-Medina, Alejandra Nieto-Garibay, and Miguel Ángel Porta-Gándara, “Automated Irrigation System Using a Wireless Sensor Network and GPRS Module”, *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 0018-9456, 2013
- [3] Dr. V .Vidya Devi, G. Meena Kumari, “Real- Time Automation and Monitoring System for Modernized Agriculture” , *International Journal of Review and Research in Applied Sciences and Engineering (IJRRASE)* Vol3 No.1. PP 7-12, 2013
- [4] Y. Kim, R. Evans and W. Iversen, “Remote Sensing and Control of an Irrigation System Using a Distributed Wireless Sensor Network”, *IEEE Transactions on Instrumentation and Measurement*, pp. 1379–1387, 2008.
- [5] Ali İbrahim Akın, Levent Abdullah Ünlenen, “Patates’te Hassas Damla Sulama Programlarının Yapılmasında Toprak Nem Sensörlerinin Kullanılması”, *Toprak Su Dergisi*, 2017, Özel Sayı: (8-12)
- [6] Chatterjee, S.; Dey, N.; Sen, S. Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications. *Sustain. Comput. Inform. Syst.* **2018**.
- [7] Morais, R.; Silva, N.; Mendes, J.; Adão, T.; Pádua, L.; López-Riquelme, J.; Pavón-Pulido, N.; Sousa, J.J.; Peres, E. Mysense: A comprehensive data management environment to improve precision agriculture practices. *Comput. Electron. Agric.* **2019**, 162, 882–894.

S-16 GENETİK ALGORİTMA TABANLI GRİ TAHMİN MODELİ KULLANARAK MAKİNE ARIZA ZAMANI TAHMİNİ

Bilal ERVURAL^{1,*}

¹ Endüstri Mühendisliği Bölümü, Necmettin Erbakan Üniversitesi, Türkiye,
bervural@erbakan.edu.tr

Özet

Etkin bakım yönetimi özellikle sermaye yoğun organizasyonlarda dikkatle üzerinde durulması gereken konuların başında gelmektedir. Kritik öneme sahip bir makinenin arıza zamanının doğru tahmini önleyici bakımın daha doğru planlanmasına olanak sağlar. Bu çalışmada makine arıza zamanının tahmini için genetik algoritma tabanlı yuvarlama mekanizmalı bir gri tahmin modeli önerilmektedir. Gri tahmin modelinin tüm parametreleri genetik algoritma kullanılarak belirlenmektedir. Geliştirilen model bir gıda işletmesinden elde edilen makine arıza süreleri kullanılarak doğrulanmıştır. Çalışmanın sonuçları geliştirilen modelin bir sonraki arıza zamanını tahmininde tatmin edici performans gösterdiğini kanıtlamıştır.

Anahtar Sözcükler: *Bakım planlama; gri modelleme; genetik algoritma*

Abstract

Effective maintenance management is one issue that needs to be carefully considered, especially in capital-intensive organizations. Accurate prediction of the failure time of a machine allows for more accurate planning of preventive maintenance. In this study, a genetic algorithm-based grey prediction model with a rolling mechanism is proposed to predict failure time of a machine. All parameters of the grey prediction model are determined using a genetic algorithm. The developed model is validated using machine failure times obtained from a food company. The study results demonstrate that the developed model performs satisfactorily in the prediction of the following failure time.

Keywords: *Genetic algorithm; grey modelling; maintenance planning*

1. Giriş

Etkin bakım yönetimi işletme verimliliği üzerinde büyük öneme sahiptir. Gıda üretim süreçleri, seri şekilde birbirine bağlı birden çok alt makineden oluşan bir sistem olarak kabul edilmektedir. Dolayısıyla herhangi bir makinenin arızalanması tüm sürecin durmasına neden olabilir. Ortaya çıkan arızaların sonuçları toplam işletme maliyeti üzerinde önemli bir etkiye sahiptir. Arıza zamanının doğru tahmini üretim planlaması, bakım planlaması, güvenilirlik analizi gibi birçok süreçte kritik öneme sahiptir. Oluşabilecek arızanın önceden tahmini, kestirimci ve önleyici bakımın daha doğru bir şekilde planlanmasını sağlayacaktır. Böylelikle verimliliğin artması, maliyetlerde azalma ve işletme kârının artmasıyla sonuçlanacaktır.

Gri teori, 1980'lerin başında Deng tarafından belirsizlikle başa çıkmak için geliştirilen disiplinler arası bir yaklaşımdır. Teorinin temel amacı sınırlı sayıdaki veri üzerinde bulanık

veya stokastik yöntemlerle ifade edilemeyen sistem davranışının tahmin edilmesidir [1]. Bu çalışmada kestirimci bakım planlamasında kullanılmak üzere arıza zamanlarını tahmin etmek için genetik algoritma tabanlı-yuvarlama mekanizmalı gri tahmin modeli (GA_GPRM) önerilmiştir. Arıza zamanı tahmin modellerinde görülen karmaşık veri (trend, mevsimsellik, doğrusal olmama) ile başa çıkmak amacıyla genetik algoritma ve gri teori birleştirilmiştir. Gri modelin en uygun parametre kümesini elde etmek için genetik algoritmadan faydalanılmıştır. Gıda işletmesinden elde edilen arızalar arası sürelerle ilişkin bir yıllık veri kullanılmıştır. Tahmin performansı Ortalama Mutlak Yüzde Hata (MAPE) ölçütüne göre değerlendirilmiştir. Çalışma sonuçları, önerilen modelin bir sonraki arıza zamanının tahmininde oldukça iyi bir performans sağladığını göstermektedir.

2. Metodoloji

2.1. Gri tahmin modeli

Gri sistemler teorisinde, bir gri modelleme $GM(n,m)$ ile gösterilir; burada n fark denkleminin derecesi iken m değişkenlerin sayısıdır. $GM(1,1)$, yani birinci dereceden tek değişkenli gri model, en sık kullanılan gri tahmin modellerinden biridir. Hesaplama etkinliği nedeniyle kısa dönemli tahminlere yaygın olarak uygulanmıştır. $GM(1,1)$ sadece bir değişkene uyması gerektiğinden, büyük bir veri seti gerektirmez. $GM(1,1)$ modelinin genel adımlar aşağıdaki gibidir [2].

Adım 1. n örnek için zaman dizisi şu şekilde tanımlanır:

$$X^{(0)} = [x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)], \quad n \geq 4$$

Birikimli üretim operatörü (AGO) orijinal veriyi monoton artan seriye dönüştürmek için kullanılır $X^{(1)} = [x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)]$, burada $x^{(1)}$ şu şekilde elde edilir:

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, \dots, n. \quad (1)$$

$X^{(1)}$ 'den üretilen ortalama dizisi $Z^{(1)}$ aşağıda verilmiştir.

$$Z^{(1)} = [z^{(1)}(1), z^{(1)}(2), \dots, z^{(1)}(n)],$$

burada, $Z^{(1)}(k)$ bitişik verilerin ortalama değeridir, şu şekilde hesaplanır:

$$Z^{(1)}(k) = 0.5x^{(1)}(k) + 0.5x^{(1)}(k-1), k = 2, 3, \dots, n \quad (2)$$

Adım 2. Birinci dereceden gri diferansiyel denklem oluşturulur:

$$x^{(0)}(k) + a z^{(1)}(k) = b \quad (3)$$

burada, a ve b sırasıyla geliştirme katsayısı ve kontrol katsayısı olarak adlandırılır. Bu katsayılar, en küçük kareler yöntemi kullanılarak şu şekilde elde edilir:

$$\begin{bmatrix} a \\ b \end{bmatrix} = [B^T \ B]^{-1} B Y \quad (4)$$

$$B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix},$$

$$Y = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]^T.$$

Adım 3. Denklem (4) ile elde edilen a ve b katsayıları kullanılarak gri tahmin denklemi aşağıdaki gibi tanımlanır:

$$\hat{x}^{(1)}(k) = \left[x^{(0)}(1) - \frac{b}{a} \right] e^{-a(k-1)} + \frac{b}{a} \quad (5)$$

burada $\hat{x}^{(1)}(k)$ k zaman noktası için gerçekleştirilen tahmini ve başlangıç koşulunu ($x^{(1)}(1) = x^{(0)}(1)$) ifade eder. Ters birikimli üretim operatörü (IAGO) dizisi aşağıdaki gibi elde edilir:

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 2, 3, \dots, n \quad (6)$$

GM(1,1) modeli tüm veriyi kullanarak bir tahmin yapar dolayısıyla verideki dalgalanmayı yeterince dikkate almamaktadır. Klasik GM(1,1) modelinin bu eksikliği ile başa çıkmak amacıyla Akay ve Atak [3] tarafından yuvarlama mekanizmalı gri sistem yaklaşımı (grey prediction with rolling mechanism - GPRM) geliştirilmiştir. GPRM’de $x^{(0)}(k+1)$, GM(1,1)’in $k < n$ olduğu durumda $x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(k))$ serisine uygulanmasıyla belirlenir. Sonuç bulunduktan sonra prosedür tekrarlanır, ancak bu sefer verinin sonuna yeni tahmin edilen $x^{(0)}(k+1)$ eklenir ve ilk kullanılan veri $x^{(0)}(1)$ çıkarılır. Daha sonra, $x^{(0)}(k+2)$ ‘yi tahmin etmek için $x^{(0)} = (x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(k+1))$ kullanılır.

2.2. Genetik algoritma tabanlı gri tahmin modeli

Klasik GM(1,1) ve GPRM’nin tahmin doğruluğu, a ve b katsayılarına oldukça bağlıdır. Bunun yanında a ve b değerleri de veri setinin yapısına bağlıdır. Bu nedenle, bu parametrelerin belirlenmesi, tahmin modelinin performansını etkileyebilecek en önemli faktörlerden biridir. Bu çalışmada, a ve b parametrelerinin optimal değerlerini elde ederek tahmin doğruluğunu iyileştirmek amacıyla genetik algoritma kullanılmıştır.

GPRM(1,1) modelinin tahmin doğruluğunu geliştirmek için GA_GPRM(1,1) olarak adlandırılan GA tabanlı gri tahmin modeli önerilmiştir. GA_GPRM(1,1) modelinin adımları aşağıda verilmiştir.

Adım 1. Orijinal zaman dizisi $X^{(0)}$, n veri noktası kullanılarak oluşturulur:

$$X^{(0)} = [x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)]$$

Adım 2. Geliştirme ve kontrol katsayıları, GA yöntemi kullanılarak elde edilir. Prosedür aşağıdaki gibi özetlenebilir.

- (i) *Başlangıç yığılı:* Her katsayı için başlangıç değerleri önceden belirlenmiş bir aralıkta rastgele oluşturulur. Literatür incelendiğinde çoğu uygulamada a değerinin $-0,5$ ile $0,5$ arasında olduğu görülmüştür [4]. Dolayısıyla geliştirme katsayısı (a) için aralık $[-0,5, 0,5]$ olarak belirlenir. Kontrol katsayısı (b) için başlangıç değerleri aşağıdaki gibi seçilir.

$$b \in \left[\min \left(0.5 \cdot x^{(0)}(k) \right), \max \left(0.5 \cdot x^{(0)}(k) \right) \right], \quad k = 1, 2, \dots, n \quad (7)$$

- (ii) *Tahmin değerlerinin elde edilmesi ve uygunluk fonksiyonu:* Yığılıdaki her bir birey için Denklem (8) ve (9) kullanılarak tahmin değerleri elde edilir. Ardından uygunluk fonksiyonu, modelin tahmin doğruluğundaki performansı değerlendirmek için kullanılır. Bu çalışmada tahmin doğruluğunu artırmak amacıyla uygunluk fonksiyonu olarak Denklem (10)'da verilen ortalama mutlak yüzde hata (MAPE) kullanılmıştır.

$$\hat{x}^{(1)}(k) = \left[x^{(0)}(1) - \frac{b}{a} \right] e^{-a(k-1)} + \frac{b}{a} \quad (8)$$

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 2, 3, \dots, n \quad (9)$$

$$MAPE = \left(\frac{1}{n-1} \sum_{k=2}^n \frac{|x^{(0)}(k) - \hat{x}^{(0)}(k)|}{x^{(0)}(k)} \right) \times 100 \quad (10)$$

burada $x^{(0)}(k)$ gerçek değeri ifade ederken $\hat{x}^{(0)}(k)$ tahmin edilen değerdir.


- (iii) *Seçim, çaprazlama ve mutasyon:* Seçim operatörü, mevcut popülasyondan daha uygun kromozomu seçmek için kullanılır. MAPE değeri yüksek olan kromozom, MAPE değeri düşük olan kromozomlarla değiştirilir. Bu çalışmada en çok tercih edilen seçim yöntemi olan rulet çemberi yöntemi kullanılmıştır. Yeni kromozomlar üretmek için çaprazlama ve mutasyon operatörleri kullanılır. Bu prosedürde, çaprazlama operatörü olarak tek nokta çaprazlama kullanılmıştır. Mutasyon operatörü olarak ise kromozomun ilgili kısmını adaptif bir orana göre değiştiren bir yapı tercih edilmiştir.

Adım 3. Elde edilen optimal parametre değerleri (a, b) kullanılarak, GA_GPRM(1,1) modelinin nihai tahmin değerleri hesaplanır (Denklem (8) - (9)).

3. Makine Arıza Zamanının Tahmini

Bu bölümde bir gıda işletmesi için kritik öneme sahip bir makinenin arıza zamanı GA_GPRM yöntemi ile tahmin edilmiştir. Üretim hattında belirlenen makine için meydana gelen arızaların

gün ve saatini içeren toplamda bir yıllık veri temin edilmiş ve tahminlemede bu veriler kullanılmıştır. Şekil 1’de birikimli arızalar arası geçen süreler sunulmuştur.



Şekil 7. Seçilen makine için arıza verisi


Önerilen modelin etkinliğini doğrulamak amacıyla, klasik GM(1,1) uyarlamalı akıllı gri tahmin modeli (SIGM) [5] kullanılmıştır. Tablo 1, GA_GPRM(1,1), GM(1,1) ve SIGM ile elde edilen tahmin sonuçlarını sunmaktadır. Önerilen iyileştirilmiş gri model için gerçek ve tahmin değerleri Şekil 2 'de gösterilmektedir.

Ele aldığımız veride değişkenliğin fazla olmasından dolayı küçük k değerine sahip bir yuvarlama mekanizması tercih edilmiştir. Buna göre son dört veri ($k-3, k-2, k-1, k$) kullanılarak ($k+1$) tahmin edilecektir, yani $k = 4$ seçilmiştir. Makine arıza zamanı tahmini için geliştirilen GA_GPRM yaklaşımının uygun parametre seti deneysel çalışma sonucunda elde edilmiştir. Yığın büyüklüğü = 300, yığın boyutu = 2, maksimum iterasyon sayısı = 200 ve mutasyon oranı = 0,2'dir.

Tablo 3. Arıza zamanı tahmini için modellerin karşılaştırılması

No	Arızalar arası süre (saat)	Biriki mli arızalar arası süre (saat)	GM(1,1)		SIGM		GA_GPRM(1,1)	
			Tahmi n değeri	Hat a (%)	Tahmi n değeri	Hat a (%)	Tahmi n değeri	Hat a (%)
91	17	7993	9125	0,1 42	7981,4 0	0,0 01	8011,0 0	0,0 02
92	91	8084	9213	0,1 40	8029,9 0	0,0 07	7977,7 0	0,0 13
93	47	8131	9303	0,1 44	8078,6 0	0,0 06	8197,5 0	0,0 08
94	8	8139	9394	0,1 54	8127,4 0	0,0 01	8139,4 0	0,0 00
95	28	8167	9485	0,1 61	8176,2 0	0,0 01	8167,1 0	0,0 00
96	50	8217	9577	0,1 66	8225,1 0	0,0 01	8219,3 0	0,0 00
97	28	8245	9671	0,1 73	8274,2 0	0,0 04	8236,5 0	0,0 01
98	63	8308	9765	0,1 75	8323,3 0	0,0 02	8330,9 0	0,0 03
99	110	8418	9860	0,1 71	8372,5 0	0,0 05	8353,9 0	0,0 08
00	293	8511	9956	0,1 70	8421,9 0	0,0 10	8532,2 0	0,0 02
01	212	8523	10053	0,1 80	8471,3 0	0,0 06	8618,5 6	0,0 11
02	277	8600	10151	0,1 80	8520,8 0	0,0 09	8580,5 7	0,0 02

2	27	8627	10250	0,1	8570,4	0,0	8554,6	0.0
03				88	0	07	8	08
2	12	8750	10349	0,1	8620,1	0,0	8582,5	0.0
04	3			83	0	15	5	19
MAPE				41,	5,1	0,6		
(%)				06	2	7		



Şekil 8. GA_GPRM ile makine arıza zamanı tahmini

Tablo 1’de görülebileceği gibi, son bir yılda gerçekleşen 204 arıza arası geçen süreye uygulanan GM(1,1), SIGM ve GA_GPRM(1,1) modellerinin MAPE değerleri sırasıyla % 41,06, % 5,12 ve % 0,67 bulunmuştur. Sonuçlar, önerilen modelin karşılaştırılan diğer gri yöntemlerden daha yüksek bir tahmin hassasiyetine sahip olduğunu göstermektedir.

4. Sonuç

Bir gıda işletmesinde gerçekleştirilen bu çalışmada seçilen bir makinede gerçekleşebilecek arızalar arası sürenin tahmini için GA tabanlı yuvarlama mekanizmalı bir gri tahmin modeli geliştirilmiştir. GA, gri modelin parametrelerinin optimal olarak elde edilmesi için kullanılmıştır. Böylelikle, değişkenliği yüksek bir veri seti ile robust bir performans ve güvenilir tahmin sonuçları elde etmek mümkündür.

Önerilen yaklaşımların performans düzeyi, literatürde yaygın olarak kullanılan MAPE ölçütü ile araştırılmıştır. Önerilen GA_GPRM(1,1) yaklaşımının performansını göstermek için farklı gri yaklaşımlar ile karşılaştırılmış ve oldukça iyi sonuçlar verdiği görülmüştür.

Referanslar

- [1] J. Deng, ‘Control problems of grey systems’, *Syst. Control Lett.*, vol. 1, no. 5, pp. 288–294, Mar. 1982.
- [2] L. Sifeng and Y. Lin, *Grey Information: Theory and Practical Applications*. Berlin, 2006.
- [3] D. Akay and M. Atak, ‘Grey prediction with rolling mechanism for electricity demand

- forecasting of Turkey’, *Energy*, vol. 32, no. 9, pp. 1670–1675, 2007.
- [4] K. Li, L. Liu, J. Zhai, T. M. Khoshgoftaar, and T. Li, ‘The improved grey model based on particle swarm optimization algorithm for time series prediction’, *Eng. Appl. Artif. Intell.*, vol. 55, pp. 285–291, Oct. 2016.
- [5] B. Zeng and C. Li, ‘Forecasting the natural gas demand in China using a self-adapting intelligent grey model’, *Energy*, vol. 112, pp. 810–825, 2016.

S-44 CONTROL OF THE FLUENCE PARAMETER FOR LASER THERAPY IN MELASMA TREATMENT WITH FUZZY LOGIC SYSTEM

İlayda ALPAY¹, Ayşegül ALAYBEYOĞLU²

Department of Biomedical Engineering, Izmir Katip Çelebi University, Turkey,
ilaydaalpay97@hotmail.com

Department of Computer Engineering, Izmir Katip Çelebi University, Turkey,
aysegul.alaybeyoglu@ikcu.edu.tr

Özet

Bu çalışmada lazer tedavisindeki en önemli parametrelerden biri olan enerji yoğunluğunun belirlenmesi amaçlanmıştır. Bu amaçla cilt rengi ve melazmanın histolojik derinliği girdi olarak kullanılmıştır. Girdi olarak Melasma görüntü veri tabanı kullanılarak elde edilmiş hastaların cilt rengi, epidermis ve dermis kalınlığı kullanılmıştır. Bulanık mantık ile girdilerin aralıkları kullanılarak enerji yoğunluğu çıktı olarak elde edildi. Buna ilaveten, hangi lazerin hangi melasma tedavisine uygun olacağı da belirtilmiştir. Bu çalışmanın sonunda, enerji yoğunluğu tedaviye uygun seçilen lazer tipi için tanımlandı. Uygun olmayan değerlerin kullanılması hastanın cildi üzerinde birçok yan etkiye neden olabilir. Lazer parametre ayarlaması uzmanlar tarafından kritik ve tartışmalı bir konu olduğu için bu çalışma yapılmıştır.

Anahtar Kelimeler: *Bulanık Mantık, Lazer Tedavisi, Melazma Tedavisi.*

Abstract

In this study, determination of one of the most essential parameter in laser therapy which is fluence was aimed. For this purpose, skin color and histological depth of melasma were utilized as inputs. Melasma image database to define skin color of patients and thickness of epidermis and dermis were used as inputs. By using the ranges of the inputs with fuzzy logic, the output, fluence, was obtained. It is also stated which laser will be suitable for which melasma treatment. At the end of this study, the fluence was defined specifically for selected laser type. The use of inappropriate values can cause many side effects on the patient's skin. Since laser parameter adjustment is a critical and controversial issue by experts, this study has been carried out.

Key Words: *Fuzzy Logic, Laser Therapy, Melasma Treatment.*

1. Introduction

The skin contains melanin, the pigment that gives skin its color. Having more melanin makes the skin darker. Skin pigmentation problems are quite common nowadays. These problems can be refractory and recurrent, therefore patients are looking for various alternative methods, except for traditional treatment methods using topical medications. One of these alternative methods are laser and light therapy, which is in common today[1]. Various types of laser can be used in the treatment of melasma. The most common of these are Q-switched Nd:YAG, Er:YAG, Q-switched alexandrite, ruby, pulsed dye laser, and various fractional lasers. Using appropriate laser type for melasma is important in terms of post-inflammatory hyper or hypopigmentation after treatment[2]. At the same time, irradiation with appropriate parameters

during treatment is one of the points to be considered in order to prevent carbonization, which is an undesirable condition in the skin. In the wrong application, some thermal damage may occur on the skin. This damages may vary depending on the wavelength of the light, the power level of the laser, the irradiation time, the optical and thermal characteristics of the target tissue, the thickness of the target tissue, and the blood perfusion rate[3]. To model uncertainty, one of the most frequent approaches is fuzzy logic. Since choosing the right parameters is controversial, it is predicted that fuzzy logic-based algorithm will ease the decision making at this stage[4].

Melasma is a skin problem that occurs as a result of the deterioration of skin pigmentation balance and excess melanin pigment accumulation. There are many factors that can cause melasma. Some of these are genetic factors, sunlight exposure, hormonal influences, thyroid disease[5]. The site of the lesions (craniofacial, malar, mandibular), histological depth of pigmentation (epidermal, dermal, mixed) and appearance under the Wood’s lamp (epidermal, dermal, mixed, indeterminate) are used for the classifications of melasma[2]. Non-ablative Q-switched lasers such as the Q-switched neodymium:yttrium–aluminium-garnet (QNd:YAG) lasers, Q-switched ruby laser (QSRL), pulsed dye laser (PDL) and ablative lasers like carbon dioxide (CO₂), erbium:YAG (Er:YAG) target the chromophore melanin and treat melasma with several parameters[6].

There are various studies that are conducted with the aim of melasma treatment by using laser therapy. These studies reveal how effective laser therapy is for pigmentation problems. Fuzzy logic-based studies of laser therapy on pigmentation problems are very rare in the literature. Thus, the novelty of this study is high. It is important to determine which types of laser with which parameters should be used in melasma treatment. Sarkar et al. discussed the effects of various lasers on pigmentation problems and also compared the results of several important studies in their article "Lasers for Treatment of Melasma and Post-inflammatory Hyperpigmentation"[2]. In another important article, "Evaluation of a Fuzzy Logic Controller for Laser Thermal Therapy", Choy et al. studied the effect of laser thermal therapy (LTT) on solid tumors using fuzzy logic controller (FLC). They placed the temperature sensor on the center and the boundary of the target tissue and determined the difference between the measured temperature and the target temperature, the velocity and the acceleration of the temperature changes for these two sensors as input values. As a result, if the target tissue exceeded the desired temperature, the laser output power was decreased, while if the target tissue could not reach the desired temperature, the laser output power was increased. Thus, they aimed to perform laser thermal therapy with the least damage[3]. In this study, the goal is to select correct input parameters by using fuzzy logic system to evaluate the most efficient result in melasma treatment without any thermal damage. Thus, this system can prevent long duration of treatment, pain and post-treatment skin damage.

2. Materials and Methods

2.1. Dataset and Skin Type Grouping

For the first input ‘Skin Color’, a melasma image database was obtained from “<https://dermnetnz.org/topics/melasma-images/>” web site. There were 23 skin images which have melasma. By using this database, skin color were grouped in dark skin and light skin[7]. The images obtained from melasma image database were examined via patient skin color intensity by using ImageJ application. There were a range between 0 and 255 in intensity level. In this process, minimum and maximum intensity levels of each patient were evaluated. This data were used in the range of the input parameters of fuzzy logic system.

2.2. Determination of the Histological Depth of Melasma

Melasma occurs due to the overproduction of melanocyte cells that make up the color of the skin. These cells can occur in the epidermis, which is the upper layer of the skin, in the dermis, lower layer of the skin, or as a mixed type that can occur in both areas. Both the epidermis and dermis layer can be found in different thicknesses in certain parts of the body. The epidermis layer can have a minimum thickness of 0.05 mm and a maximum thickness of 1.5 mm, while the dermis layer can have a minimum thickness of 0.6 mm and a maximum thickness of 3 mm[8].

2.3. Fuzzy Logic System

Fuzzy logic was developed in 1965 by Prof. Dr Lotfi A. Zadeh. Zadeh identified the fuzzy set as a group of items with membership degrees. According to this system, each item in the fuzzy set is ranked according to the membership function ranging from zero to one. It does not have strict boundaries like Boolean logic. A fuzzy inference system is needed to design a fuzzy logic controller. A fuzzy inference system consists of the fuzzification process, the rule base, the fuzzy inference system (decision-making module), and the defuzzification process[9].

In this study, there were two inputs and one output. The inputs were skin color and histological depth of melasma while the output was the fluence of the defined laser. Skin color was given as dark and light skin. By using ImageJ, intensity of the light skin ranged between 76 to 255 and intensity of dark skin varied between 36 to 185. Histological depth of melasma were classified among epidermis, dermis and mixed type. Epidermal depth was determined as 0.05 mm to 1.5 and dermal depth was calculated as 0.65 mm to 4.5 mm. Moreover, MATLAB® R2020a Fuzzy Logic Toolbox™ was used in the fuzzy logic system design. The applied method was min max theorem with the rule base Mamdani and for the defuzzification process centroid method was used. In continuation of designing membership fuction step, four types of laser were used. The accurate type of lasers in melasma treatment was shown in Table 1 according to several papers. The output was set as fluence range of the lasers[10][2][11]. Then, fuzzy rules were prepared.

2.4. Fluence for Specific Laser Types

In each melasma treatment, different parameters and laser types have to be used in order to achieve accurate results. By investigating the popular studies in this field such as [10][2][11], appropriate laser types were demonstrated in Table 1. For treatments with each laser type, fluence range have to be set to avoid carbonisation and other side-effects in the skin. The optical fluence is the optical energy per unit area at some location and its formula was stated as below. The fluence ranges for the lasers were shown in Table 2.

Skin Color	Histological Depth of Melasma		
	Epidermal	Dermal	Mixed
Light	Nd:YAG 532 nm	Er:YAG 2940 nm	Ruby Laser 694 nm
Dark	Nd:YAG 532 nm	Nd:YAG 1064 nm	Nd:YAG 1064 nm

Table 4. Laser Types via Melasma Treatment Parameters

Laser Type	Fluence Range (J/cm ²)	
	Minimum	Maximum
Nd:YAG 532 nm	0.4	4.0
Nd:YAG 1064 nm	3.0	4.0
Ruby Laser 694 nm	4.0	8
Er:YAG 2940 nm	5.1	7.6

Table 5. Fluence Ranges in Laser Types

3. Results

In this study, firstly melasma image database was obtained then, images were evaluated by using ImageJ via skin color intensity. The second input as histological depth of melasma was determined according to the thickness of epidermis and dermis layer of the skin. By using MATLAB® R2020a Fuzzy Logic Toolbox™, the input and output parameters were set and 6 rules were utilized. Finally, the output as fluence range was determined. In a sample, skin color was selected with the intensity as 200 which means the patient has light skin tone while the second input was set as 4 mm which implies the melasma is only in dermis layer. After the fuzzification, rule base and defuzzification steps, it is known that Er:YAG laser with the wavelength 2940 nm should be used with the fluence 6.03 J/cm².

4. Discussion

Today, the use of lasers in melasma treatment is undeniably large and there are many studies about the use of lasers in these applications. Fuzzy logic, on the other hand, is a very convenient method for obtaining results in controversial issues. Therefore, this study has a great importance in the literature. Experts in applying melasma treatment with laser therapy should be careful about adjusting the parameter value because it is possible to have an unexpected side effect. For one of these parameters, the fluence value, the most appropriate adjustments were made for both the patient's skin color and the histological depth of the melasma, considering the most successful studies in the literature.

5. Conclusion

In this study, adjusting one of the most important laser parameter in melasma treatment which is the fluence value was obtained by using fuzzy logic system with the inputs skin color and histological depth of melasma. The results showed that this system can be able to decide the fluence easily. Also it can be said that in the future, by improving this work, the melasma can be detected using an image database and laser parameter adjustment can be made using a closed-loop system by using fuzzy logic control mechanism.

References

- [1] M. Trivedi, F. Yang, and B. Cho, “A review of laser and light therapy in melasma,” 2017.
- [2] R. Sarkar, V. Garg, L. Arya, and P. Arora, “Lasers for treatment of melasma and post-inflammatory hyperpigmentation,” *J. Cutan. Aesthet. Surg.*, vol. 5, no. 2, p. 93, 2012.
- [3] V. Choy, A. Sadeghian, M. D. Sherar, and W. M. Whelan, “<title>Evaluation of a fuzzy logic controller for laser thermal therapy</title>,” *Laser Tissue Interact. XIII Photochem. Photothermal, Photomech.*, vol. 4617, pp. 77–86, 2002.
- [4] A. S. Szalas and A. Szalas, “Paraconsistent reasoning with words,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2009, vol. 5070 LNCS, pp. 43–58.
- [5] W. E. Roberts, M. Henry, C. Burgess, N. Saedi, S. Chilukuri, and D. A. Campbell-Chambers, “Laser Treatment of Skin of Color for Medical and Aesthetic Uses With a New 650-Microsecond Nd:YAG 1064nm Laser,” *J. Drugs Dermatol.*, vol. 18, no. 4, pp. s135–s137, Apr. 2019.
- [6] O. A. Ogbechie-Godec and N. Elbuluk, “Melasma: an Up-to-Date Comprehensive Review,” *Dermatology and Therapy*, vol. 7, no. 3. Springer Healthcare, pp. 305–318, 01-Sep-2017.
- [7] “Melasma images | DermNet NZ.” [Online]. Available: <https://dermnetnz.org/topics/melasma-images/>. [Accessed: 17-May-2021].
- [8] “Skin Anatomy: The Layers of Skin and Their Functions.” [Online]. Available: <https://www.verywellhealth.com/skin-anatomy-1068880>. [Accessed: 17-May-2021].

- [9] T. Dereli, C. Cetinkaya, and N. Celik, “Designing a Fuzzy Logic Controller Intersection : a Case Study in Gaziantep for Single,” *Sigma J. Eng. Nat. Sci.*, vol. 36, no. 3, pp. 767–781, 2018.
- [10] S. Hilton, H. Heise, B. A. Buhren, H. Schrumpf, E. Bölke, and P. A. Gerber, “Treatment of melasma in Caucasian patients using a novel 694-nm Q-switched ruby fractional laser,” *Eur. J. Med. Res.*, vol. 18, no. 1, 2013.
- [11] R. M. P. Manaloto and T. Alster, “Erbium:YAG laser resurfacing for refractory melasma,” *Dermatologic Surg.*, vol. 25, no. 2, pp. 121–123, 1999.

S-50 GERÇEK ORTAMDA ZEYTİN MEYVESİNİN YOLOV4 NESNE TANIMA ALGORİTMASI İLE TESPİTİ

Demet OFLAZOGLU ¹, Ersin ÖZDEMİR ²

¹ Elektrik-Elektronik Müh. A.B.D., İskenderun Teknik Üniversitesi, Türkiye,
demetoflazoglu.mfbel8@iste.edu.tr

² Elektrik-Elektronik Müh., İskenderun Teknik Üniversitesi , Türkiye,
ersin.ozdemir@iste.edu.tr

Özet

Gelişen tarım teknolojileri ile birlikte yapay zeka ve görüntü işleme tekniklerinin kullanımının artması, birçok üretim sürecinin otomatik olarak gerçekleşmesine imkan sağlamıştır. Otomatik hasat sistemlerinin başarılı olabilmesi için sistemin modellenmesinde kullanılacak veritabanının önemi büyüktür. Bu çalışmada, zeytin ağacının meyvesine ait görüntü veritabanı oluşturulmuş ve bu veritabanındaki resimlere çeşitli görüntü işleme teknikleri ve meyve etiketleme işlemleri uygulanmıştır. Oluşturulan veritabanı ile YOLOv4 algoritması kullanılarak zeytin meyvesinin tespiti için modelleme yapılmıştır. Oluşturulan model ile %95’lik bir tanıma oranı elde edilmiştir.

Anahtar Sözcükler: *Derin Öğrenme; YOLOv4; Zeytin Meyvesi Tespiti*

Abstract

The use of artificial intelligence and image processing techniques in agriculture has enabled many production processes to take place automatically. In order for automatic harvesting systems to be successful, the database to be used in the modeling of the system is of great importance. In this study, an image database of the fruit of the olive tree was created and various image processing techniques and fruit labeling processes were applied to the images in this database. Modeling was done for the detection of olive fruit by using the YOLOv4 algorithm with the created database. With the created model, a recognition rate of 95% was obtained.

Keywords: *Deep Learning; YOLOv4; Olive Fruit Detection*

1. Giriş

Gelişen teknoloji ile her alanda kısıtlı kaynakların daha verimli değerlendirilmesi insan gücünün minimuma, verimliliğin ise maksimuma çıkarılması ana hedeftir. Geçmişten günümüze tarımda kullanılan ve kullanım alanları genişleyen makineleşme ile birlikte ekim, sulama, hasat, ilaçlama, bakım vb. süreçler otomatize edilerek süre, işgücü gibi konularda tasarruf sağlanmış ve verim arttırılmıştır. Ancak bazı bitki türlerinde meyvelerinin yerden yüksekte, dal ve yapraklarının fazla olması gibi olumsuzluklar otomatik hasat sürecini zorlaştırmaktadır. Bu aşamada tıpkı insanların elle toplama süreçlerini taklit edebilecek robot kollara olan ihtiyaç artmaktadır. Kişiselleştirilmiş bir meyve hasat robotunun mekanik kolu ağaçtaki her meyve parçasına doğru yönlendirebilmelidir. Bu nedenle, meyvenin konumu üç

boyutlu düzlem üzerinde hesaplanmalıdır. Meyvelerin tespiti ve hasadın otomatik olarak gerçekleştirilebilmesi için literatürde birçok çalışma mevcuttur.

Meyvelerin otomatik olarak tespit edilmesine ilk çalışmalar 1968’li yıllara dayanır. Schertz ve Brown [1], meyvelerin konumunun o dönemin kısıtlı imkanları kullanılarak fotometrik bilgilerle, özellikle elektromanyetik spektrumun görünür veya kızılötesi kısmında yapraklar ve meyveler arasındaki ışık yansıtma farkları kullanılarak belirlenebileceğini öne sürmüştür. Jimenez ve ark. [2] meyve rengi veya olgunluk aşamasından bağımsız olarak portakal, şeftali ve elma gibi küresel şekilli herhangi bir meyveyi tespit etmek için şekil analizine dayanan bir lazer telemetre kullanmışlardır. Kanae ve ark. [3], 3 boyutlu kırmızı kızılötesi lazer diyotlardan oluşan bir görüş sensöründen alınan anlık görüntüleri işleyerek kirazların ve engellerin yerini tespit etmiş ve 4 serbestlik derecesine sahip bir robotla kiraz hasadını gerçekleştirmişlerdir. Yuki ve ark. [4], bir stereo kamera ile meyvelerin 3 boyutlu konumunu sadece bir derin sinir ağı kullanan SSD (Single Shot MultiBox Detector) yöntemiyle tespit etmiş ve 6 serbestlik derecesine sahip robot kol ile elma hasadını gerçekleştirmişlerdir. Boaz ve ark. [5], özel olarak tasarlanmış bir uç efektör, RGB-D kamera, grafik işleme ünitesi ile 6 serbestlik derecesine sahip endüstriyel bir robot kol ile tatlı biber hasat makinesi geliştirmişlerdir. Christopher ve ark.[6] uç efektöre yerleştirilmiş bir RGB-D kamera ile Kinect Fusion (Gerçek Zamanlı Yoğun Yüzey Haritalama ve İzleme) algoritmasını kullanarak bir algılama sistemi oluşturmuş ve biberlerin yerlerini tespit etmişlerdir. Daha sonra her bir biberin 3 boyutlu şeklini belirlemiş ve buna göre kesme veya kavrama noktalarını seçmiş ve hasat işlemini gerçekleştirmişlerdir. Mu ve ark.[7], Kinect sensöründen alınan bilgilerden görüntü işleme teknikleri ile kivi meyvesinin konumunu tespit ederek hasadı gerçekleştirmişlerdir. Anna ve ark.[8], hasat robotlarında kullanılmak üzere YOLOv3 algoritması ile ağaçtaki yeşil ve kırmızı elma meyvesini tespit eden bir çalışma yapmışlardır. Yapmış oldukları çalışmada %87 doğruluk oranında bir başarı elde etmişlerdir.

Literatürde birçok meyve için çeşitli tespit yöntemleri denenmiş olsa da özellikle ülkemizin akdeniz ikliminin hakim olduğu güney ve ege bölgesinde yetişen zeytin meyvesi için az sayıda literatür çalışması yer almaktadır. Gabriel ve ark.[9] zeytin ağacından alınan dalların kontrollü bir ortamda sabit bir fon kullanılarak elde edilen RGB görüntüleri üzerinden yapay sinir ağları ve temel bileşenler analizini kullanarak zeytin tanınması yapmışlardır. Çalışmada kullanılan veri setinin, kontrollü ortam ve fon ile elde edilmiş olması çalışmanın gerçek zamanlı başarısını olumsuz etkiler.

Türkiye, zeytinyağı ve sofralık zeytin üretiminde dünya ülkeleri arasında önemli bir paya sahiptir. Son yıllarda Türkiye genelinde zeytin alanları artış göstermiş ve üreticiler verim arttırıcı uygulamalara yönelmiştir. Dolayısıyla zeytin üretiminde önemli artışların olması beklenmektedir. Ancak buna paralel olarak hasat süreleri ve maliyetlerinin de artması beklenen bir sonuçtur. Zeytin meyvesinin hasadında günümüzde elle, sırkla vurarak, titreşimli veya sensörlü teleskopik hasat makinaları gibi yöntemler tercih edilmektedir. Her bir yöntemin hasatta farklı bir zorluğu ve olumsuz etkisi mevcuttur. Örneğin, elle veya sırkla vurarak

toplamak çok yorucu ve zaman alan bir yöntemdir. Hasadın hem sonbahar aylarına denk gelmesi hem de insan işgücü ihtiyacının çok olması sebebiyle işçi maliyetleri, üretim maliyetlerinin ciddi oranda artmasına sebep olmaktadır. Titreşimli veya teleskopik hasat makinalarında ise sadece yağlık zeytinler toplamak mümkündür. Çünkü sofralık zeytinlerin zarar görmemesi için elle toplanması gerekmektedir. Ayrıca bu tip makinalar ağaçlarda hem fazla yaprak kaybına hem de bir sonraki senenin mahsulünü verecek olan yeni filizlenmiş dalların zarar görmesine neden olabilmektedir. Dolayısıyla zeytin hasadının otomatik olarak gerçekleştirmesi hem insan iş gücü hem de verimlilik ve hasat maliyetleri için önem taşımaktadır. Bu amaçla, yapılan bu çalışmada otomatik hasat robotları için görüntü işleme teknikleri ve yapay zeka yöntemleri kullanılarak zeytin meyvesinin tespiti hedeflenmiştir.


Çalışmanın sonraki bölümünde zeytin meyvesi için veri setinin oluşturulması, görüntülerin ön işlem ve etiketleme adımları, derin öğrenme ağı ile zeytin meyvesi tanıma modelinin oluşturulması ve başarımların sonuçları yer almaktadır.

2. Materyal ve Yöntem

2.1. Veri Setinin Oluşturulması


Oluşturulan veri setinde iki farklı kaynaktan elde edilmiş resimler bulunmaktadır. Kamera ile çekilen resimler 1280x960 piksel iken, cep telefonu kamerası ile çekilen resimler ise 4032x2268 piksel çözünürlüğe sahiptir. Veri setinde bulunan resimlerin çözünürlükleri birbirinden farklı olması sebebi ile resim boyutları literatürdeki çalışmalara benzer şekilde aynı boyuta normalize edilmiştir. Resimlerin aynı boyuta getirilmesi için her bir resme Şekil-1 ile verilen örnekte olduğu gibi kayan pencere algoritması uygulanmış ve resimler 700x700 piksel boyutunda kırılmıştır.

Kayan pencere algoritması uygulandıktan sonra elde edilen resimler içerisinde, içerisinde yeterli sayıda zeytin meyvesi bulunan toplam 1413 adet resim seçilmiştir. Bu resimler; güneş ışığı, yapay ışık(flaş) gibi farklı ortam özelliklerine sahiptir.



Şekil 1. Kayan Pencere Algoritması (700x700 pencere)

Veri seti oluşturulduktan sonra BBox-Label-Tool[10] yardımıyla resim üzerindeki zeytinler etiketlenmiş (Şekil 2) ve her bir zeytinin resim dosyasındaki koordinatları bir metin dosyasına kaydedilmiştir.



Şekil 2. BBox-Label-Tool ile zeytin meyvesinin etiketlenmesi

2.2. Modelleme

Çalışmada YOLO (You Only Look Once)[11, 12] kullanılmıştır. YOLO mimarisi, evrimsel sinir ağı kategorisinde kabul edilen, özellikle görüntü üzerinde gerçek zamanlı hızlı nesne tespiti yapabilen bir algoritmadır. Daha önceki derin öğrenme algoritmalarında, resimlerden nesnelerin tespit edilmesi için tek bir görüntüye birkaç kez farklı bölge ve/veya ölçeklerde yapay sinir ağlarına dayalı sınıflandırma modeli uygulanmaktaydı. YOLO algoritmasında ise bir sinir ağı resmin tamamına uygulanır ve görüntü bölgelere ayrılarak her nesne için nesnelerin kapsamı ve sınıfların olasılıkları belirlenir. YOLO algoritması kullanarak özel nesne tespit aşamaları Şekil 3’te verilmiştir. Modelin eğitimi Google COLAB üzerindeki GPU’lar (24-40 core) kullanılarak YOLOv4/darknet aracılığıyla gerçekleştirilmiştir. Çalışmada YOLOv4-tiny-custom kullanılmış ve parametreleri kullanılan sınıf sayısına uygun olarak güncellenmiştir.



Şekil 3. Sistem modellemesine ilişkin blok diyagram

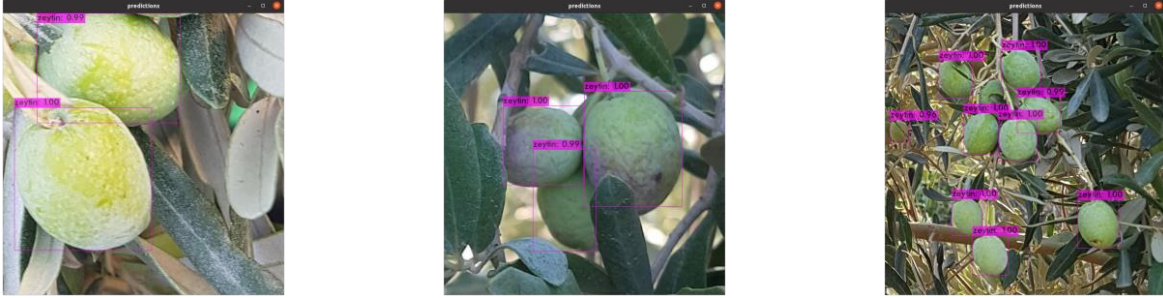
2.3. Sonuçlar

Eğitim ve test veri setinde bulunmayan 15 adet resim üzerinde yapılan sınıflandırma sonuçları Tablo 1’de verilmiştir. Bu resimlerde bulunan toplam zeytin sayısı 92 tanedir. Eğitilen model

zeytinlerin 87 tanesini doğru tespit etmiş, 5 tanesi tespit edilememiştir. Model başarısı kullanılan test veri seti için %95’lik bir başarıya ulaşmıştır. Modelin zeytin olmayıp zeytin olarak sınıflandırdığı nesne bulunmamaktadır. Şekil 4’te modele ait tahmin sonuçları verilmiştir.

Tablo 1. Modelin sınıflandırma sonuçları

Toplam Zeytin Sayısı	Doğru Tespit Edilen	Yanlış Tespit Edilen	Tespit Edilemeyen
92	87	0	5



Şekil 4. Modele ait tahmin sonuçları

Yapılan bu çalışma ile ağaç üzerindeki zeytin meyvesini tespit edebilen bir derin öğrenme modeli oluşturularak zeytin hasadının ilk aşaması gerçekleştirilmiştir.

Çalışmalar, konumu belirlenen zeytin meyvelerinin birden fazla robot kol ile toplanabilmesi için gerekli algoritmanın geliştirilmesi konusunda devam etmektedir.

Referanslar

- [1] E. Schertz, and GK Brown, "Basic considerations in mechanizing citrus harvest," Transactions of the ASAE, vol. II, no. 3, pp. 343-346, 1968.
- [2] A.R. Jimenez, R. Ceres, and J. L. Pons, "A survey of Computer Vision Methods for Locating Fruit on Tree", ASAE, 43: p. 1911-1920, 2000.
- [3] K. Tanigaki, T. Fujiura, A. Akase, and J. Imagawa, "Cherry-harvesting robot," Comput. Electron. Agric., vol. 63, no. 1, pp. 65–72, 2008.
- [4] Y. Onishi, T. Yoshida, H. Kurita, T. Fukao, H. Arihara, and A. Iwai, "An automated fruit harvesting robot by using deep learning," ROBOMECH J., vol. 6, no. 1, 2019.

- [5] B. Arad et al., “Development of a sweet pepper harvesting robot,” *J. field robot.*, vol. 37, no. 6, pp. 1027–1039, 2020.
- [6] C. Lehnert, A. English, C. McCool, A. W. Tow, and T. Perez, “Autonomous sweet pepper harvesting for protected cropping systems,” *IEEE Robot. Autom. Lett.*, vol. 2, no. 2, pp. 872–879, 2017.
- [7] L. Mu et al., “Design of end-effector for kiwifruit harvesting robot experiment,” in 2017 Spokane, Washington July 16 - July 19, 2017, 2017, p. 1.
- [8] A. Kuznetsova, T. Maleva, and V. Soloviev, “Using YOLOv3 algorithm with pre- and post-processing for apple detection in fruit-harvesting robot,” *Agronomy (Basel)*, vol. 10, no. 7, p. 1016, 2020.
- [9] G. Gatica, S. Best, J. Ceroni, and G. Lefranc, “Olive fruits recognition using neural networks,” *Procedia Comput. Sci.*, vol. 17, pp. 412–419, 2013.
- [10] BBox-Label-Tool, Sep 2021, [online] Available: <https://github.com/puzzledqs/BBox-Label-Tool>.
- [11] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” *arXiv [cs.CV]*, pp. 779–788, 2015.
- [12] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal speed and accuracy of object detection,” *arXiv [cs.CV]*, 2020.

S-27 YUSUFÇUK ALGORİTMASI İLE TERMOPLASTİK HİBRİT KOMPOZİTLERİN ÜRETİMİNDE KATKI MADDELERİ ORANLARININ OPTİMİZASYONU

Ercüment ÖZTÜRK^{1,*}, Ayfer DÖNMEZ ÇAVDAR^{2*}, Tuğrul ÇAVDAR³

¹ Bilgisayar Mühendisliği, Karadeniz Teknik Üniversitesi, Türkiye,
ercumentozturk@ktu.edu.tr

² Orman Endüstri Mühendisliği, Karadeniz Teknik Üniversitesi, Türkiye,
adonmez@ktu.edu.tr

³ Bilgisayar Mühendisliği, Karadeniz Teknik Üniversitesi, Türkiye, ulduz@ktu.edu.tr

Özet

Hammadde kaynaklarının yüksek maliyetli olması, tükenme noktasına ulaşmaya yakın olması ve kalitenin artırılması gerekliliği nedeniyle kompozit üretime yönelim son dönemlerde giderek artmıştır. Bununla birlikte, kompozit üretiminde kalite, zaman ve maliyet iyileştirmeleri yapmak gerekmektedir. Bu çalışmada Yusufçuk Algoritması kullanılarak termoplastik hibrit kompozit malzemelerin karışım bileşenlerinin / oranlarının optimize edilmesi üzerinde çalışılmıştır. Elde edilen sonuçlar başka bir optimizasyon algoritması olan Parçacık Sürü Optimizasyon Algoritması (PSO) ile elde edilen sonuçlar karşılaştırılmış ve iki algoritmanın çalışma üzerindeki başarımlarının birbirine yakın olduğu gözlemlenmiştir. Sonuç olarak, kompozit üretiminde yapay zekanın kullanılmasıyla üretim sürecini kısaltması, kaliteyi artırması ve üretim öncesi deneysel çalışmalara bağlı maliyeti ciddi oranda düşürmesi sağlanmıştır.

Anahtar Sözcükler: *Optimizasyon, Termoplastik Hibrit Kompozitler, Yapay Zekâ, Yusufçuk Algoritması.*

Abstract

Due to the high cost of raw material resources, being close to the point of depletion and increasing quality, the tendency to composite production has increased in recent years. However, it is necessary to make quality, time, and cost improvements in composite production. In this paper, we studied on optimizing the mixture components / ratios of thermoplastic hybrid composite materials using the Dragonfly Algorithm. The obtained results were compared with the results obtained with another optimization algorithm, Particle Swarm Optimization Algorithm (PSO), and it was observed that the performances of the two algorithms on the study were close to each other. As a result, with the use of artificial intelligence in composite production, it has been provided to shorten the production process, increase the quality, and significantly reduce the cost related to pre-production experimental studies.

Keywords: *Optimization, Thermoplastic Hybrid Composites, Artificial Intelligence,*

Dragonfly Algorithm.

1. Giriş

Kompozit malzemelerin üretim ve kullanımı çok eskilere dayanmaktadır. Milattan Önce (MÖ) başlayıp günümüze kadar gelen süreçte farklı amaç ve ihtiyaçlar doğrultusunda çok farklı çeşitlerde kompozit malzeme üretilmiş ve kullanılmıştır. Süreç içerisinde özellikle savunma, inşaat, mühendislik ve üretim sektörlerinde farklı uygulama alanları için geniş bir yelpazede kompozit malzeme üretimi sürdürülmüştür [1]. Kompozit malzeme, geleneksel malzemelerde olmayan veya sınırlı olan bazı özellikleri geliştirebilmek için birbirinden farklı fiziksel, kimyasal ve termal özelliklere sahip ve birbiri içerisinde çözünemeyen en az iki bileşen (biri ana malzeme (matris) ve bir veya daha fazla takviye malzeme)’den meydana getirilen ve elde edilen ürünün önceki bileşenlerinden farklı özelliklere sahip olduğu karışım ürünüdür. Kompoziti oluşturan bileşenler arasında kimyasal bağ oluşmaz. Bir başka ifadeyle, aralarında atomik bir bileşik oluşturmazlar [2]. Matris veya matriks; kompozit içindeki elyafları destekleyen ve onları bir arada tutan ana yapıdır. Kompozit yapıya uygulanan kuvvet matris tarafından karşılanır ve elyaflara aktarılır. Ayrıca matris, elyafların belirlenen düzende kalmasını ve mevcut konumlarını korumalarını sağlar.

Günümüzde, endüstri alanında kullanılması düşünülen ve istenen hemen hemen tüm özellikleri sağlayan yegâne malzeme grubunun kompozitler olduğu düşünülmektedir. Kompozitler gelişen teknolojiyle kullanımı yaygınlaşan bir malzeme olduğundan, birçok ülkede Ar-Ge çalışmaları bu malzemeler üzerinde devam etmektedir. Kısacası diğer malzemelere göre daha yüksek mukavemet/yoğunluk oranına sahip olmaları, daha dayanıklı ve hafif olmaları kompozitleri kıymetli yapan en büyük özelliktir. Kompozit malzemelerin yüksek ve homojen bir kaliteyi garanti edebilmesi ve üretim maliyetlerinin kabul edilebilir düzeyde tutulabilmesi için yüksek teknolojiye dayalı bir işlemin uygulanması şarttır.

Kompozit malzeme üretimindeki temel amaç; tek başına bir malzeme ile elde edilemeyen dayanım, tokluk, elektrik iletkenliği, termal iletkenlik, ağırlık (yoğunluk), termal genleşme, sertlik, dayanım, kırılma direnci gibi özelliklerin artırılmasıdır [3], [4], [5]. Bununla birlikte, tek başına uygun olmayan, birbiri içerisinde çözünemeyen malzemeleri kullanım alanlarına uygun özellikleri verebilecek duruma getirmek için yeni özellikler katmaktır. Gelişen teknoloji ve sanayileşmeden kaynaklanan malzeme ihtiyacı, kompozit malzemelerin keşfedilip, geliştirilmesine katkıda bulunur [6]. Savunma sanayi, uzay teknolojisi, balistik ve havacılık, inşaat, otomotiv, kara ve deniz ulaşımı, sağlık, robotik, kimya, elektrik-elektronik, müzik aletleri, gıda ve tarım, spor malzemeleri ve enerji gibi geniş bir kullanım yelpazesine sahip olan kompozitlerin istenilen özelliklerde üretimi için birçok yöntem bulunmaktadır [7]. Bununla birlikte, üretilen kompozit malzemeler üzerinde çok sayıda testler uygulanır ve bu testler sonucunda üretilen kompozitin kalitesi belirlenir.

Kompozit ürünler üzerine gerçekleştirilen testler şunlardır; Eğilme Direnci Testi, Çekme Direnci Testi, Darbe Direnci Testi, Dinamik Mekanik Termal Analiz (DMTA) Testleri, HidroTesti, Termogravimetrik Analiz (TGA), Diferansiyel Taramalı Kalorimetri Analizi (DSC), Yanma Testleri

Bütün bu testler her üretim sonrasında yapılmakta ve her deney için üretim maliyetini çok büyük oranda arttırmaktadır. Bu nedenle üretim aşaması öncesinde daha önceki deneylerden elde edilen veriler doğrultusunda yapay zekâ kullanılarak optimizasyon işleminin yapılması ve böylelikle hem zamandan kazanç elde edilmesi hem de üretim test aşamasındaki büyük maliyetin önüne geçilmesi amaç edinilmiştir.

Bu amaç doğrultusunda Yusufçuk Algoritması kullanılarak hammadde katkı oranlarının iyileştirilmesi yapılmış ve yeni bir üretim reçetesi elde edilmiştir. Elde edilen bu üretim reçetesi ile PSO algoritmasıyla elde edilen sonuçlar ile karşılaştırılmıştır.

2. Amaç

Kompozit malzeme üretiminde yüksek maliyet, deneysel çalışmalar için gereken uzun zaman dilimleri ve son ürün kalitesinin bireysel tecrübeye dayalı olması ileri teknolojiden yararlanmayı zorunlu hale getirmiştir. Bu anlamda yapay zekâ optimizasyon algoritmalarından yararlanılarak belirtilen kriterleri sağlama amaç edinilmiştir. Bununla birlikte, Yusufçuk Algoritmasının kolay kullanılabilirlik, uyarlanabilirlik ve verimliliği dikkate alındığında termoplastik hibrit kompozit malzeme üretiminde kullanılmasını yaygınlaştırmak ve bu alandaki çeşitli problemler üzerindeki etkinliğini arttırmak hedeflenmiştir. Termoplastik hibrit kompozit malzeme üretimindeki süreçlerin sürü yapısıyla benzerlikler göstermesi bu alandaki reel problemlerin çözümünde çok daha işlevsel ve verimli sonuçlar alınabileceği öngörülmektedir. Ayrıca, üretim öncesinde kontrol grubu için gerekli olan zorunlu deneysel üretimlerin sezgisel algoritmalar ile simülasyonları yapılarak istenilen maliyet, zaman ve kalite kriterlerini sağlanmasını kolaylaştırmaktadır. Nitekim daha önce yapmış olduğumuz çalışmalar bu öngörüğü desteklemektedir [8].

3. Materyal ve Yöntem

Yusufçuk Algoritması, 2016 yılında Mirjalili tarafından yusufçukların doğadaki davranışlarından ilham alınarak geliştirilen, çeşitli optimizasyon problemlerini çözmek için kullanılan yeni bir meta sezgisel bir yapay zekâ optimizasyon algoritmasıdır [9]. Meta-sezgiseller, bilgisayar bilimi, yöneylem araştırması, biyo-enformatik ve mühendislik gibi çeşitli alanlarda birçok araştırma alanının ilgisini çeken optimizasyon algoritmalarıdır. Bu durum, sezgisel algoritmaların çeşitli optimizasyon problemlerini makul bir sürede çözmek için basitlik, esneklik ve sağlamlıklarından kaynaklanmaktadır. Çeşitli alanlarda kapsamlı bir dizi kullanım ve uygulamayı optimize etmek için araştırmacılar tarafından sıkça kullanılan algoritmalarından biridir. Bazen en iyi bilinen optimizasyon tekniklerine kıyasla üstün

performans sunar. Bununla birlikte, bu algoritma karmaşık optimizasyon problemlerini geliştirmek için kullanıldığında çeşitli zorluklarla karşı karşıya kalmaktadır [10].

Algoritma yusufçukların gezinme, yiyecek arama, dinamik veya istatistiksel olarak sürü halindeyken düşmanlardan kaçınmadaki sosyal etkileşimi modellenerek tasarlanmıştır. Tüm bireylerin ve sürüsel davranışların temel amacı hayatta kalmak olsa da avlanma, savunma, keşif ve yiyecek arama gibi çeşitli nedenlerle sürüler halinde iş birliği yapar ve etkileşime girerler. Yusufçuklar, dünya üzerinde yaklaşık 3000 farklı türü bulunan süslü böceklerdir [11]. Yusufçuklar, doğadaki hemen hemen tüm diğer küçük böcekleri avlayan küçük yırtıcı hayvanlar olarak kabul edilir. Yusufçuklar sadece iki amaç için toplanır: avlanma ve göç. Avlanma sürüsü statik(beslenen), göç sürüsüne ise dinamik (göç eden) sürü adı verilir. Algoritmanın ana ilham kaynağı, statik ve dinamik sürü davranışlarından gelmektedir. Bu iki davranış, meta-sezgisel yöntemlerin kullanıldığı iki ana optimizasyon aşamasına çok benzer: keşif ve kullanım. Yusufçuklar, keşif aşamasının temel amacı olan statik bir sürüde alt sürüler oluşturur ve farklı alanlar üzerinde uçar. Bununla birlikte, statik sürüde, yusufçuklar daha büyük sürüler halinde ve tek bir yön boyunca uçarlar, bu da kullanım aşamasında elverişlidir [9].

Yusufçuk algoritmasının kolay uygulanabilir olması ve verimliliği nedeniyle, farklı alanlarda kullanımını arttırmaktadır. Yusufçukların davranışı, ayrılma, hizalanma, uyum, düşmanlardan uzaklaşma ve yiyeceğe karşı çekim ilkelerini takip eder. Sürü davranışı bu temel beş operatör tarafından belirlenir [12]. Bununla birlikte, Sürüdeki her bir yusufçuk, reel problemlerin arama uzayındaki bir çözüme karşılık gelmektedir [13]. Yusufçukların sürü davranışlarını modellemek için beş temel ilkedden yararlanılmaktadır [14], [9].

1. Ayrılma, bireylerin gruptaki diğer bireylerle çarpışmaktan kaçınmak için takip ettikleri yol
2. Hizalama, bireyin aynı grubun diğer komşu bireyleri arasındaki hız eşleşmesi
3. Uyum, bireylerin sürünün merkezine doğru eğilimi
4. Besin kaynağına yönelme isteği
5. Düşmanlardan kaçınma

Algoritma kodlanırken her bir yusufçuk muhtemel bir çözüm şeklinde değerlendirilmiştir. Ayrılma kriteri; her bir olası çözümün karışıma dahil edilen hammaddelere benzemesinden kaçınmasını temsil eder. Hizalama kriteri; her bir olası çözümün diğer çözümler ile arasındaki değişim farkını temsil eder. Uyum kriteri; olası her bir çözümün optimum değere ulaşmaya çalışmasını temsil eder. Besin kaynağına yönelme kriteri; olası her bir çözümün hammaddelerden biri veya birkaçına benzeme isteğini temsil eder. Son olarak düşmanlardan kaçınma kriteri ise en kötü durumu (istenmeyen kalite ve kritere sahip ürün) temsil etmektedir.

Aşağıda formülü verilen amaç fonksiyonu kullanılarak simülasyon gerçekleştirilmiştir. Amaç fonksiyonuyla birlikte yemek kaynağı, düşman (en kötü durum), bireysel hız, komşuların konumu ve hızları, yön ve iterasyon sayıları da ayrıca işleme fonksiyonel olarak dahil edilerek işlemler yapılmıştır.

$$\text{Dragonfly}[i] = \frac{(x_i - \bar{x})^2}{n-1} \quad (i = 0 \dots n) \quad (x_i: \text{olası bir çözüm, } n: \text{yusuřuk sayısı})$$

4. Bulgular


Bu çalışmada, Yusufçuk Algoritması kullanılarak termoplastik hibrit kompozit malzeme üretiminde, hammadde karışım oranlarının belirlenmesi ve belirlenen bu karışım oranlarıyla yeni üretim reçeteleri elde edilmiştir. Elde edilen bu üretim reçeteleri PSO algoritması kullanılarak elde edilen üretim reçeteleriyle karşılaştırılmıştır. PSO kullanılarak elde edilen üretim reçeteleriyle fiziksel üretimler gerçekleştirilmiş ve bu ürünler üzerinde çeşitli testler (*çekme ve eğilme testleri*) uygulanmıştır. Yapılan karşılaştırma işlemleri sonucunda iki algoritmanın da bu problemin çözümünde kullanılabilirliği ve sonuçlarının birbirine yakın olduğu gözlemlenmiştir.

Tablo 1. PSO ve Yusufçuk Algoritması kullanılarak elde edilen reçeteler.

Reçeteler	P1	P2	P3	P4	P5	Total
R1	68	2.00	7.129	17.130	5.739	100
R2	68	2.00	6.989	17.111	5.898	100
R3	66	3.76	7.100	17.200	5.940	100

Tablo 1’de görülen R1 ve R2 PSO algoritması kullanılarak elde edilen üretim reçeteleridir yani karışıma dahil edilme oranlarını, R3 ise Yusufçuk algoritması kullanılarak elde edilen üretim reçetesini göstermektedir. Reçetelerdeki değerlerin birbirine yakın olması çözüme konu olan problem üzerinde iki algoritmanın da başarılı bir şekilde çalıştığını göstermektedir. P1, P2, P3, P4 ve P5 değerleri de karışıma dahil edilen hammaddelerden her birini temsil etmektedir.

PSO ve Yusufçuk algoritmaları kullanılarak elde edilen üretim reçeteleri Tablo 1’de verilmiştir. R1 ve R2 üretim reçeteleri doğrultusunda üretilen ürünler üzerinde deneysel testler gerçekleştirilmiştir. Ayrıca, Yusufçuk algoritması ile elde edilen değerler ile karşılaştırılarak Şekil 1’de verilmiştir.



Şekil 1: PSO ve Yusufçuk algoritmaları ile elde edilen üretim reçetelerinin test sonuçları (Dikey sütunda ürünlere uygulanan tüm fiziksel test sonuçlarının sayısal değerleri toplanarak elde edilen sonuçları temsil eder)

5. Sonuç ve Öneriler

Bu çalışmada, sezgisel bir yapay zekâ optimizasyon algoritması olan Yusufçuk Algoritması ile daha öncesinde termoplastik hibrit kompozitler üzerinde deneysel çalışmalar sonucunda oluşturduğumuz (alanında kullanılan en büyük 2. veri seti) veriler üzerinde simülasyon çalışmaları yapıldı. Yapılan simülasyon sonuçları yine aynı veri seti üzerinde çalıştırılan PSO algoritmasının sonuçları ile karşılaştırıldı ve sonuçların birbirine yakın olduğu gözlemlendi. Bu durum Yusufçuk Algoritmasının bu alanda kullanılabileceğini göstermektedir.

Teşekkür

Bu çalışma 120O339 kodlu TÜBİTAK projesi kapsamında elde edilen veri setinden yararlanılarak gerçekleştirilmiştir.

Referanslar

- [1] mar-bal.com, “History of Composites,” [Online]. Available: <https://www.mar-bal.com/language/en/applications/history-of-composites/>. [Erişildi: 10 Eylül 2021].
- [2] Wikipedia, “Kompozit Malzemeler,” [Çevrimiçi]. Available: https://tr.wikipedia.org/wiki/Kompozit_malzemeler [Erişildi: 10 Eylül 2021].
- [3] M. Balasubramanian, Composite Materials and Processing, Florida: CRC Press, 2013.
- [4] F. L. Matthews ve R. D. Rawlings, Composite Materials: Engineering and Science, Florida: CRC Press, 1999.
- [5] M. Zor, “Kompozit Malzeme Mekaniği Ders Notları,” [Çevrimiçi]. Available: <http://mehmetzor.com/dersler/kompozit-malzeme-mekanigi/ders-notlari/>. [Erişildi: 11 Eylül 2021].
- [6] EuroLab Laboratory Services, “Kompozit Testleri,” [Çevrimiçi]. Available: <https://www.eurolab.com.tr/sektorel-test-ve-analizler/spesifik-testler/kompozit-testleri>. [Erişildi: 10 Eylül 2021].

- [7] Ü. Kirenci. “Kompozit Malzeme Üretim Yöntemleri,” [Çevrimiçi]. Available: <https://acemimuhendis.com/2011/06/22/kompozit-malzeme-uretim-yontemleri/>. [Erişildi: 11 Eylül 2021].
- [8] A. Dönmez Çavdar, E. Öztürk ve T. Çavdar, “A Novel Approach to Determine the Amount of Natural Fiber and Polymer of Composite Materials via Artificial Neural Networks,” International Conference on Artificial Intelligence and Data Processing (IDAP), Malatya, 2018.
- [9] S. Mirjalili, “Dragonfly Algorithm: A New Metaheuristic Optimization Technique for Solving Singleobjective, Discrete, and Multi-Objective Problems,” Neural Computing and Applications, no. 27, p. 1053–1073, 2016.
- [10] C. M. Rahman, T. A. Rashid, A. Alsadoon, N. Bacanin, P. Fattah ve S. Mirjalili, “A Survey on Dragonfly Algorithm and Its Applications in Engineering,” Evolutionary Intelligence, pp. 1-21, 2021.
- [11] J. H. Thorp ve D. C. Rogers, “Thorp and Covich’s Freshwater Invertebrates: Ecology and General Biology,” Amsterdam: Elsevier, 2014.
- [12] C. W. Reynolds, “Flocks, Herds and Schools: A Distributed Behavioral Model,” 14th Annual Conference on Computer Graphics and Interactive Techniques, New York, 1987.
- [13] S. Ranjini K.S. ve S. Murugan, “Memory Based Hybrid Dragonfly Algorithm for Numerical Optimization Problems,” Expert Systems with Applications , cilt 83, pp. 63-78, 2017.
- [14] Y. Meraihi, A. Ramdane-Cherif, D. Acheli ve M. Mahseur , “Dragonfly Algorithm: A Comprehensive Review and Applications,” Neural Computing and Applications, p. 16625–16646, 2020.

S-28 MASKE TESPİT VE ANLI UYARI SİSTEM TASARIMI

Muhsin KAVAN¹ Ayşegül ALAYBEYOĞLU², Serpil YILMAZ^{3*},

¹ Yazılım Mühendisliği, İzmir Katip Çelebi Üniversitesi, Türkiye, muhsinkavan@gmail.com

² Bilgisayar Mühendisliği, Yapay Zeka ve Veri Bilimi Uyg. Arş. Mrz., İzmir Katip Çelebi Üniversitesi, Türkiye, aysegul.alaybeyoglu@ikcu.edu.tr

³ Bilgisayar Mühendisliği, Yapay Zeka ve Veri Bilimi Uyg. Arş. Mrz., İzmir Katip Çelebi Üniversitesi, Türkiye,serpil.yilmaz@ikcu.edu.tr

Özet

Bu çalışmada bir üniversite kampüsünün içerisindeki kişilerin maske takma zorunluluğunu sağlamak için yapılan maske tespit ve ikaz sistemi tasarımı sunulmuştur. Önerilen sistemde anlık veri akışı sağlayan ve uyarı veren bir sistem bulunmaktadır. Çalışma kapsamında yapılan sistemin akış diyagramı detayları ile sunulmuştur. Yapay zeka, görüntü işleme, ve makine öğrenmesi bu sistemi oluşturan temel konulardır. Yapılan sistem sayesinde kampüs içerisine yerleştirilen kameralar anlık olarak maske takmayanları sesli bir şekilde ikaz etmeyi hedeflemektedir. Yapılan bu çalışma sadece kampüslere özel değildir. Kamu kurumları, alışveriş merkezleri, konserler, toplu taşıma araçlarında kullanılması hedeflenmekte ve planlanmaktadır. Geliştirilen ilk sistem tasarımının İzmir Katip Çelebi Üniversitesi merkez kampüsünde uygulanması planlanmaktadır.

Anahtar Sözcükler: *maske tespiti, yapay zeka, görüntü işleme*

Abstract

In this study, the mask detection and alert system design, which are made to ensure that people wear masks on a university campus, are presented. In the proposed design, there is a system that provides instant data flow and send warning messages. The flow diagram of the system made within the scope of the study is presented in detail. Artificial intelligence, image processing, and machine learning are the main subjects covered in this system. By placing the cameras on the campus it is aimed to send audible warnings immediately for those who do not wear masks. It is aimed and planned to use the proposed system not only on campuses but also in public institutions, shopping malls, concerts and public transportation vehicles. The system design is planned to be first implemented at the central campus of İzmir Katip Çelebi University.

Keywords: *mask detection system, artificial intelligence, image processing.*

1. Giriş

Koronavirüs hepimizin hayatını derinden etkileyen bir salgın haline gelmiştir. Bulaşma hızı ve verdiği ciddi hasarlar nedeniyle tüm dünyada çok katı önlemler alınmıştır. Bu kapsamda alınan en önemli önlemlerden birisi de kişilerin maske takma zorunluluğudur. Yetkili merciler tarafından alınan kararla; üniversiteler, kamu kurumları, mağaza, alışveriş merkezi, market, iş

yeri, fabrika ve üretim yerleri gibi kapalı alanlarda kişilerin maske kullanma zorunluluğu bulunmaktadır. Yapılan bu sistemde maskenin takılıp takılmaması kontrol edilmesi planlanmaktadır. Kişilerin maske takmaması durumlarında anlık olarak sesli bir şekilde ikaz edilmesi planlanmaktadır.

Yasal olarak alınan önlemlerin başarılı olabilmesi için bir denetim mekanizması olmak durumundadır. Sağlıkımızın korunması için bu denetimleri denetleyen bir sistem olması gerekmektedir. Yaptığımız bu maske tespit ve ikaz sistemi ile insanların bu salgından en az zarar alması hedeflenmektedir. Görüntü işleme yaparak maske takmayanların tespiti ve maske takılmadığında ise uyarı yapan bir sistem geliştirilecektir. Bu çalışmada makine öğrenmesi ve yapay zeka algoritmaları çalıştırılarak farklı şekillerde takılan maskeler öğretilerek her türlü maske çeşidinin tespiti hedeflenmektedir.

2. Maske Tanıma Sistem Tasarımı

2.1 Genel Fikir

Geliştirilmesi planlanan maske tanıma sistemi, temel bileşen analizi (principal component analysis) yöntemlerinden biri olan, özyüz uzayı yansıtma ile yüzlere ait özellik kümesini çıkarılmaktadır. Temel bileşen analizi yöntemi, maske tanıma problemine iki boyutlu bir tanıma problemi olarak yaklaşmakta ve yüzler arasındaki farklılıkları en iyi ortaya çıkaran yüz uzayının (face space) özvektörlerinin, yani özyüzlerin elde edilerek, diğer yüzlerin bunların kombinasyonu ile ifade edilmesi ilkesine dayanmaktadır. Son olarak, tanıma işlemi sırasında elde edilen eğitim ve test yüzlerinin özellikleri arasındaki benzerlikler destek vektör makinesi yöntemi ile bulunacaktır. Özyüzler, eğitim kümesinde yer alan yüzlerin temel bileşenlerini oluşturmaktadır.

Tanıma işlemi yeni bir yüzün, elde edilen birçok özyüzler tarafından girilen yüz uzayına projeksiyonu ile gerçekleştirilmektedir. Projeksiyon sonucu elde edilen konum, sisteme tanıtılmış yüzlerin bu yüz uzayındaki yerleri ile karşılaştırılır. Yeteri kadar yakın olan bireyler varsa, bu durum yeni yüz sisteme daha önceden tanıtılmıştır anlamına gelir. Aksi halde, istenirse bu yeni yüzün, yüz uzayındaki konumu saklanarak sistemin yeni yüzü öğrenmesi sağlanabilir [1]. Şekil 2’de örnek bir maske tespit sistem arayüzü sunulmuştur.



Şekil 1. Maske takan ve takmayanların tespiti[2].

2.2. Amaç /Gerekçe

Koronavirüsün bulaşma hızı ve verdiği ciddi hasarlar nedeniyle bazı önlemlerin alınması kaçınılmazdır. Bu kapsamda alınan en önemli önlemlerden birisi de kişilerin maske kullanmasıdır [2]. Maske kullanımı, COVID-19 dâhil olmak üzere virüs sonucu ortaya çıkan belirli solunum yolu hastalıklarının önlenmesine ve kontrolüne yönelik kapsamlı önlemler paketinin bir parçasını oluşturur. Maskeler sağlıklı kişilerin korunması için (enfeksiyonu olan bir kişiyle temastayken kişinin kendini koruması için) ya da kaynak kontrolü amacıyla kullanılır. Amaç insanların maske takmalarını sağlamak ve bulaşma riskini en aza indirmektir. Ayrıca pandemi kurallarına uymayan kişilere anlık müdahale etmektir. Böylelikle bulaş riskini en aza indirmek hedeflenmektedir.

2.3. Özgün Değeri

Projenin özgünlüğü, gerçek zamanda yapay zeka algoritmalarını kullanan kameramız ile anlık olarak yüzdeki maskenin tespit işlemi yapılması planlanmaktadır. Eğer maske tespiti yapılamazsa anlık ikaz sesli bir şekilde verilecektir. Ayrıca TV üzerinden bireylerin de kendilerini görebilmeleri sağlanarak; bireylerin daha duyarlı olması hedeflenmektedir.

2.4. Hedef kitlemiz

Hedef kitlemiz; üniversiteler, alışveriş merkezleri, kamu binaları, konserler, toplu taşıma araçları, mitingler gibi toplumun bir arada olduğu bütün alanlarda sistemimizin kullanılması hedeflenmektedir. Geliştirilen ilk sistem tasarımının İzmir Katip Çelebi Üniversitesi merkez kampüsünde uygulanması planlanmaktadır.

2.5. Yöntem

Bu bölümde önerilen maske tespit ve ikaz sistem tasarımının alt yapısını oluşturan yapay zeka; makine öğrenmesi ve görüntü işleme hakkında bilgiler verilmiştir.

2.5.1 Yapay zeka

Özellikle son yıllarda çok önem kazanan ve akıllı sistem denildiğinde ilk akla gelen yapay zeka kavramı genel olarak, insan gibi karar veren, insan zekasını gerektiren görevleri yapabilecek makinelerin tasarlanması amacıyla kullanılan yöntemler bütünü olarak tanımlanabilmektedir.

Günümüzde bir çok farklı uygulama alanı olan yapay zeka, önerilen sistemde bütün modüllerde çıkarsama ve karar verme amacıyla kullanılacak temel yöntemdir. Sosyal alanlarda insanların maske zorunluluğuna uyup uymadığını yapay zeka algoritmaları olan yolo v4 kullanılması hedeflenmektedir.[3].

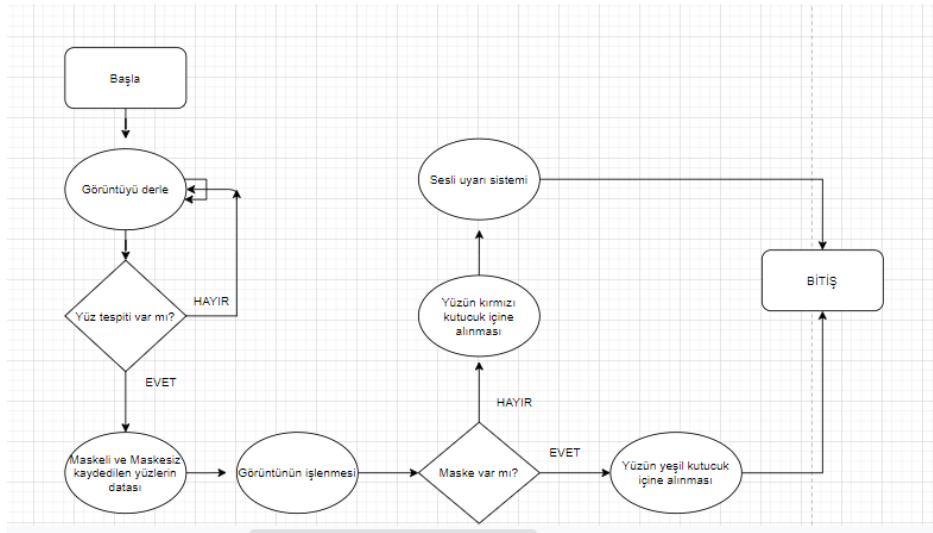
2.5.2 Makine öğrenmesi

Makine öğrenimi veya makine öğrenmesi, bilgisayarların algılayıcı verisi ya da veri tabanları gibi veri türlerine dayalı öğrenimini olanaklı kılan algoritmaların tasarım ve geliştirme süreçlerini konu edinen bir bilim dalıdır. Makine öğrenimi araştırmalarının odaklandığı konu bilgisayarlara karmaşık örüntüleri algılama ve veriye dayalı akılcı kararlar verebilme becerisi kazandırmaktır. Bu, makine öğreniminin istatistik, olasılık kuramı, veri madenciliği, örüntü

tanıma, yapay zekâ, uyarlamalı denetim ve kuramsal bilgisayar bilimi gibi alanlarla yakından ilintili olduğunu göstermektedir.

2.5.3 Görüntü işleme

Görüntü işleme, analog bir görüntünün sayısal formata dönüştürülerek, bu görüntüden anlamlı bilgilerin çıkarılması için çeşitli yöntemler ile işlenmesi olarak tanımlanabilir. Görüntünün elde edilmesi, ön işlemde geçirilmesi, bölümlenmesi, çıkarımda bulunulması ve yorumlanması görüntü işleme temelde adımlardandır. Günümüzde farklı birçok alanda kullanılan görüntü işleme teknikleri önerilen sistemde çok yoğun bir şekilde kullanılacaktır. Görüntü işleme çok yoğun işlem yüküne sahiptir. Bu yüzden bu yoğun işlem yükünü kaldıracak GPU (Grafik Bellek Kartı) kullanılması hedeflenmektedir.



Şekil 2. Maske tespit sistemi algoritması.

2.5.4 Sistem Gerçekleştirimi

Sistem; Yapay zeka (AI) destekli Nvidia jatson nano geliştirme kartında python ve yolo v4 ile yazılan yazılımın kamera modülü ile sürülmesi gerçekleştirilecektir. Sürülen bu data TV ekranına yansıtılacaktır. Sesli anlık uyarı veren bu sistem tarafından uyarılması hedeflenmektedir. Bu şekilde maske takmayan insan sağlığını tehlikeye atan insanlar anlık uyarılacaktır. Bu çalışmadaki yüz maskesi tanıma sistemi, görüntü sınıflandırma yöntemi olan Yolo v4 aracılığıyla makine öğrenmesi algoritması ile geliştirilecektir. Yolo v4, Google tarafından geliştirilmiş performans ve iyileştirme ile daha verimli olması için geliştirilen Convolutional Neural Network (CNN) tabanlı bir yöntemdir [3]. Şekil 3’te sistemin gerçekleştirimi için kullanılacak olan geliştirme kartı ve kamera cihazları görselleri sunulmuştur.



Şekil 3. Geliştirme kartı ve kamera[4].

Bilgilendirme

Bu proje İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma projeleri kapsamında desteklenmektedir.

Referanslar

- [1] J. Gerald, “Sega Ends Production of Dreamcast,” vnunet.com, para. 2, September. 29, 2021. [Online]. Available: <https://towardsdatascience.com/detecting-masks-in-dense-crowds-in-real-time-with-ai-and-computer-vision-9e819eb9047e>. [Accessed Sept. 12, 2021].
- [2] 2. Zhao S. Musa SS. Lin Q. Ran J. Yang G. Wang W. Et al. Estimating the Unreported Number of Novel Coronavirus (COVID-19) Cases in China in the First Half of January 2020: A Data-Driven Modelling Analysis of the Early. Outbreak. J. Clin. Med. 2020; 9, 388. J. Smith, R. Jones, and K. Trello, “Adaptive filtering in data communications with self improved error reference,” In Proc. IEEE International Conference on Wireless Communications '04, 2004, pp. 65-68.
- [3] Russel Stuart, Norvig Peter, Artificial Intelligence, A Modern Approach, Prentice Hall, 2nd Edition, 2003 K. E. Elliott and C. M. Greene, “A local adaptive protocol,” Argonne National Laboratory, Argonne, France, Tech. Report. 916-1010-BB, 7 Apr. 2020.
- [4] J. Gerald, “Sega Ends Production of Dreamcast,” vnunet.com, para. 2, September. 29, 2021. [Online]. Available: <https://www.youtube.com/watch?v=W7SxGhJp8CA&t=311s> [Accessed Sept. 12, 2021]. [3] K. E. Elliott and C. M. Greene, “A local adaptive protocol,” Argonne National Laboratory, Argonne, France, Tech. Report. 916-1010-BB, 7 Apr. 2020.

S-26 OPTIMUM DESIGN of THE ROCKET’s SUB-UNITS BASED ON NEURO-REGRESSION APPROACH for MODELING

Mustafa DİNÇ¹, Turan SARGIN², Levent AYDIN^{2*}, Elif ARAS GÜLTÜRK³

¹ Graduate School of Natural And Applied Sciences, İzmir Katip Çelebi University, Turkey, mstafa.dnc16@gmail.com

² Department of Mechanical Engineering, İzmir Katip Çelebi University Turkey, turan.sargin1@gmail.com

^{2*} Department of Mechanical Engineering, İzmir Katip Çelebi University Turkey, leventaydinn@gmail.com

³ Department of Mechanical Engineering, Kocaeli University, Turkey, elifgulturk@gmail.com

Abstract

Rockets are widely used in aerospace and defense with their speed and improved mechanical properties. The skills and mechanical properties of rockets can be developed depending on the design methods, production process and structural features. Lots of design parameters in the rocket modeling process has an impact on the structural features. In this study, the effects of fourteen different major design variables on the output parameters in rocket modeling process were investigated. This study was carried out in two stages, simulation and design-optimization. In the first part, scenarios were determined by using the Design of Experiment (DoE) approach to collect data and these scenarios were realized through the OpenRocket simulator. MacroRecorder app was used to speed up to process applied tries on the OpenRocket and the outputs such as maximum velocity, apogee were recorded. In the second part, different mathematical models were created to define the phenomena by using the multiple nonlinear regression analysis with combining neuro-regression method. The coefficient of determination (R^2), adjusted coefficient of determination (R^2_{adjusted}) also R^2_{training} and R^2_{testing} values were calculated for each model, to see how well the models define the phenomena. As a design-oriented solution, the values of the process parameters that provide the maximum speed values are optimized based on stochastic optimization algorithms (Differential Evolution Algorithm, DE). The results show that modeling and optimization are important in achieving higher efficiency in the rocket modeling process.

Keywords: Optimal Design; Stochastic Optimization; Sub-Units of the Rocket.

1. Introduction

Rocket science is a combination of top rings of many disciplines and many technologies. So it is an extremely expensive, dangerous and difficult science. However, with simpler materials and techniques, a rocket science that brought a less payload to shorter distances than commercial/military rockets developed and was called 'model rocketry'. Model aviation science, pyrotechnic materials, and modern rocket technologies are the cornerstones of this model science. Model rocketry became a safer and more attractive science with the

establishment of an authoritarian institution (National Association of Rocketry - NAR) in 1957[1]. A sample model rocket was seen in Figure 1.




Figure 1. Model Rocket [1]

Design is always a process that must be carried out systematically. The main purpose of product design is to achieve a talent that is not yet possessed due to need. Rocket design can also be evaluated from this perspective. But the materials are not just any product, but quality and energetic materials. Therefore, errors should be eliminated in the early stages of the design. The best way to do this is to learn and retain the existing information used in the design before starting the design. This information includes design requirements, capabilities, geometric criteria, fuel science, thermodynamics, etc. covers many topics. In the design process, the subsystems of the design should be examined separately. However, these subsystems cannot be considered independently of each other when designing. The output of one subsystem may be the input of another subsystem, or a subsystem may delimit another subsystem.

In this study, the criteria of the TEKNOFEST medium altitude rocket competition which was held for the first time in January 2017 by the Republic of Turkey Ministry of Industry and Technology under the leadership of the Technology Team Foundation (T3 Foundation) were taken as reference values [2]. The effects of fourteen different main design variables on output parameters such as Maximum Velocity (MV) and Apogee (AP) were investigated. Input parameters were determined as Nose Length (NL), Nose Wall Thickness (NWT), Power Variable (PV), Middle Body Length (MBL), Middle Body Wall Thickness (MBWT), Payload Weight (PW), Motor Body Wall Thickness (MOWT), Total Weight of Motor System (TWMS), Fin Wall Thickness (FT), Fin Location (FL), Fin Bottom Edge Length (FBEL), Fin Top Edge Length (FTEL), Fin Height (FH) and Fin Position (FP). The Design of Experiment (DoE) approach was used to collect data and scenarios were realized through the OpenRocket simulator and the outputs were recorded. Different mathematical models were created to define the phenomena by using the multiple nonlinear regression analysis with combining neuro-regression method. The coefficient of determination (R^2), adjusted coefficient of determination (R^2_{adjusted}) also R^2_{training} and R^2_{testing} values were calculated for each model to see how well the models define the phenomena. As a design-oriented solution, the values of the process parameters that provide the maximum velocity values have been optimized based on the Differential Evolution Algorithm, one of the stochastic optimization algorithms.

2. Materials and Method

The choice of material to be used should be made by considering factors such as the height of the rocket, the external forces it will be exposed to, the rocket integration strategy, and the

rocket mounting strategies of the rocket systems. In this study, fiber glass was chosen as the material for the rocket that will reach 3000m altitude.

Multiple nonlinear regression analysis with combining neuro-regression method was performed. The problem is first modeled by way of the use of the proper model. After modeling, the R^2 value is calculated to understand how close the equipped version is to the experimental statistics [3]. The aim is to make R^2 value exceed 0.85. The increased R^2 value is not enough to define reliable modeling. The main concept of the determination of R^2 value is identifying the physical phenomena as actual as feasible. Because of that, R^2_{adjusted} needs to be calculated to test the model's suitability.

In the Neuro regression method, the data were divided into training and test data. 80% of the data is used to calculate the R^2_{training} value. Then, R^2_{testing} values were calculated by putting 20% data into the training model.

Numerical operations including regression and optimization studies were performed using the 'Wolfram Mathematica' software.

DOE is a helpful tool for finding new processes, learning more about the existing processes, and optimizing them for an excellent performance [4]. The design of experiment has accomplished by way of the usage of alternative methods, including Box Behnken, Taguchi, General Factorial, D-Optimal, etc. By specifying all factors, levels, and responses, each method offers an exclusive variety of test situations. In this study, D-Optimal method was chosen.

Mathematically, optimization can be defined as minimizing and maximizing of objective functions in order to reach the best suitable solution under desired scenarios by changing the design parameters [5]. Stochastic optimization algorithms based on probability elements, which do not need derivative information to find the global optimum, can produce high-quality solutions in short computation times [6]. Differential Evolution algorithms were used in this study to acquire the optimum parameters of model rockets. Differential Evolution (DE) algorithm, which is in stochastic optimization algorithms, is a population-based method for non-linear optimization problems over continuous domains [7].

OpenRocket simulation program provided access to critical data before the production process of the rocket. All dimensions on the rocket can be changed individually and the results of these changes can be observed in the flight chart.

2.1. Problem Definition

This study aims to determine the model rocket dimensions suitable for the desired reference values by using optimization methods. The effects of the data obtained as a result of optimization on the flight profile were investigated. In determining the outputs, the values in the Teknofest medium altitude rocket competition were taken. These restrictions are as follows: $2400 \text{ m} < \text{Apogee} < 3600 \text{ m}$, $\text{Maximum Velocity} < 270 \text{ m/s}$ (0.8 Mach number). Thus, the outputs used in the optimization were determined as the apogee of the rocket and the maximum velocity of the rocket.

During the simulation, the flight was analyzed with the OpenRocket program and it was checked whether the obtained outputs were within the desired apogee range. Before using Experimental Design, which is the first step for optimization, a base index for each input and the maximum, minimum and (if necessary) median values associated with this index must be determined.

The 'Weighted Decision Matrix' method used in determining the importance indices of the inputs and the effect of the inputs on the outputs was taken into account. Input levels and level values of rocket design variables were shown in Table 1. The 505 trial data series obtained with the Design of Experiment program were tested using OpenRocket simulator. The outputs of all trials were recorded to be used in optimization. Thus, the experimental part of this study was formed from the simulation results. In the numerical section, these steps are defined as follows: i) Defining the Objective Function, Design Variables and Constraints, ii) Modeling the Problem, iii) Optimization. First, regression analysis was performed using the data obtained as a result of the simulation. The R^2 and R^2_{adjusted} values were calculated for each model. Then models with a value above 0.85 were selected. The next phase of the study started with an appropriate model. All of the data obtained up to this step was used for modeling. The objective function, design variables and constraints of this study in regression analysis are given in Table 2.

Table 1. *Input levels and level values of rocket design variables.*

Input Levels	Input parameters													
	NL (mm)	NW T (mm)	PV (mm)	MB L (mm)	MB WT (mm)	PW (gr)	MOW T (mm)	TW MS (gr)	FT (mm)	FL (mm)	FBE L (mm)	FTE L (mm)	FH (mm)	FP (mm)
Level 1	100	2	0.3	750	2	4000	3	1500	4	-100	100	0	90	-100
Level 2	225	-	0.5	-	6	-	6.5	-	-	0	250	150	120	-50
Level 3	350	10	0.7	1200	10	5000	10	3000	8	100	400	300	150	0

Table 2. Objective function, design variables and constraint of the process

Objective function	Apogee (AP)		
Design Variables	NL, NWT, PV, MBL, MBWT, PW, MOWT, TWMS, FL, FT, FBEL, FTEL, FH, FP		
Constraint	MV < 270	1 < MBWT < 11	-120 < FL < 120
	90 < NL < 380	3000 < PW < 7000	90 < FBEL < 450
	1 < NWT < 11	2 < MOWT < 12	0 < FTEL < 330
	0.2 < PV < 0.9	1300 < TWMS < 3300	75 < FH < 180
	650 < MBL < 1400	3 < FT < 9	-120 < FP < 20

2.2. Models

Different multiple regression models were used to best describe the relationship between the response and the actual data. Second-Order Multiple Non-Linear (SON) form and Third Order Multiple Non-Linear (TON) form are given in Table 3.

Table 3. Forms of different multiple regression models

Model Name	Nomenclature	Formula
Second order multiple nonlinear	SON	$Y = \sum_{k=1}^{14} \sum_{j=1}^{14} (a_j x_j x_k) + \sum_{i=1}^{14} (a_i x_i) + c_1$
Third order multiple nonlinear	TON	$Y = \sum_{l=1}^{14} \sum_{m=1}^{14} \sum_{p=1}^{14} (\beta_l x_l x_m x_p) + \sum_{k=1}^{14} \sum_{j=1}^{14} (a_j x_j x_k) + \sum_{i=1}^{14} (a_i x_i) + c_2$

3. Results and Discussion

In this study, multiple nonlinear neuro-regression analyzes consisting of linear, trigonometric, logarithmic, quadratic and rational forms were performed for AP and MV. The

appropriate model selection was made with four separate “goodness of fit” criteria by looking at the R^2 and R^2_{adjusted} values as well as R^2_{training} and R^2_{testing} values. Among the models suitable for R^2 and R^2_{adjusted} values, those with larger R^2_{training} and R^2_{testing} values were selected to describe the system more appropriately. Third order multiple nonlinear (TON) model, Second order multiple nonlinear (SON) model are selected for the AP and MV, respectively. It is expected that the R^2 determination coefficient will be higher than 0.95 for all models. Choosing appropriate models with high R^2 values in a preliminary study is important in terms of defining the relationship between response and actual data better than other models. Model type, coefficient and determination values for output were shown in Table 4.

Table 4. Model type, coefficient and determination values for output.

Outputs	Model	R^2_{training}	R^2_{testing}
AP	TON	0.999	0.999
MV	SON	0.997	0.986

In order to find the optimum design parameters of the model rocket that will provide the desired outputs within the constraints, the optimization process has been carried out. The optimization process is systematically and sequentially performed, as mentioned in the method section. The optimization process was done separately for the problems specified in the problem definition section and all of the constraints.

Results of Differential Evolution optimization operation showed that when the input parameters are taken as;

NL = 100 mm, NWT = 0.975 mm, PV = 0.521, MBL = 1070 mm, MBWT = 6.02 mm, PW = -4858 gr,

MOWT = 8 mm, TWMS = 1500 gr, FT = 8 mm, FL = 85.77 mm, FBEL = 194 mm, FTEL = 104.93 mm,

FH = 90 mm, FP = -79.2 mm, output values were found as Apogee = 2897 m, Maximum Velocity = 246 m/s.

4. Conclusion

In this study, the effects of fourteen different rocket parameters on outputs such as apogee and maximum velocity were investigated. The data used in the study were obtained as a result of experiments created using the simulation study design. This study suggested that different regression models can describe the engineering problem and can be used to obtain flight profiles. Although neuro-regression models with an R^2 value below 0.95 give reasonable results, they are unreliable for engineering and not recommended for real-life applications. This study showed that second and third order multiple models (SON, TON) are quite reliable to

determine the effect of design parameters on Apogee and Maximum Velocity in model rockets. In addition, it has been demonstrated that the stochastic optimization method (Differential Evolution Algorithm) can be applied beneficially and the values in the flight profile can be brought to the desired range under appropriate conditions.

Referanslar

- [1] Model Rocketry Katalog, Rocketsan, Mar.,2020.
- [2] <https://www.teknofest.org/>
- [3] N. J. D. Nagelkerke, “A Note on a General Definition of the Coefficient of Determination,” *Biometrika*, vol. 78, No.3, Sep., pp. 691-692, 1991.
- [4] İ. Polatođlu, L. Aydın, B. Ç. Nevruz, S. Özer, “A Novel Approach for the Optimal Design of a Biosensor,” *Analytical Letters*, vol.53, no.9, Dec., pp. 1428-1445, 2020.
- [5] S. Öztürk, L. Aydın, E. Çelik, “A comprehensive study on slicing processes optimization of silicon ingot for photovoltaic applications,” *Solar Energy*, Feb., vol. 161, pp. 109-1247, 2018.
- [6] M. Savran, L. Aydın, “Chapter Fourteen - Material selection for hybrid natural fiber laminated composites in vibration using a stochastic optimization method, ” *Hybrid Natural Fiber Composites*, Woodhead Publishing Series in Composites Science and Engineering, Jan., pp. 281-307, 2021.
- [7] L. Aydın, S. Artem, S. Oterkus, “Designing Engineering Structures Using Stochastic Optimization Methods,” *CRC Press*, Apr., 2020.

S-37 MAKİNE ÖĞRENME YÖNTEMLERİYLE GÖĞÜS KANSERİ TESPİTİ

Yasemin Gülay TONGUÇ^{1*}

¹ Yazılım Mühendisliği, İzmir Katip Çelebi Üniversitesi, Türkiye,
yasemingulaytonguc@gmail.com

Özet

Veri madenciliği büyük verilerden anlamlı bilgileri çıkartmak için kullanılan bir yöntemdir. Sağlık sektöründe veri madenciliği hastalıkların erken teşhisini sağlamak ve tıp alanındaki verilerin detaylı incelenmesi için diğer alanlardan daha önemli bir hale gelmiştir. Bu amaçlar için UCI makine havuzundan alınan 699 örnekten oluşan meme kanser veri kümesi kullanılarak hastaların iyi ya da kötü huylu kitleye sahip olduğu tahmin edilmiştir. Veri setini bilimsel araştırmaya hazır hale getirebilmek için, veri setine gözetimli öğrenme yöntemlerinden nominal değerleri ikili sisteme çeviren filtre uygulanmıştır. WEKA Explorer arayüzünde topluluk öğrenme yöntemleri Adaboost-M1 ve Bagging, kümeleme EM ve IBk (kNN), karar ağaçları J48 (C4.5) ve Random Forest algoritmaları ve test modelleri kullanılarak kanser veri seti analizi yapılmıştır.

Anahtar Sözcükler: *Göğüs Kanseri, Hastalık teşhisi, Makine Öğrenmesi, Topluluk Öğrenmesi, Veri Analizi.*

Abstract

Data mining is a method used to extract meaningful information from big data. In the healthcare industry, data mining has become more important than other areas to provide early detection of diseases and examine medical examinations. For these purposes, patients were estimated to have benign or malignant masses using a breast cancer dataset consisting of 699 samples from the UCI machine pool. To make the data set ready for scientific research; NominaltoBinary filter, which converts nominal values to binary system from supervised learning methods, has been applied., Breast Cancer data set analysis was performed using community learning methods AdaboostM1 and Bagging, clustering EM and IBk (kNN), decision trees J48 (C4.5) and Random Forest algorithms and test modes in the WEKA Explorer interface.


Keywords: *Breast Cancer, Data Analysis, Disease Diagnosis, Ensemble Learning, Machine Learning.*

1. Giriş

Göğüs dokusunu meydana getiren hücrelerden birinin değişmeye başlaması ve istemsiz olarak artması sonucu oluşan tümörle meydana gelen hastalığa göğüs kanseri denir. Hastalıklı doku önce ilk önce çevresine sonra da memenin etrafındaki lenf bezlerine doğru ilerler. Hızlı bir şekilde tanısı ve teşhisi yapılmazsa hastanın başka organlarına doğru sıçrar. Bu durumda hastanın iyileşmesi ve tedaviye cevap vermesi imkansız evreye geçer.

Kadınlara özgü kanser türleri arasında göğüs kanseri ilk sırada yer almaktadır. Ömürleri boyunca 8 kadından bir tanesinin meme kanseri olma ihtimali vardır.

Estimated age-standardized incidence and mortality rates (World) in 2020, worldwide, females, all ages



Şekil-1. Dünya’da ki tüm kanser türleri arasında kadınlar için göğüs kanseri istatistiği.

Riski arttıran faktörler

- Vücut kitle indeksinin >30 olması
- Hareketsiz yaşam
- İçki tüketimi
- Papillomatosis ve fibroadenom gibi göğüs hastalıkları
- 55> Yaş üstü menopoz
- Hastanın daha önce kanser öyküsünün bulunması
- BRCA-1, BRCA-2 genlerinde mutasyonlar
- Radyoterapi tedavisi olunması
- Doğum hikayesi olmamak
- 30 > Yaş üstü doğurmak
- Ailesinde kanser hikayesi olanlar
- Adet olma yaşının çok erken olması

Hastalık belirtisi

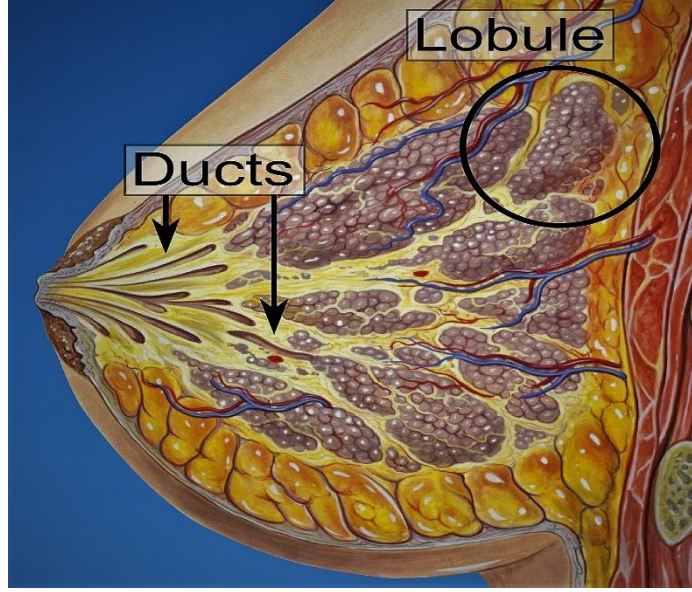
En önemli belirtisi meme dokusunda ağrı olmayan ve sürekli büyüyen bir kitlenin farkedilmesidir. Bazı hastalarda ağrı da olabilir.

- Regl zamanında normalden farklı seyreden göğüs ağrıları
- Memeden gelen kırmızı ya da pembe akıntılar
- Göğüsün herhangi bölgesinde ya da ucunda çöküntü
- Göğüs bölgesinde ele gelen sertlik
- Göğüs ucunun şeklinin ve yönünün değişmesi
- Göğüsler arasında asimetri meydana gelmesi

- Kol altında lenflerde sertleşme, ele gelen kitle ve şişme
- Göğüs cildinde berelenme, kızarma, döküntü, çatlama
- Meme cilt üstünde portakal kabuğu gibi görüntünün oluşması

Göğüs kanser çeşitleri

Meme kanallarında gelişen türüne “duktal” denir. Süt bezlerinde gelişen türüne ise “lobiler” denir.



Şekil-2. Göğüs kanallarında ve süt bezlerinde görülen meme kanserinin anatomik kesiti

1 *İnvaziv meme kanseri*

Diğer organlara yayılma özelliği gösterir. Tehlikeli sayılan türüdür.

2 *Non- invaziv meme kanseri*

Bu kanser türünde yayılma özelliği yoktur.

2. Amaç

Hastalık tanısı konusunda yapılan tarama da derin öğrenme, makine öğrenmesi ve sınıflandırma çalışmalarının sayısı, teşhis edilen hastalık çeşidine göre günden güne artmaktadır. Hastalık tanısının erken dönemde olması tedaviye hızla başlanması ve hastanın hayatını kurtarabilme açısından çok önemlidir. Bu çalışma da tıp alanında veri analizi yapılmıştır. Ölümcül sonuçları

olan meme kanserine, veri setinin karakteristiğine uygun çeşitli makine öğrenme teknikleri uygulanmıştır. Medikal bilişim alanında bu yöntem ve tekniklerle meme kanserinin tespiti için makina öğrenmesi algoritmaları ile bulunan istatistiklerle ön bilgi vermesi amaçlanmaktadır.

3. İlgili çalışmalar

Pala vd. [1], Karar Ağaçları ve K-Nearest Neighbor algoritmalarını meme kanseri teşhisi için veri setine uygulamışlardır. Sert [2] Naïve Baes, SVM ve K-NN makina öğrenmesi algoritmaları ile uyku apnesi bozukluğu tanıma ve biyoinformatik uygulamalarına Alpaslan [3] Derin veya düşük öznelik seçimleri kullanılarak meme kanseri tespitinde AÖM yöntemleri uygulamalarına Xu vd.[4] Meme kanseri ile hastalık seyri tahminlenmesi için gen seçimi ve SVM kullanılarak biyomedikal uygulamalarına, Buldu vd. [5] Kan şekeri anormallikleri üzerine tıbbi bileşim uygulamalarına, He Wang vd. [6] Meme kanseri teşhisi için EL algoritması ve SVM yöntemleri kullanımına, Kaya vd. [7] çalışmalarında, tıpta veri madenciliği uygulamalarına, Henegis vd. [8] Göğüs kanseri tahmini için,RNA profili çıkarılarak SVM tabanlı nitelik seçimi kullanımına örnek olarak verilebilir.

4. Materyal ve yöntem

4.1 Materyaller

Bu çalışmadaki makine öğrenmesi yöntemleri, sınıflandırma algoritma denemeleri ve veri madenciliği çalışmaları; Waikato Üniversitesi tarafından yazılmış, Java tabanlı Weka 3.8.4 Development versiyonlu yazılımın araç ve teknikleri kullanılarak yapılmıştır.

Wisconsin Üniversite Hastanesi ve Dr. William H. Wolberg tarafından 1992 yılında sağlanan ve ICU veri tabanından alınan göğüs kanseri hastalığına ait veri seti ile veri analizi yapılmıştır.

Veri Kümesi Özellikleri:	Değişkenlik	Örnek Sayısı	699	Çalışma Alanı:	Hayat
Öznelik Özellikleri:	Tam Sayı	Öznelik Sayısı:	10	Bağış Tarihi	1992-07-15
İlişkili Görevler:	Sınıflandırma	Kayıp Değerler	Evet	Web Ziyaretleri Sayısı	663881

Tablo:1 Meme Kanseri Veri Setinin Karakteristik Özellikleri

Attribute Information

1.	Sample	code	number:	id	number	
2.	Clump	Thickness:	1	-	10	
3.	Uniformity	of Cell	Size:	1	-	10
4.	Uniformity	of Cell	Shape:	1	-	10
5.	Marginal	Adhesion:	1	-	10	
6.	Single	Epithelial Cell	Size:	1	-	10
7.	Bare	Nuclei:	1	-	10	
8.	Bland	Chromatin:	1	-	10	
9.	Normal	Nucleoli:	1	-	10	
10.	Mitoses:	1	-	10		
11.	Class: (2 for benign, 4 for malignant)					

Tablo:2 Sınıflandırma Tablosu

4.2 Yöntemler

4.2.1 Sınıflandırma Teknikleri

4.2.1.1 Topluluk Öğrenmesi

Birden fazla zayıf modelin aynı problemi çözmek için birleştirildiği ve eğitildiği makine öğrenmesi yöntemidir. Karar ağacında doğru birleştirme yapılırsa daha güçlü modeller elde edilir.

4.2.1.1.1 Adaboost M1 Algoritması

Zayıf sınıflandırıcılardan oluşan ardışık topluluklarla öğrenme yöntemidir. Her öznitelik için negatif ve pozitif örneklerin ağırlık ortalaması alınır. Hafızayı az kullanması, uygulanabilirlik özelliği ve tahmin hızının yüksekliği bakımından tercih edilen bir makine öğrenmesi yöntemidir.

4.2.1.1.2 Torbalama Algoritması

Mevcut eğitim setinden yeni eğitim setleri yapılarak makinayı tekrar eğitir. Bu şekilde farklılıklar oluşturup totalde sınıflandırma başarısını arttırmak amaçlanır.

4.2.1.2 Kümeleme Yöntemi

Denetimsiz öğrenme yöntemi olan kümeleme de etiketli yanıtlar içermeyen girdi verilerinden oluşan veri kümeleri referans alınır. Popülasyon ya da aynı gruptaki veri noktalarına daha benzer ve diğer veri noktalarına benzemeyecek şekilde birkaç gruba böler. Benzerlik ve farklılıklar temelinde çalışan nesne koleksiyonudur.

4.2.1.3 Beklenti Maksimizasyonu

Temeldeki bir dağılımda veri noktalarının, sayısı bilinmeyen veri eksiklikleri ya da kümelenmeleri olabilir. Beklenti maksimizasyonu bu tür problemler için uygundur. Temeldeki bir dağılımdan gözlemi yöneten bir dağılıma kadar çoktan bire bir eşleştirme olduğunda parametrelerin maksimum olasılık tahminlerini üretir.

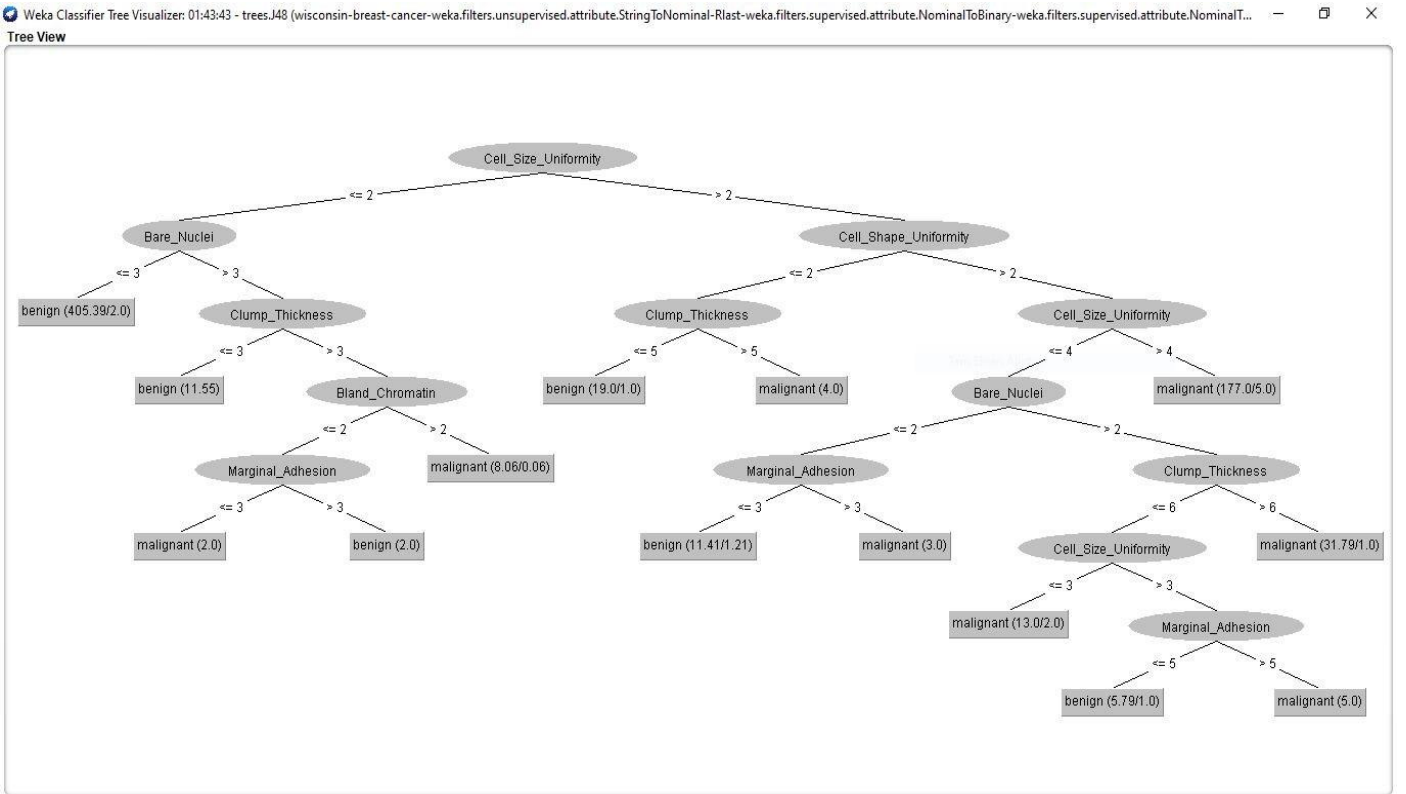
4.2.1.4 Karar ağaçları

4.2.1.4.1 J-48 (C4.5) algoritması

Bilgi kazanımını en yüksek sağlayan değişken tespit edilip, bu değişkenden ağaç dallandırılır. Ağacın her bir dalının alt kısmında veriler dengeli olarak dağılır. Tespit edilen değişken entropi üstünden değil, bilgi değeri üzerinden tekrarlanır. Tahmin edilen tüm değişkenler ağaca yerleşinceye kadar işlem sürer.

4.2.1.4.2 Rassal orman algoritması

Denetimli öğrenme tekniğinde bir makina öğrenmesidir. Verilen veri kümelerinde bir dizi karar ağacı içeren ve bu veri kümesinin tahmin doğruluğunu iyileştirmek için ortalamayı alan bir sınıflandırıcıdır.



Şekil-3 Weka’ da Göğüs kanseri veri setine J48 (C4.5) algoritma uygulamasında karar ağacının dal ve yaprak görüntüsü

4.2.1.5 Tembel öğrenme yöntemleri

4.2.1.5.1 En yakın komşu algoritması

Tembel öğrenme de eğitim süreci yoktur. Makine verileri öğrenmez verileri ezberler ve bir tahmin gerektiği zaman veri setinin tüm içeriğinde en yakın komşuları bulur. Uzaklık önce hesaplanıp sonra sıralanır uygun sınıfa bu değerler atanır.

SONUÇ VE ÖNERİLER

Makine öğrenmesinin tıp alanlarında kullanılması ile insanların yaşam kalitesinin yükseltilmesi hedeflenip, bunun için bilimsel çalışmalar sürekli yapılmaktadır. Veri bilimi ile verilerin toplanması, kategorize edilmesi ve doğru sınıflandırılıp bilimsel analize hazırlanması sağlanmaktadır. Hazırlanan verilerle makine öğrenmesi yöntemleriyle eğitilen makinelerle, geçmişte birçok hastalık ile ilgili çalışmalar yapılmış ve umut verici sonuçlar elde edilmiştir.

Yapılan araştırmalarda 2020' de teşhis edilen her 8 kanserden 1'inin göğüs kanseri olduğu tespit edilmiştir. Göğüs kanseri, 2020 yılında 685.000 ölümle tüm dünyadaki kanser ölümlerinde beşinci sıradadır. Bu yüzden göğüs kanseri hastalığının erken tanısı , teşhisinin konması ve tedavisinin hızla başlatılması yaşam mücadelesi için çok önemlidir.

Bu tıp alanında yapılan veri analizi ve makina öğrenmesi ile göğüs kanseri tespit çalışmasında; Topluluk öğrenmesi yöntemleri AdabostM1, Bagging, Kümeleme yöntemi EM (denetimsiz öğrenme), Karar Ağaçları Yöntemleri J48 (C4.5) ve Random Forest (denetimli öğrenme), Tembel Öğrenme Yöntemi IBk (kNN) algoritmaları uygulanmıştır. Göğüs kanseri hastalığı ve hastalıklı kitle teşhisinde ; **%95.71** ile başlayan test ve örnekleme çalışmalarında **% 100'** e yakın istatistiksel başarı oranı elde edilmiştir.

Makine öğrenmesi yöntemleriyle; tıp alanında yeni yapılacak hastalık teşhisi çalışmalarında, yeni, temiz ve daha büyük veri setleri ile daha güncel ve işlevsel sınıflandırılmaların kullanılması önerilmektedir

Referanslar

- [1] M. A. Pala, A. F. Boz , M. E. Çimen, M. Z. Yıldız, Ö. F. Boyraz, “Meme Kanserinin Teşhis Edilmesinde Karar Ağacı Ve KNN Algoritmalarının Karşılaştırmalı Başarım Analizi”, 7th International Symposium on Innovative Technologies in Engineering and Science, 2019.
- [2] Sert, M. "Feature Selection for Obstructive Sleep Apnea Recognition". Bilişim Teknolojileri Dergisi 12 : 333-342, 2019
- [3] N. Alpaslan, “Meme Kanseri Tanısı için Derin Öznitelik Tabanlı Karar Destek Sistemi”, Selçuk Üniversitesi Mühendislik, Bilim Ve Teknoloji Dergisi, 7(1), 213-227, 2019.
- [4] X. Xu, Y. Zhang, L. Zou, M. Wang, A. Li "A gene signature for breast cancer prognosis using support vector machine” 2012 5th International Conference on BioMedical Engineering and Informatics ,Page(s):928 – 931, 2019
- [5] A. Buldu, K. Yıldız, Ö. Demir E, E. Ülkü, U. Kurgan, “Data Collection from Blood Glucose Meter and Anomaly Detection”, Karaelmas Fen ve Mühendislik Dergisi, 7(2), 428-433, 2017.

[6] H.Wang, S.W.Yoon, B. Zheng, H. S. Ko “A support vector machine-based ensemble algorithm for breast cancer diagnosis” European Journal of Operational Research, Volume 267, Issue 2, Pages 687-699, 1 June 2018

[7] E. Kaya, A. Arslan, M. Bulun, “Tıpta Veri Ambarları Oluşturma ve Veri Madenciliği Uygulamaları”, Akademik Bilişim, 2003.

[8] C. Hennekes, R. Fux D.Bullinger, N. Friese, H. Neubauer, H. Seeger, S. Laufer, C.H. Gleiter, M. Schwab, A. Zell & B. Kammerer “Prediction of breast cancer by profiling of urinary RNA metabolites using Support Vector Machine-based feature selection” BMC Cancer 9, 104, 2009

[10] Feb. 27, 2020. [Online]. Available: <https://www.wikipedia.org/>

[11] Feb. 24, 2020. [Online]. Available: <https://archive.ics.uci.edu/ml/index.php>

[12] Dec. 16, 2020. [Online]. Available: <https://github.com/>

[13] Jan. 2, 2021. [Online]. Available: <https://www.cancer.org/cancer/breast-cancer/>

S-19 YÜZ TANIMA ALGORİTMALARININ ARAŞTIRMALARDA KULLANIM ŞEKLİNE İLİŞKİN DARALTILMIŞ LİTERATÜR ÇALIŞMASI

Asiye Rümeysa ÜNSAL^{1*}, Serkan DERELİ²

¹ Elektrik Elektronik Mühendisliği, Sakarya Uygulamalı Bilimler Üniversitesi, TR,
asiyerumeysaunsal@gmail.com.tr

² Bilgisayar Teknolojileri Bölümü, Sakarya Uygulamalı Bilimler Üniversitesi, TR,
dereli@subu.edu.tr

Özet

Günümüzde en çok çalışılan konuların başında görüntü işleme ve bilgisayarlı görme konuları gelmektedir. Zira bu konular yapay zekanın alt dalları olarak kabul gören makine öğrenmesi ve derin öğrenme gibi konuların her geçen gün gelişmesini de sağlamaktadır. Görüntüdeki verilerin anlamlandırılması, görüntüler içerisinde nesnelere veya yüzün tanınması adına bir çok çalışmalar mevcuttur. Yüzün tanınması kişisel telefon kilitleri olmak üzere güvenlik, kimlik tanıma, suçlu takibi, yüz ifadesi tespiti ve benzeri bir çok çalışmada sıklıkla kullanılmaktadır. Yüz tanıma işlemi için literatürde önemiyetinden dolayı oldukça fazla çalışma ve teknik sunulmuştur. Bu çalışmada yüz tanıma teknikleri arasında geniş bir literatür taraması yapılmış ve en sık başvuru alan algoritma teknikleri, dezavantaj ve avantajları değerlendirilmiştir. Yapılan çalışma sonucunda kullanılan yöntemler de derin öğrenme modellerinin ışık açısı, gürültü, ön işleme vb yan etkilerden neredeyse bağımsız olması ile birlikte en iyi başarıma sahip olduğu sonucuna varılmış ve diğer teknikler ile ilgili karşılaştırmalar yapılmıştır.

Anahtar Sözcükler: *Yüz Tanıma; CNN; HOG; TBA; LBP; Gabor Dalgacık Dönüşümü*

Giriş

Yapay zeka konusunda ciddi bir önem arz eden görüntü işleme alanının da, nesne ve yüz tanıma işlemleri, güncel çalışmalar arasında gösterilmektedir. Bu çalışmalar hızlı ivme kazanıp multidisiplinler arasında ciddi bir sükseye sahip olmuştur. [1] Yüz tanıma işlemleri başta güvenlik ve kimlik tespiti olmakla birlikte, yüz ifadesi, duygu, cinsiyet, yaş vb. tespiti için bir çok alan ve çalışmada başvuru alan bir yöntemdir. [2, 3, 4]


Yüz tanıma işlemi gereklilik ve çalışma koşullarına uygun olarak birçok farklı teknik ile yapılabilmektedir. Yüz tanıma işleminde ilk aşama olarak görüntü içerisinde mevcut bir yüz şeklinin olup olmadığının belirlenmesi adına yüz tespitinin sağlanmasıdır [5]. Bu işlemi aydınlatma, yüzün belirli bölgelerinin kamufle olması, gürültü, aksesuar gibi faktörler etkilemektedir. Bu nedenden ötürü ihtiyaç ve yapılan işlemlere kolaylık sağlamak adına literatürde dört farklı yolla sağlanmaktadır. Bunlar görüntü, öznitelik, bilgi ve şablon tabanlı yöntemler olarak sınıflandırılmaktadır. [6] Ardından yüzün tespit edilmesi ile birlikte yüzün nitelikli parçalara ayrılması ve özelliklerinin belirlenmesi işlemi gerçekleştirilmektedir. Bu işlemde literatürde genel olarak görüntü ve geometrik öznitelik tabanlı yöntemler olarak iki başlık altında sınıflandırılmaktadır. Bu işlemleri baz alarak farklı teknikler çalışmalar ve algoritmalar literatürde yer almıştır. [6]

Bu çalışmada yüz tanıma işlemleri üzerine uygulanan algoritmaların genel teknik bilgilerine ikinci bölümde yer verilmiştir. Ardından üçüncü bölümde algoritmaların uygulandığı çalışmalar ve başarı oranları ayrıca bu algoritmaların güçlü-zayıf yönlerinin karşılaştırılması ve bulgular gösterilmiştir. Son olarak bu algoritmalar üzerinde yorum ve tespitler yapılmış ve sonuçlar tartışılmıştır.

YÜZ TANIMA ALGORİTMALARI

CNN (Evrşimsel Sinir Ağları)

Görüntüleri girdi olarak alıp görüntü özelliklerine göre yakalayıp sınıflandırmaya dayanan bir derin öğrenme modelidir. Çok katmanlı bu ağlar yüz tanıma işlemlerinde yüksek başarıma sahiptir. Bu katmanlar farklı amaç ve ihtiyaçlar için farklı şekilde modellenmektedir. [7] Yüz tanıma işlemi için de farklı CNN modeller tasarlanmıştır. Bunlardan bazıları; GoogleNet, ResNet, VGG, FaceNet, AlexNet vb. sıralanabilmektedir. [8, 9]



Şekil 9 CNN modelinin Genel Mimarisi [7, 10]

CNN modeller de ilk aşama yüz görüntü girdileri model standartlarına göre “Giriş Katmanı” içerisinde düzenlenmesidir. [3] Ardından görüntüler üzerinde özelliklerin tespit edilebilmesi için “Konvolüsyon Katmanı” uygulanır. [3] Bu katman ile görüntülerin özellik haritalaması yapılarak yeni bir matrise aktarılır. Yeni oluşan özellik harita matrisi “Havuzlama Katmanı” adı verilen katmandan geçirilerek özellikleri belirli bir eşik değerine göre düzenler ve zayıf özellikler çıkarılır. [11] Havuzlama ve evrişim katmanları birkaç kez tekrarlanabilmektedir. Son olarak kendinden önceki tüm elemanlarla bağlantılı olarak sınıflandırma işleminde en uygun skora optimize ederek sınıflandırma verilerinden çıktılarını oluşturmak için “Tam Bağlantılı Katmanı” kullanılır. [12]

HOG (Histogram of Oriented Gradients) Algoritması

Görüntüdeki piksellerin değerleri ve yönelimlerinin oluşturduğu karakteristik ifadeye dayanan bir algoritma olan HOG son yıllarda yüz tanıma sıklıkla tercih gören algoritmalar arasında gösterilmektedir. [13] İlk olarak 2004 yılında Shashua ve ardından 2005 yılında Dalal tarafından önerilen bu algoritma, görüntülerin dikeyde ve yatay da kenarları tespit edildikten sonra görüntüdeki bölgelerin gradyanların açısı (yönelim) ve büyüklüklerinin bulunmasına dayanarak bölgeyi histogramlar olarak tanımaktadır. Bu işlemin gerçekleşmesi için öncelikle girdi olan görüntünün dikeyde ve yatayda bir kenar tanıma filtresine (Sobel, Canny vb.) tabi

tutulması gerekmektedir. Görüntü üzerine uygulanan yatay filtre sonucu oluşan yeni görüntü I_x ve dikey filtreden geçirilerek oluşan yeni görüntü I_y olarak adlandırıldığında;

$$I_x = I * S_y \quad (1)$$

$$I_y = I * S_d \quad (2)$$

Ardında oluşan iki görüntü ile gradyan büyüklüğü ve açı değeri hesaplanır.

$$|G| = \sqrt{I_x^2 + I_y^2} \quad (3)$$


$$\theta = \arctan \frac{I_x}{I_y} \quad (4)$$

Yönelim ve büyüklükler bulunduktan sonra açısal değerlere göre gruplandırma işlemleri yapılabilir. 0-360 derecelik açılar istenilen aralıklarda gruplandırılarak açısal yönetime göre bir sınıflandırma işlemine tabi tutulur [13, 14, 15].

Local Binary Pattern (LBP- Yerel İkili Örüntüler)

Önceleri doku sınıflandırma çalışmalarında kullanılan LBP öznitelikleri, yüz betimleme de başarılı sonuçlar elde edildikten sonra yüz tanıma alanında da kullanılmaya başlanmıştır. Yüz tanıma amacıyla LBP özniteliklerinin elde edilmesinde ilk olarak yüz görüntüleri belirli sayıda bölgeye bölünür. Her bir bölge için LBP kodlarından histogramlar elde edilir. [16] Daha sonra bu histogramlar birbirine eklenerek elde edilen yeni histogram, yerel ikili örüntü öznitelik vektörü olarak kullanılır. [17]

LBP yönteminin uygulanma mantığında 3x3'lük bir matrisin çekirdeğindeki değer referans olarak komşuluk değerleri karşılaştırılır. Büyük olan değerler 1, küçük olan değerler ise 0 değerini atanarak 8-bitlik bir sayı elde edilir. Bu sayı ondalık tabandaki değer karşılığı çekirdek piksele atanır. Böylece tüm pikseller için hesaplanan LBP kodlarıyla oluşturulan görüntünün histogramı, bu kodların hangi sıklıkla kendilerini tekrar ettiğini belirtir. [18, 17]



Şekil 10 LBP yönteminin örnek bir hesaplama gösterimi (3x3) [18]


Temel Birleşen Analizi (TBA)

Temel Birleşen Analizi, büyük ve bir biri ile bağlantılı vektörleri bir birinden ilişkisiz anlamlar taşıyan parçalar halinde genel bilgiyi barındıran küçük vektörler olarak elde edilmesi yönteminde kullanılır. Bu işlem yüz tanıma işlemlerinde verilerin azaltılması ve yüksek başarımların vermesi nedeni ile tercih edilir. [19] TBA yöntemi uygulanırken verilerin minimal düzeyde değişkenlerle anlamlı parçaları tutması amaçlanarak en iyi dönüşümün belirlenmesi gerekmektedir. [20] Dönüşümün tamamlanması ardından veriyi gösteren ilk değişkenlere temel birleşenler adı verilmektedir. Temel birleşenlerin varyans değerleri büyük olan değişkenler olup bu değişkenler en aza inecek şekilde sıralanır. [21]

Bu yöntemi temel olarak özyüzler (eigenfaces) ve fisherfaces yöntemleri geliştirilmiş ve yüz tanıma çalışmalarında özellikle sınıflandırma algoritmalarında düşük bellek ile çalışma imkanı sağlaması ile birlikte çalışmalara konu olmuştur. [21, 22, 23, 24]

Gabor Dalgacık Dönüşümü

Yüz tanıma işlemleri için tercih edilen Gabor dalgacık dönüşümü öznitelik tabanlı bir yöntemdir. Gabor öznitelikleri, gri seviye değerlerinin iki boyutlu karmaşık Gabor filtreleri ile filtrelenmesiyle oluşturulan özniteliklerdir. Gabor filtrelerinin öznitelik çıkarımında kullanım nedeni beyindeki görme sisteminin matematiksel çıkarımlarının Gabor fonksiyonlarıyla benzeşmesidir. Ayrıca Gabor yönteminin kullanım avantajı yönsel seçicilik olmakla birlikte farklı çalışmalara konu olmaktadır. [25] Yüz görüntüsüne uygulanması için görüntünün uzay frekans analizinin sağlanması gerekmektedir. Bu yöntem ile hem yüz görüntüsü tanıma işlemi için maksimum verim sağlanırken hem de ışık vb etkenlerin etkisi minimuma indirilmiştir. [25, 26, 27]



Şekil 11 Gabor dalgacık dönüşümünün yüz şekli üzerinde uygulaması a) örnek bir yüz görüntüsü (FERET) b) Gabor Dalgacık Dönüşüm Büyüklüğü c) Dönüşümün Gerçek Kısmı [25]

Tartışma ve Bulgular

Yüz tanıma işlemleri için kullanılan algoritmalar çeşitli çalışmalara konu olmuştur. Örneğin; Eknel ve ark. [28] tarafından gerçekleştirilen çalışmada aydınlatma alt-uzaylarına dayalı yüz tanıma sisteminde, TBA'dan yararlanmıştır. Yapılan çalışma sonucunda sadece TBA'ya dayalı özneliklerinin yararlandığında eğitim oranının %49 olduğu ve aydınlatma alt-uzayı ile geliştirdiği çalışma ile %82.4 oranında bir başarımlar elde etmiştir. Ayrıca Kekül ve ark. [29] tarafından yapılan çalışmada öz yüzler metodu ile yüz tespitin ideal şartlarda ön profilden alınan görüntülerin tanınmasında özyüzlerin tanıma performansının %96,25 gibi çok üst düzeyde olduğu görülmüştür. Holat ve ark. [4] geliştirdiği çalışmada farklı aydınlatma durumlarının yüz tanıma üzerine etkisini anlamak için özyüzler ve fisherfaces algoritmaları ile tanıma metodunda yararlanarak tba, lda ve lbp seçim yöntemlerini karşılaştırmışlardır. Bu yöntemde %91'e varan başarımlar oranları elde etmiştir.

Ayrıca literatürde yapılan araştırmalar neticesinde özyüzler ve fisherfaces metodu karşılaştırılmıştır. Örneğin Özdemir [30] tarafından yapılan çalışmada özyüzler ve fisherfaces metodları ile LBP yöntemi temelinde geliştirilmiş olan LBPH algoritmaları karşılaştırılmıştır. Sonuç olarak LBPH algoritmasının fisherfaces ve özyüzler algoritmasından daha iyi bir başarımlara sahip olduğu gözlemlenmiştir. Başka bir çalışmada Mamak ve ark [31] tarafından özyüzler, fisherfaces ve LBPH yöntemlerinin yüz tanıma hız oranları karşılaştırılmasına yönelik bir çalışma yapılmıştır. Yapılan çalışma sonucu elde edilen sonuçlara göre, yerel ikili arama histogramı (LBPH) yöntemi ortalama 1,99 saniyede, özyüzler algoritması 2,66 saniyede ve fisherfaces algoritması 2,50 saniyede yüz algılama ve tanıma işlemlerini gerçekleştirmektedir.

Aksoy [17] tarafından gerçekleştirilen çalışmada LBP, LDA, PCA ve SVD algoritmaları karşılaştırılmış. Çalışmada yüz görüntüsü; ön, alt, yan ve üst yüz olarak ayrı ayrı parçalarda tanınması sağlanmıştır. Çalışmada alt yüzün bulunması için en iyi sonucu LBP algoritmasının verdiği tespit edilmiştir. Başarımlar oranı olarak 41 gönüleden alınmış görüntü de %78.1'lik bir başarımlar elde edilmiştir. Yan yüzde ise oldukça başarısız olan LBP algoritması %0'lık bir başarımlar göstermiştir. Son olarak Yıldız ve ark. [32] tarafından yapılan kapsamlı bir çalışmada bir çok modelin yüz tanıma üzerinde zayıf ve güçlü yanlarının tespit edilmiştir. Yapılan çalışma sonuçlarında; kullanılan derin öğrenme modelleri olan CNN ve HOG algoritmaları diğer algoritmalara göre daha yüksek başarımlara sahip olduğu sonucuna varılmıştır. Bu algoritmalar CPU işlemci ile en iyi sonucu HOG algoritması sağlarken yan yüzde başarımlar oranının GPU destekli CNN modellere göre çok daha düşük olduğu gözlemlenmiştir. CNN modellerin tartışılan modeller arasında en iyi sonuç verdiği gözlemlenmiştir. Ayrıca klasik modellerde ise LBP yönteminin en iyi başarımlara sahip olduğu ve hızlı sonuç verdiği tespit edilmiştir. Yüz tanıma yöntemleri ile yapılan çalışmalar ışığında algoritmaların zayıf ve güçlü tarafları Tablo-1'de gösterilmektedir.

Tablo 4. *Yüz tanıma algoritmalarının avantaj ve dezavantajları*

Yüz tanıma algoritması	Avantajlar	Dezavantajlar
CNN (Evrışimsel Sinir Ağları)	<ul style="list-style-type: none"> • Resimleri ön işlem gerekliliği duymama ya da az duyma • Açık ve ışıklandırma sorunundan oldukça az etkilenme • Yüksek başarımlı ve tanıma • Gerçek zamanlı uygulanabilir ve güvenilir olma 	<ul style="list-style-type: none"> • Güçlü cihaz gereksinimi (GPU ile işlem yapma) • Yüksek maliyet
HOG (Histogram of Oriented Gradients)	<ul style="list-style-type: none"> • Düşük işlem maliyeti • Gerçek zamanlı uygulanabilirlik • CPU ile yapılan işlemlerde yüksek hız ve başarılı sonuç 	<ul style="list-style-type: none"> • Görüntüdeki şekil ve doku hakkında bilgileri göz ardı etme • Tekrar sebepli gereksiz bilgi tutma
Gabor Dalgacık Dönüşümü	<ul style="list-style-type: none"> • Tek yönde mükemmel seçicilik • Dönme-kayma vb durumlarda yüksek başarımlı • Frekans uzay dönüşümü ile açı ve ışık gibi etkilerden minimum etkilenme 	<ul style="list-style-type: none"> • Farklı yönlerde düşük başarımlı
LBP (Yerel İkili Örüntüler)	<ul style="list-style-type: none"> • Işık Faktörlerine karşı güçlü yanıt verme • Hızlı sonuç verme 	<ul style="list-style-type: none"> • Gürültüye karşı hassasiyet
TBA (Temel Birleşen Analizi)	<ul style="list-style-type: none"> • Minimalize edilmiş veriler ile düşük kapasitede işlem imkanı • Gürültülerden düşük hassasiyet ile etkilenme • Küçük alt uzaylarda başarılı sonuç verme 	<ul style="list-style-type: none"> • Işık, açı gibi yan etkilerden etkilenme • Verilerin ön işleme ve hizalama gibi işlemlere tabi tutulma zorunluluğu

Sonuç

Günümüz teknolojisinin gelişimi ile birlikte, bilgilerin ulaşılması, toplanması ve depolanmasında da ciddi bir yoğunluk ve hız kazanılmıştır. Bu depolanan verilerinin anlamlandırılması adına veri madenciliği, istatistik, görüntü işleme, yapay zekâ gibi bir çok çalışma alanları kullanılmaktadır. Bu çalışmada güncel konulardan birisi olması nedeniyle yüz tespit ve tanıma teknikleri üzerine yapılan çalışmalar ve algoritmalar değerlendirilmiştir.

Yüz tanıma güvenlik, kimlik doğrulama, banka işlemleri ve birçok alan için tercih sebebi olan hata payı düşük ve gerçek zamanda çalışma imkânı suna bilen ve sürekli gelişim de olan bir çalışma alanıdır. Bu kadar fazla rağbet görülmesi nedeniyle oldukça farklı alanlar için ve farklı sorunlara çözüm üretmesi adına farklı algoritmalar literatürde sunulmuş ve sunulmaya devam etmektedir.

Yapılan literatür taraması ışığında; TBA tabanlı öz yüzler ve fisherfaces, HOG, LBP, CNN algoritmaları sıklıkla tercih sebebi olmuştur. Bu algoritmalar içinde öz yüzler ve fisherfaces ve LBP arasında karşılaştırmalar yapılmıştır. Hız ve başarımları olarak LBP algoritması diğerlerine göre daha iyi sonuçlar verdiği literatür de görülmektedir. Ayrıca yapılan araştırmalarda kullanılan klasik teknikler yanı sıra derin öğrenme ile yapılan yüz tanıma işlemleri de karşılaştırılmıştır. Burada CNN ve HOG algoritmalarının çalışma başarımının oldukça güçlü olduğu görülmektedir. Bunlardan HOG algoritması ön yüz işleme için oldukça başarımlı verirken yan yüz işleme için başarımlı düşüktür. Bu durumda CNN derin ağ modeli yapılan araştırma sonucunda, araştırılan teknikler arasından en yüksek başarımlıya sahiptir. Ancak CNN modeli yalnızca GPU destekli işlemler için çalışma olanağı sağlamakta olduğu literatür sonucunda görülmektedir

Kaynakça

- [1] G. Y. ÖZTEL, «Yüz Analizine dayalı Derin Öğrenme Tabanlı Bir İlgilendirme Sisteminin Gerçekleştirilmesi,» YÖK/DOKTORA, Sakarya , 2019.
- [2] Ç. K. Ersin Öztürk, «Görünüm Tabanlı Yüz Tanıma Yöntemleri Kullanılarak Cinsiyet Belirleme,» *Avrupa Bilim ve Teknoloji Dergisi*, 2020.
- [3] M. T. Emre Arıç, «Video Duygu Analizi,» *Avrupa Bilim ve Teknoloji Dergisi*, pp. 59-67, 2020.
- [4] S. K. Recep Holat, «Yüz bulma ve yüz tanıma sistemleri kullanarak kimlik tanıma,» 22nd Signal Processing and Communications Applications Conference, 2014.
- [5] D. A. İ. Y. Sümeyye Bayrakdar, «Video dosyaları üzerinde yüz ifade analizi için hızlandırılmış bir yaklaşım,» *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 2017.

- [6] A. Y. Erdoğan, «Yüz tanıma özyüz ve fisher yüz algoritmalarının incelenmesi,» Ankara Üniversitesi /YL Tezi, Ankara, 2010.
- [7] Z. Tan, «DERİN ÖĞRENME YARDIMIYLA ARAÇ SINIFLANDIRMA,» Fırat Üniversitesi / YL TEZİ, 2019.
- [8] F. A. Erkan DUMAN, «YÜZ TANIMA SÜRECİNDE FARKLI CNN MODELLERİNİN PERFORMANS KARŞILAŞTIRMASI,» %1 içinde *MARDİN ARTUKLU ULUSLARARASI MULTİDİSİPLİNER ÇALIŞMALAR KONGRESİ*, Mardin, 2019.
- [9] B. KABASAKAL, «UZAKLIK VE CİNSİYET TABANLI AKILLI REKLAM GÖRÜNTÜLEME SİSTEMİ,» Başkent Üniversitesi/ YL, 2018.
- [10] WILDML, ««UNDERSTANDING CONVOLUTIONAL NEURAL NETWORKS,» 2016. [Çevrimiçi]. Available: <http://www.wildml.com/2015/11/understanding-convolutional-neural-networks-for-nlp/>.
- [11] İ. ÖZTEL, «KİSMİ VE TAM YÜZ GÖRÜNTÜLERİ ÜZERİNDE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE YÜZ İFADESİ TESPİTİ,» Sakarya Üniversitesi/ DOKTORA TEZİ, 2018.
- [12] S. Murat, «İNSANSIZ HAVA ARACI GÖRÜNTÜLERİNDEN DERİN ÖĞRENME YÖNTEMLERİYLE NESNE TANIMA,» Maltepe Üniversitesi/ YL TEZİ, 2021.
- [13] H. A. F. K. M. Peker, «HOG Temelli Bir Yöntem ile Ölçek ve Yönden Bağımsız Gerçek Zamanlı Nesne Tanıma,» %1 içinde *Otomatik Kontrol Türk Milli Komitesi'nin Otomatik Kontrol Ulusal Toplantısı*, 2012.
- [14] N. ALPASLAN, «GRADYAN TABANLI HETEROJEN ÖZNİTELİK ÇIKARMA YÖNTEMLERİNE YENİ YAKLAŞIMLAR,» İnönü Üniversitesi/ YL Tezi, Malatya, 2013.
- [15] A. E. ÇAPANOĞLU, «BÜYÜK YÜZ VERİTABANLARINDA HIZLI ARAMA SİSTEMİ,» Gazi Üniversitesi/ YL Tezi, Ankara, 2016.
- [16] Ş. Erol, «YÜZ BÖLGELERİNİN AĞIRLIKLANDIRILMASININ YEREL İKİLİ ÖRÜNTÜLER İLE YÜZ TANIMA PERFORMANSINA ETKİSİ».
- [17] B. Aksoy, «TEMLERİNDE DOĞRULUK PERFORMANSLARININ DEĞERLENDİRİLMESİ,» *Mühendislik Bilimleri ve Tasarım Dergisi*, 2019.
- [18] E. A. Türker Tuncer, «Yerel İkili Örüntü Tabanlı Veri Gizleme Algoritması: LBP-LSP,» *TÜRKİYE BİLİŞİM VAKFI BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ DERGİSİ*, 2017.
- [19] A. Yayılıcı, «Temel bileşenler analizi için robust algoritmaları,» Gazi Üniversitesi/ YL tezi, 2006.

- [20] Z. Filiz, «Temel Bileşenler ve Faktör Çözümlemesi,» *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 2003.
- [21] I. Yazar, «Temel Bileşen Analizi ve Bağımsız Bileşen Analizi Yöntemlerini Temel Alan Bazı Görüntü Tanıma Uygulamaları ve Karşılaştırmaları,» Eskişehir Osmangazi Üniversitesi, Eskişehir, 2008.
- [22] A. A. Serkan Tüzün, «YÜZ UZAYININ DİKLEŞTİRİLMESİNE DAYANAN YENİ BİR YÜZ TANIMA YÖNTEMİ,» İstanbul Üniversitesi BAP.
- [23] M. Ç. v. F. Özen, «Özyüzler ile Yüz tanıma,» *GELECEĞİN TEKNOLOJİLERİ SEMPOZYUMU*, 2011.
- [24] B. K. F. k. A. Ç. M Gökmen, «Çok Amaçlı Gürbüz Yüz Tanıma,» TÜBİTAK, 2017.
- [25] G. ELEYAN, «GÖRÜNTÜ ÇERÇEVELERİNDE YÜZ ALGILAMA VE VERİTABANI İLE EŞLEME YAPILMASI,» YÖK/ YL TEZİ.
- [26] H. Çevikalp, «Frontal imgelerden otomatik yüz tanıma,» %1 içinde *Sinyal İşleme ve İletişim Uygulamaları Konferansı*, 2013.
- [27] M. O. İ. H. D. L. A. E. Berk Gökberk, «Yüz tanıma için en iyi gabor parametrelerin seçimi,» %1 içinde *Örüntü ve Nesne Tanıma*, İstanbul, 2003.
- [28] H. E. R. S. D. Kern, «Aydınlanma Alt-uzaylarına dayalı Gürbüz Yüz Tanıma,» Bilinmeyen.
- [29] H. KEKÜL, «YÜZ TANIMA UYGULAMALARINDA ÖZYÜZLER VE YAPAY SİNİR AĞLARININ KARŞILAŞTIRILMASI,» *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilim Dergisi*.
- [30] M. F. ÖZDEMİR, «GÖMÜLÜ SİSTEMLERDE YÜZ TANIMA ALGORİTMALARININ KARŞILAŞTIRILMASI,» YÖK, Afyon, 2018.
- [31] M. Z. K. S. S. M. H. B. U. Uğur Mamak, «Gerçek Zamanlı Yüz Tanıma Tabanlı Personel Kontrol ve Takip Sistemi Tasarımı,» *Avrupa Bilim ve Teknoloji Dergisi*, 2020.
- [32] E. Ö. N. B. Sedat Yıldız, «Yapay Zeka Tabanlı Yüz Tanıma Sisteminin Geliştirilmesi Ve Optimizasyonu,» 2019.
- [33] B. K. v. F. Özen, «Yüz Tanıma Tekniklerindeki Gelişmeler,» %1 içinde *Geleceğin teknolojileri sempozyumu*, 2011.
- [34] «Yüz ifadelerinin otomatik analizi üzerine bir literatür çalışması,» *SaU Fen Bil. Dergisi*, 2016.

- [35] Y. D. Prof. Dr. Fikret Arı, «VİDEO GÖRÜNTÜLERİNE DAYALI OLARAK GERÇEK ZAMANLI GÖZ HAREKETLERİ TAKİP SİSTEMİ TASARIMI,» Ankara Üniversitesi BAP, 2015.

S-40 COVID19 PANDEMİSİNDE TÜRKİYE İBBS-1 BÖLGELERİ GÜNLÜK VAKA SAYISI TRENDİNİN DOĞRUSAL REGRESYONLA TAHMİNİ İÇİN DİJİTAL BİR UYGULAMA

Hatice Sena Manap, Abdullah Uçar, Şeyma Arslan

Giriş

Aralık 2019’da Çin’de (Hubei-Wuhan) ilk şüpheli vakalarla başlayan salgın, 11 Mart 2020 tarihinde DSÖ tarafından pandemi olarak ilan edildi.⁹ T.C. Sağlık Bakanlığı tarafından pandemiye özgü test sayısı, yeni hasta sayısı gibi Türkiye’nin 12 İBBS1 bölgesine ait epidemiyolojik veriler 29 Haziran-23 Kasım 2020 tarihleri arasında günlük rapor şeklinde ve 17 Ağustos-25 Eylül 2020 tarihleri arasında haftalık raporlar şeklinde yayınlandı.¹⁰ TURCOVID19 tarafından açık veri setine dönüştürülen veriler online olarak kullanıcılara sunuldu.¹¹ . Salgın yönetiminde veri temini amacıyla web tabanlı platformların kurulması, mevcut verileri gerçek zamanlı sunan çevrimiçi portalların oluşturulması salgın seyrini izleme ve alınacak önlemlere karar vermeyi kolaylaştırmaktadır.¹²

Salgın seyrinin takibinde periyodik vaka artış hızı, duplikasyon süresi ve salgın değerlendirmesindeki en güçlü parametrelerden olan Rt değerleri gibi parametreler kullanılır. Vakaların artış veya azalış hızındaki eğilimi görselleştirmek için ise veri kümesine lineer ve çoklu lineer regresyon teknikleri uygulanabilmektedir.¹³ Regresyon modellerinde basit lineer regresyon modeli, COVID-19 yeni olgu ve yeni ölümlerin verilerine kuadratik ve kübik regresyon modellerine göre daha uygun bulunmuştur.¹⁴

Bu çalışmada Türkiye’deki 12 İBBS-1 bölgesinin son 1 aylık verisiyle oluşturulan lineer regresyon eğrisinin eğimine göre bölgenin vaka artış / azalış hızının tespit edilmesi ve kademelere ayrılması, bu işlemlerin otomatize edilerek kamuoyuna gerçek zamanlı bilgi sunacak bir uygulama geliştirilmesi.

Materyal Metot

Çalışma kapsamında, Sağlık Bakanlığı tarafından PDF formatında yayınlanan günlük raporlardaki verilerin düzenli olarak ve ekran kontrolü ile girişinin yapıldığı dinamik bir veri tabanı hazırlanmıştır. Veri tabanında yapılan kodlama ile her bir İBBS-1 bölgesinin son 30 günlük hasta sayıları ile lineer regresyon eğrisi oluşturulmuş, son 30 günlük sürede her bir bölgenin regresyon eğrisinin eğimi hesaplanmıştır.

⁹ <https://www.medrxiv.org/content/10.1101/2020.09.04.20188094v1.full.pdf>


¹⁰ <https://covid19.saglik.gov.tr/TR-68443/covid-19-durum-raporu.html>

¹¹ <https://turcovid19.com/acikveri/>

¹² <https://dergipark.org.tr/tr/download/article-file/1015576>

¹³ <https://www.medrxiv.org/content/10.1101/2020.09.04.20188094v1.full.pdf>

¹⁴ <https://www.medrxiv.org/content/10.1101/2020.09.04.20188094v1.full.pdf>



Şekil 12: Regresyon eğrisi ve eğim hesaplama parametreleri


Eğim hesaplanırken, Şekil 1’de görülen regresyon eğrisi için eğim formülü olarak $Eğim = \frac{\alpha}{\beta}$ formülü kullanılmıştır. Bu formülde α (alfa), regresyon denkleminde göre bugünkü tahmini değer ile 30 gün önceki tahmini değer farkını ifade etmektedir. β (Beta) ise 30 günlük süreyi ifade etmektedir ve 12 İBBS-1 bölgesi için de bu süre hesaplamalarda 1 birim olarak kabul edilmiştir. Bu durumda α doğrudan eğimi ifade eden birim olarak kullanılmıştır. α değeri grafik yükselirken pozitif, alçalırken negatif değerler almaktadır, grafik düz çizdiğinde ise sıfıra yakınsamaktadır.

İkinci aşamada, hesaplanan eğim değerlerine göre bölgelerdeki hasta artış veya azalışı yüksek, orta ve hafif olmak üzere 6 kategoriye ayrılmıştır. Bölgelerdeki hasta artış hızları bazı dönemlerde üstel artış hızıyla yükseldiği için bu kategoriler arasındaki kestirim değerlerinin sabit değerler olarak belirlenmesi yöntemi tercih edilmemiş, bölgelerin birbirine görece artışı veya azalışı temel alınmıştır. Buradaki göreceliliğin hesabında ise eğim değerleri, ortalaması 0 ve standart sapması grup standart sapmasına eşit olan bir dağılıma standardize edilmiş, böylece her bir değer hangi yönde ve 0’dan kaç standart sapma uzaklıkta olduğu tespit edilmiştir. Bu standardizasyon neticesinde 0-1 standart sapma arası hafif artış, 1-2 arası orta artış, 2 ve üzeri ise yüksek artış olarak, -1 ve 0 arası hafif azalış, -2 ve -1 arası orta azalış, -2 ve altı ise yüksek azalış olarak kategorize edilmiştir.

Son olarak tüm bu süreç yapılan kodlamalar ile otomatize edilmiş, veri tabanına veri girildiği anda gerçek zamanlı hesaplama yapan, verileri ve hesaplama sonucunu otomatik olarak görselleştiren kamuya açık, interaktif bir izlem ekranı oluşturulmuştur. Yazılım alt yapısı olarak Google Tablolar ve Google Datastudio kullanılmıştır.

Bulgular

Son raporun yayınlandığı 23 Kasım 2021 tarihinde vaka sayısı son 1 ayda azalan bölge bulunmamaktadır. Son 1 aylık hasta artış trendi en yüksek olan bölge İstanbul bölgesidir. Bu tarihten 1 ay önceye göre İstanbul’daki günlük hasta sayısı 594 kişi artmıştır. Aynı tarih aralığında en az artış gösteren bölge ise Kuzey Doğu Anadolu bölgesidir ve bir aydaki günlük hasta sayısı 61 kişi artmıştır. 4 bölge yüksek artış, 3 bölge orta artış, 5 bölge hafif artış eğilimindedir. (Şekil 2).



Şekil 13: Türkiye 12 İBBS-1 bölgesinde günlük hasta sayısı dağılımı ve değişim trendleri

Sonuç ve Öneriler

Bu çalışmada Türkiye 12 İBBS-1 bölgesinde COVID19 günlük hasta artış ve azalış trendleri anlık olarak hesaplanarak bilim insanları ve karar vericiler için sunulmuştur. İzlem ekranı interaktif yapıda olup istenilen bölgeler seçilerek karşılaştırma yapılmasına imkan tanımaktadır.

Salgın hastalıklar gibi hızlı karar verilmesi gereken durumlarda sağlık hizmetlerinin önceliklendirilmesinde ve sunumunda karar destek sistemlerinin önemi ve gerekliliği Covid-19 pandemisinde daha iyi anlaşılmıştır. Özellikle olağandışı durumda takip edilmesi gereken birçok parametre bulunmakta ve bu parametreler anlık olarak değişmektedir. Bu verilerin anlık olarak takip edilebilmesi için dinamik veri setleri ile analiz yapan dijital epidemiyoloji uygulamalarına ihtiyaç bulunmaktadır.

Lineer regresyon modellerinin kısa vadede eğilim tespit edilebildiğine dair çalışmalar, bu yöntemin trend analizinde de kullanılabileceğine kanıt teşkil etmektedir. Bu modellerin sağlık alanında farklı veri tiplerine uygulanması ile salgın başta olmak üzere hızlı harekete geçilmesi gereken durumlarda karar vericilere öngörü desteği sağlayacağı düşünülmektedir.

**S-41 DERİN ÖĞRENME YÖNTEMİYLE AKUT PULMONER EMBOLİNİN
BİLGİSAYARLI TOMOGRAFİK PULMONER ANJİOGRAFİDE
SEGMENTASYONU**

NEVİN AYDIN¹

1.Radyoloji Anabilim Dalı, Eskişehir Osmangazi
Üniversitesi,Türkiye,drnevinaydin@gmail.com

Özet

Akut pulmoner emboli tanısını derin öğrenme metoduyla koyabilmek, pulmoner embolinin segmentasyonunu yapmak amaçlanmaktadır.

Çalışmamızda toplam 2339 adet aksiyel bilgisayarlı tomografi görüntüsünde toplam 5992 etiketleme yapılmış olup train data setinde 1879 görüntü - 4929 etiketleme kullanılmış olup, validation aşamasında 230 görüntü, 530 etiket; test grubu aşamasında 230 görüntü , 533 etiket kullanılmıştır. Karışık boyutlardaki görüntüler 512x512 olarka resize edildi. Test grubunda Doğru Bulunan: 471, Yanlış Bulunan: 35, Bulunamayan: 27 olarak saptanmıştır.

Pulmoner embolinin segmentasyonunda bilgisayarlı tomografide derin öğrenme yöntemi kullanılabilir bir yöntemdir.

Anahtar Sözcükler: Bilgisayarlı Tomografi, Derin Öğrenme, Pulmoner Emboli

Abstract

It is aimed to diagnose acute pulmonary embolism with deep learning method and to segment pulmonary embolism.

In our study, a total of 5992 labels were made on 2339 axial computed tomography images, and 1879 images - 4929 labels were used in the train data set. 230 images and 533 tags were used in the test group stage. Mixed size images were resized to 512x512. In the test group, it was determined as 471, False: 35, Not Found: 27.

Deep learning method in computed tomography is a usable method in the segmentation of pulmonary embolism.

Keywords: Computed Tomography, Deep Learning, Pulmonary Embolism

1. GİRİŞ:

Pulmoner emboli ana pulmoner arterde ve dallarında izlenen tromboemboli çeşididir. Mortalite ve morbiteyi azaltmak için tanısının çabuk konulması önemlidir. Bilgisayarlı tomografik pulmoner anjiyografi pulmoner emboli için gold standarttır(1-2). Pulmoner emboliyi segmente eden çalışmalar yapılmış olup(3) çalışmamızdaki görüntülerde U-net mimarisini kullanarak segmentasyon yapıldı.

Segmentasyon genellikle görüntü analizinin ilk aşamasında kullanılır. Görüntü segmentasyonu, bir görüntüyü her biri içerisinde farklı özelliklerin tutulduğu anlamlı bölgelere ayırmak olarak tarif edilebilir.

2. AMAÇ:

Akut pulmoner emboli tanısını derin öğrenme metoduyla koyabilmek, pulmoner embolinin segmentasyonunu yapmak amaçlanmaktadır.

3. MATERYAL VE YÖNTEM:

ESOGÜ Tıp Fakültesi'nde Radyoloji Anabilim Dalı'nda etik kurul onayı alındıktan sonra 01.01.2016-01.01.2021 yılları arasında hastalar retrospektif olarak tarandı. 18 yaş üstü hastalar çalışmaya dahil edilmedi. Randevulu çekim yapılan pulmoner emboli tanısı alan hastalar çalışmaya dahil edildi.

Görüntülerin etiketlenen bölgelerinin mask görüntüleri oluşturulup aynı isimlerle kaydedildikten sonra veri seti 80-10-10% oranlarında eğitim-doğrulama-test olacak şekilde 3 parçaya bölünür. Hacimsel girişi işlemek için genişletilen geleneksel Pytorch UNet mimarisi ile epoch eğitimleri yapılır. Karşılık gelen kodlayıcı ve kod çözücü katmanları arasında kullanılan atlama bağlantıları, ağın derin bölümlerinin verimli bir şekilde eğitilmesini ve aynı alıcı özelliklerin farklı alıcı alanlarla karşılaştırılmasını sağlar (4).

Sonlu örnek kümeleri arasındaki benzerliği ölçen ve kesişme boyutunun örnek kümelerinin birleşiminin boyutuna bölünmesi olarak tanımlanan (5) Birleşim Üzerinde Kesişim (The Intersection over Union, IoU, Jaccard Endeksi) istatistiğinin eşik değeri olarak %50 seçilerek sonuçlar hesaplanır.

4. BULGULAR:

Çalışmamızda toplam 2339 adet aksiyel bilgisayarlı tomografi görüntüsünde toplam 5992 etiketleme yapılmış olup train data setinde 1879 görüntü - 4929 etiketleme kullanılmış olup, validation aşamasında 230 görüntü, 530 etiket; test grubu aşamasında 230 görüntü, 533 etiket kullanılmıştır. Karışık boyutlardaki görüntüler 512x512 olarak resize edildi. Görüntülere %50 oranında zoom uygulanarak segmente edilecek bölgeler görüntüye sığabilecek en yüksek

oranda büyütüldü. Clahe uygulanarak segmente edilecek bölgelerin belirginliği arttırıldı. Train ve Validation üzerinde augmentation uygulanarak (Both - Horizontal - Vertical) veri sayısı 4 katına çıkarıldı. (Train: 7516 görüntü - 19716 label, Validation: 920 Görüntü - 2120 label). Pytorch Unet ile 400 epoch eğitildi, en iyi model olan 178. epoch modeli kaydedildi. Test grubunda Doğru Bulunan: 471, Yanlış Bulunan: 35, Bulunamayan: 27 olarak saptanmıştır.

5. SONUÇLAR:

Pulmoner embolinin segmentasyonunda bilgisayarlı tomografide derin öğrenme yöntemi kullanılabilir bir yöntemdir.

REFERANSLAR:

1. Agnelli G, Becattini C. Acute pulmonary embolism. *N Engl J Med.* 2010;363(3):266-74
2. Moroni C, Bartolucci M, Vanni S, Peiman N, Bartolini M, Miele V, editors. Prognostic value of CT pulmonary angiography (CTPA) parameters in acute pulmonary embolism parameters in acute pulmonary embolism (APE) 2017: European Congress of Radiology 2017.
3. Huang SC et al. PENet- a scalable deep-learning model for automated diagnosis of pulmonary embolism using volumetric CT imaging. *Npj Digital Medicine* 2020;3:61
4. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention- MICCAI 2015* pp 234-241 Springer.
5. Tan PN, Steinbach M, Kumar V (2005), *Introduction to Data Mining*. ISBN 0-321-32136-7.

***İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma Projeleri
Koordinatörlüğü tarafından desteklenmiştir...***

Tanıtım Sponsoru



**Patentli Dijital Pazarlama Otomasyonu ile
Siz de İnternet Reklamlarınızın Performansının
6 Kata kadar Artmasını İster misiniz?**

Detaylı Bilgi için

444 0 964

www.adresgezgini.com