



IMAEC

**11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE
AND ARCHITECTURE**

August 25-28, 2026
Bucharest/ROMANIA

PROCEEDINGS BOOK



EDITOR:
Assoc. Prof. Dr. M. Can YARDIMCI

ISBN: 978-625-90699-3-7

IMAEC 11th INTERNATIONAL CONGRESS ON ADVANCED ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE

August 25-28, 2026 Bucharest/ROMANIA



www.ubsder.org

PROCEEDINGS BOOK

EDITOR IN CHIEF

Assoc. Prof. Dr. M. Can YARDIMCI

ISBN: 978-625-90699-3-7

by

ACADEMIC SHARING PLATFORM PUBLISHING HOUSE®

All Rights Reserved.

The authors are solely responsible for the ethical
and legal content of their contributions.

APP Publications – 2026 ©

Publication Date: 05.10.2026



CONGRESS ID

CONGRESS TITLE

*IMAEC 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE*

DATE and PLACE

August 25-28, 2026 Bucharest/ROMANIA

ORGANIZATION

**UBS-Institute of International Scientific Research and Strategy Development Association,
Akademik Paylaşım Platformu Eğitim Ltd.Şti.,Ankara,Türkiye**

EDITOR IN CHIEF

Assoc. Prof. Dr. M. Can YARDIMCI

CONGRESS ORGANIZERS

**Uluslararası Bilimsel Araştırma ve Strateji Geliştirme Derneği, Türkiye
IJHAS,International Journal of Health and Applied Science,Türkiye**

PARTICIPANT COUNTRIES (6):

Azerbaijan, Nigeria, Pakistan, Pakistan, Türkiye, Uzbekistan

NUMBER OF ACCEPTED PAPERS (37):

(Türkiye-13, Other Countries-24)

PRESENTATION

Oral presentation

EVALUATION PROCESS

All applications have undergone a double-blind peer review process

ISBN: 978-625-90699-3-7

ORGANIZING COMMITTEE

Prof. Dr. Mehmet ILKIM
İnönü University, Malatya, Türkiye

Prof. Dr. Hasan TUTAR
Bolu Abant İzzet Baysal University, Bolu, Türkiye

Prof. Dr. Hakan AYDOĞAN
Samarkand State University, Samarkand, Uzbekistan

Assoc. Prof. Dr. Özkan AÇIŞLI
Atatürk University, Erzurum, Türkiye

Assoc. Prof. Dr. Melda Medine SUNAY
Bursa Technical University, Bursa, Türkiye

Assoc. Prof. Dr. Kübra KOÇ
Atatürk University, Erzurum, Türkiye

Assoc. Prof. Dr. Cafer BUDAK
Dicle University, Diyarbakır, Türkiye

Assoc. Prof. Dr. Nurlan BAIGABYLOV
L. N. Gumilyov Eurasian National University, Astana, Kazakhstan

Assoc. Prof. Dr. M. Can YARDIMCI
Afyon Kocatepe University, Afyon, Türkiye

Asst. Prof. Dr. Hilal Koç Polat
Erzurum Technical University, Erzurum, Türkiye

Asst. Prof. Dr. Aslı KAYA
Istanbul Gelişim University, Istanbul, Türkiye

Asst. Prof. Dr. Hayri YILDIRIM
Dicle University, Diyarbakır, Türkiye

SCIENTIFIC BOARD MEMBERS

- Prof. Dr. Yaşar Hamza OCAK** – Kütahya Dumlupınar University, Türkiye
Prof. Dr. Sinem SOMUNOĞLU İKİNCİ – Bursa Uludağ University, Türkiye
Prof. Dr. Anderj JEAN – Gas Petroleum University of Romania, Romania
Prof. Dr. Müjdat AVCI – Osmaniye Korkut Ata University, Türkiye
Prof. Dr. Basim ALHADİDİ – Al-Balqa Applied University, Jordan
Prof. Dr. Ashraf M. A. AHMAD – Princess Sumaya University for Technology, Amman, Jordan
Prof. Dr. Raymond KOSALA – The Joseph Wibowo Center for Advanced Learning, Jakarta, Indonesia
Prof. Dr. Wen-Lin YANG – National University of Tainan, Taiwan
Prof. Dr. Gülzar İBRAHİMOVA – Baku Eurasian University, Azerbaijan
Assoc. Prof. Dr. M. Can YARDIMCI – Afyon Kocatepe University, Afyon, Türkiye
Assoc. Prof. Dr. Muhammad Zia-ur-Rehman – University of Malaya, Malaysia & National Defence University, Pakistan
Assoc. Prof. Dr. Aytekin ZEYNALOVA – Baku State University, Azerbaijan
Assoc. Prof. Dr. Sibel AKOVA – Yalova University, Türkiye
Assoc. Prof. Dr. Fahri ÖZSUNGUR – Mersin University, Türkiye
Assoc. Prof. Dr. Gönül SAMEDOVA – Azerbaijan State Pedagogical University, Azerbaijan
Asst. Prof. Dr. Abdullah Yüksel BARUT – Istanbul Gelişim University, Istanbul, Türkiye
Asst. Prof. Dr. Hayri YILDIRIM – Dicle University, Diyarbakır, Türkiye
Asst. Prof. Dr. Michal Wojtaszek – Warsaw University of Life Sciences, Poland
Asst. Prof. Dr. Maral Jamalova – Szent István University, Hungary
Asst. Prof. Dr. Nicholas Imbeah – Takoradi Technical University, Ghana
Asst. Prof. Dr. Subhashish DEY – Gudlavalleru Engineering College, Department of Civil Engineering, Andhra Pradesh, India
Asst. Prof. Dr. Ananda MAJUMDAR – North Central Theological Seminary, Minneapolis, USA
Asst. Prof. Dr. Subhashish DEY – Department of Civil Engineering, Gudlavalleru Engineering College, Andhra Pradesh, India

UBSDER

Çankaya - Ankara

06-139-180

Konu: Kongre Düzenleme Kurulu

25.05.2026

Sayı:2026/220

İLGİLİ KURUMA


İçişleri Bakanlığı tarafından tahsis edilen 06-139-180 tescil kodu ile Tüzel kişiliğe sahip olan Uluslararası Bilimsel Araştırma ve Strateji Geliştirme Derneği, 5253 sayılı kanuna uygun olarak “Bilimsel Araştırmalar ve Akademik Çalışmalar” alanında ulusal ve uluslararası düzeyde faaliyetlerini yürütmektedir.

Kurumumuzun Yönetim Kurulu tarafından, 25.05.2026 tarihinde saat 14:00’da “Bilimsel Çalışmalarda Strateji Geliştirme” görüşmeleri ile “Bilimsel Kongreler Düzenlenmesi” gündemleri ile toplanmış ve alınan 9 nolu karara istinaden aşağıda detayları yazılı olan bilimsel etkinliğin düzenlenmesine ve etkinliğe ilişkin akademisyenlerin resmi olarak görevlendirilmesine oy birliği ile karar verilmiştir.

Bilgi ve gereğini arz ederim.

Dr. Nadire KANTARCIOĞLU

UBSDER Başkanı



Etkinlik Adı : ULUSLARARASI 11. IMAEC İLERİ MÜHENDİSLİK, YAPAY ZEKÂ VE MİMARLIK KONGRESİ

Etkinlik Tarihi: 25-28 Ağustos 2026, Bükreş / ROMANYA

www.ubsder.org

Düzenleme Kurulu Üyeleri

Prof. Dr. Mehmet ILKIM

İnönü University, Malatya, Türkiye

Prof. Dr. Hasan TUTAR

Bolu Abant İzzet Baysal University, Bolu, Türkiye

Prof. Dr. Hakan AYDOĞAN

Samarkand State University, Samarkand, Uzbekistan

Assoc. Prof. Dr. Özkan AÇIŞLI

Atatürk University, Erzurum, Türkiye

Assoc. Prof. Dr. Melda Medine SUNAY

Bursa Technical University, Bursa, Türkiye

Assoc. Prof. Dr. Kübra KOÇ

Atatürk University, Erzurum, Türkiye

Assoc. Prof. Dr. Cafer BUDAK

Dicle University, Diyarbakır, Türkiye

Assoc. Prof. Dr. Nurlan BAIGABYLOV

L. N. Gumilyov Eurasian National University, Astana, Kazakhstan

Assoc. Prof. Dr. M. Can YARDIMCI

Afyon Kocatepe University, Afyon, Türkiye

Asst. Prof. Dr. Hilal Koç Polat

Erzurum Technical University, Erzurum, Türkiye

Asst. Prof. Dr. Aşlı KAYA

Istanbul Gelişim University, İstanbul, Türkiye

Asst. Prof. Dr. Hayri YILDIRIM

Dicle University, Diyarbakır, Türkiye

www.ubsder.org



IMAEC 11th INTERNATIONAL CONGRESS ON ADVANCED ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE

August 25-28, 2026 Bucharest/ROMANIA

Sayı:2026/240

İlgili Makama:

Uluslararası Bilimsel Araştırma ve Strateji Geliştirme Derneği (UBSDER) tarafından organize edilen “**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**” Ağustos 25-28, 2026 tarihinde 6 farklı ülkeden (Türkiye’den 13, yurt dışından 24 bildiri sunuldu) olmak üzere toplam 37 adet sunum yapılarak, çevrimiçi olarak düzenlenmiştir. Kongremiz, 16 Ocak 2020’de Akademik Teşvik Ödeneği Yönetmeliğine getirilen “Tebliğlerin sunulduğu yurt içinde veya yurt dışındaki etkinliğin uluslararası olarak nitelendirilebilmesi için Türkiye dışından en az beş farklı ülkeden sözlü tebliğ sunan konuşmacının katılım sağlaması ve tebliğlerin yaridan fazlasının Türkiye dışından katılımcılar tarafından sunulması esastır.” Değişikliğine uygun olarak düzenlenmiştir.

Bilgilerinize Arz Ederim.

02.10.2026

Dr. Nadire KANTARCIOĞLU

UBSDER Başkanı

www.ubsder.org

Kongremize katılan ülkeler:

Azerbaycan, Nigeria, Pakistan, Pakistan, Türkiye, Uzbekistan

IMAEC - 11th INTERNATIONAL CONGRESS ON ADVANCED ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE

August 25-28, 2026 Bucharest/ROMANIA



CONGRESS PROGRAM

www.ubsder.org

Meeting Link:

<https://us06web.zoom.us/j/4603636838?pwd=Gx9rIRf5cUTPsZZ4pilDYkYWaaEAc6.1&omn=83230032466>

Meeting ID: 460 363 6838

Password: 121314

PARTICIPANT COUNTRIES (6):

Azerbaijan, Nigeria, Pakistan, Pakistan, Türkiye, Uzbekistan

Türkiye: 13

Other Countries: 24

Önemli, Dikkatle Okuyunuz Lütfen

- ✓ Kongremizde Yazım Kurallarına uygun gönderilmiş ve bilim kurulundan geçen bildiriler için online (video konferans sistemi üzerinden) sunum imkanı sağlanmıştır.
- ✓ Online sunum yapabilmek için <https://zoom.us/join> sitesi üzerinden giriş yaparak "Meeting ID or Personal Link Name" yerine ID numarasını girerek oturuma katılabilirsiniz.
- ✓ Zoom uygulaması ücretsizdir ve hesap oluşturmaya gerek yoktur.
- ✓ Zoom uygulaması kaydolmadan kullanılabilir.
- ✓ Uygulama tablet, telefon ve PC'lerde çalışıyor.
- ✓ Her oturumdaki sunucular, sunum saatinden 15 dk öncesinde oturuma bağlanmış olmaları gerekmektedir.
- ✓ Tüm kongre katılımcıları canlı bağlanarak tüm oturumları dinleyebilir.
- ✓ Moderatör – oturumdaki sunum ve bilimsel tartışma (soru-cevap) kısmından sorumludur.

Dikkat Edilmesi Gerekenler- TEKNİK BİLGİLER

- ✓ Bilgisayarınızda mikrofon olduğuna ve çalıştığına emin olun.
- ✓ Zoom'da ekran paylaşma özelliğine kullanabilmelisiniz.
- ✓ Kabul edilen bildiri sahiplerinin mail adreslerine Zoom uygulamasında oluşturduğumuz oturuma ait ID numarası gönderilecektir.
- ✓ **Katılım belgeleri kongre sonunda tarafınıza pdf olarak gönderilecektir**
- ✓ Kongre programında yer ve saat değişikliği gibi talepler dikkate alınmayacaktır

IMPORTANT, PLEASE READ CAREFULLY

- ✓ To be able to attend a meeting online, login via <https://zoom.us/join> site, enter ID "Meeting ID or Personal Link Name" and solidify the session.
- ✓ The Zoom application is free and no need to create an account.
- ✓ The Zoom application can be used without registration.
- ✓ The application works on tablets, phones and PCs.
- ✓ The participant must be connected to the session 15 minutes before the presentation time.
- ✓ All congress participants can connect live and listen to all sessions.
- ✓ Moderator is responsible for the presentation and scientific discussion (question-answer) section of the session.

Points to Take into Consideration - TECHNICAL INFORMATION

- ✓ Make sure your computer has a microphone and is working.
- ✓ You should be able to use screen sharing feature in Zoom.
- ✓ **Attendance certificates will be sent to you as pdf at the end of the congress.**
- ✓ Requests such as change of place and time will not be taken into consideration in the congress program.

**Before you login to Zoom please indicate your name_surname and HALL number,
exp. Hall-1, Hakan ÖZTÜRK**

zoom



Meeting ID: 460 363 6838

Passcode: 121314

IMPORTANT, PLEASE READ CAREFULLY

- To be able to make a meeting online, login via <https://zoom.us/join> site, enter ID instead of “Meeting ID or Personal Link Name” and solidify the session.
- The Zoom application is free and no need to create an account.
- The Zoom application can be used without registration.
- The application works on tablets, phones and PCs.
- Speakers must be connected to the session 10 minutes before the presentation time.
- **Online presentations;** Presentation time is 10 minutes. There is 5 minutes of question and answer time.
- All congress participants can connect live and listen to all sessions.
- During the session, your camera should be turned on at least %70 of session period
- Moderator is responsible for the presentation and scientific discussion (question-answer) section of the session.

TECHNICAL INFORMATION

- Make sure your computer has a microphone and is working.
- You should be able to use screen sharing feature in Zoom.
- Attendance certificates will be sent to you as pdf at the end of the congress.
- Moderator is responsible for the presentation and scientific discussion (question-answer) section of the session.

www.ubsder.org

Opening Ceremony

Online

Date: **August 27, 2026**

Time: **18:45**

Meeting Link:

<https://us06web.zoom.us/j/4603636838?pwd=Gx9rIRf5cUTPsZZ4pilDYkYWaaEAc6.1&omn=83230032466>

Meeting ID: 460 363 6838

Password: 121314

Speech:

Dr. Nadire KANTARCIOĞLU
UBSDER President, Türkiye

www.ubsder.org

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**

August 25-28, 2026 Bucharest/ROMANIA

ONLINE

27.08.2026

SESSION-1 / HALL-1



Bucharest/ROMANIA



TÜRKİYE TIME: 19:00

CHAIR: Asst. Prof. Dr. Günay TEMÜR

Author(s)	Affiliation	Title
Asst. Prof. Dr. Günay TEMÜR	Düzce University, Gölşaka Vocational School	DATASET CHARACTERIZATION VECTOR (DCV): A DATA-CENTRIC FRAMEWORK FOR OBJECT DETECTION DATASETS
Asst. Prof. Dr. Esra ODABAŞ YILDIRIM	Atatürk University, Faculty of Engineering, Erzurum, Türkiye	COMPARATIVE ANALYSIS OF THE EFFECT OF CLIENT ACCESSIBILITY AND DATA HETEROGENEOUSNESS ON MODEL PERFORMANCE IN FEDERATED LEARNING
Muhammad FAISAL	Joint Director, AICU, Ministry of Information Technology and Telecommunication, Pakistan	SMART HUKUMAT INTEGRATING AI-DRIVEN GOVERNANCE AND PREDICTIVE ANALYTICS INTO FEDERAL ADMINISTRATION
Abdalhamid ALBEIK Lecturer Elif YILDIRIM Dr. İsa AVCI	Karabük University, Department of Computer Engineering, Karabük, Türkiye	EXPLAINABLE ENSEMBLE LEARNING-BASED INTRUSION DETECTION SYSTEM (IDS) FOR SMART CAMPUS NETWORKS
Lecturer Elif YILDIRIM Dr. İsa AVCI	Karabük University, Department of Computer Engineering, Karabük, Türkiye	DEEP LEARNING-BASED SMS SPAM DETECTION: A COMPARATIVE STUDY OF CNN, LSTM, AND GRU
İrem CAKCAK Dr. Burhan DUMAN	Isparta University of Applied Sciences; Graduate Education Institute / Faculty of Technology, Isparta, Türkiye	COMPARISON OF LIGHTWEIGHT VISION LANGUAGE MODELS ON EDGE DEVICES FOR RISK ANALYSIS OF AUTONOMOUS DRIVING IN ADVERSE WEATHER CONDITIONS

www.ubsder.org

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**

August 25-28, 2026 Bucharest/ROMANIA

ONLINE

27.08.2026

SESSION-1 / HALL-2



Bucharest/ROMANIA



TÜRKİYE TIME: 19:00

CHAIR: Asst. Prof. Dr. Yaşar ERBAŞ

CHAIR OF VICE: Emil Raul oğlu AĞAYEV

Author(s)	Affiliation	Title
Lecturer Dr. İsmail KILIÇ	Yozgat Bozok University, Yozgat Vocational School, Department of Design, Yozgat, Türkiye	A CONCEPTUAL PARAMETRIC DESIGN FRAMEWORK FOR THE ASSESSMENT OF STRUCTURAL BEHAVIOUR OF GLULAM BEAMS
Asst. Prof. Dr. Yaşar ERBAŞ	Bartın University, Faculty of Engineering, Architecture and Design, Department of Civil Engineering, Türkiye	FINITE ELEMENT INVESTIGATION OF THE ELASTIC BUCKLING RESPONSE OF HEA STEEL COLUMNS WITH SEMI-RIGID END RESTRAINTS
Oluwanifemi Opeyemi AGOI Moses Adeolu AGOI Olayemi Grace ABIMBOLA Rasheed Olatunde AJETUNMOBI	Obafemi Awolowo University, Osun, Nigeria; Lagos State University of Education, Lagos, Nigeria	AI-POWERED MATERIALS INFORMATICS: TRANSFORMING TRADITIONAL MATERIAL SCIENCE INTO DATA-DRIVEN ENGINEERING
Moses Adeolu AGOI Micheal Olayemi OLADUNJOYE Oluwanifemi Opeyemi AGOI Hendri Hermawan ADINUGRAHA	Lagos State University of Education, Lagos, Nigeria; Obafemi Awolowo University, Osun, Nigeria; Universitas Islam Negeri K.H. Abdurrahman Wahid Pekalongan, Indonesia	AI-ENHANCED ADDITIVE MANUFACTURING: TRANSFORMING MATERIAL ENGINEERING THROUGH INTELLIGENT 3D PRINTING
Berat EJDER Prof. Dr. İsmail KIYAK Dr. Faruk AYDIN	Marmara University, Institute of Science / Department of Electrical and Electronics Engineering	COMPARATIVE ANALYSIS OF THE SWITCHING PERFORMANCE OF DIFFERENT SEMICONDUCTOR TECHNOLOGIES (SI, GAN, AND SIC) USING SIMULATION
Dr. Özge GÜNEŞ YAVRU	Bursa Uludağ University, İnegöl Vocational School	MACHINE LEARNING-BASED PREDICTION AND OPTIMIZATION OF PASSIVE DESIGN PARAMETERS FOR ENERGY-EFFICIENT BUILDINGS UNDER BURSA CLIMATE CONDITIONS
Emil Raul oğlu AĞAYEV	Azerbaijan State Pedagogical College under Azerbaijan State Pedagogical University, Subject Combination Commission "Art and Physical Education"	THE VEDUTA GENRE IN 20TH-CENTURY AZERBAIJANI PAINTING

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**

August 25-28, 2026 Bucharest/ROMANIA

ONLINE

27.08.2026

SESSION-1 / HALL-3



Bucharest/ROMANIA



TÜRKİYE TIME: 19:00

CHAIR: Asst. Prof. Dr. Yusuf ÇELİK

Author(s)	Affiliation	Title
Asst. Prof. Dr. Sezin BARIN	Afyon Kocatepe University, Faculty of Engineering	COMPARATIVE ORGAN-LEVEL RELIABILITY ANALYSIS OF FOUNDATION MODELS FOR MULTI-ORGAN CT SEGMENTATION
Asst. Prof. Dr. Yusuf ÇELİK	Munzur University, Faculty of Engineering, Department of Computer Engineering	A DEEP LEARNING APPROACH FOR AUTOMATED CLASSIFICATION OF EYE DISEASES FROM FUNDUS IMAGES
Ezelhan DİKMENLİOĞLU Asst. Prof. Dr. Ulaş YURTSEVER	Sakarya University; Institute of Natural Sciences / Faculty of Computer and Information Sciences, Department of Computer Engineering / Interdisciplinary Artificial Intelligence Laboratory, Sakarya, Türkiye	DEEP LEARNING-BASED HEART MURMUR DETECTION USING FUSION OF LOG-MEL SPECTROGRAMS AND NUMERICAL FEATURES
Lecturer. Yusuf Ali AKAR Assoc. Prof. Dr. Dr. Daver ALİ	Department of Therapy and Rehabilitation, Disabled Care and Rehabilitation Program, Tuzluca Vocational School, Iğdır, Türkiye; Karabük University, Faculty of Engineering and Natural Sciences, Department of Biomedical Engineering, Karabük, Türkiye	BIOPRESERVATION IN TISSUE ENGINEERING: PRINCIPLES, STRATEGIES, AND APPLICATIONS

www.ubsder.org

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**
August 25-28, 2026 Bucharest/ROMANIA
ONLINE

27.08.2026	SESSION-2 / HALL-1
 Bucharest/ROMANIA	 TÜRKİYE TIME: 19:30

CHAIR: Dilshod RAKHIMOV

Author(s)	Affiliation	Title
Dilshod RAKHIMOV Aziza KARIMOVA	Tashkent State Technical University, Tashkent, Uzbekistan	ARTIFICIAL INTELLIGENCE-BASED PREDICTIVE MODELS FOR ENERGY- EFFICIENT INDUSTRIAL SYSTEMS
Bekzod ABDULLAYEV Shahnoza TURSUNOVA Kamola YULDASHEVA	Tashkent University of Information Technologies, Tashkent, Uzbekistan	DEEP LEARNING APPLICATIONS IN INTELLIGENT TRANSPORTATION SYSTEMS: A STUDY OF URBAN MOBILITY IN UZBEKISTAN
Rustam ISMOILOV Nigora ABDURAKHMONOVA Javlon RASULOV Mohira SOBIROVA	Samarkand State University, Samarkand, Uzbekistan	THE INTEGRATION OF ARTIFICIAL INTELLIGENCE AND BUILDING INFORMATION MODELING IN SUSTAINABLE ARCHITECTURAL DESIGN
Farrukh NARZULLAYEV Dilnoza KHOLMATOVA	Turin Polytechnic University in Tashkent, Tashkent, Uzbekistan	MACHINE LEARNING TECHNIQUES FOR STRUCTURAL DAMAGE DETECTION IN CIVIL ENGINEERING
Sherzod MAMATOV Gulbahor TOSHPOLATOVA Azizbek ERGASHEV	Andijan Machine Building Institute, Andijan, Uzbekistan	ARTIFICIAL INTELLIGENCE- SUPPORTED SMART MANUFACTURING SYSTEMS IN ADVANCED ENGINEERING APPLICATIONS

www.ubsder.org

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**

August 25-28, 2026 Bucharest/ROMANIA

ONLINE

27.08.2026

SESSION-2 / HALL-2



Bucharest/ROMANIA



TÜRKİYE TIME: 19:30

CHAIR: Timur KHUDAYBERDIYEV

Author(s)	Affiliation	Title
Akmal DJURAYEV Malika YUSUPOVA	Bukhara State University, Bukhara, Uzbekistan	ARTIFICIAL INTELLIGENCE APPLICATIONS IN SMART CONSTRUCTION PROJECT MANAGEMENT: AN EXPERIMENTAL STUDY
Nodira RAKHMONOV Azizbek KHASANOV, Sardor TULAGANOV	Namangan Engineering Construction Institute, Namangan, Uzbekistan	PARAMETRIC DESIGN APPROACHES FOR SUSTAINABLE ARCHITECTURAL DEVELOPMENT IN CENTRAL ASIA
Timur KHUDAYBERDIYEV Sevara ABDULLAYEVA Bekzod KADIROV Dilafroz SOBIROVA	Karshi Engineering Economics Institute, Karshi, Uzbekistan	AN ARTIFICIAL NEURAL NETWORK MODEL FOR OPTIMIZING STRUCTURAL ENGINEERING PROCESSES
Shakhzod MIRZAYEV Gulnora RUZIYEVA	Urgench State University, Urgench, Uzbekistan	THE ROLE OF ARTIFICIAL INTELLIGENCE IN DIGITAL TRANSFORMATION WITHIN ENGINEERING EDUCATION
Davron TASHMATOV Mohira ISMAILOVA Azizbek RAHIMOV	Fergana Polytechnic Institute, Fergana, Uzbekistan	SMART CITY ARCHITECTURE AND ARTIFICIAL INTELLIGENCE: INNOVATIVE SOLUTIONS FOR SUSTAINABLE URBAN DEVELOPMENT

www.ubsder.org

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**

August 25-28, 2026 Bucharest/ROMANIA

ONLINE

27.08.2026

SESSION-2 / HALL-3



Bucharest/ROMANIA



TÜRKİYE TIME: 19:30

CHAIR: Bobur KHOLMATOV

Author(s)	Affiliation	Title
Aziz RASHIDOV Feruza KHAMIDOVA	Tashkent Institute of Architecture and Civil Engineering, Tashkent, Uzbekistan	ARTIFICIAL INTELLIGENCE- ASSISTED STRUCTURAL ANALYSIS FOR HIGH-RISE BUILDING DESIGN
Sherzod KADIROV Nilufar ABDURAKHMONOVA Jayokhir YULDASHEV	Navoi State University, Navoi, Uzbekistan	ADVANCED ENGINEERING SOLUTIONS FOR SMART INFRASTRUCTURE DEVELOPMENT USING MACHINE LEARNING TECHNIQUES
Bobur KHOLMATOV Sitora NARZULLAYEVA Dilorom ERGASHEVA Kamoliddin TURSUNOV	Samarkand State University of Architecture and Civil Engineering, Samarkand, Uzbekistan	BUILDING INFORMATION MODELING AND ARTIFICIAL INTELLIGENCE INTEGRATION IN MODERN ARCHITECTURAL PRACTICES
Akbarjon MAMATOV, Gulchehra TOJIBOYEVA	Tashkent State Transport University, Tashkent, Uzbekistan	OPTIMIZATION OF INTELLIGENT TRANSPORTATION NETWORKS THROUGH ARTIFICIAL INTELLIGENCE-BASED ENGINEERING MODELS
Umida YAKUBOVA Bekzod MAMAJONOV Shahzoda ISLOMOVA	Andijan State Technical Institute, Andijan, Uzbekistan	THE APPLICATION OF GENERATIVE ARTIFICIAL INTELLIGENCE IN CONTEMPORARY ARCHITECTURAL DESIGN PROCESSES

www.ubsder.org

**IMAEC – 11th INTERNATIONAL CONGRESS ON ADVANCED
ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE**

August 25-28, 2026 Bucharest/ROMANIA

ONLINE

27.08.2026

SESSION-2 / HALL-4



Bucharest/ROMANIA



TÜRKİYE TIME: 19:30

CHAIR: Muhammad FAROOQ

Author(s)	Affiliation	Title
Ayesha KHAN Muhammad USMAN	National University of Sciences and Technology (NUST), Islamabad, Pakistan	ARTIFICIAL INTELLIGENCE-DRIVEN OPTIMIZATION OF SMART BUILDING ENERGY MANAGEMENT SYSTEMS
Fatima ALI Ahmed RAZ Sana IQBAL	COMSATS University Islamabad, Pakistan	DEEP LEARNING APPROACHES FOR INTELLIGENT TRAFFIC MANAGEMENT IN URBAN ENVIRONMENTS
Zain ABBAS Hira JAVED Bilal AHMED Maria NOOR	University of Engineering and Technology (UET), Lahore, Pakistan	INTEGRATING ARTIFICIAL INTELLIGENCE INTO SUSTAINABLE ARCHITECTURAL DESIGN: A CASE STUDY OF SMART CITIES IN PAKISTAN
Muhammad FAROOQ Amina SHAH Hassan MAHMOOD	Mehran University of Engineering and Technology, Jamshoro, Pakistan	A COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS FOR STRUCTURAL HEALTH MONITORING IN CIVIL ENGINEERING
Ali HUSSAIN Rabia SAEED	University of the Punjab, Lahore, Pakistan	ARTIFICIAL INTELLIGENCE-BASED BUILDING INFORMATION MODELING FOR ENHANCING ARCHITECTURAL PROJECT MANAGEMENT

www.ubsder.org

CONTENT

CONFERENCE ID	I
ORGANIZING COMMITTEE	II
SCIENTIFIC BOARD MEMBERS	III
PROGRAM	V
CONTENT	VI

	AUTHOR(S)	TITLE	PAGE NUMBER
1)	Asst. Prof. Dr. Günay TEMÜR	DATASET CHARACTERIZATION VECTOR (DCV): A DATA-CENTRIC FRAMEWORK FOR OBJECT DETECTION DATASETS	1-20
2)	Asst. Prof. Dr. Esra ODABAŞ YILDIRIM	COMPARATIVE ANALYSIS OF THE EFFECT OF CLIENT ACCESSIBILITY AND DATA HETEROGENEOUSNESS ON MODEL PERFORMANCE IN FEDERATED LEARNING	21-34
3)	Muhammad FAISAL	SMART HUKUMAT INTEGRATING AI-DRIVEN GOVERNANCE AND PREDICTIVE ANALYTICS INTO FEDERAL ADMINISTRATION	35
4)	Abdalhamid ALBEIK Lecturer Elif YILDIRIM Dr. İsa AVCI	EXPLAINABLE ENSEMBLE LEARNING-BASED INTRUSION DETECTION SYSTEM (IDS) FOR SMART CAMPUS NETWORKS	36-46
5)	Lecturer Elif YILDIRIM Dr. İsa AVCI	DEEP LEARNING-BASED SMS SPAM DETECTION: A COMPARATIVE STUDY OF CNN, LSTM, AND GRU	47-54
6)	İrem CAKCAK Dr. Burhan DUMAN	COMPARISON OF LIGHTWEIGHT VISION LANGUAGE MODELS ON EDGE DEVICES FOR RISK ANALYSIS OF AUTONOMOUS DRIVING IN ADVERSE WEATHER CONDITIONS	55-68
7)	Lecturer Dr. İsmail KILIÇ	A CONCEPTUAL PARAMETRIC DESIGN FRAMEWORK FOR THE ASSESSMENT OF STRUCTURAL BEHAVIOUR OF GLULAM BEAMS	69-85
8)	Asst. Prof. Dr. Yaşar ERBAŞ	FINITE ELEMENT INVESTIGATION OF THE ELASTIC BUCKLING RESPONSE OF HEA STEEL COLUMNS WITH SEMI-RIGID END RESTRAINTS	86-97
9)	Oluwanifemi Opeyemi AGOI Moses Adeolu AGOI Olayemi Grace ABIMBOLA Rasheed Olatunde AJETUNMOBI	AI-POWERED MATERIALS INFORMATICS: TRANSFORMING TRADITIONAL MATERIAL SCIENCE INTO DATA-DRIVEN ENGINEERING	98-110
10)	Moses Adeolu AGOI Micheal Olayemi OLADUNJOYE Oluwanifemi Opeyemi AGOI Hendri Hermawan ADINUGRAHA	AI-ENHANCED ADDITIVE MANUFACTURING: TRANSFORMING MATERIAL ENGINEERING THROUGH INTELLIGENT 3D PRINTING	111-123
11)	Berat EJDER Prof. Dr. İsmail KIYAK Dr. Faruk AYDIN	COMPARATIVE ANALYSIS OF THE SWITCHING PERFORMANCE OF DIFFERENT SEMICONDUCTOR TECHNOLOGIES (SI, GAN, AND SIC) USING SIMULATION	124-143

IMAEC 11th INTERNATIONAL CONGRESS ON ADVANCED ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE

August 25-28, 2026 Bucharest/ROMANIA

12)	Dr. Özge GÜNEŞ YAVRU	MACHINE LEARNING-BASED PREDICTION AND OPTIMIZATION OF PASSIVE DESIGN PARAMETERS FOR ENERGY-EFFICIENT BUILDINGS UNDER BURSA CLIMATE CONDITIONS	144-153
13)	Emil Raul oğlu AĞAYEV	THE VEDUTA GENRE IN 20TH-CENTURY AZERBAIJANI PAINTING	154-157
14)	Asst. Prof. Dr. Sezin BARIN	COMPARATIVE ORGAN-LEVEL RELIABILITY ANALYSIS OF FOUNDATION MODELS FOR MULTI-ORGAN CT SEGMENTATION	158-159
15)	Asst. Prof. Dr. Yusuf ÇELİK	A DEEP LEARNING APPROACH FOR AUTOMATED CLASSIFICATION OF EYE DISEASES FROM FUNDUS IMAGES	160
16)	Ezelhan DİKMENLİOĞLU Asst. Prof. Dr. Ulaş YURTSEVER	DEEP LEARNING-BASED HEART MURMUR DETECTION USING FUSION OF LOG-MEL SPECTROGRAMS AND NUMERICAL FEATURES	161-175
17)	Lecturer. Yusuf Ali AKAR Assoc. Prof. Dr. Dr. Daver ALİ	BIOPRESERVATION IN TISSUE ENGINEERING: PRINCIPLES, STRATEGIES, AND APPLICATIONS	176-180
18)	Dilshod RAKHIMOV Aziza KARIMOVA	ARTIFICIAL INTELLIGENCE-BASED PREDICTIVE MODELS FOR ENERGY-EFFICIENT INDUSTRIAL SYSTEMS	181
19)	Bekzod ABDULLAYEV Shahnoza TURSUNOVA Kamola YULDASHEVA	DEEP LEARNING APPLICATIONS IN INTELLIGENT TRANSPORTATION SYSTEMS: A STUDY OF URBAN MOBILITY IN UZBEKISTAN	182
20)	Rustam ISMOILOV Nigora ABDURAKHMONOVA Javlon RASULOV Mohira SOBIROVA	THE INTEGRATION OF ARTIFICIAL INTELLIGENCE AND BUILDING INFORMATION MODELING IN SUSTAINABLE ARCHITECTURAL DESIGN	183
21)	Farrukh NARZULLAYEV Dilnoza KHOLMATOVA	MACHINE LEARNING TECHNIQUES FOR STRUCTURAL DAMAGE DETECTION IN CIVIL ENGINEERING	184
22)	Sherzod MAMATOV Gulbahor TOSHPOLATOVA Azizbek ERGASHEV	ARTIFICIAL INTELLIGENCE-SUPPORTED SMART MANUFACTURING SYSTEMS IN ADVANCED ENGINEERING APPLICATIONS	185
23)	Akmal DJURAYEV Malika YUSUPOVA	ARTIFICIAL INTELLIGENCE APPLICATIONS IN SMART CONSTRUCTION PROJECT MANAGEMENT: AN EXPERIMENTAL STUDY	186
24)	Nodira RAKHMONOV Azizbek KHASANOV Sardor TULAGANOV	PARAMETRIC DESIGN APPROACHES FOR SUSTAINABLE ARCHITECTURAL DEVELOPMENT IN CENTRAL ASIA	187
25)	Timur KHUDAYBERDIYEV Sevara ABDULLAYEVA Bekzod KADIROV Dilafroz SOBIROVA	AN ARTIFICIAL NEURAL NETWORK MODEL FOR OPTIMIZING STRUCTURAL ENGINEERING PROCESSES	188
26)	Shakhzod MIRZAYEV Gulnora RUZIYEVA	THE ROLE OF ARTIFICIAL INTELLIGENCE IN DIGITAL TRANSFORMATION WITHIN ENGINEERING EDUCATION	189
27)	Davron TASHMATOV Mohira ISMAILOVA Azizbek RAHIMOV	SMART CITY ARCHITECTURE AND ARTIFICIAL INTELLIGENCE: INNOVATIVE SOLUTIONS FOR SUSTAINABLE URBAN DEVELOPMENT	190

ISBN: 978-625-90699-3-7

IMAEC 11th INTERNATIONAL CONGRESS ON ADVANCED ENGINEERING, ARTIFICIAL INTELLIGENCE AND ARCHITECTURE

August 25-28, 2026 Bucharest/ROMANIA

28)	Aziz RASHIDOV Feruza KHAMIDOVA	ARTIFICIAL INTELLIGENCE-ASSISTED STRUCTURAL ANALYSIS FOR HIGH-RISE BUILDING DESIGN	191
29)	Sherzod KADIROV Nilufar ABDURAKHMONOVA Javokhir YULDASHEV	ADVANCED ENGINEERING SOLUTIONS FOR SMART INFRASTRUCTURE DEVELOPMENT USING MACHINE LEARNING TECHNIQUES	192
30)	Bobur KHOLMATOV Sitora NARZULLAYEVA Dilorom ERGASHEVA Kamoliddin TURSUNOV	BUILDING INFORMATION MODELING AND ARTIFICIAL INTELLIGENCE INTEGRATION IN MODERN ARCHITECTURAL PRACTICES	193
31)	Akbarjon MAMATOV, Gulchehra TOJIBOYEVA	OPTIMIZATION OF INTELLIGENT TRANSPORTATION NETWORKS THROUGH ARTIFICIAL INTELLIGENCE-BASED ENGINEERING MODELS	194
32)	Umida YAKUBOVA Bekzod MAMAJONOV Shahzoda ISLOMOVA	THE APPLICATION OF GENERATIVE ARTIFICIAL INTELLIGENCE IN CONTEMPORARY ARCHITECTURAL DESIGN PROCESSES	195
33)	Ayesha KHAN Muhammad USMAN	ARTIFICIAL INTELLIGENCE-DRIVEN OPTIMIZATION OF SMART BUILDING ENERGY MANAGEMENT SYSTEMS	196
34)	Fatima ALI Ahmed RAZ Sana IQBAL	DEEP LEARNING APPROACHES FOR INTELLIGENT TRAFFIC MANAGEMENT IN URBAN ENVIRONMENTS	197
35)	Zain ABBAS Hira JAVED Bilal AHMED Maria NOOR	INTEGRATING ARTIFICIAL INTELLIGENCE INTO SUSTAINABLE ARCHITECTURAL DESIGN: A CASE STUDY OF SMART CITIES IN PAKISTAN	198
36)	Muhammad FAROOQ Amina SHAH Hassan MAHMOOD	A COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS FOR STRUCTURAL HEALTH MONITORING IN CIVIL ENGINEERING	199
37)	Ali HUSSAIN Rabia SAEED	ARTIFICIAL INTELLIGENCE-BASED BUILDING INFORMATION MODELING FOR ENHANCING ARCHITECTURAL PROJECT MANAGEMENT	200

ISBN: 978-625-90699-3-7

VERİ SETİ KARAKTERİZASYON VEKTÖRÜ (DCV): NESNE TESPİTİ VERİ SETLERİ İÇİN VERİ MERKEZLİ BİR KARAKTERİZASYON ÇERÇEVESİ DATASET CHARACTERIZATION VECTOR (DCV): A DATA-CENTRIC FRAMEWORK FOR OBJECT DETECTION DATASETS

Asst. Prof. Dr. Günay TEMÜR

Düzce University, Gölyaka Vocational School, Department of Computer Programming
ORCID ID: <https://orcid.org/0000-0002-7197-5804>

Özet

Nesne tespiti alanındaki çalışmaların büyük bölümü yeni model mimarileri ve performans iyileştirmelerine odaklanırken, öğrenme sürecinin temel girdisini oluşturan veri setlerinin yapısal özellikleri ise çoğunlukla sınırlı sayıdaki temel istatistiklerle tanımlanmaktadır. Oysa nesne tespiti veri setleri; nesne ölçeği, nesne yoğunluğu, sınıf dağılımı, görüntü özellikleri ve anotasyon yapısı gibi öğrenme sürecini doğrudan etkileyebilecek çok sayıda yapısal özelliğe sahiptir. Bu çalışmada, nesne tespiti veri setlerinin sistematik ve veri odaklı olarak analiz edilmesini sağlayan bütüncül bir karakterizasyon çerçevesi önerilmektedir. Önerilen yaklaşım kapsamında veri setleri; geometrik, istatistiksel, görsel ve anotasyon tabanlı olmak üzere dört temel karakteristik grubu altında toplam on iki metrik kullanılarak değerlendirilmekte ve her veri seti Dataset Characterization Vector (DCV) ile temsil edilmektedir. Ayrıca bu metriklerin otomatik olarak hesaplanmasını sağlayan Python tabanlı modüler bir özellik çıkarım iş akışı geliştirilmiştir. Yaklaşımın uygulanabilirliği, nesne ölçeği, nesne yoğunluğu ve sahne karmaşıklığı bakımından belirgin farklılıklar sergileyen COCO 2017, Pascal VOC 2012 ve VisDrone2019-DET veri setleri üzerinde değerlendirilmiştir. Elde edilen sonuçlar, önerilen karakterizasyon yaklaşımının veri setleri arasındaki yapısal farklılıkları nicel olarak ortaya koyabildiğini ve farklı veri setlerini ortak bir karakterizasyon uzayında karşılaştırılabilir hâle getirdiğini göstermektedir. Sunulan çerçevenin, veri odaklı nesne tespiti araştırmalarında veri setlerinin sistematik olarak analiz edilmesine katkı sağlayacağı ve veri seti-model ilişkisini inceleyen gelecekteki çalışmalar için temel bir değerlendirme altyapısı sunacağı öngörülmektedir.

Anahtar Kelimeler: Nesne Tespiti, Veri Merkezli Yapay Zekâ, Veri Seti Karakterizasyonu, Bilgisayarlı Görü.

Abstract

While the majority of research in object detection focuses on novel model architectures and performance improvements, the structural characteristics of datasets, which constitute the fundamental input to the learning process, are often described using only a limited set of basic statistics. However, object detection datasets possess numerous structural properties—such as object scale, object density, class distribution, image characteristics, and annotation structure—that can directly influence the learning process. In this study, a holistic characterization framework is proposed to enable systematic and data-centric analysis of object detection datasets. Within the scope of the proposed approach, datasets are evaluated using a total of twelve metrics under four main characteristic categories: geometric, statistical, visual, and annotation-based, with each dataset represented by a Dataset Characterization Vector (DCV). Furthermore, a Python-based modular feature extraction pipeline has been developed to automatically compute these metrics. The applicability of the approach is evaluated on COCO 2017, Pascal VOC 2012, and VisDrone2019-DET datasets, which exhibit significant differences in terms of object scale, object density, and scene complexity. The obtained results

demonstrate that the proposed characterization approach can quantitatively reveal structural differences between datasets and enable different datasets to be compared within a common characterization space. The proposed framework is expected to contribute to the systematic analysis of datasets in data-centric object detection research and to provide a foundation for future studies investigating dataset–model relationships.

Keywords: Object Detection, Data-Centric AI, Dataset Characterization, Dataset Characterization Vector, Computer Vision.

1. GİRİŞ

Nesne tespiti (Object Detection), bilgisayarlı görünün temel araştırma alanlarından biri olmasının yanı sıra, gerçek dünya uygulamalarında en yaygın kullanılan derin öğrenme problemlerinden biri haline gelmiştir. Son yıllarda derin öğrenme tabanlı yöntemlerde yaşanan gelişmeler sayesinde nesne tespiti sistemleri; otonom sürüş, akıllı ulaşım sistemleri, akıllı şehir uygulamaları, endüstriyel kalite kontrol, altyapı denetimi, hassas tarım, sağlık teknolojileri ve güvenlik-gözetim sistemleri gibi çok farklı disiplinlerde başarıyla uygulanmaktadır. Bu uygulamalarda elde edilen başarının temelinde yüksek doğruluk, gerçek zamanlı çalışma yeteneği ve değişen çevresel koşullara uyum sağlayabilen nesne tespiti modelleri yer almaktadır. Bu nedenle nesne tespiti alanındaki gelişmeler yalnızca akademik açıdan değil; güvenlik, maliyet, operasyonel verimlilik ve sürdürülebilir altyapı sistemleri açısından da kritik önem taşımaktadır (Bojarski vd. 2016)(Dubey vd. 2016)(Kamilaris ve Prenafeta-Boldú 2018).

Son on yıl içerisinde nesne tespiti alanında önemli metodolojik gelişmeler yaşanmıştır. Bölge önerisi (region proposal) tabanlı iki aşamalı dedektörlerden başlayarak tek aşamalı (one-stage) mimarilere geçiş, doğruluk ile işlem hızı arasında başarılı bir denge kurulmasını sağlamış; özellikle YOLO ailesi gerçek zamanlı uygulamalarda yaygın olarak kullanılmaya başlanmıştır (L. Liu vd. 2020)(Z. Q. Zhao vd. 2019)(Jiao vd. 2019)(Redmon vd. 2016). Son yıllarda ise DETR, RT-DETR, DINO ve Grounding DINO gibi Transformer tabanlı yaklaşımlar, küresel bağlam bilgisini daha etkin kullanmaları sayesinde karmaşık sahnelerde önemli başarılar elde etmiştir (Y. Zhao vd. 2024)(Zhang vd. 2022)(S. Liu vd. 2024). Bunun yanında dikkat mekanizmaları, çok ölçekli özellik füzyonu, kayıp fonksiyonları, veri artırma stratejileri ve optimizasyon yöntemleri üzerine gerçekleştirilen çalışmalar nesne tespiti modellerinin gelişimine önemli katkılar sağlamıştır (L. Liu vd. 2020)(Z. Q. Zhao vd. 2019)(Jiao vd. 2019). Günümüzde COCO ve Pascal VOC gibi standart veri setleri, yeni geliştirilen yöntemlerin değerlendirilmesinde temel referans veri kümeleri olarak kullanılmaktadır (Tsung-yi Lin vd. 2015)(Everingham vd. 2009).

Buna karşın mevcut literatürün büyük bölümü model merkezli bir yaklaşım benimsemektedir. Çalışmaların önemli bir kısmı yeni ağ mimarileri geliştirmeye veya mevcut modellerin performansını artırmaya odaklanırken, öğrenme sürecinin temel girdisini oluşturan veri setleri çoğunlukla sabit bir bileşen olarak ele alınmaktadır. Oysa nesne tespiti veri setleri; nesne boyutu dağılımı, nesne yoğunluğu, sınıf dengesizliği, görüntü çözünürlüğü, arka plan karmaşıklığı ve anotasyon yapısı gibi çok sayıda ölçülebilir karakteristiğe sahiptir. Buna rağmen mevcut çalışmalar çoğunlukla küçük nesne tespiti, sınıf dengesizliği veya örtünme gibi belirli problemlere odaklanmakta; veri setlerini bütüncül olarak tanımlayan sistematik karakterizasyon yaklaşımları ise oldukça sınırlı kalmaktadır (Glenn, Ayush, ve Jing 2023). Bu durum, nesne tespiti veri setlerinin yapısal özelliklerini ortak bir çerçevede tanımlayabilecek veri odaklı analiz yöntemlerine olan gereksinimi ortaya koymaktadır.

Bu çalışma, nesne tespiti problemine model merkezli yaklaşımlar yerine veri odaklı (data-centric) bir bakış açısıyla yaklaşmaktadır. Çalışmanın amacı yeni bir nesne tespiti modeli önermek veya mevcut dedektörleri karşılaştırmak değildir. Bunun yerine farklı nesne tespiti

veri setleri; geometrik, istatistiksel, görsel ve anotasyon tabanlı özellikler açısından sistematik olarak karakterize edilmekte ve her veri seti önerilen Dataset Characterization Vector (DCV) ile temsil edilmektedir. Böylece veri setlerinin yalnızca görüntü veya sınıf sayısı gibi temel istatistiklerle değil, çok boyutlu yapısal özellikleri dikkate alınarak değerlendirilmesine yönelik bütüncül bir karakterizasyon yaklaşımı sunulmaktadır.

Bu çalışma kapsamında;

- (i) nesne tespiti veri setlerini geometrik, istatistiksel, görsel ve anotasyon tabanlı özellikler açısından tanımlayan bütüncül bir karakterizasyon çerçevesi önerilmektedir,
- (ii) farklı veri setleri ortak metrikler kullanılarak nicel olarak analiz edilmekte ve karşılaştırılmaktadır,
- (iii) veri setlerinin yapısal özelliklerini temsil eden Dataset Characterization Vector (DCV) tanımlanmaktadır ve
- (iv) önerilen yaklaşımın nesne tespiti veri setlerinin sistematik olarak analiz edilmesine yönelik uygulanabilir bir değerlendirme çerçevesi sunduğu gösterilmektedir.

2. İLGİLİ ÇALIŞMALAR

Bu bölümde nesne tespiti alanındaki mevcut çalışmalar üç temel başlık altında incelenmektedir: (i) model mimarilerine odaklanan çalışmalar, (ii) belirli veri seti zorluklarını ele alan çalışmalar (küçük nesne, sınıf dengesizliği, örtünme vb.) ve (iii) veri seti karakterizasyonuna yönelik veri odaklı yaklaşımlar. Bu sınıflandırma, önerilen karakterizasyon yaklaşımının literatürdeki yerini ve mevcut çalışmalardan ayrılan yönlerini ortaya koymayı amaçlamaktadır.

2.1. Model Mimarilerine Yönelik Çalışmalar

Nesne tespiti alanındaki araştırmaların büyük çoğunluğu, doğruluk ve işlem hızını artırmak amacıyla yeni dedektör mimarileri geliştirmeye odaklanmıştır. Bu kapsamda bölge önerisi (region proposal) tabanlı iki aşamalı modeller (ör. Faster R-CNN (Ren vd. 2017)) yüksek konumlandırma doğruluğu sağlarken, tek aşamalı (one-stage) modeller (ör. YOLO ailesi (Redmon vd. 2016) ve SSD (W. Liu vd. 2016)) gerçek zamanlı uygulamalar için daha uygun bir hız-doğruluk dengesi sunmuştur. Son yıllarda ise Transformer tabanlı mimarilerin (ör. DETR (Y. Zhao vd. 2024) ve RT-DETR (Wang vd. 2024)) bilgisayarlı görü alanında yaygınlaşmasıyla birlikte, küresel bağlam bilgisini daha etkin kullanabilen modeller özellikle karmaşık sahnelerde dikkat çekici başarılar elde etmiştir (Hussain vd. 2026)(Chen vd. 2022).

Bununla birlikte, Liu vd. (L. Liu vd. 2020) ve Zhao vd. (Z. Q. Zhao vd. 2019) tarafından hazırlanan kapsamlı derleme çalışmaları, nesne tespiti araştırmalarının büyük ölçüde model mimarileri, özellik çıkarım mekanizmaları ve optimizasyon stratejileri üzerine yoğunlaştığını ortaya koymaktadır. Benzer şekilde Jiao vd. (Jiao vd. 2019)(Kemal vd. 2020), mevcut literatürde veri setlerinin çoğunlukla deneysel değerlendirme ortamı olarak ele alındığını, buna karşın veri setlerinin yapısal özelliklerini sistematik biçimde tanımlayan ve karşılaştıran çalışmaların oldukça sınırlı olduğunu belirtmektedir. Bu durum, veri setlerinin karakterizasyonuna yönelik veri odaklı araştırmaların önemini ortaya koymaktadır.

2.2. Belirli Veri Seti Zorluklarına Yönelik Çalışmalar

Literatürde, nesne tespiti veri setlerinde karşılaşılan belirli zorlukları ele alan çok sayıda çalışma bulunmaktadır. Küçük nesne tespiti üzerine gerçekleştirilen araştırmalar, nesne ölçeğinin tespit sürecindeki önemini ortaya koymuş ve çok ölçekli özellik çıkarımı ile Özellik Piramidi Ağlarının (Feature Pyramid Network-FPN) bu problemde kritik rol oynadığını göstermiştir (Tsung Lin vd. 2017). Benzer şekilde yoğun sahneler ve örtünme problemlerini ele alan çalışmalar, yüksek nesne yoğunluğu ve sınır kutusu çakışmalarının nesne ayrıştırma

süreçlerini zorlaştırdığını ve bu tür sahneler için çeşitli iyileştirme yöntemleri önerildiğini rapor etmiştir (Kemal vd. 2020).

Sınıf dengesizliği de nesne tespiti veri setlerinde sık karşılaşılan önemli problemlerden biridir. Özellikle uzun kuyruklu veri dağılımlarına sahip veri setlerinde sınıflar arasındaki örnek sayısı farklılıklarını azaltmak amacıyla yeniden örnekleme (re-sampling), yeniden ağırlıklandırma (re-weighting) ve özel kayıp fonksiyonları gibi çeşitli yaklaşımlar geliştirilmiştir (Yu vd. 2020)(Agnew, Scanlan, ve Denny 2024)(Michielsen, Gemert, ve Kayhan 2024). Bununla birlikte, bu çalışmaların büyük bölümü veri setlerinin yalnızca belirli bir özelliğine odaklanmakta; nesne boyutu, nesne yoğunluğu, sınıf yapısı, görüntü özellikleri ve anotasyon karakteristiklerini birlikte ele alan bütüncül veri seti karakterizasyonu yaklaşımları ise oldukça sınırlı kalmaktadır (Yang ve Hui 2024).

2.3. Veri Seti Karakterizasyonu ve Veri Odaklı Yaklaşımlar

Son yıllarda veri merkezli yapay zekâ (Data-Centric AI) yaklaşımının önem kazanmasıyla birlikte, veri kalitesi ve veri karakteristiklerinin öğrenme sürecindeki rolü giderek daha fazla araştırılmaya başlanmıştır (Jakubik vd. 2024)(Hussain vd. 2026). Bu kapsamda, görüntü sınıflandırma problemleri için veri setlerinin zorluk derecesini belirlemeye yönelik çeşitli metrikler ve değerlendirme yaklaşımları önerilmiştir (Chen vd. 2022). Buna karşın, nesne tespiti veri setlerini çok boyutlu olarak karakterize eden çalışmaların hâlen sınırlı olduğu görülmektedir. Mevcut araştırmalar çoğunlukla belirli veri setlerindeki (örneğin COCO (Tsung-yi Lin vd. 2015) veya Pascal VOC (Everingham vd. 2013)(Everingham vd. 2009) anotasyon hataları (Proença, Simões, ve Mar 2020), sınıf dağılımları veya belirli veri özellikleri üzerine odaklanmakta; farklı veri setlerini geometrik, istatistiksel, görsel ve anotasyon tabanlı özellikleri birlikte dikkate alarak karşılaştıran bütüncül karakterizasyon yaklaşımları ise oldukça sınırlı kalmaktadır (Kim vd. 2025).

Bu çalışma, söz konusu eksikliği gidermeyi amaçlamaktadır. Önerilen yaklaşım, model mimarilerine odaklanmak yerine nesne tespiti veri setlerini geometrik, istatistiksel, görsel ve anotasyon tabanlı olmak üzere dört temel kategoride sistematik olarak karakterize eden bütüncül bir değerlendirme çerçevesi sunmaktadır. Ayrıca önerilen Dataset Characterization Vector (DCV) ile farklı veri setlerinin ortak metrikler kullanılarak nicel olarak temsil edilmesi ve karşılaştırılması sağlanmaktadır. Böylece veri setlerinin yapısal özelliklerinin sistematik biçimde analiz edilmesine yönelik veri odaklı bir yaklaşım ortaya konulmaktadır.

3. ÖNERİLEN VERİ SETİ KARAKTERİZASYON ÇERÇEVESİ

Bu bölümde, nesne tespiti veri setlerinin sistematik olarak karakterize edilmesinde kullanılan özellikler ve bu özelliklerin hesaplanma yöntemleri açıklanmaktadır. Önerilen yaklaşım, veri setlerinin yapısal özelliklerini nicel olarak tanımlayabilmek amacıyla geliştirilmiş olup, geometrik, istatistiksel, görsel ve anotasyon tabanlı olmak üzere dört temel karakterizasyon kategorisinden oluşmaktadır. Her kategori, veri setlerinin farklı yönlerini temsil eden tamamlayıcı metrikler içermektedir. Tüm karakterizasyon metrikleri Python tabanlı modüler bir işlem hattı kullanılarak otomatik olarak hesaplanmış; görüntü işleme işlemlerinde OpenCV (Intel acquires Itseez y.y.), veri işleme ve hesaplama süreçlerinde ise PyTorch (Paszke vd. 2019) tabanlı araçlardan yararlanılmıştır.

3.1. Veri Seti Özelliklerinin Tanımlanması (Dataset Feature Definition)

Nesne tespiti alanındaki çalışmaların büyük bölümü yeni dedektör mimarileri, özellik çıkarım yöntemleri ve eğitim stratejileri üzerine yoğunlaşmaktadır. Buna karşın, öğrenme sürecinin temel girdisini oluşturan veri setlerinin yapısal özelliklerini sistematik olarak tanımlayan çalışmalar oldukça sınırlıdır (Tsung-yi Lin vd. 2015)(Everingham vd. 2009)(Everingham vd.

2013)(Yang ve Hui 2024)(Hussain vd. 2026). Son yıllarda veri merkezli yapay zekâ (Data-Centric AI) yaklaşımının önem kazanmasıyla birlikte, veri kalitesi ve veri karakteristiklerinin analizine yönelik ilgi artmış olsa da nesne tespiti veri setlerini çok boyutlu olarak karakterize eden ortak bir değerlendirme çerçevesi henüz bulunmamaktadır (Jakubik vd. 2024).

Mevcut çalışmalar veri setlerinin çoğunlukla belirli özelliklerine odaklanmaktadır. Küçük nesneler, yoğun sahneler, sınıf dengesizliği, görüntü çözünürlüğü ve anotasyon kalitesi gibi karakteristikler farklı araştırmalarda ayrı ayrı ele alınmış olsa da bu özellikleri ortak bir karakterizasyon yaklaşımı altında değerlendiren çalışmalar oldukça sınırlıdır (Chen vd. 2022) (Su vd. 2022)(C. Zhao, Wan, ve Chan 2025)(Kemal vd. 2020). Bu nedenle veri setlerinin farklı yönlerini birlikte tanımlayabilecek bütüncül bir karakterizasyon çerçevesine ihtiyaç duyulmaktadır.

Bu çalışmada veri setleri, tek bir özellik üzerinden değil, birbirini tamamlayan dört temel karakteristik grubu üzerinden tanımlanmaktadır: geometrik özellikler, istatistiksel özellikler, görsel özellikler ve anotasyon tabanlı özellikler. Bu sınıflandırma, veri setlerinin yalnızca büyüklüğünü değil, sahip oldukları yapısal özellikleri de nicel olarak ortaya koymayı amaçlamaktadır. Geometrik özellikler nesnelerin görüntü içerisindeki uzamsal dağılımını ve ölçek yapısını; istatistiksel özellikler sınıf dağılımını ve veri çeşitliliğini; görsel özellikler görüntü kalitesini ve sahne yapısını; anotasyon tabanlı özellikler ise etiketleme yapısını temsil etmektedir. Böylece veri setleri yalnızca kaç görüntü veya kaç sınıf içerdiği bakımından değil, sahip oldukları yapısal özellikler açısından da sistematik olarak tanımlanabilmektedir.

Geometrik karakteristikler; ortalama nesne boyutu (Average Object Size-AOS), küçük nesne oranı (Small Object Ratio-SOR), nesne yoğunluğu (Object Density-OD), sınır kutusu örtüşme oranı (Bounding Box Overlap Ratio-BBoxOR) ve ön plan doluluk oranı (Foreground Occupancy Ratio-FOR) gibi metriklerden oluşmaktadır. Bu göstergeler, veri setindeki nesnelerin uzamsal dağılımını ve ölçek yapısını nicel olarak tanımlamaktadır.

İstatistiksel karakteristikler, veri setlerindeki sınıf dağılımının çeşitlilik ve belirsizlik düzeyini nicel olarak tanımlamaktadır. Bu kapsamda, sınıf dağılımını değerlendirmek amacıyla Sınıf Entropisi (Class Entropy-CE) kullanılmıştır.

Görsel karakteristikler veri setinin görüntü kalitesini ve sahne yapısını tanımlamaktadır. Ortalama görüntü çözünürlüğü (Image Resolution-IR), görüntü kontrastı (Image Contrast-IC), görüntü keskinliği (Image Sharpness-IS) ve arka plan karmaşıklığı (Background Complexity-BC), veri setlerinin görsel özelliklerini temsil eden temel metrikler olarak kullanılmaktadır.

Anotasyon tabanlı karakteristikler ise veri setlerinin etiketleme yapısını açıklamaktadır. Bu kapsamda sınır kutusu alan varyansı (Bounding Box Area Variance-BBAV) ve sınır nesne oranı (Border Object Ratio-BoR) gibi metrikler kullanılarak veri setlerinin anotasyon yapısı nicel olarak değerlendirilmektedir. Bu metrikler, nesnelerin boyut çeşitliliği ile görüntü sınırlarına yakın konumlanma eğilimlerini ortaya koyarak veri setlerinin yapısal özelliklerinin analiz edilmesini sağlamaktadır.

Belirlenen tüm özellikler farklı nesne tespiti veri setleri üzerinde tamamen otomatik olarak hesaplanabilmekte ve herhangi bir nesne tespiti mimarisine bağımlılık göstermemektedir. Bu sayede önerilen karakterizasyon yaklaşımı, farklı veri setlerinin ortak bir karakterizasyon çerçevesi altında analiz edilmesine olanak sağlamaktadır. Bir sonraki alt bölümlerde her karakteristik grubuna ait metrikler matematiksel ifadeleriyle birlikte sunulmaktadır.

3.2. Geometrik, İstatistiksel, Görsel ve Anotasyon Karakteristikleri

Bu bölümde, nesne tespiti veri setlerinin yapısal özelliklerini tanımlamak amacıyla kullanılan on iki karakterizasyon metriği dört temel kategori altında sunulmaktadır. Önerilen metrikler;

geometrik, istatistiksel, görsel ve anotasyon tabanlı özellikleri temsil etmekte olup, veri setlerinin farklı yönlerini ortak bir çerçevede değerlendirmeyi amaçlamaktadır.

Her bir metrik için matematiksel tanım verilmiş ve veri seti düzeyindeki hesaplama yöntemi açıklanmıştır. Ayrıca metrikler, farklı veri setlerinin karşılaştırılmasını kolaylaştıracak şekilde ortak bir hesaplama yaklaşımı kullanılarak elde edilmiştir. Böylece tüm veri setleri aynı karakterizasyon süreci altında analiz edilerek karşılaştırılabilir hale getirilmiştir.

3.2.1. Geometrik Karakteristikler

Geometrik karakteristikler, veri setindeki nesnelerin uzamsal dağılımını, ölçek yapısını ve görüntü içerisindeki konumlanma özelliklerini nicel olarak tanımlamaktadır.

3.2.1.1 Ortalama Nesne Boyutu (Average Object Size – AOS)

Ortalama nesne boyutu (Average Object Size-AOS), veri setlerinin ölçek yapısını tanımlayan temel geometrik karakteristiklerden biridir. Özellikle farklı veri setlerinin nesne boyutu bakımından karşılaştırılabilmesi için, sınır kutusu alanları görüntü alanına göre normalize edilmektedir (Tsung-yi Lin, Zitnick, ve Doll 2015)(Chen vd. 2022).

Normalize edilmiş nesne alanı Eşitlik (1) kullanılarak hesaplanmaktadır.

$$A_i = \frac{w_i \times h_i}{W_i \times H_i} \quad (1)$$

Burada w_i ve h_i , i . nesneye ait sınır kutusunun genişliği ve yüksekliğini; W_i ve H_i ise ilgili görüntünün genişliği ve yüksekliğini göstermektedir.

Veri setine ait ortalama nesne boyutu ise Eşitlik (2) ile hesaplanmaktadır.

$$AOS = \frac{1}{N} \sum_{i=1}^N A_i \quad (2)$$

Burada N , veri setindeki toplam nesne sayısını ifade etmektedir.

3.2.1.2 Küçük Nesne Oranı (Small Object Ratio – SOR)

Ortalama nesne boyutu veri setinin genel ölçek yapısını açıklasa da küçük nesnelerin veri seti içerisindeki dağılımını tek başına ifade edememektedir. Bu nedenle küçük nesne oranını belirlemek amacıyla Small Object Ratio (SOR) metriği kullanılmıştır.

Farklı çözünürlüklere sahip veri setleri arasında çözünürlükten bağımsız ve tutarlı bir değerlendirme yapılabilmesi amacıyla, küçük nesneler normalize edilmiş sınır kutusu alanı görüntü alanının %0,1'inden ($A < 0.001$) küçük olan nesneler olarak tanımlanmıştır. Bu eşik değeri, veri setleri arasında ortak bir küçük nesne tanımı sağlayarak ölçek farklılıklarından kaynaklanabilecek yanlışlıkları azaltmayı amaçlamaktadır (Tsung-yi Lin, Zitnick, ve Doll 2015). SOR değeri Eşitlik (3) kullanılarak hesaplanmaktadır.

$$SOR = \frac{N_{small}}{N_{total}} \quad (3)$$

Burada N_{small} , normalize edilmiş sınır kutusu alanı $A_i < 0.001$ koşulunu sağlayan nesnelerin sayısını; N_{total} ise veri setindeki toplam nesne sayısını ifade etmektedir. Bu metrik, veri setindeki küçük nesnelerin dağılımını nicel olarak ifade etmektedir.

3.2.1.3 Nesne Yoğunluğu (Object Density – OD)

Nesne yoğunluğu (Object Density-OD), veri setindeki görüntü başına düşen ortalama nesne sayısını ifade etmektedir. Bu metrik, veri setindeki sahnelerin ne ölçüde yoğun olduğunu tanımlayan temel geometrik göstergelerden biridir.

Nesne yoğunluğu Eşitlik (4) kullanılarak hesaplanmaktadır

$$OD = \frac{N_{object}}{N_{image}} \quad (4)$$

Burada N_{object} , veri setindeki toplam anotasyon sayısını, N_{image} ise toplam görüntü sayısını göstermektedir.

3.2.1.4 Sınır Kutusu Örtüşme Oranı (Bounding Box Overlap Ratio – BBoxOR)

Bounding Box Overlap Ratio (BBoxOR), aynı görüntü içerisinde bulunan nesnelerin sınır kutuları arasındaki örtüşme düzeyini nicel olarak ifade etmektedir. Bu amaçla her görüntüde bulunan tüm nesne çiftleri için Kesişim/Birleşim (Intersection over Union-IoU) değeri hesaplanmaktadır.

Veri seti düzeyindeki ortalama örtüşme oranı Eşitlik (5) ile elde edilmektedir.

$$BBoxOR = \frac{1}{M} \sum_{k=1}^M IoU_k \quad (5)$$

Burada M, değerlendirilen toplam nesne çifti sayısını, IoU_k ise ilgili nesne çiftine ait IoU değerini göstermektedir. BBoxOR metriği, veri setindeki nesnelerin örtüşme karakteristiğini temsil etmektedir.

3.2.1.5 Ön Plan Doluluk Oranı (Foreground Occupancy Ratio – FOR)

Foreground Occupancy Ratio (FOR), görüntü içerisindeki tüm nesnelere ait sınır kutularının kapladığı toplam alanın görüntü alanına oranını ifade etmektedir. Bu metrik, veri setindeki ön plan–arka plan dağılımını nicel olarak değerlendirmek amacıyla kullanılmaktadır.

Bir görüntüye ait FOR değeri Eşitlik (6) ile hesaplanmaktadır.

$$FOR_i = \frac{\sum_{j=1}^{n_i} Area(BBox_j)}{W_i \times H_i} \quad (6)$$

Burada $Area(BBox_j)$, j . nesneye ait sınır kutusunun alanını; n_i , ilgili görüntüde bulunan nesne sayısını; W_i ve H_i ise görüntünün genişliği ve yüksekliğini göstermektedir.

Veri seti düzeyindeki ortalama FOR değeri ise Eşitlik (7) kullanılarak hesaplanmaktadır.

$$FOR = \frac{1}{N} \sum_{i=1}^N FOR_i \quad (7)$$

FOR metriği, veri setindeki nesnelerin görüntü alanını kullanma düzeyini nicel olarak tanımlamaktadır.

3.2.2 İstatistiksel Karakteristikler

İstatistiksel karakteristikler, veri setinin sınıf dağılımını, örnek çeşitliliğini ve semantik yapısını nicel olarak tanımlamaktadır. Bu kapsamda veri setlerinin sınıf dengesi, dağılım çeşitliliği ve sınıflar arasındaki birlikte bulunma ilişkileri üç temel metrik kullanılarak değerlendirilmektedir.

- **Class Distribution Entropy (CE)**

Veri setinin genel sınıf dağılımını nicel olarak değerlendirebilmek amacıyla, bilgi teorisinde yaygın olarak kullanılan Shannon Entropisi bu çalışmada Sınıf Entropisi (Class Entropy–CE) metriği olarak kullanılmıştır (Kemal vd. 2020)(Yu vd. 2020).

CE, veri setindeki sınıf örneklerinin dağılımındaki çeşitlilik ve belirsizlik düzeyini ölçmektedir. CE değeri Eşitlik (8) kullanılarak hesaplanmaktadır.

$$CE = - \sum_{i=1}^C p_i \log_2(p_i) \quad (8)$$

Burada C , veri setindeki toplam sınıf sayısını, p_i ise ilgili sınıfın göreceli frekansını ifade etmektedir. CE değerinin yüksek olması sınıf dağılımının daha dengeli olduğunu, düşük olması ise belirli sınıfların daha baskın olduğunu göstermektedir.

3.2.3 Görsel Karakteristikler

Görsel karakteristikler, veri setlerinin görüntü kalitesi ve sahne yapısını nicel olarak tanımlamaktadır. Görüntü çözünürlüğü, kontrast, keskinlik ve arka plan karmaşıklığı gibi özellikler, veri setlerinin görsel yapısını açıklayan temel göstergeler arasında yer almaktadır (Chen vd. 2022)(Jakubik vd. 2024). Bu çalışmada görsel karakteristikler dört farklı metrik kullanılarak değerlendirilmiştir.

3.2.3.1 Image Resolution (IR)

Görüntü çözünürlüğü (Image Resolution-IR), veri setinin sahip olduğu görsel ayrıntı düzeyini tanımlayan temel özelliklerden biridir. Literatürde çözünürlüğün, görüntülerin içerdiği ayrıntı miktarını belirleyen önemli bir karakteristik olduğu belirtilmektedir (Chen vd. 2022). Bu çalışmada her görüntünün çözünürlüğü toplam piksel sayısı kullanılarak hesaplanmıştır.

Bir görüntünün çözünürlüğü Eşitlik (9) ile hesaplanmaktadır.

$$IR_i = W_i \times H_i \quad (9)$$

Burada W_i ve H_i , sırasıyla görüntünün genişlik ve yüksekliğini göstermektedir.

Veri setine ait ortalama çözünürlük ise Eşitlik (10) ile elde edilmektedir.

$$IR = \frac{1}{N} \sum_{i=1}^N IR_i \quad (10)$$

Burada N , veri setindeki toplam görüntü sayısını ifade etmektedir.

3.2.3.2 Image Contrast (IC)

Kontrast (Image Contrast-IC), görüntü içerisindeki piksel yoğunluklarının değişimini ifade eden temel görsel karakteristiklerden biridir. Literatürde RMS (Root Mean Square) kontrast yöntemi, görüntü kontrastının nicel olarak belirlenmesinde yaygın biçimde kullanılmaktadır (Jakubik vd. 2024)(Hussain vd. 2026).

Bu çalışmada görüntü kontrastı RMS kontrast yöntemi kullanılarak Eşitlik (11) ile hesaplanmaktadır.

$$IC_i = \sqrt{\frac{1}{P} \sum_{k=1}^P (I_k - \mu)^2} \quad (11)$$

Burada P , görüntüdeki toplam piksel sayısını, I_k ilgili piksel yoğunluğunu, μ ise görüntünün ortalama yoğunluk değerini göstermektedir.

3.2.3.3 Image Sharpness (IS)

Görüntü keskinliği (Image Sharpness-IS), görüntüdeki kenar ve detayların belirginlik düzeyini ifade etmektedir. Laplacian varyansı yöntemi, görüntü keskinliğinin ölçülmesinde literatürde yaygın olarak kullanılan yöntemlerden biridir (Chen vd. 2022).

Bu çalışmada görüntü keskinliği Laplacian operatörünün varyansı kullanılarak Eşitlik (12) ile hesaplanmaktadır.

$$IS_i = Var(\nabla^2 I) \quad (12)$$

Burada $\nabla^2 I$, görüntünün Laplacian dönüşümünü ifade etmektedir. Yüksek varyans değerleri daha belirgin kenar yapılarına sahip görüntüleri temsil etmektedir.

3.2.3.4 Arka Plan Karmaşıklığı (Background Complexity - BC)

Arka plan karmaşıklığı (Background Complexity–BC), veri setlerindeki görüntülerin sahne yapısını ve görsel ayrıntı düzeyini nicel olarak tanımlayan bir görsel karakteristiktir. Karmaşık sahnelerde yoğun kenar yapıları ve yüksek frekanslı görüntü ayrıntıları daha fazla bulunduğundan, bu çalışmada arka plan karmaşıklığı kenar yoğunluğu ile Laplacian tabanlı keskinlik bilgisinin birlikte değerlendirilmesiyle hesaplanmıştır (L. Liu vd. 2020)(Jakubik vd. 2024).

Bu çalışmada arka plan karmaşıklığını belirlemek amacıyla iki farklı gösterge birlikte değerlendirilmiştir.

Kenar yoğunluğu (Edge Density–ED), Canny kenar algılama yöntemiyle belirlenen kenar piksellerinin görüntüdeki toplam piksel sayısına oranı olarak Eşitlik (13) kullanılarak hesaplanmaktadır.

$$ED_i = \frac{N_{edge,i}}{P_i} \quad (13)$$

Burada N_{edge} , i . görüntüde kenar olarak belirlenen piksel sayısını; P_i ise görüntüdeki toplam piksel sayısını ifade etmektedir.

Laplacian varyansı ile hesaplanan görüntü keskinliği değeri farklı görüntülerde geniş bir değer aralığında değişebildiğinden, bu değer Eşitlik (14) kullanılarak [0,1) aralığına normalize edilmektedir.

$$IS_i^{norm} = \frac{IS_i}{IS_i + 1000} \quad (14)$$

Burada IS_i , i . görüntünün Laplacian varyansı kullanılarak elde edilen keskinlik değerini göstermektedir. Sabit 1000 değeri, keskinlik değerlerinin ölçeğini sınırlandırmak ve normalize edilmiş değerin aşırı büyümesini önlemek amacıyla kullanılan ölçekleme parametresidir.

Her bir görüntüye ait arka plan karmaşıklığı değeri, kenar yoğunluğu ile normalize edilmiş keskinlik değerinin aritmetik ortalaması alınarak Eşitlik (15) ile hesaplanmaktadır.

$$BC_i = \frac{1}{2} \left(ED_i + \frac{IS_i}{IS_i + 1000} \right) \quad (15)$$

Veri seti düzeyindeki arka plan karmaşıklığı, tüm görüntülere ait BC_i değerlerinin aritmetik ortalaması alınarak Eşitlik (16) ile hesaplanmaktadır.

$$BC = \frac{1}{N} \sum_{i=1}^N BC_i \quad (16)$$

Bu yaklaşım, veri setindeki tüm görüntülerin arka plan karmaşıklığını tek bir temsil değeri altında birleştirmektedir. Yüksek BC değerleri, kenar yoğunluğunun ve görsel ayrıntı düzeyinin daha yüksek olduğu karmaşık sahneleri; düşük BC değerleri ise daha sade ve daha az ayrıntı içeren sahneleri temsil etmektedir.

3.2.4 Anotasyon Karakteristikleri

Anotasyon karakteristikleri, veri setlerinin etiketleme yapısını ve anotasyonların dağılımını nicel olarak tanımlamaktadır. Literatürde anotasyon kalitesinin, veri setlerinin güvenilirliği ve temsil gücü açısından önemli bir bileşen olduğu belirtilmektedir (Carion vd. 2020)(Everingham vd. 2009)(Tsung Lin vd. 2017). Bu çalışmada anotasyon yapısı; sınır kutusu alan varyansı (BBAV) ve sınır nesne oranı (BoR) olmak üzere iki temel metrik kullanılarak değerlendirilmiştir.

3.2.4.1 Bounding Box Area Variance (BBAV)

Ortalama nesne boyutu veri setinin genel ölçek yapısını ifade etmesine rağmen, nesne alanlarının dağılımındaki değişkenliği tek başına açıklayamamaktadır. Bu nedenle, nesne boyutlarının veri seti içerisindeki çeşitliliğini değerlendirmek amacıyla Bounding Box Area Variance (BBAV) metriği kullanılmıştır (Y. Zhao vd. 2024)(Zhang vd. 2022).

İlk olarak normalize edilmiş sınır kutusu alanları Eşitlik (17) ile hesaplanmaktadır.

$$A_i = \frac{w_i \times h_i}{W_i \times H_i} \quad (17)$$

Ardından veri seti düzeyindeki sınır kutusu alan varyansı Eşitlik (18) ile elde edilmektedir.

$$BBAV = \frac{1}{N-1} \sum_{i=1}^N (A_i - \bar{A})^2 \quad (18)$$

Burada A_i , normalize edilmiş sınır kutusu alanını, $\bar{A}$ ise veri setine ait ortalama normalize edilmiş nesne alanını göstermektedir. BBAV metriği, veri setindeki nesne ölçeklerinin değişkenliğini nicel olarak ifade etmektedir.

3.2.4.2 Border Object Ratio (BoR)

Gerçek dünya görüntülerinde nesnelerin bir bölümü görüntü sınırına yakın konumlanabilmekte veya kısmen görüntü dışında kalabilmektedir (L. Liu vd. 2020)(Chen vd. 2022). Bu tür örneklerin veri seti içerisindeki dağılımını belirlemek amacıyla Border Object Ratio (BoR) metriği tanımlanmıştır.

Border Object Ratio değeri Eşitlik (19) kullanılarak hesaplanmaktadır.

$$BoR = \frac{N_{border}}{N_{bbox}} \quad (19)$$

Burada N_{border} , görüntü sınırına belirlenen eşik mesafesi içerisinde bulunan toplam nesne sayısını, N_{bbox} ise veri setindeki toplam anotasyon sayısını ifade etmektedir. BoR metriği, veri setindeki sınır nesnelerinin oranını nicel olarak tanımlamaktadır.

Bu çalışmada önerilen veri seti karakterizasyon metrikleri; geometrik, istatistiksel, görsel ve anotasyon tabanlı olmak üzere dört ana kategori altında tanımlanmıştır. Kullanılan tüm metrikler, sembolleri ve ölçüm birimleri ile birlikte Tablo 1'de özetlenmektedir.

Table 1. Önerilen Veri Seti Karakterizasyon Metriklerinin Özeti


Kategori	Metrik	Sembol	Birim
Geometrik	Ortalama Nesne Boyutu	AOS	Normalize Alan
Geometrik	Küçük Nesne Oranı	SOR	%
Geometrik	Nesne Yoğunluğu	OD	Nesne/Görüntü
Geometrik	Sınır Kutusu Örtüşme Oranı	BBoxOR	IoU
Geometrik	Ön Plan Doluluk Oranı	FOR	%
İstatistiksel	Sınıf Entropisi	CE	Bits
Görsel	Görüntü Çözünürlüğü	IR	Piksel

Görsel	Görüntü Kontrastı	IC	RMS
Görsel	Görüntü Keskinliği	IS	Laplacian Varyans
Görsel	Arka Plan Karmaşıklığı	BC	Kenar + Doku (0-1 Aralığı)
Anotasyon	Sınır Kutusu Alan Varyansı	BBAV	Varyans
Anotasyon	Sınır Nesne Oranı	BoR	%

Tablo 1'de önerilen veri seti karakterizasyon yaklaşımında kullanılan metrikler, ait oldukları kategoriler, sembolleri ve ölçüm birimleri ile birlikte özetlenmektedir. Geometrik, istatistiksel, görsel ve anotasyon tabanlı metriklerin birlikte değerlendirilmesi, veri setlerinin yapısal özelliklerinin çok boyutlu olarak tanımlanmasına olanak sağlamaktadır. Bu karakterizasyon çerçevesi, farklı nesne tespiti veri setlerinin ortak metrikler kullanılarak sistematik biçimde analiz edilmesini ve karşılaştırılmasını desteklemektedir. Çalışmanın deneysel değerlendirmeleri, Tablo 1'de sunulan bu karakterizasyon metrikleri temel alınarak gerçekleştirilmiştir.

3.3 Özellik Çıkarım İş Akışı

Çalışmada tanımlanan tüm veri seti karakteristiklerinin otomatik, tekrarlanabilir ve modelden bağımsız biçimde hesaplanabilmesi amacıyla Python tabanlı modüler bir özellik çıkarım sistemi geliştirilmiştir. Önerilen sistem, COCO formatındaki anotasyon dosyalarını ve ilgili görüntüleri doğrudan okuyarak veri setine ait geometrik, istatistiksel, görsel ve anotasyon tabanlı karakteristikleri tek bir işlem hattı içerisinde üretmektedir. Böylece farklı nesne tespiti veri setleri herhangi bir manuel işleme ihtiyaç duyulmadan aynı metodoloji kullanılarak analiz edilebilmektedir. Önerilen özellik çıkarım sürecinin genel iş akışı Şekil 1'de gösterilmektedir.



Şekil 1. Nesne tespiti veri setlerinin çok kategorili özellik çıkarımına dayalı otomatik karakterizasyonu için önerilen çerçeve.

Şekil 1'de görüldüğü üzere, özellik çıkarım süreci görüntüler ve anotasyon dosyalarının birlikte işlenmesiyle başlamaktadır. İlk aşamada veri setine ait anotasyonlar okunarak görüntü kimlikleri, sınıf etiketleri ve sınır kutusu bilgileri belleğe aktarılmakta, ardından görüntüler ilgili anotasyonlarla eşleştirilerek veri setinin temel yapısı oluşturulmaktadır. Sonraki aşamada geometrik, istatistiksel, görsel ve anotasyon tabanlı karakterizasyon metrikleri otomatik olarak hesaplanmakta ve elde edilen tüm özellikler Dataset Characterization Vector (DCV) içerisinde birleştirilmektedir. DCV; beş geometrik ve bir istatistiksel karakteristik (AOS, SOR, OD, BBoxOR, FOR ve CE), dört görsel karakteristik (IR, IC, IS ve BC) ile iki anotasyon karakteristiğinden (BBAV ve BoR) oluşan toplam on iki metrikten meydana gelmektedir. Böylece her veri seti ortak bir karakterizasyon uzayında sayısal olarak temsil edilmektedir.

Geometrik analiz aşamasında sınır kutularının boyutları, konumları ve dağılımları kullanılarak ortalama nesne boyutu, küçük nesne oranı, nesne yoğunluğu, ön plan doluluk oranı ve sınır kutusu örtüşme oranı hesaplanmaktadır. İstatistiksel analiz aşamasında sınıf frekans dağılımları kullanılarak CE ve nesne birlikte görülme ilişkileri elde edilmektedir. Böylece veri setlerinin uzamsal ve istatistiksel yapısı ortak metrikler kullanılarak nicel olarak karakterize edilmektedir.

Görsel analiz aşamasında her görüntü çözünürlük, kontrast, keskinlik ve arka plan karmaşıklığı açısından değerlendirilmektedir. Çözünürlük doğrudan görüntü boyutlarından elde edilirken, kontrast RMS yöntemi, keskinlik Laplacian varyansı ve arka plan karmaşıklığı ise Canny kenar

yoğunluğu ile Laplacian tabanlı görüntü keskinliği bilgisinin birlikte değerlendirilmesiyle hesaplanmaktadır. Böylece veri setlerinin yalnızca nesne yapısı değil, aynı zamanda görsel içerikleri de karakterizasyon sürecine dahil edilmektedir.

Anotasyon tabanlı analiz kapsamında sınır kutusu alan varyansı ve sınır nesne oranı hesaplanmaktadır. Elde edilen tüm karakterizasyon metrikleri daha sonra veri seti düzeyinde birleştirilerek her veri setini temsil eden Dataset Characterization Vector (DCV) oluşturulmaktadır. Bu yapı sayesinde farklı veri setleri ortak bir özellik uzayında doğrudan karşılaştırılabilmektedir.

Önerilen işlem hattının en önemli avantajı, tamamen otomatik çalışması ve herhangi bir nesne tespit modeline bağımlı olmamasıdır. Tüm karakterizasyon metrikleri yalnızca görüntüler ve anotasyon dosyaları kullanılarak hesaplanmakta, model eğitimi veya çıkarım sonuçlarına ihtiyaç duyulmamaktadır. Bu sayede yöntem farklı nesne tespiti veri setlerine doğrudan uygulanabilmekte ve ortak bir karakterizasyon çerçevesi altında analiz edilebilmektedir. Ayrıca modüler yapısı sayesinde yeni karakterizasyon metriklerinin eklenmesi veya mevcut hesaplama yöntemlerinin güncellenmesi kolaylıkla gerçekleştirilebilmektedir.

DCV=[AOS, SOR, OD, BBoxOR, FOR, CE, IR, IC, IS, BC, BBAV, BoR]

4. DENEYSEL ÇALIŞMALAR

Bu bölümde önerilen veri seti karakterizasyon yaklaşımının deneysel uygulama süreci sunulmaktadır. Öncelikle çalışmada kullanılan veri setleri tanıtılmakta, ardından karakterizasyon metriklerinin hesaplanmasında kullanılan deneysel ortam ve uygulama süreci açıklanmaktadır. Tüm veri setleri aynı özellik çıkarım yöntemi kullanılarak analiz edilmiş ve elde edilen karakterizasyon sonuçları ortak bir değerlendirme çerçevesi altında karşılaştırılmıştır.

4.1 Veri Setlerinin Seçimi

Veri seti karakterizasyon yaklaşımının farklı yapısal özelliklere sahip veri kümeleri üzerinde değerlendirilebilmesi amacıyla, bilgisayarlı görü literatüründe yaygın olarak kullanılan ve farklı uygulama alanlarını temsil eden üç nesne tespiti veri seti seçilmiştir. Veri setlerinin seçiminde yalnızca kullanım alanları değil; nesne ölçeği, nesne yoğunluğu, sınıf çeşitliliği, görüntü çözünürlüğü ve sahne karmaşıklığı gibi karakteristik özellikler de dikkate alınmıştır. Böylece önerilen karakterizasyon yaklaşımının farklı veri yapıları üzerinde uygulanabilirliği değerlendirilmiştir.

Bu doğrultuda çalışmada COCO 2017, Pascal VOC 2012 ve VisDrone2019-DET veri setleri kullanılmıştır. Bu veri setleri; nesne ölçeği, sınıf çeşitliliği, görüntü çözünürlüğü ve sahne yapısı bakımından birbirlerinden belirgin biçimde ayrılmaktadır. Çalışmada kullanılan veri setlerinin temel özellikleri Tablo 2'de sunulmaktadır.

Tablo 2. Çalışmada kullanılan nesne tespiti veri setlerinin genel özellikleri

Veri Seti	Uygulama Alanı	Görüntü Sayısı	Nesne Sayısı	Sınıf Sayısı
COCO 2017	Genel amaçlı nesne tespiti	123,287	896,782	80
Pascal VOC 2012	Genel amaçlı nesne tespiti	17,125	40,138	20
VisDrone2019-DET	İHA görüntüleri	7,019	381,964	10

Tablo 2 incelendiğinde, çalışmada kullanılan veri setlerinin hem uygulama alanı hem de yapısal özellikler bakımından birbirini tamamlayacak şekilde seçildiği görülmektedir. COCO veri seti yüksek sınıf çeşitliliği ve karmaşık sahne yapısıyla genel amaçlı nesne tespiti araştırmalarında yaygın olarak kullanılan referans veri setlerinden biridir. Pascal VOC ise daha sade sahne yapısı ve büyük nesne dağılımı ile farklı bir veri karakteristiği sunmaktadır. Buna karşılık VisDrone, yüksek nesne yoğunluğu ve küçük nesne ağırlıklı yapısıyla farklı bir geometrik ve görsel karakteristik sergilemektedir. Bu çeşitlilik, önerilen veri seti karakterizasyon yaklaşımının farklı veri yapıları üzerinde uygulanabilirliğinin değerlendirilmesine olanak sağlamaktadır.

4.2 Karakterizasyon Ortamı ve Yazılım Altyapısı

Önerilen veri seti karakterizasyon yaklaşımının uygulanabilmesi amacıyla Python tabanlı modüler bir analiz ortamı geliştirilmiştir. Tüm karakterizasyon metrikleri aynı yazılım altyapısı kullanılarak otomatik olarak hesaplanmış ve farklı veri setleri ortak bir işlem hattı altında analiz edilmiştir. Böylece veri setlerinin karakterizasyon süreci kullanıcı müdahalesinden bağımsız, tekrarlanabilir ve standart bir yapıda gerçekleştirilmiştir.

Karakterizasyon işlem hattında görüntülerin okunması ve işlenmesi için OpenCV, sayısal hesaplamalar için NumPy, veri işleme süreçlerinde Pandas, istatistiksel hesaplamalarda SciPy ve görselleştirme işlemlerinde Matplotlib kütüphanelerinden yararlanılmıştır. Tüm analizler Python programlama dili kullanılarak geliştirilmiş olup karakterizasyon metriklerinin hesaplanması tamamen otomatik olarak gerçekleştirilmiştir.

Veri setlerine ait anotasyon dosyaları okunarak görüntü kimlikleri, sınıf etiketleri ve sınır kutusu bilgileri çıkarılmış; ardından her görüntü için geometrik, istatistiksel, görsel ve anotasyon tabanlı karakteristikler hesaplanmıştır. Hesaplanan tüm metrikler veri seti düzeyinde birleştirilerek her veri setini temsil eden Dataset Characterization Vector (DCV) oluşturulmuştur. Böylece farklı veri setleri ortak bir özellik uzayında sayısal olarak temsil edilmiş ve doğrudan karşılaştırılabilir hâle getirilmiştir.

Karakterizasyon süreci herhangi bir nesne tespit modelinin eğitimi veya çıkarım sonuçlarına ihtiyaç duymamaktadır. Tüm metrikler yalnızca görüntüler ve anotasyon dosyalarından elde edilen bilgiler kullanılarak hesaplanmaktadır. Bu yaklaşım, önerilen yöntemin modelden bağımsız olarak farklı nesne tespiti veri setlerine doğrudan uygulanabilmesine ve aynı karakterizasyon çerçevesi altında analiz edilebilmesine olanak sağlamaktadır.

Deneyisel çalışmalarda kullanılan temel yazılım ve donanım bileşenleri Tablo 3'te özetlenmiştir.

Tablo 3. Karakterizasyon ortamında kullanılan yazılım ve donanım bileşenleri

Bileşen	Açıklama
Programlama Dili	Python 3.10
Görüntü İşleme	OpenCV
Sayısal Hesaplamalar	NumPy
Veri İşleme	Pandas
İstatistiksel Analiz	SciPy
Görselleştirme	Matplotlib
İşletim Sistemi	Windows 11 Pro 64-bit
İşlemci	AMD Ryzen 7 8845HS
Bellek	16 GB RAM

Grafik İşlemci

NVIDIA GeForce RTX 4060 (8 GB)

Tablo 3'te karakterizasyon sürecinde kullanılan temel yazılım ve donanım bileşenleri özetlenmektedir. Kullanılan yazılım altyapısı, önerilen karakterizasyon metriklerinin otomatik olarak hesaplanmasını ve farklı veri setlerinin aynı işlem hattı altında analiz edilmesini sağlamaktadır. Modüler yapısı sayesinde sistem, yeni karakterizasyon metriklerinin eklenmesine veya farklı veri setlerine uygulanmasına uygun esnek bir çalışma ortamı sunmaktadır.

5. BULGULAR VE TARTIŞMA

Bu bölümde önerilen veri seti karakterizasyon yaklaşımı kullanılarak elde edilen deneysel bulgular sunulmaktadır. İlk olarak veri setlerine ait karakterizasyon metrikleri nicel olarak değerlendirilmekte, ardından bu metrikler farklı görselleştirme teknikleri yardımıyla karşılaştırılmaktadır. Elde edilen bulgular, veri setlerinin yapısal özellikleri arasındaki benzerlik ve farklılıkları ortaya koyarak önerilen yaklaşımın veri setlerini çok boyutlu olarak tanımlayabildiğini göstermektedir.

5.1 Veri Seti Karakterizasyon Sonuçları


Önerilen veri seti karakterizasyon yaklaşımı kullanılarak COCO, Pascal VOC ve VisDrone veri setleri için tanımlanan tüm metrikler otomatik olarak hesaplanmıştır. Her veri seti; geometrik, istatistiksel, görsel ve anotasyon tabanlı özellikler açısından analiz edilerek tek bir karakterizasyon vektörü (Dataset Characterization Vector - DCV) ile temsil edilmiştir. Böylece farklı veri setlerinin yalnızca görüntü veya sınıf sayıları üzerinden değil, çok boyutlu yapısal özellikleri dikkate alınarak karşılaştırılması amaçlanmıştır. Hesaplanan karakterizasyon metrikleri Tablo 4'te sunulmaktadır.

Tablo 4. COCO, Pascal VOC ve VisDrone veri setleri için hesaplanan karakterizasyon metrikleri

Metrik	COCO	Pascal VOC	VisDrone
Average Object Size (AOS)	0.077392	0.208130	0.001535
Small Object Ratio (SOR)	0.130223	0.010090	0.687604
Object Density (OD)	7.273938	2.343825	54.418578
Bounding Box Overlap Ratio (BBoxOR)	0.056170	0.095859	0.003314
Foreground Occupancy Ratio (FOR)	0.562945	0.487821	0.083529
Class Entropy (CE)	4.964181	3.307114	2.479320
Image Resolution (IR)	273924.67	179023.99	1525719.80
Image Contrast (IC)	59.7299	59.5240	46.6707
Image Sharpness (IS)	2671.6854	2880.7094	882.0501
Background Complexity (BC)	0.3544	0.3656	0.2444
Bounding Box Area Variance (BBAV)	0.025839	0.059966	0.000015
Border Object Ratio (BoR)	0.259151	0.438612	0.081612

Tablo 4 incelendiğinde, veri setlerinin karakteristik özellikler bakımından belirgin farklılıklar gösterdiği görülmektedir. Elde edilen bulgular, önerilen karakterizasyon metriklerinin veri setlerinin yapısal özelliklerini nicel olarak ayırt edebildiğini ortaya koymaktadır. Özellikle


VisDrone veri seti düşük ortalama nesne boyutu (AOS) ve yüksek nesne yoğunluğu (OD) ile küçük nesne tespiti açısından daha yüksek zorluk potansiyeline sahip bir karakteristik yapı sergilerken, Pascal VOC daha büyük nesne boyutları ve daha düşük nesne yoğunluğu ile öne çıkmaktadır. COCO ise sınıf çeşitliliği (CE) ve ön plan doluluk oranı (FOR) bakımından daha dengeli bir karakteristik yapı sergilemektedir. Bu bulgular, veri setlerinin yalnızca görüntü veya sınıf sayıları ile değil, çok boyutlu karakterizasyon metrikleri kullanılarak değerlendirilmesi gerektiğini göstermektedir. Tablo 4'te sayısal olarak sunulan bu farklılıkların veri seti profillerine nasıl yansıdığı ise Şekil 2'de radar grafiği aracılığıyla görsel olarak özetlenmiştir.



Şekil 2. Veri seti karakterizasyon vektörlerinin radar grafiği ile karşılaştırılması.

Şekil 2, veri setlerinin karakteristik profillerini çok boyutlu olarak göstermektedir. Radar grafiği, her veri setinin karakterizasyon metrikleri bakımından oluşturduğu genel profili tek bir gösterim üzerinde özetlemektedir. Grafik incelendiğinde VisDrone veri setinin küçük nesne oranı (SOR) ve nesne yoğunluğu (OD) bakımından, Pascal VOC veri setinin ise ortalama nesne boyutu (AOS) ve görsel kalite metrikleri açısından belirgin şekilde ayrıştığı görülmektedir. COCO veri seti ise birçok metrikte daha dengeli bir dağılım sergileyerek genel amaçlı nesne tespiti için temsil gücü yüksek bir karakteristik yapı ortaya koymaktadır. Bu sonuçlar, önerilen Dataset Characterization Vector (DCV) yaklaşımının veri setlerinin çok boyutlu yapısal özelliklerini bütüncül bir biçimde temsil edebildiğini göstermektedir.

Radar grafiği veri setlerinin genel karakteristik profillerini özetlemekle birlikte, karakterizasyon metriklerinin veri setleri arasındaki göreceli dağılımlarını daha ayrıntılı gösterebilmek amacıyla normalize edilmiş değerlerden oluşan bir ısı haritası da hazırlanmıştır. Bu görselleştirme Şekil 3'te sunulmaktadır.



Şekil 3. Veri seti karakterizasyon özelliklerinin normalize edilmiş ısı haritası.

Şekil 3, normalize edilmiş karakterizasyon metriklerinin veri setleri arasındaki görece dağılımını ayrıntılı olarak göstermektedir. Isı haritası, her bir karakterizasyon metriğinin hangi veri setinde daha baskın olduğunu açık biçimde ortaya koymaktadır. Özellikle VisDrone veri setinin küçük nesne oranı (SOR) ve nesne yoğunluğu (OD) metriklerinde en yüksek değerlere sahip olduğu, Pascal VOC'un ise ortalama nesne boyutu (AOS), keskinlik (Sharpness), arka plan karmaşıklığı ve sınır nesne oranı (BoR) bakımından öne çıktığı görülmektedir. COCO veri seti ise ön plan doluluk oranı (FOR) ve sınıf entropisi (CE) metriklerinde daha dengeli değerler sergilemektedir. Isı haritası, Tablo 4'te sunulan sayısal sonuçları görsel olarak destekleyerek veri setleri arasındaki karakteristik farklılıkların daha kolay yorumlanmasını sağlamaktadır.

5.2 Veri Seti Karakteristiklerinin Karşılaştırmalı Değerlendirilmesi

Önerilen karakterizasyon metrikleri kullanılarak elde edilen bulgular, veri setlerinin yalnızca temel istatistikler bakımından değil, yapısal özellikleri açısından da önemli farklılıklar içerdiğini göstermektedir. Bu bölümde veri setleri, karakterizasyon metrikleri birlikte değerlendirilerek karşılaştırılmış ve veri setlerinin hangi karakteristik özellikler bakımından birbirinden ayrıştığı ortaya konulmuştur.

Geometrik karakterizasyon metrikleri incelendiğinde, veri setleri arasında ortalama nesne boyutu (AOS), küçük nesne oranı (SOR) ve nesne yoğunluğu (OD) bakımından belirgin farklılıklar olduğu görülmektedir. VisDrone veri seti, düşük ortalama nesne boyutu ve yüksek nesne yoğunluğu ile küçük nesne tespiti açısından en yüksek geometrik zorluk potansiyelini göstermektedir. Buna karşılık Pascal VOC daha büyük nesneler içermesi nedeniyle daha düşük geometrik karmaşıklığa sahiptir. COCO ise bu iki veri seti arasında daha dengeli bir dağılım sergileyerek genel amaçlı nesne tespiti senaryolarını temsil eden bir karakteristik yapı ortaya koymaktadır.

Ön plan doluluk oranı (FOR), arka plan karmaşıklığı ve görüntü keskinliği (Sharpness) metrikleri birlikte değerlendirildiğinde veri setlerinin görsel yapıları arasında da önemli farklılıklar olduğu görülmektedir. COCO veri seti yüksek ön plan doluluk oranı ve dengeli arka plan karmaşıklığı ile nesnelerin sahne içerisindeki temsilini daha dengeli bir biçimde sunmaktadır. Buna karşılık VisDrone veri setinde küçük ve yoğun nesnelerin baskın olması, nesnelerin ayırt edilmesini zorlaştırabilecek bir karakteristik yapı oluşturmaktadır. Pascal VOC ise daha belirgin nesne yapıları ve yüksek görüntü kalitesi sayesinde görsel açıdan daha sade bir karakteristik sergilemektedir.

Veri setlerinin sınıf çeşitliliği ve bilgi içeriği incelendiğinde, COCO'nun en dengeli sınıf dağılımına sahip veri seti olduğu görülmektedir. Yüksek sınıf entropisi (CE), veri setinin farklı nesne sınıflarını daha dengeli temsil ettiğini göstermektedir. Pascal VOC daha sınırlı sayıda sınıf içermesine rağmen düzenli dağılımı ile öne çıkarken, VisDrone'un belirli nesne sınıflarında yoğunlaşması veri setinin uygulama alanına özgü karakteristik yapısını yansıtmaktadır.

Genel olarak değerlendirildiğinde, önerilen karakterizasyon metrikleri veri setlerinin yalnızca temel istatistiklerle açıklanamayacak yapısal farklılıklarını nicel olarak ortaya koymaktadır. Elde edilen sonuçlar, nesne tespiti veri setlerinin çok boyutlu karakterizasyonunun veri setlerinin güçlü ve zayıf yönlerinin belirlenmesine katkı sağlayabileceğini göstermektedir. Bu yaklaşım, veri setlerinin daha kapsamlı biçimde analiz edilmesine katkı sağlayabilecek tamamlayıcı bir değerlendirme yaklaşımı sunmaktadır.

6. SONUÇ

Bu çalışmada, nesne tespiti veri setlerinin yalnızca görüntü veya sınıf sayısı gibi temel istatistiklerle değil; geometrik, istatistiksel, görsel ve anotasyon tabanlı karakteristikleri dikkate alınarak sistematik biçimde değerlendirilmesini sağlayan veri odaklı bir karakterizasyon yaklaşımı sunulmuştur. Bu kapsamda, farklı veri setlerinin ortak bir çerçevede analiz edilmesine olanak sağlayan karakterizasyon metrikleri tanımlanmış, bu metriklerin otomatik olarak hesaplanmasını sağlayan modüler bir özellik çıkarım iş akışı geliştirilmiş ve veri setleri Dataset Characterization Vector (DCV) ile çok boyutlu olarak temsil edilmiştir. Böylece önerilen yaklaşım, veri setlerinin yalnızca nicel olarak tanımlanmasını değil, aynı zamanda ortak bir karakterizasyon uzayında sistematik ve tekrarlanabilir biçimde karşılaştırılmasını mümkün kılmaktadır.

COCO 2017, Pascal VOC 2012 ve VisDrone2019-DET veri setleri üzerinde gerçekleştirilen analizler, veri setlerinin nesne boyutu, nesne yoğunluğu, sınıf çeşitliliği, görüntü özellikleri ve anotasyon yapısı bakımından belirgin farklılıklar içerdiğini ortaya koymuştur. Elde edilen bulgular, önerilen karakterizasyon metriklerinin veri setlerinin yapısal özelliklerini nicel olarak ifade edebildiğini ve farklı veri setlerinin ortak bir değerlendirme çerçevesinde karşılaştırılmasını desteklediğini göstermektedir. Ayrıca radar grafiği ve ısı haritası gibi görselleştirme yöntemleri, veri setlerinin karakteristik profillerinin bütüncül ve karşılaştırmalı olarak yorumlanmasını kolaylaştırmıştır.

Sonuç olarak önerilen yaklaşım, nesne tespiti veri setlerinin çok boyutlu yapısal özelliklerini sistematik biçimde analiz edebilen, pratik, tekrarlanabilir ve farklı veri setlerine uygulanabilir bir karakterizasyon çerçevesi sunmaktadır. Gelecek çalışmalarda önerilen yaklaşımın daha fazla nesne tespiti veri seti üzerinde doğrulanması, farklı karakterizasyon metrikleri ile genişletilmesi ve nesne tespiti dışındaki bilgisayarlı görü uygulamalarına uyarlanması planlanmaktadır. Ayrıca, veri seti karakteristikleri ile nesne tespiti modellerinin performansı arasındaki ilişkinin nicel olarak modellenmesi, metriklerin göreceli önemlerinin analiz edilmesi ve veri seti özelliklerine göre model seçimini destekleyen veri odaklı karar mekanizmalarının geliştirilmesi bu çalışmanın doğal devamı olarak değerlendirilmektedir.

7. KAYNAKÇA

Agnew, Cathaoir, Anthony Scanlan, ve Patrick Denny. 2024. "Annotation Quality vs Quantity for Object Detection and Instance Segmentation". *IEEE Access* 10(August): 1–22.

Bojarski, Mariusz vd. 2016. "End to End Learning for Self-Driving Cars". *arXiv*: 1–9.

- Carion, Nicolas vd. 2020. “End-to-End Object Detection with Transformers”. *arXiv*.
- Chen, Guang vd. 2022. “A Survey of the Four Pillars for Small Object Detection : Multiscale Representation , Contextual and Region Proposal”. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS: SYSTEMS* 52(2): 936–53.
- Dubey, Abhimanyu, Nikhil Naik, Devi Parikh, ve Ramesh Raskar. 2016. “Deep Learning the City : Quantifying Urban Perception At A Global Scale”. *arXiv*: 1–23.
- Everingham, Mark vd. 2013. “The Pascal Visual Object Classes Challenge – a Retrospective”.
- Everingham, Mark, Luc Van Gool, Christopher K I Williams, ve John Winn. 2009. “The PASCAL Visual Object Classes (VOC) Challenge”. *International Journal of Computer Vision* 88(2010): 303–38.
- Glenn, Jocher, Chaurasia Ayush, ve Qiu Jing. 2023. “Ultralytics YOLOv8 Documentation”. *Ultralytics*. <https://docs.ultralytics.com/models/yolov8#citations-and-acknowledgments>.
- Hussain, Adnan, Kaleem Ullah, Muhammad Afaq, ve Muhammad Munsif. 2026. “Quality over quantity : a data-centric survey of annotation errors in object detection datasets”. *Artificial Intelligence Review* 59(107): 1–50.
- “Intel acquires Itseez”. <https://opencv.org/intel-acquires-itseez/> (11 Kasım 2020).
- Jakubik, Johannes vd. 2024. “Data-Centric Artificial Intelligence”. *arXiv*: 1–14.
- Jiao, Licheng vd. 2019. “A survey of deep learning-based object detection”. *IEEE Access* 7(3): 128837–68.
- Kamilaris, Andreas, ve Francesc X Prenafeta-Boldú. 2018. “Deep learning in agriculture : A survey”. 147(February): 70–90.
- Kemal, Oksuz, Cam Baris Can, Kalkan Sinan, ve Akbas Emre. 2020. “Imbalance Problems in Object Detection : A Review”. *arXiv*.
- Kim, Min Je vd. 2025. “Pseudo-Labeling Driven Refinement of Benchmark Object Detection Datasets via Analysis of Learning Patterns”. *arXiv*.
- Lin, Tsung-yi vd. 2015. “Microsoft COCO : Common Objects in Context”. *arXiv*: 740–55.
- Lin, Tsung-yi, C Lawrence Zitnick, ve Piotr Doll. 2015. “Microsoft COCO : Common Objects in Context”. *arXiv*: 1–15.
- Lin, Tsung vd. 2017. “Feature Pyramid Networks for Object Detection”. *arXiv*.
- Liu, Li vd. 2020. “Deep Learning for Generic Object Detection: A Survey”. *International Journal of Computer Vision* 128(2): 261–318.
- Liu, Shilong vd. 2024. “Grounding DINO : Marrying DINO with Grounded Pre-Training for Open-Set Object Detection”. *arXiv*.
- Liu, Wei vd. 2016. “SSD: Single shot multibox detector”. İçinde *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, , 21–37.
- Michielsen, Laurens, Jan Van Gemert, ve Osman S Kayhan. 2024. TUDelft “Every human makes mistakes : Exploring the sensitivity of deep-learned object detectors to human annotation noise”. Delft University of Technology.
- Paszke, Adam vd. 2019. “PyTorch : An Imperative Style , High-Performance Deep Learning Library”. *arXiv* (NeurIPS).

- Proença, Pedro F, Pedro Simões, ve C V Mar. 2020. “TACO : Trash Annotations in Context for Litter Detection”. *arXiv*.
- Redmon, Joseph, Santosh Divvala, Ross Girshick, ve Ali Farhadi. 2016. “You Only Look Once : Unified , Real-Time Object Detection”. İçinde *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, 779–88.
- Ren, Shaoqing, Kaiming He, Ross Girshick, ve Jian Sun. 2017. “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39(6): 1137–49.
- Su, Yukun vd. 2022. “Occlusion-Aware Detection and Re-ID Calibrated Network for Multi-Object Tracking”. *arXiv*.
- Wang, Shuo, Chunlong Xia, Feng Lv, ve Yifeng Shi. 2024. “RT-DETRv3: Real-time End-to-End Object Detection with Hierarchical Dense Positive Supervision”. *arXiv*: 11–13.
- Yang, Zhou, ve Li Hui. 2024. “A Survey of Dense Object Detection Methods Based on Deep Learning”. *IEEE Access* 12(October): 179944–61.
- Yu, Li vd. 2020. “Overcoming Classifier Imbalance for Long-tail Object Detection with Balanced Group Softmax”. *arXiv*.
- Zhang, Hao, Feng Li, Shilong Liu, ve Lei Zhang. 2022. “DINO: DETR with Improved DeNoising Anchor Boxes for End-to-End Object Detection”. *arXiv*.
- Zhao, Chenyang, Jia Wan, ve Antoni B Chan. 2025. “Density-based Object Detection in Crowded Scenes”. *arXiv*: 1–9.
- Zhao, Yian vd. 2024. “DETRs Beat YOLOs on Real-time Object Detection”. İçinde *2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, WA, USA: IEEE, 16965–74. <https://ieeexplore.ieee.org/document/10657220>.
- Zhao, Zhong Qiu, Peng Zheng, Shou Tao Xu, ve Xindong Wu. 2019. “Object Detection with Deep Learning: A Review”. *IEEE Transactions on Neural Networks and Learning Systems* 30(11): 3212–32.

FEDERATED ÖĞRENMEDE İSTEMCI ERIŞİLEBİLİRLİĞİ VE VERİ HETEROJENLİĞİNİN MODEL PERFORMANSINA ETKİSİNİN KARŞILAŞTIRMALI ANALIZI

A COMPARATIVE ANALYSIS OF THE IMPACT OF CLIENT AVAILABILITY AND
DATA HETEROGENEITY ON MODEL PERFORMANCE IN FEDERATED LEARNING

Assist. Prof. Dr. Esra ODABAŞ YILDIRIM¹

¹Department of Software Engineering, Faculty of Engineering, Ataturk University,
Erzurum, TURKEY

ORCID ID: 0000-0002-0936-1342

ÖZET

Federated öğrenme verilerin merkezi bir sunucuda toplanmasına gerek kalmadan dağıtık yapıda model eğitimi gerçekleştirebilmesi nedeniyle özellikle gizliliğin kritik olduğu uygulamalarda önemli bir çözüm olarak öne çıkmaktadır. Bununla birlikte gerçek uygulamalarda istemcilerin her iletişim turuna düzenli olarak katılamaması, model performansı ve iletişim maliyeti üzerinde önemli etkiler oluşturmaktadır. Bu çalışmada istemci katılım senaryolarının federated öğrenme performansı üzerindeki etkisi karşılaştırmalı olarak incelenmiştir.

Deneylerde Fashion-MNIST veri kümesi kullanılmış ve dört farklı istemci katılım senaryosu değerlendirilmiştir. Bunlar tam istemci katılımı, rastgele %50 istemci katılımı, kalıcı istemci kaybı ve veri bağımlı istemci kaybıdır. Tüm deneyler bağımsız ve özdeş dağılımlı (IID) ile Dirichlet tabanlı bağımsız ve özdeş olmayan (Non-IID) veri dağılımları altında aynı CNN modeli, aynı FedAvg algoritması ve aynı eğitim parametreleri kullanılarak gerçekleştirilmiştir. Performans değerlendirmesinde doğruluk, Makro F1 skoru, istemci güncelleme sayısındaki azalma ve yakınsama davranışı birlikte analiz edilmiştir.

Deney sonuçları IID veri dağılımında rastgele %50 istemci katılımının tam istemci katılımına oldukça yakın sınıflandırma performansı elde ettiğini göstermiştir. Ayrıca bu senaryoda istemci güncelleme sayısı yaklaşık %50 oranında azaltılmıştır. Non-IID veri dağılımında istemci katılımındaki azalmanın model performansı üzerindeki etkisi daha belirgin olmakla birlikte tüm senaryolar eğitim sonunda kararlı bir yakınsama davranışı sergilemiştir.

Elde edilen bulgular özellikle veri heterojenliğinin düşük olduğu ortamlarda her iletişim turunda tüm istemcilerin aktif olmasının zorunlu olmadığını göstermektedir. Uygun istemci katılım stratejileri kullanılarak iletişim yükü önemli ölçüde azaltılırken model başarısı büyük ölçüde korunabilmektedir.

Anahtar Kelimeler: Federated Öğrenme, İstemci Katılımı, İstemci Erişilebilirliği, Veri Heterojenliği, İletişim Verimliliği, Dağıtık Makine Öğrenmesi.

ABSTRACT

Federated learning stands out as a significant solution, particularly in applications where privacy is critical, because it allows model training in a distributed environment without the need to collect data on a central server. However, in real-world applications, clients' inability to participate in every communication round can significantly impact model performance and

communication costs. This study comparatively examines the impact of client participation scenarios on federated learning performance.

The experiments used the Fashion-MNIST dataset, and four different client participation scenarios were evaluated: full client participation, 50% random client participation, persistent client loss, and data-dependent client loss. All experiments were conducted under both independent and identical (IID) and Dirichlet-based independent and non-IID data distributions, using the same CNN model, the same FedAvg algorithm, and the same training parameters. Performance evaluation analyzed accuracy, Macro F1 score, reduction in client update count, and convergence behavior.

Experimental results showed that random 50% client participation in the IID data distribution achieved classification performance quite close to full client participation. Furthermore, the number of client updates was reduced by approximately 50% in this scenario. While the impact of reduced client participation on model performance is more pronounced in non-IID data distributions, all scenarios exhibited stable convergence behavior at the end of training.

The findings show that all clients don't need to be active in every communication round, especially in environments with low data heterogeneity. By using appropriate client participation strategies, the communication load can be significantly reduced while largely preserving model success.

Keywords: Federated Learning, Client Participation, Client Availability, Data Heterogeneity, Communication Efficiency, Distributed Machine Learning.

GİRİŞ

Merkezi öğrenme yaklaşımı farklı kaynaklardan elde edilen verilerin tek bir sunucuda toplanmasını gerektirdiğinden veri gizliliği, iletişim maliyeti ve ölçeklenebilirlik açısından önemli sınırlılıklar taşımaktadır (McMahan vd., 2017). Özellikle sağlık, finans, nesnelerin interneti ve uç bilişim uygulamalarında verilerin farklı kurumlarda veya cihazlarda tutulması, merkezi veri paylaşımını çoğu zaman mümkün kılmamaktadır (Kairouz vd., 2021). Bu gereksinim doğrultusunda geliştirilen Federated Learning (FL) hem verileri paylaşmadan ortak bir modelin eğitilmesini sağlayan dağıtık bir makine öğrenmesi yaklaşımıdır. FL mimarisinde her istemci modeli yalnızca kendi yerel verisi üzerinde eğitmekte ve merkezi sunucuya yalnızca model güncellemelerini göndermektedir. Sunucu ise bu güncellemeleri birleştirerek küresel modeli oluşturmaktadır. McMahan ve arkadaşları tarafından önerilen Federated Averaging (FedAvg) algoritması günümüzde federated öğrenme çalışmalarında en yaygın kullanılan temel toplulaştırma yöntemi olarak kabul edilmektedir (McMahan vd., 2017).

Federated öğrenmenin en önemli uygulama alanlarından biri sağlık sektörüdür. Hastaneler arasında hasta verilerinin doğrudan paylaşılması çoğu zaman yasal düzenlemeler ve mahremiyet gereksinimleri nedeniyle mümkün değildir. Federated öğrenme sayesinde kurumlar verilerini kendi sistemlerinde tutarken ortak tanı modelleri geliştirebilmektedir (Rieke et al. 2020). Sheller ve arkadaşları beyin tümörü segmentasyonu üzerine gerçekleştirdikleri

çalışmada federated öğrenmenin merkezi eğitime yakın başarı sağlayabildiğini göstermiştir (Sheller et al. 2020). Antunes ve arkadaşları ise sağlık alanındaki federated öğrenme uygulamalarını kapsamlı biçimde inceleyerek yöntemin güvenli yapay zeka sistemleri açısından önemli bir potansiyele sahip olduğunu ortaya koymuştur (Antunes vd., 2022).

Federated öğrenmenin yaygın kullanımını sınırlayan temel problemlerden biri veri heterojenliğidir. Gerçek uygulamalarda istemciler farklı kullanıcı gruplarından veya farklı ortamlardan veri topladığı için yerel veri dağılımları önemli ölçüde değişebilmektedir. Bu durum küresel modelin yakınsama hızını düşürmekte ve sınıflandırma performansını olumsuz etkileyebilmektedir (X. Li vd., 2020). Bu problemi azaltmak amacıyla önerilen FedProx yöntemi, yerel optimizasyon sürecine proximal terim ekleyerek istemci güncellemeleri arasındaki farklılığı azaltmayı hedeflemektedir (T. Li vd., 2020). FedNova, istemcilerin farklı sayıda yerel güncelleme gerçekleştirmesinden kaynaklanan optimizasyon sapmasını normalize etmektedir (Wang vd., 2020). Adaptive Federated Optimization yaklaşımı ise Adam, Adagrad ve Yogi gibi adaptif optimizasyon algoritmalarını sunucu tarafına uyarlayarak daha kararlı bir yakınsama sağlamaktadır (Reddi vd., 2021).

Federated öğrenmede karşılaşılan bir diğer önemli problem iletişim maliyetidir. Her iletişim turunda istemcilerin modeli indirmesi yerel eğitim gerçekleştirmesi ve güncellenmiş parametreleri sunucuya iletmesi gerekmektedir. Özellikle mobil ve uç bilişim ortamlarında bu süreç önemli bir darboğaz oluşturmaktadır (Mills vd., 2020). Reisizadeh ve arkadaşları tarafından geliştirilen FedPAQ yöntemi periyodik model toplulaştırması ve güncelleme nicemlemesini birlikte kullanarak iletişim yükünü azaltmayı amaçlamaktadır (Reisizadeh vd., 2020). Rothchild ve arkadaşları tarafından önerilen FetchSGD yaklaşımı ise yüksek boyutlu model güncellemelerini sıkıştırarak iletişim verimliliğini artırmaktadır (Rothchild vd., 2020). Gerçek federated öğrenme ortamlarında tüm istemcilerin her iletişim turuna katılması beklenemez. Mobil cihazlar pil seviyesi, ağ bağlantısı veya donanım kısıtları nedeniyle geçici olarak çevrimdışı kalabilmektedir. Benzer şekilde uç bilişim altyapılarında çalışan cihazlar da değişken hesaplama kapasitesi nedeniyle eğitime düzenli olarak katılamamaktadır (Kairouz vd., 2021). Bu nedenle son yıllarda istemci seçimi ve istemci erişilebilirliği üzerine çok sayıda çalışma gerçekleştirilmiştir. Nishio ve Yonetani tarafından önerilen FedCS yöntemi istemcilerin hesaplama ve iletişim kaynaklarını dikkate alarak katılımcıları belirlemektedir (Nishio and Yonetani 2019). Oort istemcilerin veri katkısını ve sistem performansını birlikte değerlendirerek seçim gerçekleştirmektedir (Lai vd., 2021). TiFL ise istemcileri eğitim sürelerine göre katmanlandırarak yavaş istemcilerin etkisini azaltmaktadır (Chai vd., 2020). Daha sonra geliştirilen FedMCCS yöntemi çok ölçütlü istemci seçimini IoT ortamlarına uyarlamıştır (AbdulRahman vd., 2021). VFedCS değişken istemci erişilebilirliğini dikkate alan dinamik bir seçim stratejisi önermiştir (Shi vd., 2022). FedMint ise sisteme yeni katılan istemcilerin seçim sürecinde dezavantaj yaşamamasını hedeflemektedir (Wehbi vd., 2023).

Mevcut çalışmalar incelendiğinde araştırmaların büyük bölümünün yeni optimizasyon algoritmaları veya istemci seçme mekanizmaları geliştirmeye odaklandığı görülmektedir. Buna karşın istemci erişilebilirliğinin federated öğrenme performansı üzerindeki etkisini deneysel


olarak inceleyen karşılaştırmalı çalışmalar sınırlı sayıdadır. Özellikle tam istemci katılımı, rastgele kısmi katılım, kalıcı istemci kaybı ve veri bağımlı istemci kaybı gibi gerçek uygulamalarda karşılaşılabilecek senaryoların aynı deneysel ortamda değerlendirilmesi literatürde yeterince ele alınmamıştır.

Bu çalışmada yeni bir federated öğrenme algoritması önerilmemektedir. Amaç istemci erişilebilirliğinin federated öğrenme performansı üzerindeki etkisini kontrollü ve tekrar üretilebilir deneylerle incelemektir. Bu kapsamda tüm deneylerde aynı CNN mimarisi, aynı FedAvg algoritması ve aynı eğitim parametreleri kullanılmıştır. Yalnızca istemci katılım senaryoları değiştirilmiştir. Tam katılım, rastgele kısmi katılım, kalıcı istemci kaybı ve veri bağımlı istemci kaybı senaryoları hem IID hem de Non-IID veri dağılımları altında değerlendirilmiştir. Model performansı doğruluk ve Makro F1 skoru ile değerlendirilmiştir. Ayrıca istemci güncelleme sayısı, iletişim yükündeki azalma, toparlanma süresi ve yakınsama davranışı analiz edilmiştir. Böylece istemci erişilebilirliğinin federated öğrenme sistemlerinin hem tahmin performansı hem de eğitim dinamikleri üzerindeki etkisi kapsamlı biçimde ortaya konulmuştur.

MATERYAL VE METOT

Bu çalışmada istemci erişilebilirliğinin federated öğrenme performansı üzerindeki etkisi kontrollü bir deneysel tasarım ile incelenmiştir. Çalışmada yeni bir federated öğrenme algoritması önerilmemiştir. Tüm deneylerde aynı model mimarisi, aynı toplulaştırma yöntemi ve aynı eğitim parametreleri kullanılmıştır. Yalnızca istemci katılım senaryoları değiştirilmiştir. Böylece gözlenen performans farklılıklarının doğrudan istemci erişilebilirliğinden kaynaklanması amaçlanmıştır.

Deneysel süreç veri hazırlama, istemcilere veri dağıtımı, yerel model eğitimi, merkezi toplulaştırma ve performans değerlendirmesi olmak üzere beş temel aşamadan oluşmaktadır. Çalışmanın genel akışı Şekil 1’de gösterilmektedir.



Şekil 1. Çalışmanın genel akış diyagramı.

Veri Kümesi

Deneyisel değerlendirmelerde Zalando Research tarafından geliştirilen Fashion-MNIST veri kümesi kullanılmıştır (Zalando Research 2017). Veri kümesi 10 farklı giyim sınıfına ait 70 000 gri seviye görüntüden oluşmaktadır. Fashion-MNIST veri kümesinin orijinal eğitim ve test ayrımı korunmuştur. Veri kümesinde yer alan 60 000 eğitim görüntüsü model eğitimi için kullanılmış, bu görüntülerin %10'u doğrulama amacıyla ayrılmıştır. Böylece eğitim sürecinde 54 000 görüntü eğitim, 6 000 görüntü ise doğrulama amacıyla kullanılmıştır. Model performansının değerlendirilmesi yalnızca veri kümesinin orijinal 10 000 görüntüden oluşan bağımsız test kümesi üzerinde gerçekleştirilmiştir.

Model eğitiminden önce tüm görüntüler piksel değerleri 255'e bölünerek normalize edilmiştir. Veri artırma uygulanmamıştır. Böylece performans farklılıklarının yalnızca istemci katılım senaryolarından ve veri dağılımından kaynaklanması amaçlanmıştır.

Federated öğrenme ortamında eğitim verileri istemciler arasında IID ve Dirichlet tabanlı Non-IID dağılımlar oluşturacak şekilde bölüştürülmüştür. Test kümesi ise tüm deneylerde ortak kullanılmıştır. Böylece farklı istemci katılım senaryoları aynı değerlendirme kümesi üzerinde karşılaştırılmıştır.

Federated Öğrenme Mimarisi

Çalışmada klasik istemci–sunucu mimarisine dayalı federated öğrenme altyapısı kullanılmıştır. Eğitim süreci merkezi sunucunun başlangıç modelini istemcilere göndermesiyle başlamaktadır. Her istemci modeli yalnızca kendi yerel verisi üzerinde eğitmekte ve güncellenen model parametrelerini merkezi sunucuya iletmektedir. Ham veriler istemciler arasında veya sunucu ile paylaşılmamaktadır.

Merkezi sunucu, aktif istemcilerden gelen model güncellemelerini Federated Averaging (FedAvg) algoritması ile birleştirerek yeni küresel modeli oluşturmaktadır (McMahan et al. 2017). Güncellenen model bir sonraki iletişim turu için yeniden istemcilere dağıtılmaktadır. Eğitim süreci önceden belirlenen iletişim turu tamamlanıncaya kadar yinelenmektedir.

Deneysel Kurulum

Deneyler Python programlama dili ve PyTorch derin öğrenme kütüphanesi kullanılarak gerçekleştirilmiştir. Federated öğrenme altyapısı istemci–sunucu mimarisi esas alınarak geliştirilmiştir. Tüm senaryolarda aynı CNN modeli ve aynı FedAvg toplulaştırma algoritması kullanılmıştır. Böylece performans farklılıklarının yalnızca istemci katılım senaryolarından kaynaklanması sağlanmıştır.

Deneylerde toplam 20 istemci kullanılmıştır. Eğitim süreci 30 iletişim turu boyunca yürütülmüştür. Her istemci her iletişim turunda bir yerel epoch eğitimi gerçekleştirmiştir. Yerel model güncellemeleri merkezi sunucuda FedAvg algoritması ile birleştirilmiştir. Veri heterojenliğini oluşturmak amacıyla Non-IID senaryolarında Dirichlet tabanlı veri bölüştürme yöntemi uygulanmıştır. Dirichlet dağılım katsayısı 0.3 olarak belirlenmiştir.

Deneylerde kullanılan hiperparametreler Tablo 1’de verilmiştir. Tüm istemci katılım senaryolarında aynı hiperparametreler korunmuş ve yalnızca istemci erişilebilirliği değiştirilmiştir. Böylece farklı senaryolar arasındaki karşılaştırmaların adil koşullar altında gerçekleştirilmesi amaçlanmıştır.

Tablo 1. *Deneysel kurulumda kullanılan hiperparametreler*

Parametre	Değer
Veri kümesi	Fashion-MNIST
İstemci sayısı	20
Toplulaştırma algoritması	FedAvg
İletişim turu	30
Yerel epoch	1
Mini-batch boyutu	64
Test batch boyutu	256
Öğrenme oranı	0.01
Optimizasyon algoritması	SGD
Momentum	0.9
Non-IID yöntemi	Dirichlet Bölünmesi
Dirichlet katsayısı (α)	0.3
İstemci kaybı başlangıcı	15. tur

İstemci Katılım Senaryoları

Çalışmada değerlendirilen istemci katılım senaryoları, deneysel iş akışının bir parçası olarak Şekil 1’de özetlenmiştir. Bu senaryoların federated öğrenme performansı üzerindeki etkisini inceleyebilmek amacıyla tüm deneylerde aynı veri kümesi, aynı CNN modeli, aynı FedAvg algoritması ve aynı eğitim parametreleri kullanılmıştır. Senaryolar arasındaki tek değişken her iletişim turuna katılan istemci kümesidir.

İlk senaryoda tam istemci katılımı uygulanmıştır. Bu senaryoda sistemde bulunan 20 istemcinin tamamı her iletişim turunda yerel eğitim gerçekleştirmiş ve model güncellemelerini merkezi sunucuya göndermiştir. Bu yapı diğer senaryolar için temel karşılaştırma senaryosu olarak kullanılmıştır.

İkinci senaryoda rastgele kısmi katılım uygulanmıştır. Her iletişim turunda istemcilerin yalnızca yarısı rastgele seçilerek eğitime dâhil edilmiştir. Aktif istemci kümesi her iletişim turunda yeniden belirlenmiştir.

Üçüncü senaryoda kalıcı istemci kaybı modellenmiştir. İlk 15 iletişim turunda tüm istemciler eğitime katılmıştır. On beşinci turdan itibaren belirlenen istemciler sistem dışına çıkarılmış ve deney sonuna kadar yeniden eğitime dâhil edilmemiştir.

Dördüncü senaryoda veri bağımlı istemci kaybı uygulanmıştır. Bu senaryoda sistemden çıkarılacak istemciler rastgele belirlenmemiştir. Yerel veri dağılımları incelenmiş ve belirli sınıfları daha yoğun içeren istemciler sistem dışına alınmıştır. Böylece veri dağılımındaki değişimin küresel model üzerindeki etkisi değerlendirilmiştir.

Her senaryo hem IID hem de Dirichlet tabanlı Non-IID veri dağılımı altında ayrı ayrı değerlendirilmiştir. Böylece istemci erişilebilirliği ile veri heterojenliğinin birlikte oluşturduğu etkinin model performansı üzerindeki etkisi karşılaştırmalı olarak analiz edilmiştir.

PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ

Çalışmada kullanılan performans değerlendirme ölçütleri Tablo 2’te özetlenmiştir. İstemci katılım senaryolarının federated öğrenme performansı üzerindeki etkisini değerlendirmek amacıyla hem model başarısını hem de eğitim sürecini yansıtan ölçütler birlikte kullanılmıştır. Model başarısı doğruluk (Accuracy) ve Makro F1 skoru ile değerlendirilmiştir. Doğruluk, modelin genel sınıflandırma başarısını göstermektedir. Makro F1 skoru ise tüm sınıfları eşit ağırlıkla değerlendirerek sınıflar arasındaki performans dengesinin analiz edilmesine olanak sağlamaktadır.

İstemci katılımının eğitim sürecine etkisini belirlemek amacıyla toplam istemci güncelleme sayısı ile tam istemci katılım senaryosuna göre elde edilen istemci güncelleme sayısındaki azalma hesaplanmıştır. Böylece farklı istemci katılım stratejilerinin sağladığı iletişim tasarrufu nicel olarak karşılaştırılmıştır.

Kalıcı istemci kaybı ve veri bağımlı istemci kaybı senaryolarında modelin dayanıklılığı da değerlendirilmiştir. Bu kapsamda istemci kaybı sonrasında oluşan performans düşüşü ile modelin önceki performans düzeyine yeniden ulaşması için gereken iletişim turu sayısı belirlenmiştir. Ayrıca eğitim süreci boyunca elde edilen doğruluk eğrileri incelenerek farklı senaryoların yakınsama davranışı ve eğitim kararlılığı analiz edilmiştir.

Tüm performans ölçütleri IID ve Dirichlet tabanlı Non-IID veri dağılımları altında ayrı ayrı hesaplanmıştır. Böylece istemci erişilebilirliği ile veri heterojenliğinin birlikte oluşturduğu etkinin model performansı üzerindeki etkisi karşılaştırmalı olarak değerlendirilmiştir.

Tablo 2. Çalışmada kullanılan performans değerlendirme ölçütleri

Ölçüt	Açıklama
Doğruluk (Accuracy)	Genel sınıflandırma başarısı
Makro F1 Skoru	Sınıf bazlı performans dengesi
Toplam İstemci Güncelleme Sayısı	Eğitim süresince gerçekleştirilen toplam istemci güncellemeleri
İstemci Güncelleme Sayısındaki Azalma	Tam istemci katılımına göre sağlanan iletişim tasarrufu
Performans Düşüşü	İstemci kaybı sonrasında oluşan doğruluk kaybı
Toparlanma Süresi	Önceki performans düzeyine ulaşmak için gereken iletişim turu
Yakınsama Kararlılığı	Son iletişim turlarındaki performans değişiminin değerlendirilmesi

DENEYSEL BULGULAR

Bu bölümde istemci katılım senaryolarının federated öğrenme performansı üzerindeki etkisi IID ve Dirichlet tabanlı Non-IID veri dağılımları altında karşılaştırmalı olarak değerlendirilmiştir. Deneysel sonuçlar sınıflandırma performansı, istemci güncelleme sayısındaki azalma, yakınsama davranışı ve istemci kaybına karşı modelin dayanıklılığı açısından analiz edilmiştir. Tüm deneylerde aynı CNN mimarisi, aynı FedAvg algoritması ve aynı eğitim parametreleri kullanılmıştır. Böylece istemci katılım senaryolarının farklı veri dağılımları altındaki etkisi adil deney koşulları altında karşılaştırılmıştır.

İstemci Katılım Senaryolarının Genel Performans Karşılaştırması

İstemci katılım senaryolarının sınıflandırma performansı üzerindeki etkisi IID ve Dirichlet tabanlı Non-IID veri dağılımları altında karşılaştırmalı olarak değerlendirilmiştir. Her senaryo için son iletişim turunda elde edilen doğruluk ve Makro F1 skoru Tablo 3'te sunulmuştur.

IID veri dağılımı altında tüm istemci katılım senaryolarının benzer sınıflandırma performansı sergilediği görülmektedir. Tam istemci katılımı senaryosu %88.54 doğruluk ve 0.8844 Makro F1 skoru ile en yüksek performansı elde etmiştir. Rastgele %50 katılım senaryosu %88.39 doğruluk ve 0.8825 Makro F1 skoru üretirken kalıcı istemci kaybı senaryosu %88.39 doğruluk ve 0.8819 Makro F1 skoru elde etmiştir. Veri bağımlı istemci kaybı senaryosu ise %88.44 doğruluk ve 0.8831 Makro F1 skoru ile tam istemci katılımına oldukça yakın sonuçlar vermiştir. Bu bulgular, IID veri dağılımında istemci katılımındaki azalmanın model performansını yalnızca sınırlı düzeyde etkilediğini göstermektedir.

Non-IID veri dağılımında tüm senaryolarda doğruluk ve Makro F1 değerlerinde beklenen düzeyde performans düşüşü gözlenmiştir. Tam istemci katılımı senaryosu %87.17 doğruluk ve 0.8723 Makro F1 skoru ile en yüksek performansı sağlamıştır. Rastgele %50 katılım senaryosu %86.17 doğruluk ve 0.8635 Makro F1 skoru elde ederken kalıcı istemci kaybı senaryosu %86.55 doğruluk ve 0.8641 Makro F1 skoru üretmiştir. Veri bağımlı istemci kaybı senaryosu ise %86.22 doğruluk ve 0.8622 Makro F1 skoru ile benzer bir performans göstermiştir. Bu sonuçlar, veri heterojenliğinin istemci erişilebilirliği ile birlikte küresel model performansını daha belirgin biçimde etkilediğini göstermektedir.

Genel olarak değerlendirildiğinde IID veri dağılımında rastgele %50 istemci katılımı tam istemci katılımına göre yalnızca %0.15 doğruluk kaybı oluşturmalarına rağmen istemci katılım yükünü önemli ölçüde azaltabilmektedir. Buna karşılık Non-IID veri dağılımında istemci katılımındaki azalmanın etkisi daha belirgin olmakla birlikte tüm senaryolar %86'nın üzerinde doğruluk değerine ulaşarak kararlı bir öğrenme performansı sergilemiştir.

Tablo 2. Çalışmada kullanılan performans değerlendirme ölçütleri

Veri	Senaryo	Accuracy	Makro F1
IID	Tam Katılım	0.8854	0.8844
	Rastgele %50	0.8839	0.8825
	Kalıcı Kayıp	0.8839	0.8819
	Veri Bağımlı	0.8844	0.8831
Non-IID	Tam Katılım	0.8717	0.8723
	Rastgele %50	0.8617	0.8635
	Kalıcı Kayıp	0.8655	0.8641
	Veri Bağımlı	0.8622	0.8622


Öğrenme ve Yakınsama Davranışının Değerlendirilmesi

İstemci katılım senaryolarının eğitim süreci üzerindeki etkisini incelemek amacıyla her iletişim turunda elde edilen doğruluk değerleri analiz edilmiştir. IID ve Dirichlet tabanlı Non-IID veri dağılımlarına ait doğruluk eğrileri Şekil 2’de gösterilmektedir. Şekilde yer alan kesikli dikey çizgi, kalıcı istemci kaybı ve veri bağımlı istemci kaybı senaryolarında istemci kaybının başladığı 15. iletişim turunu göstermektedir.

Şekil 2 incelendiğinde tüm istemci katılım senaryolarında doğruluk değerlerinin iletişim turları ilerledikçe düzenli biçimde arttığı görülmektedir. IID veri dağılımı altında senaryoların tamamı benzer yakınsama davranışı sergilemiş ve son iletişim turlarında birbirine oldukça yakın doğruluk değerlerine ulaşmıştır. Rastgele %50 katılım senaryosu ilk iletişim turlarında daha hızlı öğrenme eğilimi göstermiş olsa da eğitim sürecinin sonunda diğer senaryolar ile benzer performansa ulaşmıştır.

Non-IID veri dağılımında ise veri heterojenliğinin etkisi nedeniyle doğruluk eğrilerinde daha belirgin dalgalanmalar gözlenmiştir. Özellikle rastgele %50 katılım senaryosunda ilk iletişim turlarında performans değişkenliği diğer senaryolara göre daha yüksek gerçekleşmiştir. Buna karşın tüm senaryolar eğitim sürecinin ilerleyen iletişim turlarında kararlı bir yakınsama davranışı göstermiştir.

Genel olarak değerlendirildiğinde istemci katılımındaki azalmanın özellikle IID veri dağılımında yakınsama davranışını önemli ölçüde etkilemediği görülmektedir. Buna karşılık Non-IID veri dağılımında istemci erişilebilirliği model performansı üzerinde daha belirgin bir etki oluşturmuş olsa da küresel model tüm senaryolarda yüksek doğruluk düzeyine ulaşmayı başarmıştır.



Şekil 2. IID ve Non-IID veri dağılımlarında istemci katılım senaryolarına ait doğruluk eğrileri


İletişim Verimliliğinin Değerlendirilmesi

İstemci Federated öğrenme sistemlerinde model başarısının yanında iletişim verimliliği de önemli bir performans ölçütüdür. Bu çalışmada iletişim verimliliği tam istemci katılım senaryosuna göre elde edilen istemci güncelleme sayısındaki azalma üzerinden değerlendirilmiştir. IID ve Dirichlet tabanlı Non-IID veri dağılımlarına ait sonuçlar Şekil 3'te gösterilmektedir.

Şekil 3 incelendiğinde rastgele %50 katılım senaryosunun hem IID hem de Non-IID veri dağılımlarında istemci güncelleme sayısını yaklaşık %50 oranında azalttığı görülmektedir. Buna karşın Tablo 3'te görüldüğü gibi doğruluk ve Makro F1 skorlarında yalnızca sınırlı düzeyde bir değişim meydana gelmiştir. Bu sonuç, her iletişim turunda tüm istemcilerin eğitime katılmasının yüksek sınıflandırma başarısı için her zaman gerekli olmadığını göstermektedir. Kalıcı istemci kaybı ve veri bağımlı istemci kaybı senaryolarında ise istemci güncelleme sayısındaki azalma yaklaşık %16 düzeyinde gerçekleşmiştir. Buna rağmen her iki senaryoda da model eğitim süreci sonunda tam istemci katılımına oldukça yakın performans değerlerine ulaşmıştır. Bu bulgu, federated öğrenme sistemlerinin belirli düzeyde istemci erişilemezliğine karşı dayanıklı olduğunu göstermektedir.

Genel olarak değerlendirildiğinde istemci katılım oranının azaltılması iletişim yükünü önemli ölçüde düşürürken model başarısını büyük ölçüde koruyabilmektedir. Özellikle rastgele %50

katılım senaryosu, iletişim verimliliği ile sınıflandırma performansı arasında en dengeli çözümü sunmuştur.



Şekil 3. İstemci katılım senaryolarına göre istemci güncelleme sayısındaki azalma.

SONUÇ

Deneyisel bulgular birlikte değerlendirildiğinde istemci katılım oranının federated öğrenme performansını etkilediği ancak bu etkinin veri dağılımına bağlı olarak değiştiği görülmektedir. IID veri dağılımında rastgele %50 istemci katılımı tam istemci katılımına oldukça yakın doğruluk ve Makro F1 değerleri üretmiştir. Bu durum istemci sayısındaki önemli azalmaya rağmen küresel modelin öğrenme yeteneğini büyük ölçüde koruyabildiğini göstermektedir.

Non-IID veri dağılımında ise istemci katılımındaki azalmanın etkisi daha belirgin hale gelmiştir. Yerel veri dağılımlarındaki farklılıklar nedeniyle özellikle rastgele kısmi katılım senaryosunda performans kaybı diğer senaryolara göre daha yüksek gerçekleşmiştir. Buna rağmen tüm istemci katılım senaryoları eğitim sürecinin sonunda kararlı bir yakınsama davranışı sergilemiş ve yüksek sınıflandırma performansına ulaşmıştır.

İletişim verimliliği açısından değerlendirildiğinde rastgele %50 katılım senaryosu istemci güncelleme sayısını yarıya indirirken model başarısında yalnızca sınırlı düzeyde bir azalma oluşturmuştur. Kalıcı istemci kaybı ve veri bağımlı istemci kaybı senaryoları ise daha düşük iletişim kazancı sağlamasına rağmen tam istemci katılımına oldukça yakın performans değerleri elde etmiştir.

Elde edilen bulgular gerçek federated öğrenme uygulamalarında her iletişim turunda tüm istemcilerin aktif olmasının zorunlu olmadığını göstermektedir. Özellikle veri heterojenliğinin

düşük olduğu ortamlarda uygun istemci katılım stratejileri kullanılarak iletişim yükü önemli ölçüde azaltılabilirken model başarısı büyük ölçüde korunabilmektedir.

REFERANSLAR

- AbdulRahman, Sawsan, Hanine Tout, Azzam Mourad, and Chamseddine Talhi. 2021. "FedMCCS: Multicriteria Client Selection Model for Optimal IoT Federated Learning." *IEEE Internet of Things Journal* 8 (6): 4723–35. <https://doi.org/10.1109/JIOT.2020.3028742>.
- Antunes, Rodolfo Stoffel, Cristiano André da Costa, Achim Küderle, Imrana Abdullahi Yari, and Bjoern M. Eskofier. 2022. "Federated Learning for Healthcare: Systematic Review and Architecture Proposal." *ACM Transactions on Intelligent Systems and Technology* 13 (4): 1–23. <https://doi.org/10.1145/3501813>.
- Chai, Zheng, Ahsan Ali, Syed Zawad, et al. 2020. "TiFL: A Tier-Based Federated Learning System." *Proceedings of the 29th International Symposium on High-Performance Parallel and Distributed Computing* (New York, NY, USA), 125–36. <https://doi.org/10.1145/3369583.3392686>.
- Kairouz, Peter, H. Brendan McMahan, Brendan Avent, et al. 2021. "Advances and Open Problems in Federated Learning." *Foundations and Trends in Machine Learning* 14 (1–2): 1–210. <https://doi.org/10.1561/22000000083>.
- Lai, Fan, Xiangfeng Zhu, Harsha V. Madhyastha, and Mosharaf Chowdhury. 2021. "Oort: Efficient Federated Learning via Guided Participant Selection." *15th USENIX Symposium on Operating Systems Design and Implementation (OSDI 21)*, 19–35.
- Li, Tian, Anit Kumar Sahu, Manzil Zaheer, Maziar Sanjabi, Ameet Talwalkar, and Virginia Smith. 2020. "Federated Optimization in Heterogeneous Networks." *Proceedings of Machine Learning and Systems* 2: 429–50.
- Li, Xiang, Kaixuan Huang, Wenhao Yang, Shusen Wang, and Zhihua Zhang. 2020. "On the Convergence of FedAvg on Non-IID Data." *Proceedings of the 8th International Conference on Learning Representations*.
- McMahan, H. Brendan, Eider Moore, Daniel Ramage, Seth Hampson, and Blaise Agüera y Arcas. 2017. "Communication-Efficient Learning of Deep Networks from Decentralized Data." *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*, Proceedings of machine learning research, vol. 54: 1273–82.
- Mills, Jenna, Jia Hu, and Geyong Min. 2020. "Communication-Efficient Federated Learning for Wireless Edge Intelligence in IoT." *IEEE Internet of Things Journal* 7 (7): 5986–94. <https://doi.org/10.1109/JIOT.2019.2956615>.
- Nishio, Takayuki, and Ryo Yonetani. 2019. "Client Selection for Federated Learning with Heterogeneous Resources in Mobile Edge." *2019 IEEE International Conference on Communications (ICC)*, 1–7. <https://doi.org/10.1109/ICC.2019.8761315>.
- Reddi, Sashank J., Zachary Charles, Manzil Zaheer, et al. 2021. "Adaptive Federated Optimization." *Proceedings of the 9th International Conference on Learning Representations*.
- Reisizadeh, Amirhossein, Aryan Mokhtari, Hamed Hassani, Ali Jadbabaie, and Ramtin Pedarsani. 2020. "FedPAQ: A Communication-Efficient Federated Learning Method with Periodic Averaging and Quantization." *Proceedings of the Twenty Third International Conference on Artificial Intelligence and Statistics*, Proceedings of machine learning research, vol. 108: 2021–31.

- Rieke, Nicola, Jonny Hancox, Wenqi Li, et al. 2020. "The Future of Digital Health with Federated Learning." *Npj Digital Medicine* 3 (1): 119. <https://doi.org/10.1038/s41746-020-00323-1>.
- Rothchild, Daniel, Ashwinee Panda, Enayat Ullah, et al. 2020. "FetchSGD: Communication-Efficient Federated Learning with Sketching." *Proceedings of the 37th International Conference on Machine Learning*, Proceedings of machine learning research, vol. 119: 8253–65.
- Sheller, Micah J., Brandon Edwards, G. Anthony Reina, et al. 2020. "Federated Learning in Medicine: Facilitating Multi-Institutional Collaborations Without Sharing Patient Data." *Scientific Reports* 10 (1): 12598. <https://doi.org/10.1038/s41598-020-69250-1>.
- Shi, Fang, Chunchao Hu, Weiwei Lin, Lisheng Fan, Tiansheng Huang, and Wentai Wu. 2022. "VFedCS: Optimizing Client Selection for Volatile Federated Learning." *IEEE Internet of Things Journal* 9 (24): 24995–5010. <https://doi.org/10.1109/JIOT.2022.3195073>.
- Wang, Jianyu, Qinghua Liu, Hao Liang, Gauri Joshi, and H. Vincent Poor. 2020. "Tackling the Objective Inconsistency Problem in Heterogeneous Federated Optimization." *Advances in Neural Information Processing Systems* 33: 7611–23.
- Wehbi, Osama, Sarhad Arisdakessian, Omar Abdel Wahab, et al. 2023. "FedMint: Intelligent Bilateral Client Selection in Federated Learning with Newcomer IoT Devices." *IEEE Internet of Things Journal* 10 (23): 20884–98. <https://doi.org/10.1109/JIOT.2023.3283855>.
- Zalando Research. 2017. *Fashion-MNIST Dataset*. <https://github.com/zalando-research/fashion-mnist>.

SMART HUKUMAT INTEGRATING AI-DRIVEN GOVERNANCE AND PREDICTIVE ANALYTICS INTO FEDERAL ADMINISTRATION

Muhammad FAISAL

Joint Director (AICU) at Ministry of IT & Telecommunication, Pakistan
ORCID: 0000-0002-5797-766X

ABSTRACT

Public sector administrative systems in developing nations often suffer from operational inefficiencies, fragmented data silos, and reactive decision-making frameworks. Under Component 5 of the NAIEDP, the \$30 million "Smart Hukumat" initiative implemented by the National IT Board (NITB) aims to embed intelligent analytical systems, predictive modeling, and automated workflows across federal ministries. This paper evaluates the structural transformation, legal prerequisites, and operational impact of integrating artificial intelligence into public administrative governance in Pakistan. Through a qualitative policy review and simulation of administrative workflow automation, the study assesses key priority deployment areas, including automated tax intelligence, predictive agricultural yield modeling, real-time healthcare monitoring, and intelligent resource allocation. The paper demonstrates that implementing interoperable, cloud-native digital public infrastructure integrated with predictive analytics can reduce bureaucratic processing delays by 55% while enhancing data transparency and evidence-based policy formulation. However, the study identifies significant implementation hurdles, such as legacy data fragmentation, organizational resistance to digital adoption, civil service skill deficits, and public sector data security risks. To address these challenges, the research outlines a risk-proportionate AI governance model emphasizing algorithmic auditability, human-in-the-loop decision protocols, and adherence to draft national data governance standards. The paper concludes with actionable directives for scaling public sector digital transformation efficiently.

Keywords: Smart Governance, Digital Public Infrastructure, Public Sector Automation, Smart Hukumat, Algorithmic Transparency, Predictive Analytics, E-Governance Policy.

AKILLI KAMPÜS AĞLARI İÇİN AÇIKLANABİLİR TOPLULUK TABANLI SALDIRI TESPİTİ EXPLAINABLE ENSEMBLE INTRUSION DETECTION FOR SMART CAMPUS NETWORKS

Abdalhamid ALBEIK¹

¹Karabük University, Department of Computer Engineering, Karabük, Türkiye
ORCID ID: 0009-0006-9885-3731

Lecturer Elif YILDIRIM¹

¹Karabük University, Department of Computer Engineering, Karabük, Türkiye
ORCID ID: 0000-0001-6336-6390

Assoc. Prof. Dr. İsa AVCI²

¹Karabük University, Department of Computer Engineering, Karabük, Türkiye
ORCID ID: 0000-0001-7032-8018

ÖZET

Akıllı kampüs ağlarında saldırı tespiti, yüksek genel doğruluğun yanında az görülen saldırıların tanınmasını ve model kararlarının incelenebilmesini gerektirir. Bu çalışma, kampüs güvenliğine yönelik bir aday çözüm olarak, özellik seçimini ağırlıklı oylama ve SHAP açıklamalarıyla birleştiren ağaç tabanlı bir yaklaşımı değerlendirir. Deneyler, gerçek bir kampüs kurulumu yerine CICIDS2017 veri kümesinde yürütülmüştür. Geçersiz ve yinelenen kayıtların temizlenmesinden sonra kalan 2.520.798 akış, sınıf oranları korunarak eğitim, doğrulama ve test kümelerine ayrılmıştır. Özellik adayları eğitim verisinden elde edilmiş; özellik alt kümesi, sınıf dengesizliği stratejisi ve topluluk ağırlıkları doğrulama kümesinde seçilmiştir. Hibrit sıralama, kullanılabilir 65 özelliği 15'e indirmiştir. Extra Trees, Random Forest ve Decision Tree olasılıkları sırasıyla 0,4, 0,5 ve 0,1 ağırlıklarıyla birleştirilmiştir. Son model, eğitim ve doğrulama verileriyle yeniden eğitildikten sonra ayrılmış test kümesinde değerlendirilmiştir. Test doğruluğu %99,8305, makro F1 değeri 0,9095 ve önceden belirlenen altı nadir saldırı sınıfının ortalama duyarlılığı 0,7376 bulunmuştur. Aynı özelliklerle kullanılan Extra Trees modelinde bu son iki değer 0,8795 ve 0,6449'dur. Bununla birlikte, XSS sınıfının F1 değeri 0,3913'te kalmış; Heartbleed sınıfı testte yalnızca bir örnekle temsil edilmiştir. Son yeniden eğitimden önce, doğrulama akışları üzerinde hesaplanan SHAP değerleri paket uzunluğu ve başlangıç pencere boyutu değişkenlerini öne çıkarmıştır. Beş yeniden örnekleme üzerinden ortalama ilk on özellik örtüşmesi 0,8909 olmuştur. Sonuçlar, bu deney düzeninde azınlık sınıfları için bir kazanıma işaret etmektedir. Ancak hesaplama maliyeti artmış, zaman temelli genelleme ve gerçek kampüs başarımı bu deneylerle gösterilmemiştir.

Anahtar Kelimeler: Akıllı kampüs, saldırı tespiti, özellik seçimi, topluluk öğrenmesi, SHAP.

ABSTRACT

Intrusion detection in smart campus networks requires more than high overall accuracy: infrequent attacks must remain visible, and model decisions must be open to inspection. This

study evaluates a tree-based approach that combines feature selection, weighted voting and SHAP explanations as a candidate for campus network security. Experiments use CICIDS2017 rather than traffic collected from an operational campus. After invalid and duplicate records were removed, 2,520,798 flows were partitioned into stratified training, validation and test sets. Feature candidates were derived from training data, while the feature subset, imbalance strategy and voting weights were selected on validation data. Hybrid ranking reduced 65 usable features to 15. The ensemble combined Extra Trees, Random Forest and Decision Tree probabilities with weights of 0.4, 0.5 and 0.1, respectively. Following a training-plus-validation refit, test accuracy reached 99.8305%, macro F1 was 0.9095, and mean recall across six predefined rare attack classes was 0.7376. Extra Trees using the same features obtained macro F1 of 0.8795 and rare-class recall of 0.6449. These aggregate gains were uneven: XSS achieved an F1 score of 0.3913, while Heartbleed had only one test observation. SHAP analysis of validation flows, performed before the final refit, emphasized packet-length and initial-window features. Five bootstrap resamples produced a mean top-ten feature-set overlap of 0.8909. The findings support a minority-class benefit under the evaluated protocol, but at increased computational cost. They do not establish temporal generalization or effectiveness in a deployed campus network.

Keywords: Smart campus, intrusion detection, feature selection, ensemble learning, SHAP.

INTRODUCTION

Smart campus services connect educational platforms, administrative systems and diverse networked devices. Their security requirements therefore extend beyond maintaining connectivity. Work on AI-assisted campus management describes the growing role of shared wireless infrastructure (Koukaras et al., 2025), while campus intrusion detection and network detection and response studies address the monitoring of that infrastructure (Chen, 2024; Mustafa et al., 2026). For these settings, a useful detector must identify attacks without concealing weak minority-class performance behind a high overall accuracy. It should also provide evidence that an analyst can inspect.

Feature selection offers one way to reduce the cost and complexity of flow-based detection. Empirical comparisons show that its value depends on both the selector and the classifier (Yıldırım et al., 2025; Zouhri et al., 2024). Hybrid approaches combine complementary criteria: information gain and Random Forest importance have been integrated with recursive elimination (Yin et al., 2023), while rank aggregation has been used to obtain smaller traffic representations (Krupski et al., 2024). Correlation-based and embedded selection have also been combined with ensemble learning (Nassreddine et al., 2025). These studies motivate testing a compact subset, but do not establish that one feature ranking will work equally well across datasets.

Prior work has examined stacking with hybrid feature selection (Badiger & Shyam, 2025), weighted voting between boosted learners (Melendrez et al., 2025), and minority-class highlighting (Oh et al., 2025) as approaches to ensemble intrusion detection. Explainable

ensembles have also incorporated adaptive model combinations and SHAP-guided selection (Ahmed, Jiangbin, Almogren, Khan, et al., 2024; Ahmed, Jiangbin, Almogren, Sadiq, et al., 2024). In parallel, campus-focused explainable detection (Yan, 2025) and tree-based SHAP analysis (Le et al., 2022) have made the relationship between a prediction and its input features more explicit. Comparisons of SHAP and LIME nevertheless show why an explanation must be interpreted in the context of the fitted model and explanation method (Hermosilla et al., 2025).

This study asks whether a compact, validation-selected tree ensemble can improve macro F1 and rare-attack recall relative to a strong single-tree-ensemble baseline. CICIDS2017 provides the experimental setting; no campus deployment is claimed. The evaluation follows recent work emphasizing explicit dataset and model comparisons (Mondragon et al., 2025). Feature selection, imbalance handling and voting weights are examined within one split protocol, followed by a held-out test and a separate analysis of feature-attribution stability. The aim is to establish a bounded benchmark result and identify the conditions that would still need testing before campus use.

MATERIAL AND METHODS

Data preparation and evaluation design.

The CICIDS2017 input comprised 2,830,743 flows, 78 predictors and 15 traffic classes. Cleaning removed 2,867 invalid records and then 307,078 duplicate records, leaving 2,520,798 flows. Constant and duplicate columns were removed, yielding 65 predictors. A stratified random split with seed 42 assigned 1,764,558 flows to training and 378,120 each to validation and testing (70:15:15). Partition indices did not overlap. Feature scoring and model fitting used training data; validation performance determined the modeling choices. Test scores were not used for selection. The frozen configuration was refitted on training plus validation data for the final test. This is a random-flow protocol, not a chronological or cross-dataset evaluation.

The validation set was consulted repeatedly during development, so its scores describe performance within the selection process. The final test addresses a different question: how the fixed configuration performs on flows that did not guide those choices. Refitting used the combined training and validation partitions but retained the selected feature identities, model settings and voting weights. Consequently, the validation-to-test difference reflects both a change in evaluation observations and a change in fitted models. It cannot be interpreted as the effect of the data partition alone, nor does this random split measure performance on a later period of traffic.

Feature selection and model comparison.

Absolute correlation above 0.95 reduced the candidate set from 65 to 47 features. Mutual information then identified 30 candidates. XGBoost gain and Random Forest TreeSHAP rankings were averaged within this candidate pool to form the hybrid ranking. The training

SHAP sample contained 2,176 flows: a nominal target of 2,000 was enlarged by rare-class minimum allocations. The notebook evaluated 22 subset configurations, including hybrid subsets of 10, 15, 20 and 30 features. Representative mutual-information, gain, SHAP and hybrid subsets were compared with all 65 predictors. Decision Tree (DT), Random Forest (RF), Extra Trees (ET), XGBoost and LightGBM were subsequently compared on five representative subsets. No feature rank was derived from validation or test labels.

The retained variables cover several aspects of a flow. Packet size and volume are represented by Fwd Packet Length Max, Bwd Packet Length Max, Max Packet Length, Packet Length Mean and Total Length of Fwd Packets. Flow Bytes/s, Flow Packets/s and Bwd Packets/s describe rates; Flow IAT Mean and Flow IAT Std describe inter-arrival timing. Fwd Header Length and Bwd Header Length retain header information, while Init_Win_bytes_forward and Init_Win_bytes_backward record initial window values. Destination Port completes the subset. This grouping describes the inputs rather than their importance. The training-derived ranking determined subset membership; the separate validation-based attribution ordering reported in Results was used to explain the fitted system, not to select these features.

Imbalance handling and ensemble selection.

The original training distribution was compared with balanced class weights, limited majority undersampling and random oversampling capped at 5,000 observations per minority class. The original distribution was retained on validation performance. This differs from pipelines that introduce synthetic sampling and learned representations (Hooshmand et al., 2024); synthetic oversampling was not used here. Six-candidate, three-fold searches on a protected training subsample targeted at approximately 180,000 flows did not improve full-validation performance over the default ET and RF configurations. The final tree ensembles used 100 estimators, seed 42 and four worker threads.

Soft voting combined class probabilities with weights of 0.4 for ET, 0.5 for RF and 0.1 for DT. Weights were searched on the validation set in increments of 0.1. An ensemble was accepted only if macro F1 improved by at least 0.001 over the best single model and rare-class recall declined by no more than 0.005. Equal-weight voting and three-fold out-of-fold stacking with a balanced logistic-regression meta-learner were also evaluated. The selected voting configuration and its 15 features were fixed before the final refit.

Performance and explanation measures.

Macro F1 assigns equal weight to the 15 class-specific F1 scores. Rare-class recall is the unweighted mean recall for Bot, Heartbleed, Infiltration, Web Attack–Brute Force, Web Attack–SQL Injection and Web Attack–XSS. Accuracy, per-class support, execution time and serialized model size provide complementary views. Five training seeds (42, 52, 62, 72 and 82), evaluated against the fixed validation set, were used for a paired comparison of the selected ET feature subset and all 65 predictors; these are not five independent test splits.

SHAP assigns additive feature contributions to model predictions (Lundberg & Lee, 2017). Following global and local IDS explanation work (Arreche et al., 2024), the notebook

analyzed 587 validation flows with class-protected sampling. These explanations concern training-fitted models before the final training-plus-validation refit. For each feature, signed SHAP values from ET, RF and DT were first combined using the voting weights; absolute values were then averaged over observations and classes. Five bootstrap resamples of these already computed explanation tensors yielded ten pairwise comparisons of top-ten feature sets and ranks. The procedure measures resampling stability, not stability after retraining. The saved execution used Windows 11 and Python 3.13.13 on a workstation reporting 12 logical CPUs.

RESULTS

Hybrid selection retained 15 of the 65 usable predictors, a 76.9% reduction. Table 1 reports representative feature-selection results under the RF screening model. The best hybrid subset exceeded the all-feature reference in both macro F1 and rare-class recall. These are validation comparisons within the search, not additional test results.

Table 1. Representative feature subsets evaluated with Random Forest on validation data.

Feature subset	Features	Macro F1	Rare-class recall
All usable predictors	65	0.8878	0.7009
Mutual information	20	0.8839	0.7028
XGBoost gain	30	0.9137	0.7508
RF SHAP ranking	30	0.8959	0.7094
Hybrid ranking	15	0.9154	0.7642

The choice of 15 features was supported by the comparison of nested hybrid subsets, not by a preset requirement to retain that number. With the same Random Forest screening protocol, the top-10, top-20 and top-30 subsets obtained validation macro F1 scores of 0.8334, 0.8927 and 0.8652, respectively. The top-15 score of 0.9154 was the highest among all 22 screened configurations. Thus, retaining additional ranked variables did not improve this screening result. The subsequent model comparison also placed Extra Trees with this subset first by validation macro F1. These findings justify the selected configuration within the evaluated search; they do not establish a universally optimal subset size or significant differences between every pair of candidates.

ET with the selected 15 features subsequently achieved validation macro F1 of 0.9265 and rare-class recall of 0.8107. Weighted voting increased these values to 0.9286 and 0.8204. Equal-weight voting reached macro F1 of 0.9128. Stacking increased macro recall to 0.9408 but lowered macro F1 to 0.7759, so it was not retained. Removing Destination Port from the selected ET subset reduced validation macro F1 to 0.8739 and rare-class recall to 0.6648.

Figure 1 compares all 25 model–feature-set combinations on validation data. The hybrid subset gave the highest macro F1 for ET and RF, although its benefit was not consistent across all five classifiers.




Figure 1. Validation macro F1 for five classifiers and five feature sets. Labels indicate feature counts; MI denotes mutual information and XGB denotes XGBoost gain ranking. Values are rounded to three decimals. The color scale covers the observed score range.

After the final refit, weighted voting improved test macro F1 by 0.0301 and rare-class recall by 0.0926 relative to ET (Table 2). Accuracy changed by only 0.0082 percentage points. The ensemble's macro F1 declined from 0.9286 on validation to 0.9095 on test.

Table 2. Final test performance after training-plus-validation refitting. Both models use 15 features.

Model	Accuracy (%)	Macro precision	Macro recall	Macro F1	Rare-class recall
Extra Trees	99.8223	0.9302	0.8559	0.8795	0.6449
Weighted voting	99.8305	0.9319	0.8930	0.9095	0.7376

The rare-class results expose the limits of the aggregate improvement (Table 3; Figure 2). Bot and Web Attack–Brute Force achieved F1 scores of 0.8256 and 0.7483. XSS detection remained weak (recall = 0.3673; F1 = 0.3913). The perfect Heartbleed result was based on a single test flow. The Infiltration and SQL Injection scores likewise rested on only six and three observations.

Table 3. Rare attack classes on the final test set, weighted voting. Support is the number of test flows.

Attack class	Precision	Recall	F1	Support
Bot	0.8593	0.7945	0.8256	292
Heartbleed	1.0000	1.0000	1.0000	1
Infiltration	1.0000	0.8333	0.9091	6
Web Attack–Brute Force	0.7336	0.7636	0.7483	220
Web Attack–SQL Injection	1.0000	0.6667	0.8000	3
Web Attack–XSS	0.4186	0.3673	0.3913	98




Figure 2. Row-normalized confusion matrix for weighted voting on the final test set after refitting. Rows denote true classes and columns predicted classes; each row sums to one. Colors represent proportions, not absolute counts.

For XSS, the support and recall in Table 3 correspond to 36 correctly classified flows out of 98, leaving 62 assigned to other classes. This count is an arithmetic interpretation of the recorded test result, not an additional experiment. Precision of 0.4186 also indicates that fewer than half of the flows predicted as XSS belonged to that class. The detector therefore made errors both when identifying true XSS flows and when assigning the XSS label. Figure 2 shows the error destinations, including confusion between XSS and Web Attack–Brute Force. Each row is normalized by its true-class support, so diagonal intensity represents recall rather than sample count. The small supports in Table 3 remain important when interpreting the darker cells; this plot does not establish whether an omitted feature would resolve the errors.

The voting ensemble required 310.46 s to fit and 5.30 s to predict the test set, compared with 113.19 s and 2.68 s for ET. Serialized size increased from 498.81 to 629.85 MiB. Voting throughput was approximately 71,365 preprocessed flows/s in the recorded batch run; this does not include live traffic capture or feature extraction. Across the five training seeds, ET

with 15 features obtained mean validation macro F1 of 0.9260 (standard deviation 0.0012), versus 0.8650 with 65 features. The paired Wilcoxon result was $p = 0.0625$ and therefore did not establish significance at 0.05. A separate binary ET experiment obtained test F1 of 0.9959 and a false-positive rate of 0.000786 at threshold 0.5.

The pre-refit explanation analysis assigned the largest aggregate contribution to Fwd Packet Length Max, followed by Init_Win_bytes_backward and Max Packet Length (Figure 3). Across bootstrap comparisons, mean Jaccard overlap for the top ten features was 0.8909 and mean Spearman rank correlation was 0.9636. These values describe repeatability within the explanation sample; they do not demonstrate that the same features would remain important under different network conditions.




Figure 3. All 15 selected features ranked by weighted SHAP contribution. Explanations use training-fitted models and 587 validation flows, before the final refit.

DISCUSSION

The main benefit of the selected ensemble is visible in class-balanced measures, not overall accuracy. A 0.0301 increase in test macro F1 accompanied a 0.0926 increase in mean rare-class recall, while accuracy was almost unchanged. This supports the attention given to minority classes in dedicated ensemble designs (Oh et al., 2025). It also shows why the binary result is insufficient on its own: combining all attacks into one class conceals the weak XSS result. The added prediction time and model size mean that the voting gain must be weighed against the available deployment resources.

The rare-class average should also be read together with the individual supports in Table 3. Because it gives equal weight to each of six class recalls, Heartbleed contributes as much to that average as Bot despite having only one test flow rather than 292. As an illustration of

sensitivity, misclassifying that single Heartbleed flow would change its recall from one to zero and reduce the six-class average by about 0.1667; this is a hypothetical calculation, not an observed alternative result. The small Infiltration and SQL Injection samples likewise provide limited evidence about future traffic. Broader claims require additional independent attack examples and an examination of the underlying errors before attributing the remaining failures to a specific modeling choice.

Compactness and within-dataset discrimination should not be confused with transferability. Destination Port was useful in this random-split experiment, but its removal may behave differently when service assignments change. Cross-dataset work on SHAP-guided selection examines this problem directly (Kılıç & Şengül, 2026), while broader studies examine temporal and semantic generalization (Elangovan et al., 2026). Although exact duplicate rows were removed, related flows can still occur across random partitions. The single benchmark, fixed validation set and very small supports for several attacks limit the conclusions. The five-seed result suggests a consistent feature-subset advantage within that validation setting, but its nonsignificant paired test does not justify a stronger statistical claim.

The explanation results are similarly bounded. They identify which flow variables influenced the training-fitted ensemble and how consistently those variables ranked under resampling. They neither explain the final refitted models directly nor establish a causal mechanism. Causal feature-selection research addresses a different objective (Gao et al., 2025). Likewise, alert prioritization and analyst-facing graph explanations (Malach et al., 2025) require operational and user evaluation beyond a feature-importance plot. No analyst study was performed here. Probability calibration is another unresolved issue: uncertainty calibration has been combined with explainable intrusion detection (Adabara et al., 2025), whereas the present voting probabilities were not calibrated.

Further evaluation should begin with chronological partitions and traffic from an independent campus, including collection and feature-extraction costs. Federated learning under non-identical local distributions (Alimov & Shin, 2025), continual adaptation to drift (Xu et al., 2026), and open-set treatment of unfamiliar traffic (Souza et al., 2025) address deployment conditions that this closed-set batch experiment does not cover. Within its tested scope, the study finds that a 15-feature weighted ensemble improves macro F1 and rare-class recall over ET, with inspectable pre-refit feature attributions. Its value is a measured benchmark trade-off, not evidence that an operational campus IDS has already been validated.

REFERENCES

- Adabara, I., Sadiq, B. O., Shuaibu, A. N., Danjuma, Y. I., Maninti, V., & Joe, M. (2025). Toward trustworthy cyber defense: A cognitive intrusion detection system with explainability and probabilistic uncertainty calibration. *KIU Journal of Science, Engineering and Technology*, 4(2), 160–172. <https://doi.org/10.59568/KJSET-2025-4-2-16>

- Ahmed, U., Jiangbin, Z., Almogren, A., Khan, S., Sadiq, M. T., Altameem, A., & Rehman, A. U. (2024). Explainable AI-based innovative hybrid ensemble model for intrusion detection. *Journal of Cloud Computing*, 13, Article 150. <https://doi.org/10.1186/s13677-024-00712-x>
- Ahmed, U., Jiangbin, Z., Almogren, A., Sadiq, M., Rehman, A. U., Sadiq, M. T., & Choi, J. (2024). Hybrid bagging and boosting with SHAP based feature selection for enhanced predictive modeling in intrusion detection systems. *Scientific Reports*, 14, Article 30532. <https://doi.org/10.1038/s41598-024-81151-1>
- Alimov, A. A., & Shin, J. S. (2025). SAFE-IDS: A privacy-preserving framework for overcoming non-IID challenges in federated intrusion detection. *Computers & Security*, 155, Article 104492. <https://doi.org/10.1016/j.cose.2025.104492>
- Arreche, O., Guntur, T., & Abdallah, M. (2024). XAI-IDS: Toward proposing an explainable artificial intelligence framework for enhancing network intrusion detection systems. *Applied Sciences*, 14(10), Article 4170. <https://doi.org/10.3390/app14104170>
- Badiger, V. S., & Shyam, G. K. (2025). A multiclass network intrusion detection system using stacking ensemble technique with hybrid feature selection. *Journal of Advances in Information Technology*, 16(3), 342–356. <https://doi.org/10.12720/jait.16.3.342-356>
- Chen, Z. (2024). Campus network security intrusion detection based on feature segmentation and deep learning. *Journal of Cyber Security and Mobility*, 13(4), 775–802. <https://doi.org/10.13052/jcsm2245-1439.1349>
- Elangovan, R., Parthasarathy, D. D., Jawahar, M., Kaliyaperumal, P., Balusamy, B., Yogarayan, S., & Venkatesan, V. (2026). Cross-dataset temporal and semantic generalization of intrusion detection models for the future Internet. *Future Internet*, 18(4), Article 194. <https://doi.org/10.3390/fi18040194>
- Gao, Y., Yang, L., Zhu, R., Wu, Y., Yang, F., & Cao, Y. (2025). IR-IDS: A network intrusion detection method based on causal feature selection and explainable model optimization. *Computers & Security*, 155, Article 104496. <https://doi.org/10.1016/j.cose.2025.104496>
- Hermosilla, P., Berríos, S., & Allende-Cid, H. (2025). Explainable AI for forensic analysis: A comparative study of SHAP and LIME in intrusion detection models. *Applied Sciences*, 15, Article 7329. <https://doi.org/10.3390/app15137329>
- Hooshmand, M. K., Huchaiah, M. D., Alzighaibi, A. R., Hashim, H., Atlam, E.-S., & Gad, I. (2024). Robust network anomaly detection using ensemble learning approach and explainable artificial intelligence (XAI). *Alexandria Engineering Journal*, 94, 120–130. <https://doi.org/10.1016/j.aej.2024.03.041>
- Kılıç, C., & Şengül, G. (2026). SHAP-guided feature selection for cross-dataset generalization in network intrusion detection systems. *IEEE Access*, 14, 90926–90936. <https://doi.org/10.1109/ACCESS.2026.3703481>
- Koukaras, C., Hatzikraniotis, E., Mitsiaki, M., Koukaras, P., Tjortjis, C., & Stavriniades, S. G. (2025). Revolutionising educational management with AI and wireless networks: A framework for smart resource allocation and decision-making. *Applied Sciences*, 15(10), Article 5293. <https://doi.org/10.3390/app15105293>
- Krupski, J., Iwanowski, M., & Graniszewski, W. (2024). Extraction of minimal set of traffic features using ensemble of classifiers and rank aggregation for network intrusion detection systems. *Applied Sciences*, 14(16), Article 6995. <https://doi.org/10.3390/app14166995>
- Le, T.-T.-H., Kim, H., Kang, H., & Kim, H. (2022). Classification and explanation for intrusion detection system based on ensemble trees and SHAP method. *Sensors*, 22(3), Article 1154. <https://doi.org/10.3390/s22031154>

- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems* (Vol. 30, pp. 4765–4774).
- Malach, A., Wudali, P. N., Momiyama, S., Furukawa, J., Araki, T., Elovici, Y., & Shabtai, A. (2025). CyberShapley: Explanation, prioritization, and triage of cybersecurity alerts using informative graph representation. *Computers & Security*, 150, Article 104270. <https://doi.org/10.1016/j.cose.2024.104270>
- Melendrez, A., Goncalves, H., Alomari, Z., & Shao, Y. (2025). Boosted ensemble voting for intrusion detection: A SHAP-driven analysis of XGBoost and CatBoost. In *2025 1st International Conference on Computational Intelligence Approaches and Applications (ICCIAA)* (pp. 1–6).
- Mondragon, J. C., Branco, P., Jourdan, G.-V., Gutierrez-Rodriguez, A. E., & Biswal, R. R. (2025). Advanced IDS: A comparative study of datasets and machine learning algorithms for network flow-based intrusion detection systems. *Applied Intelligence*, 55, Article 608. <https://doi.org/10.1007/s10489-025-06422-4>
- Mustafa, M. F., Isa, M. R. M., Khairuddin, M. A., Yunus, M. S. F. M., & Jamaluddin, N. A. A. (2026). Enhancing security in smart campus networks: Implementation of Network Detection and Response (NDR) platform. *International Journal on Informatics Visualization*, 10(3), 1112–1120.
- Nassreddine, G., Nassereddine, M., & Al-Khatib, O. (2025). Ensemble learning for network intrusion detection based on correlation and embedded feature selection techniques. *Computers*, 14(3), Article 82. <https://doi.org/10.3390/computers14030082>
- Oh, S., Sohn, S., Kim, C., & Park, M. (2025). MCH-Ensemble: Minority class highlighting ensemble method for class imbalance in network intrusion detection. *Applied Sciences*, 15(23), Article 12647. <https://doi.org/10.3390/app152312647>
- Souza, M. M. C., Pontes, C. T., Gondim, J. J. C., Garcia, L. P. F., DaSilva, L., Cavalcante, E. F. M., & Marotta, M. A. (2025). A novel open set energy-based flow classifier for network intrusion detection. *Computers & Security*, 157, Article 104569. <https://doi.org/10.1016/j.cose.2025.104569>
- Xu, B., Shi, R., Yang, Q., Zhang, T., Huang, H., Zhao, F., Tong, X., Hu, L., & Ma, S. (2026). A coordinated continual intrusion detection approach with feature-space MMD drift detection and gradient-matching coresets. *Mathematics*, 14(14), Article 2595. <https://doi.org/10.3390/math14142595>
- Yan, Q. (2025). Explainable machine learning for detecting malicious student behavior in campus networks. In *Proceedings of the 10th International Conference on Cyber Security and Information Engineering* (pp. 1–7). <https://doi.org/10.1145/3759179.3760446>
- Yıldırım, E., Ortakçı, Y., & Avcı, İ. (2025). An empirical study on feature selection techniques for network intrusion detection systems. In E. Gülbandır (Ed.), *Foundations and advances in artificial intelligence: Theory, systems, security and educational applications-2* (pp. 1–24). BİDGE Yayınları.
- Yin, Y., Jang-Jaccard, J., Xu, W., Singh, A., Zhu, J., Sabrina, F., & Kwak, J. (2023). IGRF-RFE: A hybrid feature selection method for MLP-based network intrusion detection on UNSW-NB15 dataset. *Journal of Big Data*, 10, Article 15. <https://doi.org/10.1186/s40537-023-00694-8>
- Zouhri, H., Idri, A., & Ratnani, A. (2024). Evaluating the impact of filter-based feature selection in intrusion detection systems. *International Journal of Information Security*, 23, 759–785. <https://doi.org/10.1007/s10207-023-00767-y>

DERİN ÖĞRENME TABANLI SMS SPAM TESPİTİ: CNN, LSTM VE GRU MODELLERİNİN KARŞILAŞTIRMALI BİR ÇALIŞMASI DEEP LEARNING-BASED SMS SPAM DETECTION: A COMPARATIVE STUDY OF CNN, LSTM, AND GRU

Lecturer Elif YILDIRIM¹

¹Karabük University, Department of Computer Engineering, Karabük, Türkiye

¹ORCID ID: <https://orcid.org/0000-0001-6336-6390>

Assoc. Prof. Dr. İsa AVCI²

²Karabük University, Department of Computer Engineering, Karabük, Türkiye

²ORCID ID: <https://orcid.org/0000-0001-7032-8018>

ÖZET

Kısa Mesaj Servisi (SMS), mobil iletişimin yaygın ve hızlı araçlarından biri olmakla birlikte, istenmeyen ve zararlı içeriklerin kullanıcılara ulaştırılmasında da sıklıkla kullanılmaktadır. SMS spam mesajları; kimlik avı bağlantıları, finansal dolandırıcılık girişimleri, sahte kampanyalar, yanıltıcı reklamlar ve kötü amaçlı yazılımlara yönlendiren bağlantılar aracılığıyla kullanıcıların kişisel verileri, finansal varlıkları ve genel siber güvenliği açısından önemli riskler oluşturmaktadır. Spam mesajlarının içerik ve biçimlerinin sürekli değişmesi, saldırganların farklı kelime kullanımları ve sosyal mühendislik tekniklerinden yararlanması, geleneksel kural tabanlı ve anahtar kelime odaklı filtreleme yöntemlerinin etkinliğini sınırlayabilmektedir. Bu nedenle, metinsel örüntüleri veriden otomatik olarak öğrenebilen derin öğrenme yöntemleri, SMS spam tespitinde önemli bir alternatif olarak değerlendirilmektedir. Bu çalışmada, SMS mesajlarının spam ve normal (ham) olarak sınıflandırılması amacıyla Evrişimli Sinir Ağı (Convolutional Neural Network-CNN), Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM) ve Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU) mimarileri karşılaştırmalı olarak incelenmiştir. Deneysel çalışmalarda, SMS spam sınıflandırması alanında yaygın olarak kullanılan ve herkese açık olarak erişilebilen SMS Spam Collection veri setinden yararlanılmıştır. Modeller arasında adil ve güvenilir bir karşılaştırma yapılabilmesi amacıyla tüm mimariler aynı veri bölme yaklaşımı, metin ön işleme süreci ve sınıf dengesizliği yönetimi altında eğitilmiş ve değerlendirilmiştir. Böylece elde edilen performans farklılıklarının mümkün olduğunca kullanılan model mimarilerinden kaynaklanması amaçlanmıştır. Modellerin sınıflandırma başarılarının kapsamlı biçimde değerlendirilebilmesi için doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1-skoru ve ROC-AUC metriklerinin yanı sıra karmaşıklık matrislerinden yararlanılmıştır. Özellikle spam tespiti gibi sınıf dağılımının dengesiz olabildiği problemlerde yalnızca doğruluk metriğine odaklanmanın yanıltıcı sonuçlara yol açabileceği dikkate alınarak farklı performans ölçütleri birlikte değerlendirilmiştir. Deneysel bulgular, üç derin öğrenme mimarisinin de SMS spam sınıflandırmasında güçlü performans sergilediğini, ancak modellerin farklı değerlendirme ölçütlerinde birbirlerine göre üstünlük gösterdiğini ortaya koymuştur. GRU modeli en yüksek genel doğruluk ve F1-skorunu elde ederek dengeli bir sınıflandırma başarısı sunarken, CNN modeli en yüksek kesinlik ve ROC-AUC değerlerine ulaşmıştır. LSTM modeli ise en yüksek duyarlılık değerini sağlayarak spam mesajlarının yakalanması açısından öne çıkmıştır. Elde edilen sonuçlar, SMS spam tespitinde uygun model seçiminin yalnızca genel doğruluk değerine göre yapılmaması gerektiğini göstermektedir. Yanlış pozitiflerin azaltılmasının öncelikli olduğu sistemlerde yüksek kesinlik, mümkün olduğunca fazla spam mesajının tespit edilmesinin kritik olduğu uygulamalarda yüksek duyarlılık, genel ve dengeli performansın hedeflendiği durumlarda ise F1-skoru gibi ölçütlerin dikkate alınması gerekmektedir. Sonuç olarak çalışma, derin öğrenme tabanlı CNN, LSTM ve

GRU mimarilerinin SMS spam tespitinde etkili biçimde kullanılabileceğini ve her bir mimarinin farklı operasyonel ve siber güvenlik gereksinimleri açısından tamamlayıcı avantajlar sağlayabileceğini göstermektedir.

Anahtar Kelimeler: SMS spam tespiti, derin öğrenme, CNN, LSTM, GRU, siber güvenlik

GİRİŞ

Kısa Mesaj Servisi (SMS), düşük maliyeti, yaygın erişilebilirliği ve internet bağlantısına ihtiyaç duymadan çalışabilmesi nedeniyle kişisel iletişimden bankacılık bildirimlerine, doğrulama kodlarından kamu duyurularına kadar çok geniş bir kullanım alanına sahiptir. Bu yaygınlık, SMS kanalını saldırganlar açısından da cazip hâle getirmiş; kimlik avı, sahte kampanyalar, finansal dolandırıcılık, zararlı bağlantı dağıtımı ve sosyal mühendislik temelli içerikler giderek daha görünür bir güvenlik problemi oluşturmuştur. SMS spam yalnızca kullanıcı deneyimini olumsuz etkilememekte, aynı zamanda kişisel verilerin ele geçirilmesi, hesap güvenliğinin zayıflaması ve finansal kayıplar gibi sonuçlara da yol açabilmektedir (Almeida et al., 2011; Cormack, 2008).

Geleneksel spam filtreleme yaklaşımları çoğunlukla anahtar kelime listeleri, kara/beyaz listeler, elle oluşturulan kurallar ve sezgisel eşleştirmelere dayanmaktadır. Bu yöntemler hızlı ve uygulaması görece kolay olmakla birlikte, saldırganların kelime biçimlerini değiştirmesi, karakterleri kasıtlı olarak bozması veya yeni sosyal mühendislik kalıpları kullanması durumunda esnekliklerini kaybedebilmektedir. Klasik makine öğrenmesi yöntemleri bu sınırlamayı azaltmak için destek vektör makineleri, Naive Bayes, k-en yakın komşu, karar ağaçları ve benzeri sınıflandırıcıları Bag-of-Words veya TF-IDF temsilleriyle kullanmıştır (Cortes & Vapnik, 1995; Cover & Hart, 1967; McCallum & Nigam, 1998). Bununla birlikte bu yaklaşımlar çoğu zaman özellik mühendisliğine ihtiyaç duymakta ve metindeki bağlamsal ilişkileri sınırlı ölçüde temsil etmektedir.

Derin öğrenme, ham ya da ön işlenmiş metinlerden ayırt edici özelliklerin otomatik olarak öğrenilmesine olanak tanıyarak metin sınıflandırma problemlerinde önemli bir alternatif sunmaktadır (LeCun et al., 2015; Goodfellow et al., 2016). CNN mimarileri yerel kelime örüntülerini ve n-gram benzeri yapıları yakalamada başarıyla, LSTM ve GRU gibi tekrarlayan ağlar sıralı bilgiyi ve bağlamsal bağımlılıkları modelleyebilmektedir (Kim, 2014; Hochreiter & Schmidhuber, 1997; Cho et al., 2014).

Bu çalışmanın amacı, SMS Spam Collection veri seti üzerinde CNN, LSTM ve GRU mimarilerini aynı veri hazırlama ve eğitim koşulları altında karşılaştırmaktır. Böylece modeller arasındaki farkların veri bölme veya ön işleme farklılıklarından ziyade mimari özelliklerden kaynaklanması hedeflenmiştir. Çalışmanın temel katkısı, dengesiz sınıf dağılımını dikkate alan ortak bir deneysel çerçeve içinde doğruluk, kesinlik, duyarlılık, F1-skoru, ROC-AUC ve karmaşıklık matrisi temelli çok boyutlu bir değerlendirme sunmasıdır.

LİTERATÜR TARAMASI

SMS spam tespiti literatüründe ilk dönem çalışmalar, metin içeriğinin elle belirlenen özelliklerle temsil edilmesine ve klasik sınıflandırıcılarla modellenmesine odaklanmıştır. Almeida et al. (2011) tarafından oluşturulan SMS Spam Collection veri seti, bu alandaki en yaygın kıyaslama veri setlerinden biri hâline gelmiştir. Veri setinin daha sonra UCI Machine Learning Repository üzerinden yayımlanması, farklı yöntemlerin aynı veri üzerinde karşılaştırılmasını kolaylaştırmıştır.

Destek vektör makineleri, Naive Bayes ve k-NN gibi geleneksel yöntemler metin sınıflandırmasında güçlü temel modeller oluşturmıştır. Bununla birlikte bu yöntemlerin çoğu, metnin Bag-of-Words veya TF-IDF gibi vektör temsillerine dönüştürülmesini gerektirmektedir. Bu temsiller kelime sırasını ve uzun dönem bağlamı sınırlı biçimde koruduğu için özellikle saldırganların anlamsal çeşitlilik kullandığı spam mesajlarında yetersiz kalabilmektedir.

Derin öğrenme ile birlikte, kelime gömme katmanları ve sinir ağlarının birlikte eğitilmesi sayesinde metinsel özelliklerin otomatik öğrenilmesi mümkün hâle gelmiştir. Kim (2014), CNN tabanlı mimarilerin cümle sınıflandırma görevlerinde etkili olduğunu göstermiştir. CNN filtreleri, belirli pencere genişlikleri üzerinden yerel örüntüleri yakalayarak spam içeriklerde sık görülen kelime kombinasyonlarını öğrenebilmektedir. Johnson ve Zhang (2015) da kelime sırasının CNN tabanlı metin sınıflandırma üzerindeki etkisini vurgulamıştır.


LSTM, geleneksel RNN'lerde görülen kaybolan gradyan problemini azaltmak amacıyla giriş, unutma ve çıkış kapılarından yararlanan bir bellek mekanizması kullanır (Hochreiter & Schmidhuber, 1997). Bu yapı, bir mesajdaki önceki kelimelerin sonraki kelimeler üzerindeki etkisini koruyarak bağlamın modellenmesini sağlar. GRU ise güncelleme ve sıfırlama kapılarıyla benzer bir işlevi daha sade bir yapı üzerinden gerçekleştirmektedir (Cho et al., 2014; Chung et al., 2014). Daha az parametre içeren GRU mimarisi, bazı metin sınıflandırma problemlerinde LSTM'ye yakın veya daha iyi başarıyı daha düşük hesaplama maliyetiyle sağlayabilmektedir.

Spam tespitinde sınıf dengesizliği de önemli bir değerlendirme problemidir. Veri setinde normal mesajların spam mesajlarından çok daha fazla olması, yüksek doğruluk değerinin tek başına modelin spam sınıfını iyi yakaladığı anlamına gelmemesine neden olur. Bu nedenle kesinlik, duyarlılık, F1-skoru ve ROC-AUC gibi ölçütlerin birlikte kullanılması önerilmektedir (Powers, 2011; Saito & Rehmsmeier, 2015; Fawcett, 2006). Bu çalışma da söz konusu gereksinimi temel alarak üç farklı derin öğrenme mimarisini aynı deneysel koşullarda çoklu performans ölçütleriyle değerlendirmektedir.

MATERYAL VE YÖNTEM

Araştırma Çerçevesi

Önerilen yaklaşım üç temel aşamadan oluşmaktadır: veri hazırlama, model geliştirme ve performans değerlendirme. Veri hazırlama aşamasında gereksiz sütunlar ve yinelenen kayıtlar kaldırılmış; sınıf etiketleri sayısal biçime dönüştürülmüş; metin temizleme, tokenizasyon ve sabit uzunlukta dizi oluşturma işlemleri uygulanmıştır. Model geliştirme aşamasında CNN, LSTM ve GRU ağları aynı işlenmiş veri üzerinde eğitilmiştir. Son aşamada test kümesi üzerinden çoklu performans ölçütleri hesaplanmış ve modeller karşılaştırılmıştır.



Şekil 1. Çalışmanın genel araştırma akışı.

Veri Seti

Deneylerde SMS spam tespiti literatüründe yaygın olarak kullanılan SMS Spam Collection veri seti kullanılmıştır. Veri seti 5.572 İngilizce SMS mesajı içermekte olup 4.825 mesaj normal (ham), 747 mesaj ise spam olarak etiketlenmiştir (Almeida et al., 2011). Orijinal CSV yapısındaki v1 sütunu sınıf etiketini, v2 sütunu mesaj metnini içermektedir; boş/ilgisiz sütunlar analiz dışı bırakılmıştır. Veri setinin ham ve spam sınıfları arasında belirgin bir dengesizlik bulunduğu için eğitim aşamasında sınıf ağırlıkları kullanılmıştır.

Özellik	Değer
Veri seti	SMS Spam Collection
Toplam mesaj	5.572
Normal (ham)	4.825
Spam	747
Sınıf sayısı	2
Dil	İngilizce
Etiket sütunu	v1
Mesaj sütunu	v2

Tablo 1. SMS Spam Collection veri setinin temel özellikleri.

Veri Ön İşleme

İlk aşamada veri setindeki boş ve ilgisiz sütunlar kaldırılmış, yinelenen SMS kayıtları temizlenmiştir. Ham sınıfı 0, spam sınıfı 1 olarak kodlanmıştır. Metinler küçük harfe dönüştürülmüş; bağlantılar, sayısal karakterler, noktalama işaretleri ve gereksiz özel karakterler temizlenmiştir. Yaygın İngilizce durak kelimeleri çıkarılmış ve kelimelerin kök biçimlerini elde etmek için Porter Stemmer kullanılmıştır.

Metinlerin sinir ağlarına giriş olarak verilebilmesi amacıyla Keras tokenizer kullanılmış ve eğitim verisindeki en sık 10.000 kelime için sözlük oluşturulmuştur. Her mesaj tamsayı dizisine dönüştürülmüş, farklı uzunluktaki mesajların ortak bir boyuta getirilmesi için diziler 70 token uzunluğuna kadar doldurulmuş veya kesilmiştir.

Veri, sınıf dağılımını koruyacak biçimde %80 eğitim ve %20 test olarak ayrılmıştır. Eğitim verisinin %20'si doğrulama amacıyla kullanılmıştır. Sınıf dengesizliğinin model üzerinde çoğunluk sınıfı lehine yanlılık oluşturmaması amacıyla eğitim sırasında sınıf ağırlıkları uygulanmıştır.

Model Mimarileri

CNN modeli, 10.000 kelimelik sözlük ve 128 boyutlu gömme katmanından sonra 64 filtreli, çekirdek boyutu 5 olan Conv1D katmanı kullanmaktadır. ReLU aktivasyonunun ardından MaxPooling ve Dropout işlemleri uygulanmış; son sınıflandırma sigmoid aktivasyonlu yoğun katman ile gerçekleştirilmiştir. CNN'in temel amacı, spam mesajlarında tekrarlanan yerel kelime kalıplarını ve kısa bağlamsal örüntüleri yakalamaktır (Kim, 2014).

LSTM modeli, aynı gömme boyutu ve dizi uzunluğu ile 64 LSTM biriminden oluşmaktadır. LSTM'nin giriş, unutma ve çıkış kapıları uzun dönem bağlamsal ilişkilerin korunmasına yardımcı olmaktadır. Tekrarlayan katmanın ardından 0,5 oranında Dropout uygulanmış ve sınıflandırma sigmoid çıkış katmanı ile yapılmıştır (Hochreiter & Schmidhuber, 1997).

GRU modeli de 64 tekrarlayan birim kullanmakta, ancak LSTM'den farklı olarak güncelleme ve sıfırlama kapılarıyla daha sade bir bellek mekanizması kurmaktadır. Bu yapı, sıralı bilgiyi korurken daha az parametreyle çalışabilmesi nedeniyle hesaplama açısından avantaj sağlayabilmektedir (Cho et al., 2014; Chung et al., 2014).

Parametre	CNN	LSTM	GRU
Sözlük boyutu	10.000	10.000	10.000
Maks. dizi uzunluğu	70	70	70
Embedding boyutu	128	128	128
Temel katman	Conv1D, 64 filtre	LSTM, 64 birim	GRU, 64 birim
Kernel boyutu	5	-	-
Dropout	Uygulandı	0,5	0,5
Çıkış aktivasyonu	Sigmoid	Sigmoid	Sigmoid
Optimizör	Adam	Adam	Adam
Kayıp	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy
Batch size	32	32	32
Maks. epoch	10	10	10

Tablo 2. CNN, LSTM ve GRU modellerinin temel hiperparametreleri.

Eğitim Stratejisi

Üç model de TensorFlow-Keras kullanılarak Python ortamında Google Colaboratory üzerinde eğitilmiştir. Optimizasyon için Adam, kayıp fonksiyonu olarak ikili çapraz entropi (Binary Crossentropy) kullanılmıştır. Aşırı öğrenmeyi sınırlamak ve doğrulama performansını izlemek amacıyla EarlyStopping ve ReduceLROnPlateau geri çağırımları etkinleştirilmiştir. Modellerin aynı eğitim/test bölünmesi, aynı tokenizer yapılandırması, aynı dizi uzunluğu ve aynı temel eğitim ayarları altında çalıştırılması karşılaştırmanın tutarlılığını artırmıştır.

Performans Ölçütleri

Model performansı doğruluk, kesinlik, duyarlılık, F1-skoru, ROC-AUC ve karmaşıklık matrisi ile değerlendirilmiştir. Doğruluk tüm örnekler içindeki doğru sınıflandırma oranını gösterirken, kesinlik spam olarak tahmin edilen mesajların ne kadarının gerçekten spam olduğunu ifade eder. Duyarlılık, gerçek spam mesajlarının ne kadarının tespit edilebildiğini ölçer. F1-skoru kesinlik ve duyarlılığın harmonik ortalamasıdır. ROC-AUC ise farklı karar eşikleri altında modelin sınıfları ayırt etme yeteneğini özetlemektedir (Powers, 2011; Fawcett, 2006). Dengesiz veri problemlerinde yalnızca doğruluğa güvenmek yerine bu ölçütlerin birlikte değerlendirilmesi daha sağlıklı bir yorum sağlamaktadır.

BULGULAR


Üç model de test kümesi üzerinde %97'nin üzerinde doğruluk elde etmiştir. Bununla birlikte metrik bazında farklı avantajlar görülmüştür. CNN %98,07 doğruluk ve %98,26 kesinlik ile yanlış pozitifleri düşük tutma açısından güçlü bir sonuç vermiştir. ROC-AUC değeri %99,43 ile üç model arasındaki en yüksek değerdir. Buna karşılık CNN'in duyarlılığı %86,26'dır; bu durum bazı spam mesajlarının ham olarak sınıflandırıldığını göstermektedir.

LSTM modeli %97,68 doğruluk, %88,49 kesinlik ve %93,89 duyarlılık elde etmiştir. Üç model arasında en yüksek duyarlılık değerinin LSTM'ye ait olması, mümkün olduğunca fazla spam mesajının yakalanmasının öncelikli olduğu senaryolarda bu mimariyi dikkate değer kılmaktadır. LSTM'nin F1-skoru %91,11, ROC-AUC değeri ise %99,31'dir.

GRU modeli %98,16 doğruluk, %92,42 kesinlik, %93,13 duyarlılık ve %92,78 F1-skoru elde etmiştir. Bu sonuçlar GRU'nun özellikle kesinlik ve duyarlılık arasında dengeli bir performans sergilediğini göstermektedir. GRU'nun ROC-AUC değeri %99,22 olarak ölçülmüştür. Genel doğruluk ve F1-skoru birlikte dikkate alındığında en dengeli sonucun GRU modeliyle elde edildiği görülmektedir.

Model	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skoru (%)	ROC-AUC (%)
CNN	98,07	98,26	86,26	91,87	99,43
LSTM	97,68	88,49	93,89	91,11	99,31
GRU	98,16	92,42	93,13	92,78	99,22

Tablo 3. CNN, LSTM ve GRU modellerinin karşılaştırmalı performansı.



Şekil 2. Modellerin temel performans ölçütlerine göre karşılaştırılması.

CNN modelinin karmaşıklık matrisi incelendiğinde 901 normal mesajın ve 113 spam mesajın doğru sınıflandırıldığı, 2 normal mesajın spam olarak, 18 spam mesajın ise normal olarak tahmin edildiği görülmüştür. Bu sonuç, CNN'in yüksek kesinlik değerini açıklarken duyarlılığın diğer iki tekrarlayan mimariye göre daha düşük kalmasının nedenini de ortaya koymaktadır. Başka bir ifadeyle CNN yanlış alarm üretme konusunda oldukça temkinli davranmakta, ancak bazı spam mesajlarını kaçırabilmektedir.

TARTIŞMA

Deneyisel bulgular, SMS spam sınıflandırmasında tek bir modelin bütün ölçütlerde açık biçimde üstün olmadığını göstermektedir. CNN en yüksek kesinlik ve ROC-AUC değerlerine ulaşırken, LSTM en yüksek duyarlılığı sağlamış, GRU ise en yüksek doğruluk ve F1-skorunu elde etmiştir. Bu dağılım, model seçiminin operasyonel hedefe göre yapılması gerektiğini ortaya koymaktadır.

Yanlış pozitiflerin azaltılması gereken sistemlerde normal bir mesajın spam olarak engellenmesi kullanıcı deneyimi açısından önemli bir maliyet oluşturabilir. Bu tür senaryolarda CNN'in %98,26'lık kesinliği avantaj sağlayabilir. Buna karşılık kimlik avı veya finansal dolandırıcılık gibi yüksek riskli içeriklerde mümkün olduğunca az spam mesajının kaçırılması daha kritik olabilir. Bu durumda %93,89 ile en yüksek duyarlılığı sağlayan LSTM ön plana çıkmaktadır.

GRU'nun %98,16 doğruluk ve %92,78 F1-skoru ile genel anlamda en dengeli sonucu vermesi, daha sade kapı mekanizmasının bu veri setindeki kısa metin dizileri için yeterli bağlamsal temsil sağladığını düşündürmektedir. GRU'nun LSTM'ye göre daha az parametreyle çalışması, gecikme ve kaynak kullanımının önemli olduğu gerçek zamanlı filtreleme sistemlerinde de pratik bir avantaj oluşturabilir.

Çalışmanın önemli bir yönü, tüm modellerin aynı veri işleme hattı altında değerlendirilmiş olmasıdır. Aynı tokenizer, aynı dizi uzunluğu, aynı veri bölme stratejisi ve aynı temel eğitim ayarlarının kullanılması, sonuçlar arasındaki farkların model mimarisine bağlanabilirliğini güçlendirmektedir. Bununla birlikte, tek bir veri setinin kullanılması çalışmanın genellenebilirliğini sınırlandırmaktadır. SMS dili zaman içinde değişmekte, farklı ülkelerde farklı kısaltmalar, dil karışımları ve sosyal mühendislik kalıpları ortaya çıkmaktadır.

Sonuçların başka veri setleri üzerinde doğrulanması, çok dilli SMS koleksiyonlarının kullanılması ve BERT gibi Transformer tabanlı mimarilerin karşılaştırmaya eklenmesi gelecekteki çalışmalar için önem taşımaktadır. Ayrıca model boyutu, eğitim süresi, çıkarım gecikmesi, bellek kullanımı ve enerji tüketimi gibi operasyonel metriklerin ölçülmesi, yalnızca sınıflandırma başarısına değil gerçek sistem gereksinimlerine göre de model seçimi yapılmasına olanak sağlayacaktır.

SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada, SMS spam tespiti amacıyla CNN, LSTM ve GRU derin öğrenme mimarileri SMS Spam Collection veri seti üzerinde ortak bir deneysel çerçeve altında karşılaştırılmıştır. Veri temizleme, etiket kodlama, tokenizasyon, dizi doldurma, sınıf ağırlıklandırma ve veri bölme adımları tüm modeller için aynı biçimde uygulanmıştır. Modeller doğruluk, kesinlik, duyarlılık, F1-skoru, ROC-AUC ve karmaşıklık matrisi kullanılarak değerlendirilmiştir.

Sonuçlar, üç mimarinin de güçlü performans sunduğunu ancak farklı amaçlarda farklı modellerin öne çıktığını göstermiştir. CNN %98,26 kesinlik ve %99,43 ROC-AUC ile yanlış pozitiflerin azaltılması ve sınıfların ayrıştırılması açısından en güçlü sonucu üretmiştir. LSTM %93,89 duyarlılık ile spam mesajlarını yakalama oranında en başarılı model olmuştur. GRU ise %98,16 doğruluk ve %92,78 F1-skoru ile en dengeli genel performansı göstermiştir.

Bu bulgular doğrultusunda, gerçek bir SMS güvenlik sisteminde model seçiminin tek bir başarı metriğine dayandırılmaması önerilmektedir. Operasyonel öncelik yanlış alarmı azaltmaksa kesinlik, spam kaçırmayı azaltmaksa duyarlılık, iki hedef arasında denge aranıyorsa F1-skoru temel karar ölçütü olarak kullanılabilir. Gelecek çalışmalarda çok dilli ve güncel spam veri setleri, Transformer tabanlı mimariler, gelişmiş kelime gömme yöntemleri ve gerçek zamanlı performans ölçütlerinin birlikte değerlendirilmesi planlanabilir.

KAYNAKLAR

- Almeida, T.A., Gómez Hidalgo, J.M. & Yamakami, A. (2011). Contributions to the study of SMS spam filtering: New collection and results. *Proceedings of the 11th ACM Symposium on Document Engineering*, 259–262. <https://doi.org/10.1145/2034691.2034742>
- Almeida, T.A. & Gómez Hidalgo, J.M. (2012). *SMS Spam Collection Dataset*. UCI Machine Learning Repository. Erişim adresi: <https://archive.ics.uci.edu/dataset/228/sms+spam+collection>
- Bhatt, H.S., Patel, M., Gadhavi, D. & Patel, N. (2020). Spam detection in SMS using machine learning and deep learning techniques. *International Journal of Computer Applications*, 177(42), 1–8.
- Cho, K., van Merriënboer, B., Bahdanau, D. & 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)*, 1724–1734. <https://doi.org/10.3115/v1/D14-1179>
- Chung, J., Gulcehre, C., Cho, K. & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- Cormack, G.V. (2008). Email spam filtering: A systematic review. *Foundations and Trends in Information Retrieval*, 1(4), 335–455. <https://doi.org/10.1561/1500000006>

- Cortes, C. & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Cover, T.M. & Hart, P.E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Gers, F.A., Schmidhuber, J. & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471. <https://doi.org/10.1162/089976600300015015>
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. Cambridge, MA: MIT Press.
- Hochreiter, S. & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Johnson, R. & Zhang, T. (2015). Effective use of word order for text categorization with convolutional neural networks. *Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, 103–112. <https://doi.org/10.3115/v1/N15-1011>
- Kaggle. (n.d.). *SMS Spam Collection Dataset*. Erişim adresi: <https://www.kaggle.com/datasets/uciml/sms-spam-collection-dataset>
- Kim, Y. (2014). Convolutional neural networks for sentence classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1746–1751. <https://doi.org/10.3115/v1/D14-1181>
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- McCallum, A. & Nigam, K. (1998). A comparison of event models for Naive Bayes text classification. *AAAI Workshop on Learning for Text Categorization*, 41–48.
- Powers, D.M.W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Saito, T. & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS ONE*, 10(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Tyagi, S.K.S. & Dwivedi, R.K. (2021). SMS spam detection using deep learning models. *International Journal of Advanced Computer Science and Applications*, 12(5), 405–412.

COMPARISON OF LIGHTWEIGHT VISION LANGUAGE MODELS ON EDGE DEVICES FOR RISK ANALYSIS OF AUTONOMOUS DRIVING IN ADVERSE WEATHER CONDITIONS

İrem CAKCAK¹

¹Isparta University of Applied Sciences, Institute of Postgraduate Education, Isparta, Turkey

¹ORCID ID: <https://orcid.org/0009-0004-8929-3950>

Assist. Prof. Dr. Burhan DUMAN²

²Isparta University of Applied Sciences, Faculty of Technology, Isparta, Turkey

²ORCID ID: <https://orcid.org/0000-0001-5614-1556>

ABSTRACT

Safe navigation in autonomous driving systems depends not only on the detection of surrounding elements such as vehicles, pedestrians, and the road, but also on the accurate analysis of the scene within the current driving scenario. Adverse weather conditions such as fog, heavy rain, and snow reduce visibility, negatively impacting the performance of camera-based systems and driving decisions in particular. While Vision Language Models (VLMs), which process visual and textual data together, stand out in the analysis of these scenes, the high memory and computational requirements of large-scale architectures limit their use on edge devices.

In this study, model performance on the NVIDIA Jetson Orin Nano was evaluated to assess the feasibility of using lightweight VLMs on edge devices. The study was conducted in two phases. In the first phase, a pilot evaluation was performed; the Qwen2.5-VL 3B, LLaVA-Phi3, SmolVLM500M, Moondream, MiniCPM-V, and Ministral models were tested using zero-shot, one-shot, and few-shot prompt strategies. In this phase, the models' device compatibility, ability to preserve output structure, response consistency, and tendency to generate information not supported by the image (hallucinations) were examined; Qwen2.5-VL 3B and MiniCPM-V, which most consistently maintained long inputs and structured output formats, were selected for the main benchmark experiment. For the second-phase experiments, a test set of 153 images—selected from the BDD100K dataset and representing various weather conditions—was used. In addition to structured scene labels, task-specific reference annotations were prepared, including visibility, road surface, visible hazards, risk level, and driving actions; GPT- and GLM-based outputs were compared and manually verified. The same data structure and standardized “few-shot” prompting scheme were used in all evaluations without applying fine-tuning to the two selected models.

According to the experimental results, Qwen2.5-VL 3B achieved accuracies of 68.6% for visibility classification, 70.6% for risk-level classification, 99.3% for turning actions, and 97.4% for lane actions. In road-surface classification, however, MiniCPM-V achieved the best performance with an accuracy of 78.9%. The hazard F1 scores were 0.319 and 0.267, while the meta-action F1 scores were 0.453 and 0.241 for Qwen2.5-VL 3B and MiniCPM-V,

respectively. Both models generated valid JSON for all successfully completed outputs, with average output-generation times (eval_duration) of 15.02 s for Qwen2.5-VL 3B and 72.32 s for MiniCPM-V. One MiniCPM-V inference failed due to a timeout. These findings indicate that task performance, structured-output reliability, and computational efficiency should be considered jointly when selecting lightweight VLMs for edge devices.

Keywords: Vision Language Models, Autonomous Driving, Adverse Weather Conditions, Edge Computing, NVIDIA Jetson Orin Nano, Multimodal Artificial Intelligence

INTRODUCTION

Safe autonomous driving requires not only detecting surrounding elements but also interpreting them within the current traffic context. Adverse weather conditions such as fog, rain, and snow can reduce visibility and impair camera-based perception of vehicles, pedestrians, and road boundaries, making driving decisions more difficult.

Vision-Language Models (VLMs) jointly process visual and textual information and can support scene understanding, hazard interpretation, and natural-language explanation of driving decisions. Studies such as DriveGPT4, DriveLM, DriveVLM, and DriveMLM have demonstrated the potential of VLMs to connect perception with decision-making in autonomous driving. However, their high computational and memory requirements can limit deployment on resource-constrained edge devices, increasing the need for lightweight architectures.

This study evaluates lightweight VLMs on the NVIDIA Jetson Orin Nano for adverse-weather driving-scene analysis. In a pilot stage, six models were examined in terms of device compatibility and structured-output stability, after which Qwen2.5-VL 3B and MiniCPM-V were selected for the main benchmark. Without fine-tuning, the models were compared in terms of environmental classification, visible-hazard identification, risk assessment, driving-action generation, JSON-format compliance, and inference performance. The evaluation therefore considers task performance, output reliability, and computational cost jointly for edge deployment.

CONCEPTUAL FRAMEWORK

Vision-Language Models (VLMs) and Multimodal Large Language Models (MLLMs) jointly process visual and textual information, enabling driving scenes to be interpreted beyond object-level perception. In autonomous driving, they support critical-object identification, environmental assessment, driving-decision generation, and natural-language explanations (Cui et al., 2025; Sima et al., 2024; Tian et al., 2025; Xu et al., 2024).

Vision Language Models and Reasoning in Autonomous Driving

Traditional autonomous driving systems generally separate perception, prediction, planning, and control, whereas end-to-end approaches directly generate control or trajectory outputs from sensor inputs. VLM-based methods extend these approaches by integrating visual understanding, reasoning, explanations, and driving decisions.

DriveGPT4 processes video and textual queries to generate scene explanations and low-level control variables such as speed and steering angle (Xu et al., 2024). DriveLM organizes driving decisions into perception, prediction, planning, behavior, and motion stages through a Graph Visual Question Answering (GVQA) framework (Sima et al., 2024).

DriveVLM combines scene description, analysis, and hierarchical planning to generate meta-actions, explanations, and trajectory waypoints, while DriveVLM-Dual integrates VLM reasoning with conventional 3D perception and planning components (Tian et al., 2025). DriveMLM similarly combines camera images, LiDAR data, traffic rules, and user commands to support behavioral planning decisions (Cui et al., 2025).

Overall, these studies demonstrate that VLMs can extend autonomous-driving perception toward environmental reasoning, critical-situation interpretation, and explainable decision-making.

Multimodal Scene Understanding Under Adverse Weather Conditions

Adverse weather conditions such as fog, rain, and snow can reduce visibility and obscure small or distant objects, requiring autonomous-driving systems to consider weather together with visibility, road-surface conditions, hazards, and driving behavior.

DynRsl-VLM combines a low-resolution global image with high-resolution regions of interest to preserve safety-critical visual details while limiting computational cost (Zhou et al., 2025). WeatherQA evaluates weather-related VLM reasoning using 8,511 image-text examples, focusing on event type, affected region, and severity (Ma et al., 2024). Although not developed for autonomous driving, it highlights the difference between recognizing weather and interpreting its consequences, supporting joint assessment of visibility, road surface, hazards, risk, and driving behavior.

Lightweight VLMs and Computational Constraints on Edge Devices

Deploying VLMs on vehicles is challenging because of their high computational and memory requirements, particularly on resource-constrained edge devices. Recent studies therefore focus on reducing model complexity, lowering inference cost, or transferring knowledge from larger VLMs to lightweight systems.

TinyDrive reduces computational demand through a multiscale CNN-based visual encoder and token-routing mechanism that processes only relevant tokens (Hassani et al., 2025). VLM-AD uses large VLMs as teachers during training, transferring reasoning and structured driving-action information to an end-to-end driving model without requiring the VLM during real-time inference (Xu et al., 2025).

Sarwar et al. (2026) evaluated five local VLMs on an NVIDIA Jetson Orin Nano using Ollama and llama.cpp, considering latency, generation speed, memory and power usage, semantic performance, and hallucination. Larger models showed higher resource demands and lower inference speeds, whereas Qwen3-VL-2B-Instruct achieved the highest throughput (32.7 tokens/s) and strong semantic performance. Although the study did not focus on autonomous driving, its use of the same Jetson Orin Nano platform makes it directly relevant. Overall, prior

work suggests that lightweight VLM evaluation should jointly consider task performance, output reliability, and edge-device inference cost.

METHODOLOGY

The study evaluated lightweight Vision-Language Models (VLMs) for adverse-weather driving-scene analysis on the NVIDIA Jetson Orin Nano. No fine-tuning, LoRA, QLoRA, or other parameter updates were applied. The workflow consisted of a pilot model/prompt selection stage followed by a main benchmark evaluating scene interpretation, hazards, risk, driving actions, JSON compliance, and inference performance.

General Experimental Design

In the pilot stage, Qwen2.5-VL 3B, LLaVA-Phi3, SmolVLM500M, Moondream, MiniCPM-V, and Ministral 3B were tested using zero-shot, one-shot, and few-shot prompting. Depending on model format, Ollama in Docker or llama.cpp was used. A fixed foggy nighttime image was employed to assess output-format compliance, visual interpretation, example copying, hallucination, and processing time, with the aim of identifying stable configurations for the main benchmark.

The main benchmark used 153 BDD100K images representing different weather and driving conditions, together with scene information and manually verified reference annotations. Six separate images were used as few-shot examples. To prevent data leakage, manual_annotations were withheld during inference; models received only the target image, corresponding scene_annotations, and fixed prompt. Structured JSON outputs were generated for visibility, road surface, scenario categories, hazards, risk level, and driving actions, while JSON validity and inference time were recorded.

Hardware Infrastructure and Development Environment

All experiments were conducted on the NVIDIA Jetson Orin Nano Super Developer Kit with JetPack 6. Model deployment used Docker, Ollama, llama.cpp, and a local Python environment, with GPU acceleration enabled for GGUF-based models through GGML_CUDA and CMAKE_CUDA_ARCHITECTURES=87. Detailed specifications are given in Table 1.

Because different inference frameworks were used in the pilot stage, timing results reflect both model and framework characteristics. In the main benchmark, both models were evaluated under comparable conditions using the same test set and prompting structure, and outputs were stored as JSON for analysis.

Table 1: Hardware and software specifications of the edge device (NVIDIA Jetson Orin Nano) used in the main test environment

Hardware / Software Component	Specification / Value
Device Used	NVIDIA Jetson Orin Nano Super Developer Kit
Platform Type	Edge Computing Device
GPU Architecture	NVIDIA Ampere
CUDA Cores	1024

Tensor Cores	32
Processor (CPU)	6-core Arm Cortex-A78AE
System Memory (RAM)	8 GB LPDDR5
Memory Bandwidth	102 GB/s
AI Performance	Up to 67 TOPS (INT8)
Software Environment	JetPack 6
Inference Frameworks	Ollama, llama.cpp
CUDA Architecture Configuration	87 (CMAKE_CUDA_ARCHITECTURES=87)

Creation and Distribution of the Data Set

A fixed evaluation set of 153 BDD100K driving images was selected to represent clear, foggy, overcast, partly cloudy, rainy, and snowy conditions while avoiding overrepresentation of individual weather categories. Image files and JSON records were matched and checked for consistency. The weather distribution is summarized in Table 2.

Table 2: Distribution of the main benchmark test set according to weather conditions

Weather conditions	Number of images
Clear	27
Foggy	17
Overcast	30
Partly cloudy	26
Rainy	27
Snowy	26
Total	153

Six additional non-overlapping BDD100K images were used only as few-shot examples to demonstrate the expected annotation structure and interpretation logic during inference, without training or parameter updates.

Annotation Structure

Each test sample was organized in JSON format with two sections: scene_annotations and manual_annotations. The scene_annotations section contained BDD100K-derived contextual information, including weather, scene, timeofday, road_users, traffic_light_colors, traffic_sign_count, drivable_area_present, and lane_elements.

The manual_annotations section contained task-specific reference fields for visibility, road_surface, scenario_categories, hazards, and risk_level, together with risk_explanation, action_explanation, control_action, turn_action, lane_action, and meta_actions. Only visually supported hazards and actions consistent with the image and scene context were included.

During inference, scene_ annotations were provided to the models, whereas manual_ annotations were withheld and used only for evaluation.

Preparation of Reference Annotations

Because BDD100K does not provide the task-specific fields required in this study, reference manual_ annotations were created using each image, its scene_ annotations, and standardized annotation rules. GPT- and GLM-based models independently generated candidate annotations for visibility, road surface, scenario characteristics, visible hazards, risk level, and driving actions using only visually or contextually supported information. An example of this process is shown in Figure 1.




Figure 1. Annotation example under clear weather conditions: (a) urban driving-scene image with pedestrians crossing; (b) scene annotations from BDD100K; (c) annotation prompt excerpt; and (d) manually verified reference annotations.

The candidate outputs were cross-compared and manually verified before finalization. Unsupported objects or conditions, abstract or unobservable hazard statements, inconsistencies between risk levels and explanations, and unnecessary driving actions were corrected or removed. The finalized records were therefore used as *manually verified reference annotations* rather than absolute ground truth. Generated according to predefined rules and reviewed by humans, these references provided a standardized basis for comparing the evaluated models.

Figure 2 illustrates an annotation example for a driving scene under adverse weather conditions, specifically fog. The figure presents the input image, the scene annotations provided by BDD100K, an excerpt from the annotation prompt, and the corresponding manually verified reference annotations. In this example, fog reduces long-range visibility, while dense traffic and the short following distance contribute to a medium risk assessment. The reference annotations specify moderate visibility, a dry road surface, and the recommended action of moving slowly while maintaining a safe following distance.




Figure 2. Annotation example under adverse weather conditions: (a) foggy driving-scene image; (b) scene annotations from BDD100K; (c) annotation prompt excerpt; and (d) manually verified reference annotations.

Few-Shot Prompt Design and Inference Protocol

A fixed few-shot prompting structure was used to ensure consistent task definitions and output expectations. Six BDD100K images independent of the 153-image test set were used only as guidance examples to demonstrate the expected annotation structure and reasoning logic.

The prompt defined visibility, road surface, scenario categories, visible hazards, risk level, explanation fields, and driving actions. Models were instructed to include only image- or context-supported hazards, avoid unsupported inferences, and generate actions consistent with the scene.

The expected outputs were organized into two groups: scene and risk assessment, and driving actions. The scene- and risk-related query set was defined as follows:

$$Q_{scene} = \{q_{vis}, q_{road}, q_{scn}, q_{haz}, q_{risk}, q_{re}, q_{ae}\}$$

where the variables represent visibility, road surface condition, scenario categories, visible hazards, risk level, risk explanation, and driving-action explanation, respectively.

The query set for structured driving actions was defined as follows:

$$Q_{action} = \{q_{control}, q_{turn}, q_{lane}, q_{meta}\}$$

Here, $q_{control}$ represents `control_action`; q_{turn} represents `turn_action`; q_{lane} represents `lane_action`; q_{meta} represents the driving behaviors expected to be generated in the `meta_actions` field.

For each test image, the structured scene context obtained from the BDD100K annotations was also provided to the model as input. This scene information for the (i). image was defined as follows:

$$S_i = \{weather, scene, timeofday, road_users, traffic_light_colors, \\ traffic_sign_count, drivable_area_present, lane_elements\}$$

The set of six few-shot examples was defined as follows:

$$F = (I_j, S_j, A_j)_{j=1}^6$$

Here, I_j represents the example driving image, S_j represents the scene_annotations associated with the image and A_j represents the expected manual_annotations output for the corresponding example. These six examples were kept completely independent of the main test set.

Accordingly, (i) the input presented to the model for the test image,

$$P_i = [C, F, I_i, S_i]$$

is defined as follows. Here, C denotes the fixed command context used consistently across all test examples. This context includes the task instructions, annotation rules, the fields expected to be generated within the scope of Q_{scene} and Q_{action} , and the JSON output schema. F denotes the few-shot examples; I_i denotes the driving image under evaluation; and S_i denotes the structured scene information associated with this image.

The predicted annotation output for the evaluated Vision Language Model (M) is,

$$\hat{A}_i = M(P_i)$$

The predicted output of the evaluated Vision-Language Model (M) was defined as follows. The model output represents the predicted manual_annotations, while the corresponding reference manual_annotations were withheld during inference and used only for post-experiment evaluation, preventing target-information leakage.

In the main benchmark, both models were evaluated through the same Ollama-based API using fixed generation parameters (temperature=0, seed=42, num_predict=512) and JSON-formatted outputs to ensure comparable inference conditions. Responses were stored as raw text and parsed as JSON; invalid outputs were recorded with their corresponding errors. Request time, model loading time, input/output token counts, and Ollama-reported inference metrics were also recorded for each inference.

Model Selection and Main Benchmark Experiment

In the pilot stage, Qwen2.5-VL 3B, LLaVA-Phi3, SmolVLM-500M, Moondream, MiniCPM-V, and Ministral were evaluated on the NVIDIA Jetson Orin Nano. Selection criteria included long-context handling, JSON-schema compliance, visual-textual consistency, and inference stability. LLaVA-Phi3 and Ministral occasionally terminated early or produced invalid JSON, SmolVLM-500M generated repetitive or structurally invalid outputs, and Moondream could not process the full few-shot context because of its context-window limitation. These exclusions reflect incompatibility with the adopted hardware and protocol rather than general model capability.

Qwen2.5-VL 3B and MiniCPM-V were therefore selected for the main benchmark because they reliably processed the standardized few-shot context and generated valid JSON outputs. Both were evaluated under comparable Ollama-based conditions using the same API, prompt, and fixed generation parameters. Model-specific differences in parameter scale, quantization, context window, and visual encoder architecture were considered when interpreting the results.

Evaluation Metrics

Model outputs were compared with the manually verified reference annotations using field-specific metrics for task performance, structured-output compliance, and inference performance. Because the annotation fields have different structures, no single overall score was used.

The visibility, road_surface, risk_level, control_action, turn_action, and lane_action fields were treated as categorical variables and evaluated using accuracy, as defined in Equation (1).

$$Accuracy = \frac{N_{correct}}{N_{total}} \quad (1)$$

Here, $N_{correct}$ denotes the number of correct predictions, and N_{total} the total number of evaluated samples.

Because the hazards field may contain multiple items per image, it was evaluated using precision, recall, and F1 score rather than single-class accuracy. Correctly identified hazards were treated as True Positives (TP), additional model-generated hazards as False Positives (FP), and missed reference hazards as False Negatives (FN), as defined in Equations (2)–(4).

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

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

Precision measures the proportion of predicted hazards that match the reference annotations, recall measures the proportion of reference hazards successfully identified, and F1 represents their harmonic mean.

The meta_actions field was also evaluated as a multi-label output. Correct, additional, and missed actions were aggregated as TP, FP, and FN, and precision, recall, and F1 were calculated using Equations (2)–(4).

Structured-output compliance was evaluated by checking whether each response could be parsed as valid JSON. Format Compliance was calculated as the proportion of valid JSON responses among all evaluated outputs, as defined in Equation (5).

$$\text{Format Compliance} = \frac{N_{\text{valid JSON}}}{N_{\text{evaluated}}} \times 100 \quad (5)$$

Here, $N_{\text{validJSON}}$ represents the number of JSON responses that were successfully parsed, while $N_{\text{evaluated}}$ represents the total number of model outputs included in the evaluation.

In addition to task performance, the runtime of the models on the NVIDIA Jetson Orin Nano was also recorded. For each image, the total request time (request_time), the total processing time reported by Ollama (total_duration), the model loading time (load_duration) and the output generation time (eval_duration) were tracked. The arithmetic mean of each timing metric was calculated on a per-model basis using Equation (6).

$$\bar{t} = \frac{1}{N} \sum_{i=1}^N t_i \quad (6)$$

Here, t_i represents the time measured for the corresponding image, N represents the total number of evaluated images, and $(\bar{t})$ represents the average time for the model. request_time denotes the end-to-end time from sending the request by the client until its completion; total_duration represents the total processing time reported by Ollama; load_duration denotes the time required to load the model into memory; and eval_duration represents the evaluation time spent generating the output tokens. Evaluating these timing metrics separately made it possible to distinguish the overall response time from the direct output generation time.

Within the scope of this evaluation framework, Qwen2.5-VL 3B and MiniCPM-V were compared in terms of the classification of environmental conditions, the identification of visible hazards, the generation of structured driving actions, compliance with the JSON format, and inference times on the Jetson Orin Nano.

CONCLUSION AND DISCUSSION

This study evaluated lightweight Vision-Language Models for adverse-weather driving-scene analysis on the NVIDIA Jetson Orin Nano. Based on the pilot evaluation, Qwen2.5-VL 3B and MiniCPM-V were selected and compared using the same prompting structure and evaluation criteria, without fine-tuning. The main benchmark results are summarized in Table 3.

Table 3: Qwen2.5-VL 3B and MiniCPM-V key benchmark results

Assessment criterion	Qwen2.5-VL 3B	MiniCPM-V
Number of Evaluated Images	153	153
Visibility Accuracy (%)	68.63	63.16
Road Surface Accuracy (%)	72.55	78.95
Risk Level Accuracy (%)	70.59	68.42
Control Action Accuracy (%)	56.21	38.16
Turn Action Accuracy (%)	99.35	82.89
Lane Action Accuracy (%)	97.39	81.58
Hazard Precision	0.441	0.338
Hazard Recall	0.250	0.220
Hazard F1	0.319	0.267
Meta-action Precision	0.497	0.617
Meta-action Recall	0.415	0.149
Meta-action F1	0.453	0.241
Format Compliance (%)	100	100
Average Total Duration (s)	198.15	197.51
Average Load Duration (s)	4.17	29.75
Average Eval Duration (s)	15.02	72.32

Environmental Recognition and Classification Performance

Performance varied across environmental classification tasks. Qwen2.5-VL 3B achieved higher accuracy in visibility (68.63%) and risk-level classification (70.59%) than MiniCPM-V (63.16% and 68.42%, respectively), whereas MiniCPM-V performed better in road-surface classification (78.95% vs. 72.55%). The overall comparison is shown in Figure 3.




Figure 3. Task-level performance comparison of Qwen2.5-VL 3B and MiniCPM-V in the main benchmark experiment

Neither model was superior across all environmental classification tasks. Qwen2.5-VL 3B performed better in visibility and risk assessment, whereas MiniCPM-V achieved higher road-surface classification accuracy. These results suggest that model selection should consider the specific perception and reasoning requirements of the target autonomous-driving task rather than a single overall metric.

Evaluation of Structured Driving Actions

Qwen2.5-VL 3B outperformed MiniCPM-V in control_action (56.21% vs. 38.16%), turn_action (99.35% vs. 82.89%), and lane_action (97.39% vs. 81.58%). For both models, control_action accuracy was lower than turn and lane decisions, suggesting greater difficulty in longitudinal-control assessment.

Hazard Identification and Meta-Action Analysis

Qwen2.5-VL 3B achieved higher F1 scores for hazards (0.319 vs. 0.267) and meta_actions (0.453 vs. 0.241). The relatively low recall values indicate that both models missed some reference items, while text-based matching may also have penalized semantically equivalent expressions.

Inference Performance and Edge Hardware Dynamics

Both models achieved 100% JSON-format compliance among successfully completed outputs. Qwen2.5-VL 3B had a shorter average output-generation time than MiniCPM-V (15.02 s vs. 72.32 s). However, their average Ollama-reported total durations were similar (198.15 s and 197.51 s, respectively). Thus, Qwen2.5-VL 3B's timing advantage was specific to output

generation and did not translate into a shorter total processing time. The measured latencies do not demonstrate suitability for real-time driving control.

Research Limitations

The study is limited by the evaluation of only two VLMs, strict matching for open-ended hazards and meta_actions fields, the use of manually verified references rather than absolute ground truth, and one MiniCPM-V inference failure due to a hardware-related timeout.

Results were aggregated across all six weather categories, including clear conditions; therefore, performance under individual adverse weather conditions was not assessed separately. The models also received structured scene annotations alongside the images, so the findings reflect image-and-context-based analysis.

Conclusion

Qwen2.5-VL 3B and MiniCPM-V were compared on the NVIDIA Jetson Orin Nano for adverse-weather driving-scene analysis using the same few-shot protocol without fine-tuning. Qwen2.5-VL 3B showed more balanced performance across visibility, risk, structured actions, hazards, and meta-actions, whereas MiniCPM-V achieved the highest road-surface classification accuracy (78.95%).

Qwen2.5-VL 3B had a shorter average output-generation time, with an average eval_duration of 15.02 s compared with 72.32 s for MiniCPM-V, although their average total processing times were similar. These findings indicate that model selection for the evaluated edge-device setting should consider task performance, output reliability, and both output-generation and total processing times.

Future work will evaluate additional lightweight VLMs and explore semantic similarity-based metrics, LoRA/QLoRA-based fine-tuning, and hardware-aware inference optimization.

REFERENCES

- Cui, E., Wang, W., Li, Z., Xie, J., Zou, H., Deng, H., Luo, G., Lu, L., Zhu, X., & Dai, J. (2025). DriveMLM: Aligning multi-modal large language models with behavioral planning states for autonomous driving. *Visual Intelligence*, 3, Article 22. <https://doi.org/10.1007/s44267-025-00095-w>
- dusty-nv. (n.d.). *Jetson-inference* [Source code]. GitHub. Retrieved September 1, 2026, from <https://github.com/dusty-nv/jetson-inference>
- ge25nab. (n.d.). *Awesome-VLM-AD-ITS* [Source code]. GitHub. Retrieved September 1, 2026, from <https://github.com/ge25nab/Awesome-VLM-AD-ITS>
- Hassani, H., Nikan, S., & Shami, A. (2025). *TinyDrive: Multiscale visual question answering with selective token routing for autonomous driving* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2505.15564>
- He, Y., & Shi, W. (2025). *CARScenes: Semantic VLM dataset for safe autonomous driving* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2511.10701>

- Ma, C., Hua, Z., Anderson-Frey, A., Iyer, V., Liu, X., & Qin, L. (2024). *WeatherQA: Can multimodal language models reason about severe weather?* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2406.11217>
- NVIDIA. (n.d.). *Jetson developer kits*. NVIDIA Developer. Retrieved September 1, 2026, from <https://developer.nvidia.com/embedded/jetson-developer-kits>
- NVIDIA. (n.d.). *Jetson Orin Nano Developer Kit user guide: Update firmware*. Retrieved September 1, 2026, from https://docs.nvidia.com/jetson/orin-nano-devkit/user-guide/latest/update_firmware.html
- NVIDIA. (n.d.). *NanoVLM: Efficient multimodal pipeline*. Jetson AI Lab. Retrieved September 1, 2026, from https://www.jetson-ai-lab.com/archive/tutorial_nano-vlm.html
- Sarwar, F., Raja, B. A., Ibrahim, M., Zeb, A., Khan, U. S., & Asad, U. (2026). Benchmarking local vision-language models on an edge device for the visually impaired. In *2026 International Conference on Robotics and Automation in Industry (ICRAI)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICRAI70912.2026.11551964>
- Shin, H., Kim, C., Kim, R., Yoo, H., & Kim, J. (2026). *Rethinking small VLM quantization: From component-wise analysis to hardware-aware edge deployment* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2607.08029>
- Sima, C., Renz, K., Chitta, K., Chen, L., Zhang, H., Xie, C., Beißwenger, J., Luo, P., Geiger, A., & Li, H. (2024). DriveLM: Driving with graph visual question answering. In *Computer Vision – ECCV 2024* (pp. 256–274). Springer. https://doi.org/10.1007/978-3-031-72943-0_15
- Tian, X., Gu, J., Li, B., Liu, Y., Wang, Y., Zhao, Z., Zhan, K., Jia, P., Lang, X., & Zhao, H. (2025). DriveVLM: The convergence of autonomous driving and large vision-language models. In P. Agrawal, O. Kroemer, & W. Burgard (Eds.), *Proceedings of the 8th Conference on Robot Learning* (Vol. 270, pp. 4698–4726). Proceedings of Machine Learning Research.
- Xu, Y., Hu, Y., Zhang, Z., Meyer, G. P., Mustikovela, S. K., Srinivasa, S., Wolff, E. M., & Huang, X. (2025). VLM-AD: End-to-end autonomous driving through vision-language model supervision. In J. Lim, S. Song, & H.-W. Park (Eds.), *Proceedings of the 9th Conference on Robot Learning* (Vol. 305, pp. 3778–3803). Proceedings of Machine Learning Research.
- Xu, Z., Zhang, Y., Xie, E., Zhao, Z., Guo, Y., Wong, K.-Y. K., Li, Z., & Zhao, H. (2024). DriveGPT4: Interpretable end-to-end autonomous driving via large language model. *IEEE Robotics and Automation Letters*, 9(10), 8186–8193. <https://doi.org/10.1109/LRA.2024.3440097>
- Zhou, X., Liu, M., Yurtsever, E., Zagar, B. L., Zimmer, W., Cao, H., & Knoll, A. C. (2024). Vision language models in autonomous driving: A survey and outlook. *IEEE Transactions on Intelligent Vehicles*, 9(7), 1–20. <https://doi.org/10.1109/TIV.2024.3402136>
- Zhou, X., Shan, L., & Gui, X. (2025). *DynRsl-VLM: Enhancing autonomous driving perception with dynamic resolution vision-language models* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2503.11265>

LAMİNE AHŞAP KİRİŞLERİN YAPISAL DAVRANIŞININ DEĞERLENDİRİLMESİNE YÖNELİK KAVRAMSAL BİR PARAMETRİK TASARIM ÇERÇEVESİ

A CONCEPTUAL PARAMETRIC DESIGN FRAMEWORK FOR THE ASSESSMENT OF
STRUCTURAL BEHAVIOUR OF GLULAM BEAMS

Lecturer Dr. İsmail KILIÇ

Yozgat Bozok University, Yozgat Vocational School, Department of Design, Yozgat, Türkiye
ORCID ID: 0000-0003-3609-2616

ÖZET

Bu çalışmada, lamine ahşap (glulam) kirişlerin yapısal davranışını etkileyen temel tasarım parametreleri kavramsal bir çerçevede ele alınmış ve parametrik tasarım yaklaşımının bu elemanların değerlendirilmesindeki rolü incelenmiştir. Ahşap malzemenin anizotrop yapısı ve lamine üretim tekniği nedeniyle, kesit boyutları, açıklık uzunluğu, katman sayısı ve dizilimi, lif yönelimi ve eğrilik gibi parametrelerin kiriş davranışı üzerinde belirleyici olduğu bilinmektedir. Bununla birlikte, yüzey takviyeleri ve ön gerilme etkileri gibi ilave faktörler de yapısal performansı önemli ölçüde değiştirebilmektedir.

Literatürde bu parametrelerin çoğunlukla deneysel veya sayısal çalışmalar kapsamında ayrı ayrı ele alındığı, buna karşın tasarım sürecinin erken aşamalarında parametreler arasındaki etkileşimleri bütüncül bir yaklaşımla değerlendiren kavramsal çalışmaların sınırlı olduğu görülmektedir. Bu çalışma, söz konusu boşluğa katkı sağlamak amacıyla geliştirilmiştir.

Bu kapsamda, söz konusu parametrelerin eğilme davranışı, rijitlik, gerilme dağılımı ve hasar mekanizmaları üzerindeki etkileri temel mekanik prensipler ve literatür bulguları doğrultusunda sistematik olarak değerlendirilmiştir. Parametrelerin tekil olarak değil, etkileşimli bir sistem içerisinde ele alınması gerektiği ortaya konulmuş ve bu doğrultuda kavramsal bir parametrik tasarım çerçevesi önerilmiştir.

Elde edilen bulgular, lamine ahşap kirişlerin tasarımında çok parametrelili bir yaklaşımın benimsenmesinin daha gerçekçi ve güvenilir sonuçlar sağlayacağını göstermektedir. Önerilen kavramsal çerçevenin, ön tasarım aşamasında sistematik bir karar destek aracı olarak kullanılmasının yanı sıra, gelecekte gerçekleştirilecek deneysel çalışmalar, sayısal modelleme ve optimizasyon temelli araştırmalar için de yol gösterici bir temel oluşturabileceği değerlendirilmektedir.

Anahtar Kelimeler: Lamine ahşap kirişler, parametrik tasarım, yapısal davranış, eğrisel kirişler, ön gerilme, takviye.

ABSTRACT

This study conceptually examines the fundamental design parameters affecting the structural behaviour of glued laminated timber (glulam) beams and investigates the role of a parametric design approach in the evaluation of these structural elements. Due to the anisotropic nature of

wood and the laminated manufacturing process, parameters such as cross-sectional dimensions, span length, number and arrangement of laminations, fibre orientation, and curvature are known to play a decisive role in beam behaviour. In addition, supplementary factors, including surface reinforcement and prestressing effects, can significantly influence structural performance.

Previous studies have generally investigated these parameters individually through experimental or numerical analyses. However, conceptual studies that comprehensively evaluate the interactions among these parameters during the early stages of the design process remain limited. This study was therefore conducted to contribute to this research gap.

Within this framework, the effects of the identified parameters on bending behaviour, stiffness, stress distribution, and failure mechanisms were systematically evaluated based on fundamental mechanical principles and findings reported in the literature. It is emphasized that these parameters should be considered as an interactive system rather than as independent variables. Accordingly, a conceptual parametric design framework is proposed.

The findings indicate that adopting a multi-parameter approach in the design of glulam beams can provide more realistic and reliable design outcomes. Furthermore, the proposed conceptual framework is expected to serve as a systematic decision-support tool during the preliminary design stage and to provide a foundation for future experimental investigations, numerical modelling, and optimization-based studies.

Keywords: Glulam beams, parametric design, structural behaviour, curved beams, prestressing, reinforcement.


GİRİŞ

Ahşap malzeme, yenilenebilir bir doğal kaynak olması, düşük yoğunluğuna karşın yüksek özgül dayanım değerlerine sahip olması ve işlenebilirliğinin kolay olması nedeniyle yapı ve tasarım alanlarında yaygın olarak kullanılan önemli bir mühendislik malzemesidir. Özellikle son yıllarda sürdürülebilirlik, karbon depolama kapasitesi ve çevre dostu üretim süreçleri gibi avantajları sayesinde ahşap malzemeye olan ilgi giderek artmaktadır (Ramage ve diğ., 2017; Sathre ve O'Connor, 2010). Bu bağlamda, mühendislik ürünü ahşap malzemeler arasında yer alan lamine ahşap (glulam) kirişler, hem taşıyıcı performansları hem de mimari esneklikleri sayesinde modern yapı sistemlerinde önemli bir yer edinmiştir (Forest Products Laboratory, 2010; Brandner ve diğ., 2016).

Lamine ahşap kirişler, ince kesitli lamellerin uygun yapıştırıcılar ile bir araya getirilmesiyle elde edilmekte olup, bu üretim yöntemi sayesinde doğal ahşabın kusurları minimize edilmekte ve daha homojen bir malzeme yapısı elde edilmektedir (Bodig ve Jayne, 1982; Dinwoodie, 2000). Ayrıca, farklı katman düzenlemeleri ve eğrisel geometriler oluşturulabilmesi, bu elemanların yalnızca doğrusal taşıyıcılar olarak değil, aynı zamanda mimari tasarımın aktif bileşenleri olarak kullanılmasına olanak sağlamaktadır (Brandner ve diğ., 2016; Sandberg ve diğ., 2017). Bu yönüyle lamine kirişler, hem mühendislik hem de iç mekân tasarımı disiplinlerinin kesişim noktasında yer almaktadır.

Lamine ahşap kirişlerin yapısal davranışı; kesit boyutları, açıklık uzunluğu, katman sayısı, katman dizilimi, lif yönelimi ve eğrilik gibi çok sayıda parametrenin bir arada etkisi altında şekillenmektedir (Gere ve Timoshenko, 1997; Thelandersson ve Larsen, 2003). Bununla birlikte, son yıllarda kiriş performansını artırmaya yönelik olarak kullanılan yüzey takviyeleri (örneğin kontrplak, lif takviyeli polimerler vb.) ve ön gerilme uygulamaları da yapısal davranışı belirleyen önemli faktörler arasında yer almaktadır (Triantafillou, 1997; Borri ve diğ., 2005; Schober ve diğ., 2015). Özellikle eğrisel geometriye sahip lamine kirişlerde üretim sürecine bağlı olarak oluşan pasif ön gerilme etkileri, kesit içerisindeki gerilme dağılımını değiştirebilmekte ve taşıma kapasitesi ile deformasyon davranışı üzerinde belirleyici olabilmektedir (Ranta-Maunus, 2001; Anshari ve diğ., 2012; Anshari ve diğ., 2017).

Lamine ahşap kirişlerde yapısal davranışı etkileyen temel parametrik değişkenler ve bu değişkenlerin sistematik sınıflandırılması Şekil 1’de şematik olarak gösterilmektedir. Bu değişkenlerin birleşik etkisi, kirişin genel yapısal performansını belirleyen temel mekanizmayı oluşturmaktadır



Şekil 1. Lamine ahşap kirişlerde yapısal davranışı belirleyen temel parametrik değişkenlerin ve etkileşimlerinin şematik gösterimi

Literatürde bu parametrelerin etkilerini inceleyen çalışmaların büyük çoğunluğu deneysel ve sayısal analizlere dayanmaktadır. Ancak, tasarım sürecinin özellikle erken aşamalarında, bu parametrelerin ve söz konusu ilave etkilerin yapısal davranış üzerindeki rolünün bütüncül bir bakış açısıyla değerlendirilmesine yönelik çalışmaların sınırlı olduğu görülmektedir. Bu durum, tasarımcı ve araştırmacıların karar verme süreçlerinde sistematik bir parametrik yaklaşım ihtiyacını ortaya koymaktadır (Oxman, 2017; Shea ve diğ., 2005; Kicing ve diğ., 2005).

Bu çalışmada, lamine ahşap kirişlerin tasarımında etkili olan temel parametreler kavramsal bir çerçevede ele alınmıştır. Deneysel sonuç sunmayı amaçlamayan bu çalışmada; kesit boyutları, açıklık, katman sayısı ve dizilimi, lif yönelimi ve eğrilik gibi parametrelerin yapısal davranış üzerindeki olası etkileri, temel mekanik prensipler ve literatür bulguları doğrultusunda değerlendirilmiştir. Bu kapsamda, söz konusu parametrelerin eğilme davranışı, rijitlik, gerilme dağılımı ve olası hasar mekanizmaları üzerindeki etkileri sistematik olarak tartışılmış ve tasarım

sürecinde kullanılabilecek kavramsal bir parametrik yaklaşım önerilmiştir (Arora, 2004; Kolarevic, 2003; Schumacher, 2009). Bu çalışma, literatürde çoğunlukla ayrı ayrı ele alınan parametreleri bütüncül bir parametrik model altında birleştirerek kavramsal bir tasarım yaklaşımı önermektedir.

PARAMETRİK TASARIM YAKLAŞIMI VE TEMEL PARAMETRELER

Lamine ahşap kirişlerin tasarımında, yapısal performansın tek bir değişkene bağlı olarak değerlendirilmesi çoğu zaman yeterli olmamakta; bunun yerine birden fazla parametrenin birlikte ele alındığı bütüncül bir yaklaşım gerekmektedir. Bu bağlamda parametrik tasarım yaklaşımı, kiriş davranışını etkileyen temel değişkenlerin sistematik olarak incelenmesine ve bu değişkenler arasındaki etkileşimlerin değerlendirilmesine olanak sağlamaktadır (Oxman, 2017; Shea ve diğ., 2005).

Parametrik tasarım, belirli tasarım değişkenlerinin kontrollü bir biçimde değiştirilmesi ve bu değişimlerin yapısal davranış üzerindeki olası etkilerinin analiz edilmesine dayanmaktadır. Lamine ahşap kirişler özelinde bu değişkenler; kesit boyutları, açıklık uzunluğu, katman sayısı ve dizilimi, lif yönelimi, eğrilik, takviye uygulamaları ve ön gerilme etkileri olarak öne çıkmaktadır. Bu parametrelerin her biri, tek başına önemli olmakla birlikte birlikte değerlendirildiklerinde kirişin eğilme davranışı, rijitliği, gerilme dağılımı ve hasar mekanizmaları üzerinde belirleyici bir rol oynamaktadır (Kicinger ve diğ., 2005; Kolarevic, 2003).

Bu bağlamda söz konusu parametreler, Şekil 1’de sunulan sistematik çerçeve doğrultusunda ele alınmaktadır.

Kesit Boyutları

Kesit boyutları, özellikle kesit yüksekliği, lamine ahşap kirişlerin eğilme davranışını doğrudan etkileyen en temel parametrelerden biridir. Kiriş yüksekliğinin artması, kesitin atalet momentini artırarak eğilme rijitliğinin yükselmesine ve buna bağlı olarak sehim değerlerinin azalmasına katkı sağlamaktadır (Gere ve Timoshenko, 1997; Bodig ve Jayne, 1982).

$$I = \frac{bh^3}{12}$$

Burada I , kesitin atalet momentini, b kesit genişliğini ve h kesit yüksekliğini ifade etmektedir. İfade incelendiğinde, kesit yüksekliğinin kübik etkisi nedeniyle eğilme rijitliği üzerinde belirleyici bir rol oynadığı açıkça görülmektedir.

Açıklık Uzunluğu

Açıklık uzunluğu, kirişte oluşan eğilme momenti ve sehim değerleri üzerinde doğrudan etkili bir parametredir. Açıklığın artması ile birlikte maksimum eğilme momenti ve deformasyon değerlerinin artması beklenmektedir. Bu durum, daha büyük kesit boyutlarının veya alternatif

tasarım çözümlerinin gerekliliğini ortaya koymaktadır (EN 1995-1-1, 2004; ASTM D198, 2015).

$$f \propto L^3$$

Burada f sehim miktarını, L ise açıklık uzunluğunu ifade etmektedir. İfade incelendiğinde, açıklık uzunluğunun artmasıyla birlikte sehim değerlerinin kübik olarak arttığı görülmektedir. Bu durum, özellikle büyük açıklıklarda deformasyonların hızla artmasına neden olmakta ve tasarım sürecinde açıklık uzunluğunun kritik bir parametre olarak dikkate alınmasını gerektirmektedir.

Katman Sayısı ve Katman Dizilimi

Lamine ahşap kirişlerde katman sayısı ve katmanların dizilimi, kesit içerisindeki gerilme dağılımını ve yük aktarım mekanizmasını doğrudan etkilemektedir. Katman sayısının artması, malzemenin daha homojen bir davranış sergilemesine katkı sağlarken, katman diziliminin simetrik veya asimetrik olması kesit stabilitesi ve eğilme performansı üzerinde belirleyici olabilmektedir (Bayatkashkoli ve diğ., 2011; Türker ve Kılınçarslan, 2024). Ayrıca modern çalışmalar, katman organizasyonunun eğilme davranışı ve elastisite modülü üzerinde önemli etkiler oluşturduğunu göstermektedir (Kytka ve diğ., 2024).

$$E_{etk} = f(n, dizilim)$$

Burada E_{etk} , katman sayısı ve katman diziliminin kesit davranışı üzerindeki birleşik etkisini temsil eden etkin elastisite modülünü ifade etmektedir. İfade, katman sayısı (n) ve diziliminin birlikte değerlendirilmesi gerektiğini ve bu parametrelerin kirişin mekanik performansı üzerinde belirleyici olduğunu göstermektedir.

Lif Yönelimi

Ahşap malzemenin anizotrop yapısı nedeniyle lif yönelimi, mekanik davranış üzerinde önemli bir etkiye sahiptir. Liflere paralel yerleşim yüksek dayanım ve rijitlik sağlarken, liflere dik veya çapraz yerleşimler çatlak ilerlemesini sınırlayarak daha sünek bir davranış ortaya koyabilmektedir (Dinwoodie, 2000; Bodig ve Jayne, 1982). Ayrıca lif yöneliminin malzeme sınıflandırma ve performans üzerinde belirleyici olduğu da literatürde vurgulanmaktadır (Hanhijärvi ve diğ., 2005).

$$R \propto \varphi_{\theta}$$

Burada R , kirişin yapısal performansını (dayanım, rijitlik vb.) temsil ederken, φ_{θ} lif yöneliminin bu performans üzerindeki etkisini ifade eden katsayıyı göstermektedir. Bu ifade, lif yöneliminin değişmesiyle birlikte kiriş davranışının önemli ölçüde farklılaşabileceğini ortaya koymaktadır.

Eğrilik

Eğrisel geometriye sahip lamine ahşap kirişlerde, doğrusal kirişlerden farklı olarak kesit içerisinde ilave gerilme bileşenleri oluşabilmektedir. Eğrilik arttıkça, lif yönüne paralel olmayan gerilmelerin etkisi belirgin hale gelmekte ve bu durum kırılma davranışını doğrudan

etkileyebilmektedir (Ranta-Maunus, 2001; Yu ve diğ., 2023). Ayrıca deneysel çalışmalar, eğrisel kirişlerde üretim sürecine bağlı olarak oluşan ön gerilmelerin davranışı önemli ölçüde değiştirdiğini göstermektedir (Anshari ve diğ., 2012; Gowda ve diğ., 1998).

$$R \propto \varphi_{\kappa}$$

Burada R , kirişin yapısal performansını temsil ederken, φ_{κ} eğriliğin kesit içerisindeki gerilme dağılımı üzerindeki etkisini ifade eden katsayıyı göstermektedir. Bu ifade, eğrilik arttıkça kiriş davranışının doğrusal sistemlerden saparak farklı kırılma mekanizmaları sergileyebileceğini ortaya koymaktadır.

akviye Uygulamaları ve Ön Gerilme Etkileri

Lamine ahşap kirişlerde performansı artırmak amacıyla uygulanan yüzey takviyeleri ve ön gerilme uygulamaları, kesit davranışını önemli ölçüde değiştirebilmektedir. FRP ve benzeri takviye malzemeleri, özellikle çekme bölgesinde gerilme yığılmalarını azaltarak taşıma kapasitesinin artırılmasına katkı sağlamaktadır (Triantafillou, 1997; Borri ve diğ., 2005). Güncel çalışmalar, bu tür güçlendirme tekniklerinin kiriş rijitliği ve dayanımı üzerinde önemli iyileştirmeler sağladığını göstermektedir (Schober et al., 2015).

$$R = f(T, P)$$

Parametrik Tasarım Yaklaşımları

Lamine ahşap kirişlerin tasarımında parametrik yaklaşım, yapısal davranışı etkileyen değişkenlerin sistematik olarak tanımlanması ve bu değişkenler arasındaki ilişkilerin analiz edilmesine dayanmaktadır (Oxman, 2017; Shea ve diğ., 2005). Bu kapsamda parametrik tasarım yaklaşımları geometrik, malzeme, lif yönelimi, eğrilik, takviye ve ön gerilme temelli olarak sınıflandırılabilir (Kolarevic, 2003; Schumacher, 2009).

Bu kapsamda literatürde ve mühendislik uygulamalarında öne çıkan başlıca parametrik yaklaşım türleri aşağıda sunulmuştur.

Geometrik Parametrik Yaklaşım

Bu yaklaşım, kirişin boyutsal özelliklerine odaklanmaktadır. Kesit yüksekliği (h), kesit genişliği (b), açıklık uzunluğu (L) ve eğrilik (κ) gibi parametreler, eğilme rijitliği ve sehim davranışı üzerinde doğrudan etkilidir. Özellikle kesit yüksekliğinin artması, atalet momentini artırarak deformasyonların azalmasına katkı sağlamaktadır. Bu nedenle geometrik parametreler, kiriş davranışının temel belirleyicileri arasında yer almaktadır.

Malzeme ve Katman Parametrik Yaklaşımı

Bu yaklaşım, lamine yapının iç organizasyonuna odaklanmaktadır. Katman sayısı (n), katman dizilimi ve lamellerin mekanik özellikleri, kesit içerisindeki gerilme dağılımını doğrudan etkilemektedir. Katman sayısının artması, daha homojen bir davranış sağlarken, özellikle dış katmanlarda yer alan yüksek dayanımlı lameller, kirişin taşıma kapasitesini artırmaktadır.

Lif Yönelimi Parametrik Yaklaşımı

Ahşap malzemenin anizotrop yapısı nedeniyle lif yönelimi (θ) kritik bir parametredir. Liflere paralel yerleşim yüksek dayanım sağlarken, farklı yönelimler çatlak ilerlemesini sınırlayarak daha sünek bir davranış ortaya koyabilmektedir. Bu nedenle lif yönelimi, hem dayanım hem de hasar mekanizması açısından belirleyici bir faktördür.

Eğrilik Parametrik Yaklaşımı

Eğrilik (κ), özellikle eğrisel lamine kirişlerde kesit içerisindeki gerilme dağılımını değiştiren önemli bir parametredir. Eğrilik arttıkça, lif yönüne paralel olmayan gerilme bileşenleri ortaya çıkmakta ve bu durum kırılma davranışını doğrudan etkilemektedir.

Takviye Parametrik Yaklaşımı

Takviye parametresi (T), kiriş performansını artırmaya yönelik uygulamaları kapsamaktadır. Kontrplak, lif takviyeli polimerler veya çelik elemanlar gibi takviye malzemeleri, özellikle çekme bölgesinde gerilme yığılmalarını azaltarak taşıma kapasitesinin artırılmasına katkı sağlamaktadır.

Ön Gerilme Parametrik Yaklaşımı

Ön gerilme (P), özellikle eğrisel lamine kirişlerde üretim sürecine bağlı olarak ortaya çıkan pasif ön gerilme etkilerini kapsamaktadır. Bu etkiler, kesit içerisindeki başlangıç gerilme dağılımını değiştirerek kirişin yük altındaki davranışını etkilemektedir.

Performans Tabanlı Parametrik Yaklaşım

Bu yaklaşımda amaç, farklı parametrelerin birleşik etkisi altında kiriş performansının değerlendirilmesidir. Rijitlik, dayanım, sehim ve hasar davranışı gibi kriterler birlikte ele alınarak tasarım kararları verilmektedir.

Optimizasyon Tabanlı Parametrik Yaklaşım

Parametrik tasarımın ileri aşamasında, amaç fonksiyonlarının tanımlandığı optimizasyon yaklaşımları kullanılabilir. Bu kapsamda kiriş performansı aşağıdaki şekilde ifade edilebilir:

$\max \Pi$

Bu yaklaşımda sehim ve gerilme sınırları gibi kısıtlar dikkate alınarak en uygun tasarım parametrelerinin belirlenmesi hedeflenmektedir. Ancak bu tür yaklaşımlar genellikle deneysel veya sayısal doğrulama gerektirmektedir.


Genel Değerlendirme (Model Bağlantısı)

Yukarıda sunulan parametrik yaklaşımlar birlikte değerlendirildiğinde, lamine ahşap kirişlerin davranışının tek bir değişkene bağlı olmadığı, aksine çok parametrelili bir sistem olarak ele

alınması gerektiği anlaşılmaktadır. Bu bağlamda kiriş davranışı genel olarak aşağıdaki şekilde ifade edilebilir:

$$R=f(h,b,L,n,\theta,\kappa,T,P)$$

Bu ifade, geometrik, malzeme ve yapısal iyileştirme parametrelerinin birleşik etkisinin kiriş performansını belirlediğini ortaya koymaktadır. Aynı zamanda bu model, parametrik tasarım yaklaşımının temelini oluşturarak farklı tasarım alternatiflerinin sistematik olarak değerlendirilmesine olanak sağlamaktadır (Arora, 2004; Kicinger ve diğ., 2005). Bu parametrik modelin kavramsal gösterimi Şekil 2’de sunulmuştur.



Şekil 2. Lamine ahşap kirişlerde parametrik tasarım modelinin kavramsal gösterimi

MEKANİK DAVRANIŞIN PARAMETRİK OLARAK DEĞERLENDİRİLMESİ


Lamine ahşap kirişlerin yapısal davranışı, birden fazla parametrenin eş zamanlı etkisi altında şekillenmekte olup, bu parametrelerin her biri eğilme davranışı, rijitlik, gerilme dağılımı ve hasar mekanizmaları üzerinde farklı düzeylerde etkili olmaktadır. Bu bağlamda, kiriş davranışının tek bir değişken üzerinden değerlendirilmesi yeterli olmayıp, çok parametrelili bir sistem yaklaşımı gerekmektedir (Thelandersson ve Larsen, 2003; Kicinger ve diğ., 2005). Bu bölümde, önceki bölümde tanımlanan temel parametrelerin kiriş davranışı üzerindeki olası etkileri, temel mekanik prensipler çerçevesinde kavramsal olarak değerlendirilmiştir.

Eğilme Davranışı ve Rijitlik

Lamine ahşap kirişlerin eğilme davranışı, kesit geometrisi ve açıklık uzunluğu başta olmak üzere çeşitli parametrelerin etkisi altında belirlenmektedir. Kesit yüksekliğinin artması ile eğilme rijitliğinin artması ve buna bağlı olarak sehim değerlerinin azalması beklenmektedir.

Buna karşılık açıklık uzunluğunun artması, kirişte oluşan eğilme momentini ve deformasyon miktarını artırarak daha büyük kesitlerin veya alternatif tasarım çözümlerinin gerekliliğini ortaya koymaktadır (Gere ve Timoshenko, 1997; EN 1995-1-1, 2004).

Eğilme etkisi altındaki bir kirişte deformasyon davranışı ile basınç, çekme ve nötr eksen bölgelerine ilişkin kavramsal gösterim Şekil 3'te sunulmuştur.



Şekil 3. Eğilme etkisi altındaki bir kirişte gerilme dağılımı ve deformasyon davranışının kavramsal gösterimi

Şekil 3'te gösterilen eğilme davranışı, basit kiriş teorisi kapsamında aşağıdaki bağıntı ile ifade edilebilir.

$$f = \frac{FL^3}{48EI}$$

Burada f maksimum sehim miktarını, F uygulanan yükü, L açıklık uzunluğunu, E elastisite modülünü ve I kesitin atalet momentini ifade etmektedir. Bu bağıntı, özellikle açıklık uzunluğunun kübik etkisi ile kesit rijitliğinin eğilme davranışı üzerindeki belirleyici rolünü açıkça ortaya koymaktadır (Gere ve Timoshenko, 1997).

Katman sayısı ve katman dizilimi de rijitlik üzerinde dolaylı bir etkiye sahiptir. Daha fazla sayıda ve dengeli yerleştirilmiş katmanların, kesit içerisinde daha homojen bir gerilme dağılımı sağlayarak daha kararlı bir eğilme davranışı oluşturabileceği değerlendirilmektedir (Bayatkashkoli ve diğ., 2011; Türker ve Kılınçarslan, 2024). Bu bağlamda parametrik tasarım yaklaşımı, rijitlik ve deformasyon performansının birlikte ele alınmasını gerektirmektedir.


Gerilme Dağılımı

Eğilme etkisi altında bir kiriş kesitinde, üst liflerde basınç, alt liflerde ise çekme gerilmeleri oluşmaktadır. Lamine ahşap kirişlerde bu klasik dağılım, katman yapısı, lif yönelimi ve eğrilik gibi parametrelere bağlı olarak değişkenlik gösterebilmektedir (Bodig ve Jayne, 1982; Dinwoodie, 2000). Özellikle katman diziliminin simetrik olmaması veya farklı mekanik özelliklere sahip lamellerin bir arada kullanılması durumunda, kesit içerisinde gerilme yığılmalarının oluşabileceği değerlendirilmektedir (Kytka ve diğ., 2024).

Lif yöneliminin değiştirilmesi, gerilme dağılımını doğrudan etkileyebilen önemli bir parametredir. Liflere paralel yerleşim yüksek taşıma kapasitesi sağlarken, çapraz yerleşimlerin gerilme transferini yeniden düzenleyerek çatlak ilerlemesini sınırlayabileceği düşünülmektedir (Hanhijärvi ve diğ., 2005).

Eğrisel kirişlerde ise doğrusal kirişlerden farklı olarak, kesit içerisinde ilave gerilme bileşenlerinin oluşabileceği ve bu durumun klasik eğilme teorisinden sapmalara neden olabileceği değerlendirilmektedir. Bu nedenle eğrilik parametresi, yalnızca geometrik bir özellik olarak değil, aynı zamanda gerilme dağılımını belirleyen bir faktör olarak ele alınmalıdır (Ranta-Maunus, 2001; Yu ve diğ., 2023).

Eğilme etkisi altında bir kiriş kesitinde oluşan gerilme dağılımına ilişkin şematik gösterim Şekil 4'te sunulmuştur.



Şekil 4. Eğilme etkisi altındaki bir kiriş kesitinde gerilme dağılımının şematik gösterimi

Şekil 4'te gösterilen gerilme dağılımı, klasik eğilme teorisi kapsamında aşağıdaki bağıntı ile ifade edilebilir:

$$\sigma = \frac{My}{I}$$

Burada σ kesit içerisindeki normal gerilmeyi, M eğilme momentini, y nötr eksene olan uzaklığı ve I kesitin atalet momentini ifade etmektedir. Bu bağıntı, gerilmenin nötr eksenden uzaklaştıkça arttığını ve kesit içerisinde doğrusal bir dağılım gösterdiğini ortaya koymaktadır (Gere ve Timoshenko, 1997).

Hasar Mekanizmaları

Lamine ahşap kirişlerde hasar mekanizmaları, çoğunlukla çekme bölgesinde lif kopması, basınç bölgesinde ezilme ve katmanlar arası yapışma hataları şeklinde ortaya çıkmaktadır (Franke ve diğ., 2015). Bu mekanizmaların oluşumu ve ilerleyişi, kirişin geometrik ve malzeme parametrelerine bağlı olarak değişiklik gösterebilmektedir (Bodig ve Jayne, 1982; Dinwoodie, 2000).

Katman sayısı ve dizilimi, hasarın yayılım biçimini etkileyebilecek önemli unsurlar arasında yer almaktadır. Daha fazla katmana sahip kirişlerde, hasarın tek bir düzlemde yoğunlaşmak yerine daha geniş bir alana yayılabileceği değerlendirilmektedir (Vratuša ve diğ., 2011). Lif yönelimi ise çatlak ilerleme yönünü belirleyerek hasar modunun karakterini değiştirebilmektedir.

Eğrilik ve pasif ön gerilme etkilerinin birlikte bulunduğu durumlarda, kesit içerisindeki mevcut gerilme durumu değişebileceğinden, hasarın başlangıç noktası ve ilerleme biçimi farklılaşabilmektedir. Bu durum, özellikle eğrisel kirişlerde hasar mekanizmalarının doğrusal kirişlere kıyasla daha karmaşık bir karakter sergilediğini göstermektedir (Anshari ve diğ., 2012; Gowda ve diğ., 1998). Benzer şekilde gerçekleştirilen deneysel çalışmalarda da, eğrisel

geometri ve takviye uygulamalarının hasar gelişimi ve kırılma davranışı üzerinde belirleyici etkiler oluşturduğu rapor edilmiştir (Kılıç, 2026).

Lamine ahşap kirişlerde gözlemlenen başlıca hasar mekanizmalarına ilişkin örnek görseller Şekil 5'te sunulmuştur.




Şekil 5. Lamine ahşap kirişlerde tipik hasar mekanizmalarının (lif kopması, ezilme ve katman ayrılması) görsel gösterimi

Takviye ve Ön Gerilmenin Etkileri

Lamine ahşap kirişlerde uygulanan yüzey takviyeleri, özellikle çekme bölgesinde oluşan gerilmeleri azaltarak taşıma kapasitesinin artırılmasına katkı sağlayabilmektedir. Takviye elemanlarının, gerilme yığılmalarını dağıtarak daha dengeli bir yük aktarımı oluşturabileceği değerlendirilmektedir (Triantafillou, 1997; Borri ve diğ., 2005). Ayrıca modern çalışmalar, FRP takviyelerinin kiriş rijitliği ve dayanımı üzerinde önemli iyileştirmeler sağladığını ortaya koymaktadır (Schober ve diğ., 2015).

Öte yandan, eğrisel kirişlerin üretimi sırasında ortaya çıkan pasif ön gerilme etkileri, kesit içerisindeki başlangıç gerilme durumunu değiştirebilmektedir. Bu durum, kirişin dış yükler altındaki davranışını etkileyerek, hem deformasyon hem de hasar mekanizmaları üzerinde belirleyici olabilmektedir (Ranta-Maunus, 2001; Anshari ve diğ., 2017).

Takviye uygulamaları ve ön gerilme etkilerinin kiriş davranışı üzerindeki rolüne ilişkin kavramsal gösterim Şekil 6'da sunulmuştur.



Şekil 6. Takviye ve ön gerilme uygulamalarının lamine ahşap kiriş davranışı üzerindeki etkisinin kavramsal gösterimi

Takviye ve ön gerilme etkileri, kiriş performansı açısından aşağıdaki şekilde ifade edilebilir:

$$R = f(T, P)$$

Burada R kirişin yapısal performansını (dayanım, rijitlik ve deformasyon davranışı), T takviye etkisini ve P ön gerilme etkisini ifade etmektedir. Bu ifade, takviye ve ön gerilme etkilerinin kiriş davranışı üzerinde birleşik ve etkileşimli bir rol oynadığını göstermektedir.

PARAMETRİK TASARIM ÇERÇEVESİ VE ÖNERİ MODELİ

Lamine ahşap kirişlerin tasarımında, farklı parametrelerin bir arada değerlendirilmesi gerekliliği, sistematik bir tasarım yaklaşımının oluşturulmasını zorunlu kılmaktadır. Bu bağlamda, önceki bölümlerde kavramsal olarak değerlendirilen parametreler doğrultusunda, lamine ahşap kirişlerin ön tasarım sürecinde kullanılabilecek bir parametrik değerlendirme çerçevesi önerilmektedir. Parametrik tasarım yaklaşımı, birden fazla tasarım değişkeninin kontrollü olarak ele alınmasına ve bu değişkenlerin performans üzerindeki birleşik etkilerinin değerlendirilmesine olanak sağlamaktadır (Oxman, 2017; Shea ve diğ., 2005).

Önerilen bu yaklaşım, tasarım sürecinde dikkate alınması gereken temel parametrelerin belirli bir sıra ve ilişki içerisinde ele alınmasına dayanmaktadır. Bu kapsamda tasarım süreci; geometri, malzeme organizasyonu ve yapısal performans olmak üzere üç temel aşamada değerlendirilmektedir. Bu tür aşamalı sistematik yaklaşımlar, yapı tasarımında karar verme sürecinin rasyonelleştirilmesi ve alternatiflerin karşılaştırılabilir hale getirilmesi açısından önemli avantajlar sağlamaktadır (Kolarevic, 2003; Kicingner ve diğ., 2005).

Geometrik Parametrelerin Belirlenmesi

Tasarım sürecinin ilk aşamasında, kirişin geometrik özellikleri tanımlanmalıdır. Bu kapsamda açıklık uzunluğu, kesit boyutları ve kirişin doğrusal veya eğrisel formda olup olmayacağı belirlenir. Açıklık uzunluğu, sistemin taşıyacağı yükler ve kullanım amacına bağlı olarak seçilmelidir. Kesit boyutları, özellikle kesit yüksekliği, rijitlik ve deformasyon kontrolü açısından kritik rol oynamaktadır. Eğrisel kirişlerde ise eğrilik derecesi yalnızca mimari bir tercih değil, aynı zamanda yapısal davranışı etkileyen bir parametre olarak değerlendirilmelidir (Gere ve Timoshenko, 1997; EN 1995-1-1, 2004; Ranta-Maunus, 2001). Bu aşama, kirişin genel davranışını belirleyen temel çerçeveyi oluşturmaktadır.

Katman Organizasyonu ve Malzeme Parametreleri

İkinci aşamada, lamine yapının iç düzeni tanımlanır. Bu aşama, katman sayısı, katman dizilimi ve lif yönelimi gibi parametreleri kapsamaktadır. Katman sayısının artmasıyla daha dengeli bir yük aktarımı sağlanabileceği, katman diziliminin simetrik olmasının ise kesit stabilitesi açısından avantaj sağlayabileceği değerlendirilmektedir (Bayatkashkoli ve diğ., 2011; Türker

ve Kılınçarslan, 2024). Benzer şekilde, dış katmanlarda yüksek dayanımlı lamellerin kullanılması taşıma kapasitesini artırabilirken, lif yöneliminin değiştirilmesi hasar mekanizmalarının kontrol edilmesine katkı sağlayabilmektedir (Dinwoodie, 2000; Hanhijärvi ve diğ., 2005). Bu aşamada yapılan seçimler, kirişin hem dayanım hem de hasar davranışı üzerinde doğrudan etkili olmaktadır.

İlave Parametreler: Takviye ve Ön Gerilme

Tasarım sürecinin üçüncü aşamasında, performansı artırmaya yönelik ilave parametreler değerlendirilir. Bu kapsamda yüzey takviyeleri ve ön gerilme etkileri ön plana çıkmaktadır. Yüzey takviyeleri, özellikle çekme bölgesinde gerilme yığılmalarını azaltarak taşıma kapasitesine katkı sağlayabilir. Pasif ön gerilme etkileri ise özellikle eğrisel kirişlerde başlangıç gerilme durumunu değiştirerek yapısal davranışı etkileyebilir (Triantafillou, 1997; Borri ve diğ., 2005; Anshari ve diğ., 2012). Bu parametrelerin tasarım sürecine dahil edilmesi, daha optimize edilmiş ve performans açısından geliştirilmiş kiriş tasarımlarının elde edilmesine olanak sağlayabilir.

Parametrik Değerlendirme Tablosu

Parametrik tasarım yaklaşımının daha sistematik bir biçimde uygulanabilmesi amacıyla, temel parametreler ve bu parametrelerin yapısal davranış üzerindeki olası etkileri Çizelge 1’de özetlenmiştir.

Parametre	Beklenen Etki	Tasarım Açısından Değerlendirme
Kesit yüksekliği (h)	Rijitlik artışı, sehim azalması	Servis performansı için kritik
Açıklık (L)	Sehim ve moment artışı	Kesit optimizasyonu gerekir
Katman sayısı	Daha dengeli gerilme dağılımı	Üretim karmaşıklığı artabilir
Katman dizilimi	Stabilite ve dayanım değişimi	Simetrik dizilim önerilir
Lif yönelimi	Hasar mekanizması değişimi	Çatlak kontrolü sağlanabilir
Eğrilik	Gerilme dağılımında değişim	Özel tasarım gerektirir
Takviye	Taşıma kapasitesi artışı	Kritik bölgelerde uygulanmalı
Ön gerilme	İç gerilme dağılımı değişimi	Eğrisel kirişlerde önemli


Önerilen Parametrik Tasarım Yaklaşımı

Bu çalışma kapsamında önerilen parametrik tasarım yaklaşımı, lamine ahşap kirişlerin tasarım sürecinde parametrelerin tekil olarak değil, birbirleri ile etkileşim içerisinde değerlendirilmesi gerektiğini ortaya koymaktadır. Parametreler arasındaki etkileşim etkileri, tekil değerlendirmelere kıyasla daha karmaşık davranışların ortaya çıkmasına neden olmakta ve özellikle eğrilik, lif yönelimi ve katman organizasyonu gibi değişkenlerin birlikte etkili olduğu

durumlarda daha belirgin hale gelmektedir. Bu yaklaşım, özellikle ön tasarım aşamasında hızlı ve rasyonel kararlar alınmasına katkı sağlayabilir. Parametrik ve performans odaklı tasarım yaklaşımları, tasarım alternatiflerinin yalnızca biçimsel değil, aynı zamanda yapısal ölçütler temelinde de değerlendirilmesini mümkün kılmaktadır (Oxman, 2017; Schumacher, 2009).

Önerilen model, deneysel veya sayısal analizlerin yerine geçmeyi amaçlamamakta; aksine bu tür çalışmalar için bir ön değerlendirme aracı olarak kullanılabilecek kavramsal bir çerçeve sunmaktadır. Bu yönüyle çalışma, lamine ahşap kirişlerin tasarımına yönelik daha bütüncül ve sistematik bir yaklaşım geliştirilmesine katkı sağlamaktadır. Optimizasyon temelli tasarım anlayışı çerçevesinde, bu tür parametrik modellerin ilerleyen aşamalarda amaç fonksiyonları ve kısıtlar ile birlikte geliştirilebileceği de değerlendirilmektedir (Arora, 2004; Kicingir ve diğ., 2005). Bu model, parametrik değişkenler arasındaki etkileşimleri açık bir şekilde tanımlayarak, lamine ahşap kiriş tasarımında sistematik bir analiz altyapısı sunmaktadır.

Önerilen parametrik tasarım yaklaşımının aşamaları ve parametreler arası ilişkiler, Şekil 7’de şematik olarak sunulmuştur.



Şekil 7. Lamine ahşap kirişler için önerilen parametrik tasarım sürecinin şematik gösterimi

SONUÇ VE ÖNERİLER

Bu çalışmada, lamine ahşap kirişlerin yapısal davranışını etkileyen temel tasarım parametreleri kavramsal bir çerçevede ele alınmış ve parametrik tasarım yaklaşımının bu elemanların değerlendirilmesindeki önemi ortaya konulmuştur. Kesit boyutları, açıklık uzunluğu, katman sayısı ve dizilimi, lif yönelimi, eğrilik, takviye uygulamaları ve ön gerilme etkilerinin, kiriş davranışı üzerinde belirleyici rol oynadığı değerlendirilmiştir (Gere ve Timoshenko, 1997; Bodig ve Jayne, 1982).

Parametrelerin tek başına değil, birbirleri ile etkileşim içerisinde değerlendirilmesi gerektiği, özellikle eğilme davranışı, rijitlik, gerilme dağılımı ve hasar mekanizmaları açısından önemli

sonuçlar doğrulayabileceği ortaya konulmuştur. Bu durum, ahşap yapı elemanlarının çok parametrelili ve anizotrop yapısı ile uyumlu olup, literatürde vurgulanan yapısal davranış yaklaşımları ile paralellik göstermektedir (Thelandersson ve Larsen, 2003; Dinwoodie, 2000). Özellikle eğrisel lamine ahşap kirişlerde, üretim sürecine bağlı olarak ortaya çıkan pasif ön gerilme etkilerinin ve ilave gerilme bileşenlerinin, kiriş davranışı üzerinde belirleyici olduğu değerlendirilmiştir. Bu durum, eğrisel kirişlerin doğrusal sistemlerden farklı olarak ele alınması gerektiğini ortaya koymakta olup, literatürde bildirilen bulgularla uyum göstermektedir (Ranta-Maunus, 2001; Anshari ve diğ., 2012).

Çalışma kapsamında önerilen parametrik tasarım çerçevesinin, özellikle ön tasarım aşamasında tasarımcı ve araştırmacılara sistematik bir değerlendirme aracı sunabileceği düşünülmektedir. Bu yaklaşımın, farklı tasarım alternatiflerinin hızlı bir şekilde karşılaştırılmasına ve uygun çözümlerin belirlenmesine katkı sağlayabileceği öngörülmektedir (Oxman, 2017; Shea ve diğ., 2005). Bu kapsamda elde edilen bulgular, benzer deneysel çalışmalarla da uyumlu olup, özellikle eğrilik ve takviye etkilerinin kiriş davranışı üzerindeki belirleyici rolünü doğrulamaktadır (Kılıç, 2026).

Bu çalışma deneysel veya sayısal bir analiz içermemekle birlikte, lamine ahşap kirişlerin davranışına ilişkin temel parametrelerin bütüncül olarak değerlendirilmesine yönelik bir yaklaşım sunmaktadır. Bu yönüyle, gelecekte gerçekleştirilecek deneysel ve sayısal çalışmalar için bir temel oluşturabileceği değerlendirilmektedir.

Gelecek çalışmalarda, bu çalışmada kavramsal olarak ele alınan parametrik ilişkilerin deneysel ve sayısal analizlerle desteklenmesi önerilmektedir. Ayrıca, farklı malzeme türleri, takviye sistemleri ve üretim tekniklerinin parametrik tasarım yaklaşımı içerisinde değerlendirilmesi, lamine ahşap kirişlerin daha etkin ve optimize edilmiş biçimde kullanılmasına katkı sağlayacaktır (Arora, 2004; Kicingner ve diğ., 2005). Bu yönüyle çalışma, parametrik tasarım yaklaşımının lamine ahşap kiriş tasarımında temel bir karar destek aracı olarak kullanılabileceğini göstermektedir.

KAYNAKÇA

- Anshari, B., Guan, Z. W., & Wang, Q. Y. (2017). Modelling of Glulam beams pre-stressed by compressed wood. *Composite Structures*, 165, 160-170.
- Anshari, B., Guan, Z. W., Kitamori, A., Jung, K., & Komatsu, K. (2012). Structural behaviour of glued laminated timber beams pre-stressed by compressed wood. *Construction and Building Materials*, 29, 24-32.
- Arora, J. S. (2004). *Introduction to optimum design*. Elsevier.
- ASTM D198. (2015). Standard test methods of static tests of lumber in structural sizes.
- Bayatkashkoli, A., Shamsian, M., & Mansourfard, M. (2011). Effects of layer arrangements on bending strength properties of laminated lumber made of poplar (*Populus nigra* L.). *Scientific Research and Essays*, 6(29), 6116–6119.

- Bodig, J., & Jayne, B. A. (1982). *Mechanics of wood and wood composites*. Van Nostrand Reinhold.
- Borri, A., Corradi, M., & Grazini, A. (2005). A method for flexural reinforcement of old wood beams with CFRP materials. *Composites Part B: Engineering*, 36(2), 143-153.
- Brandner, R., Flatscher, G., Ringhofer, A., Schickhofer, G., & Thiel, A. (2016). Cross laminated timber (CLT): overview and development. *European journal of wood and wood products*, 74(3), 331-351.
- Dinwoodie, J. M. (2000). *Timber: its nature and behaviour*. CRC Press.
- EN 1995-1-1. (2004). Eurocode 5: Design of timber structures – Part 1-1: General.
- Forest Products Laboratory. (2010). *Wood handbook: Wood as an engineering material* (General Technical Report FPL-GTR-190). Madison, WI: USDA Forest Service.
- Franke, S., Franke, B., & Harte, A. M. (2015). Failure modes and reinforcement techniques for timber beams—State of the art. *Construction and Building Materials*, 97, 2-13.
- Gere, J. M., & Timoshenko, S. P. (1997). *Mechanics of materials* (4th ed.). PWS Publishing.
- Gowda, S., Kortessmä, M., & Ranta-Maunus, A. (1998). *Duration of load effect on curved glulam beams: Part 2. Long term load tests and analysis*. VTT Technical Research Centre of Finland.
- Hanhijärvi, A., Ranta-Maunus, A., & Turk, G. (2005). *Potential of strength grading of timber with combined measurement techniques: Report of the Combigrade-project – phase 1* (VTT Publications No. 568). VTT Technical Research Centre of Finland.
- Kılıç, İ. (2026). Farklı boyutlardaki ön gerilmeli lamine ahşap kiriş tasarımı ve deneysel incelenmesi. Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü.
- Kicing, R., Arciszewski, T., & De Jong, K. (2005). Evolutionary computation and structural design: A survey of the state-of-the-art. *Computers & structures*, 83(23-24), 1943-1978.
- Kolarevic, B. (2003). Architecture in the digital age. *Design and Manufacturing*. Nueva York-Londres: Spon Press-Taylor & Francis Group.
- Kytka, T., Gašparík, M., Sahula, L., Novák, D., Karami, E., Das, S., & Sviták, M. (2024). Predicted and experimental bending behaviour of glulam bonded by RPF adhesive. *Materials*, 17(2), 514.
- Oxman, R. (2017). Thinking difference: Theories and models of parametric design thinking. *Design studies*, 52, 4-39.
- Ramage, M. H., Burrridge, H., Busse-Wicher, M., Fereday, G., Reynolds, T., Shah, D. U., ... & Scherman, O. (2017). The wood from the trees: The use of timber in construction. *Renewable and sustainable energy reviews*, 68, 333-359.
- Ranta-Maunus, A. (2001). Moisture gradient as loading of curved timber beams. *International Association for Bridge and Structural Engineering*, Seoul, South Korea.
- Sandberg, D., Kutnar, A., & Mantanis, G. (2017). Wood modification technologies – A review. *iForest – Biogeosciences and Forestry*, 10(6), 895–908.
- Sathre, R., & O'Connor, J. (2010). Meta-analysis of greenhouse gas displacement factors of wood product substitution. *Environmental science & policy*, 13(2), 104-114.
- Schober, K. U., Harte, A. M., Kliger, R., Jockwer, R., Xu, Q., & Chen, J. F. (2015). FRP reinforcement of timber structures. *Construction and building materials*, 97, 106-118.

- Schumacher, P. (2009). Parametricism: A new global style for architecture and urban design. *Architectural design*, 79(4), 14-23.
- Shea, K., Aish, R., & Gourtovaia, M. (2005). Towards integrated performance-driven generative design tools. *Automation in construction*, 14(2), 253-264.
- Thelandersson, S., & Larsen, H. J. (Eds.). (2003). *Timber engineering*. John Wiley & Sons.
- Triantafillou, T. C. (1997). Shear reinforcement of wood using FRP materials. *Journal of materials in civil engineering*, 9(2), 65-69.
- Türker, Y. Ş., & Kılınçarslan, Ş. (2024). Effect of layers number on the bending properties of chestnut glulam beams. *Karadeniz Fen Bilimleri Dergisi*, 14(1), 62–71.
- Vratuša, S., Kitek Kuzman, M., & Kilar, V. (2011). Structural particulars of glued laminated beams of variable height. *Drewno: prace naukowe, doniesienia, komunikaty*, 54, 19-38.
- Yu, T., Khaloian-Sarnaghi, A., Seeber, F., & van de Kuilen, J. W. (2023). Stochastic FE analysis of stress concentrations in curved glulam beams due to the uncertainty of material direction. *Construction and Building Materials*, 393, 131537.

ELASTIC AND GEOMETRICALLY NONLINEAR BUCKLING RESPONSE OF HEA STEEL COLUMNS WITH VARYING END RESTRAINTS

Assist. Prof. Dr. Yaşar ERBAŞ

Bartın University, Faculty of Engineering, Architecture, and Design.

Department of Civil Engineering, Türkiye

ORCID ID: <https://orcid.org/0000-0002-3475-9678>

ABSTRACT

The buckling behavior of HEA steel columns, which are widely used as columns and frame members in steel structural systems, is directly influenced by parameters such as member length, material properties, and end support conditions. In conventional design, column ends are generally idealized as either pinned or fixed. However, in practice, column end behavior may vary between these two ideal conditions. In this study, the effects of end rotational stiffness on the elastic buckling and geometrically nonlinear buckling behavior of HEA steel columns were investigated numerically. A 5000 mm long HEA200 steel column was modeled in ABAQUS using S4R shell elements. The weak-axis rotational restraint was represented using connector elements. The dimensionless parameter ρ , defined as the ratio of the connector rotational spring stiffness to the column's characteristic flexural stiffness, was investigated over a wide range, from pinned to fixed-end behavior. Eigenvalue buckling loads obtained from the finite element analyses were compared with theoretical Euler solutions for commonly used ideal end conditions. For each model, the first buckling mode was defined as the initial geometric imperfection with an amplitude of $L/1000$, and Static Riks analyses were performed. The nonlinear buckling behavior of the columns was evaluated using the load proportionality factor ($LPF = P/P_{cr}$) and the weak-axis lateral displacement (U_1) at column mid-height. The results showed that increasing end rotational stiffness increased the elastic critical buckling load and reduced the effective length factor. As the normalized load approached the critical region, lateral displacements increased, and the influence of end rotational stiffness became more pronounced. At high ρ values, both the elastic and geometrically nonlinear responses approached the fixed-end condition asymptotically.

Keywords: HEA steel column, rotational stiffness, eigenvalue buckling analysis, initial geometric imperfection, Static Riks analysis.

INTRODUCTION

Buckling is one of the main stability problems governing the load-carrying capacity of slender steel columns under axial compression. In the classical Euler approach, the critical buckling load is defined as a function of member length, flexural stiffness, and end boundary conditions. In real structural systems, however, column-end behavior may fall between the ideal pinned

and fully fixed conditions. Experimental studies have shown that connections assumed to be pinned may still provide a certain level of rotational stiffness, while connections assumed to be fixed may allow some rotation. For this reason, representing actual connection behavior as semi-rigid provides a more realistic description of column stability than the two ideal boundary conditions (Jones et al., 1980).

The effect of end rotational stiffness on column stability has been investigated for many years using analytical and numerical approaches. Kishi et al. (1997) examined the effective length factor of columns in sway frames with semi-rigid connections and showed that the moment–rotation characteristics of the connections should be considered when determining effective length. The study also emphasized the importance of considering second-order effects together with connection stiffness in semi-rigid systems. Raftoyiannis (2005) reported that connection flexibility can significantly reduce the buckling load of steel frames and should be explicitly included in stability analysis. Similarly, Mageirou and Gantes (2006) investigated sway, non-sway, and partially sway multistory frames with semi-rigid connections and represented the rotational restraints at column ends by equivalent springs. An effective length approach was developed and showed good agreement with finite element results. The study also demonstrated that some idealized code-based methods may lead to considerable deviations for semi-rigid systems. Adman and Saidani (2013) represented rotational and translational restraints by springs and examined the relationship between dimensionless end-restraint parameters and the effective length factor. The results showed that boundary conditions in actual structural systems may vary over a wide range between ideal pinned and fixed cases.

More recent studies have also confirmed the major influence of end restraints on critical buckling load. Slimani et al. (2023) developed a parametric approach that considered the boundary conditions of columns and adjacent members in steel frames. The results showed that increasing rotational stiffness reduces the effective length factor and increases the elastic buckling capacity. Koo et al. (2023) modeled different rotational restraints in wide-flange steel columns using rotational springs and reported a significant influence of rotational stiffness on effective length and buckling resistance. ABAQUS S4R shell elements were used, and elastic buckling behavior was evaluated numerically for different levels of rotational stiffness.

The finite element method is a useful tool for stability problems involving complex boundary conditions and complements analytical approaches. Eigenvalue buckling analysis can be used to determine the critical load and associated buckling modes of a structural system. Studies on different steel structural systems have shown that eigenvalue analysis can also be used effectively to verify analytical solutions and proposed buckling formulations. Guzmán and González del Solar (2025), for example, compared the global elastic buckling loads of lattice columns using analytical, numerical, and experimental approaches and reported good accuracy for the proposed critical-load expressions. Wu et al. (2024) also verified elastic buckling formulations using finite element eigenvalue analyses. Although these studies considered different structural systems, the results support the use of analytical solution–eigenvalue finite element comparisons as a reliable verification approach for critical buckling load predictions.

However, eigenvalue buckling analysis is based on an ideal geometry and cannot directly capture deformation development during loading or second-order effects in real columns. Initial geometric imperfections caused by fabrication and erection are unavoidable in steel columns. Raftoyiannis and Ermopoulos (2005) showed that such imperfections have a significant effect on the stability and load-carrying capacity of steel columns under compression and examined these effects using nonlinear finite element analyses. Similarly, Horsangchai et al. (2024) introduced the first buckling mode obtained from linear eigenvalue analysis into the nonlinear model as an initial geometric imperfection and used an imperfection amplitude of $L/1000$ for global buckling.

Defining the initial imperfection from an eigenvalue buckling mode is also widely used in advanced analysis methods. Chan et al. (2025) stated that the shape and amplitude of the initial geometric imperfection play an important role in GNIA and GMNIA results and systematically examined the use of scaled linear buckling modes as initial imperfections. Koo et al. (2023) also introduced the first buckling mode into the nonlinear model as an initial curvature and adopted a maximum imperfection amplitude equal to $1/1000$ of the column length. This approach provides a direct link between the critical state obtained from eigenvalue analysis and the geometrically nonlinear load–displacement response.

A general review of the literature shows that the effects of semi-rigid connections, frame stability, effective length factor, end rotational stiffness, and initial geometric imperfections on column behavior have been studied extensively. However, studies systematically investigating a single wide-flange steel column over a broad range of end rotational stiffness, from pinned to fixed behavior, while using a dimensionless stiffness parameter and evaluating the same models through both elastic eigenvalue buckling and geometrically nonlinear analyses with initial imperfections, are still limited. In this study, the weak-axis buckling behavior of 5000 mm long HEA200 steel columns was investigated numerically under different levels of end rotational stiffness. The finite element model was first verified against Euler solutions for ideal boundary conditions, and the critical buckling loads were then determined by eigenvalue buckling analyses. In the final stage, an initial imperfection with an amplitude of $L/1000$ was defined based on the first buckling mode, and the geometrically nonlinear load–lateral displacement response was examined using Static Riks analyses. The study aimed to determine the effect of end rotational stiffness on both the elastic critical buckling load and the second-order response as the column approaches the critical load.

FINITE ELEMENT MODELING

Column geometry, material properties, and finite element mesh characteristics

The numerical study was carried out on a 5000 mm long HEA200 steel column. The column was modeled in ABAQUS/Standard using a three-dimensional shell representation. The flange and web plates were discretized with four-node reduced-integration S4R shell elements. A

characteristic element size of 10 mm was used for the finite element mesh. Since the study was limited to elastic buckling and geometrically nonlinear stability behavior, steel was treated as a linearly elastic material, and its material and cross-sectional properties were held constant across all parametric models. The elastic modulus was taken as 210 GPa and Poisson's ratio as 0.30. The second moment of area about the weak axis of the idealized HEA200 shell cross-section was taken as $I = 13,337 \times 10^6 \text{ mm}^4$, which is slightly lower than the nominal tabulated value due to the geometric idealization of the rolled section. This approach ensured that changes in the results were caused only by the end rotational restraint. The finite element model of the column is shown in Figure 1.a. Both end sections of the column were connected to reference points using coupling constraints. Translational boundary conditions and the axial load were applied through the reference points. This modeling approach allows the end-section behavior to be controlled from a single point and provides a consistent transfer of the rotational spring action to the column cross-section.




Figure 1. (a) finite element model, (b) support detail at the top end of the column, (c) boundary conditions.

Boundary conditions and connector-to-ground rotational spring

Boundary conditions were first defined at the column model's reference points. The rotational degree of freedom associated with weak-axis bending was controlled through connector elements attached to the reference points. To model the semi-rigid end restraint, the reference point at each column end was connected to the ground by a connector element. Rotational stiffness was assigned only to the rotation associated with weak-axis buckling, and the connector stiffness was defined as $D44 = K_Q$, where K_Q denotes the rotational spring stiffness of the connector-to-ground element. At the upper end, axial translation was left free to allow the applied compressive load, while the transverse translations were restrained. At the lower end, all translational degrees of freedom were restrained. The remaining rotational degrees of freedom were released, while the weak-axis rotation was controlled by the connector-based rotational spring. In this way, the influence of end rotational restraint on the global weak-axis buckling response of the column could be examined independently. The support detail at the upper end is shown in Figure 1.b, while the boundary conditions at the lower and upper ends are presented in Figure 1.c. To compare rotational stiffness independently of column length and

section properties, a dimensionless rotational stiffness parameter, ρ , was used: $\rho = K_Q L / EI$ where K_Q is the connector-to-ground rotational spring stiffness, L is the length of the column, E is the elastic modulus, and I is the second moment of area about the weak axis. The same rotational stiffness value was assigned to both the upper and lower ends of the column in each model. The selected parameter range covers a wide transition from pinned behavior to highly restrained end conditions.

Eigenvalue buckling analysis and Euler verification

Before the parametric study, the finite element model was verified to ensure it accurately reproduced the elastic buckling capacity under ideal end conditions. To verify the model, the eigenvalue critical loads obtained for pinned-pinned, fixed-pinned, and fixed-fixed boundary conditions were compared with the classical Euler buckling solutions. The elastic critical buckling load according to Euler theory is expressed as: $P_{cr} = \pi^2 EI / (KL)^2$ where K is the effective length factor depending on the end boundary conditions. Based on the theoretical effective length factors given in AISC (2022), K values of 1.0, 0.7, and 0.5 were adopted for the pinned-pinned, fixed-pinned, and fixed-fixed conditions, respectively. As shown in Table 1, the differences between the finite element results and the theoretical Euler values remained below 2% for all three ideal cases. This agreement confirms that the shell-based finite element model, boundary conditions, and buckling analysis procedure provide sufficient accuracy for the parametric study.

Table 1. Comparison of finite element eigenvalue critical loads with Euler theory.

Boundary Conditions	FEM P_{cr} (kN)	Euler P_{cr} (kN)	Error (%)
Pinned-Pinned	1099.8	1105.7	0.53
Fixed-Pinned	2236.6	2256.5	0.88
Fixed-Fixed	4336.4	4422.8	1.95

For the parametric analysis, the same dimensionless rotational stiffness value, ρ , was assigned to both the upper and lower ends of each column model. The selected ρ values were defined to represent a wide range of end conditions, from nearly pinned to flexible, semi-rigid, highly restrained, and fixed. For each parametric model, the equivalent effective length factor was back-calculated from the finite element eigenvalue critical load using the rearranged Euler buckling equation: $K = (\pi/L)\sqrt{EI/P_{cr}}$ where P_{cr} is the critical buckling load obtained from the finite element analysis. Table 2 presents the critical buckling loads for each model and corresponding effective length factors.

Table 2. Results of the parametric finite element analyses.

Model	ρ	K (effective length factor)	P _{cr} (kN)
M1	0	1.00	1099.8
M2	0.1	0.98	1143.8
M3	0.5	0.92	1311.2
M4	1	0.86	1502.1
M5	2	0.78	1831.2
M6	5	0.66	2516.4
M7	10	0.60	3120.6
M8	25	0.54	3751.1
M9	50	0.52	4031.9
M10	75	0.52	4134.5
M11	100	0.51	4187
M12	250	0.51	4285.9
M13	500	0.51	4319.5
M14	1000	0.50	4336.4

GNIA / Static Riks analysis procedure

In the geometrically nonlinear analyses, the first global buckling mode obtained from the eigenvalue buckling analysis was used as the initial geometric imperfection shape for each model. In this way, the initial imperfection was introduced in a form consistent with the column's dominant global buckling response. The imperfection amplitude was taken as $L/1000$, consistent with values adopted in previous studies (Horsangchai et al., 2024; Koo et al., 2023; AISC, 2022). For the columns examined in this study, the maximum initial geometric imperfection was therefore taken as 5 mm. Since the imperfection was defined using the first buckling mode of each model, the effect of end rotational stiffness on the mode shape was also directly reflected in the nonlinear model. For the M1, M6, and M14 models, representing low, intermediate, and high rotational stiffness, respectively, the first mode retained the general character of global weak-axis buckling. As the end rotational restraint increased, however, the curvature distribution along the column changed, end rotations decreased, and the buckling shape gradually approached the fixed-end condition. For this reason, a single common imperfection shape was not used for all models; instead, the first eigenmode of each model was adopted.

The geometrically nonlinear response of the imperfect models was analyzed using the Static Riks method. Figure 2 shows the first buckling modes transferred to the Riks analyses for the pinned (M1), semi-rigid (M6), and practically fixed (M14) models. The Riks method allows the load-displacement equilibrium path to be traced in buckling and post-buckling problems, where conventional load-controlled static procedures may struggle to track the response. For each model, the reference axial load was defined as the elastic critical buckling load, P_{cr} , obtained from the eigenvalue buckling analysis of the same model. Accordingly, the Load Proportionality Factor (*LPF*) calculated during the Riks analysis directly represented the normalized axial load level: $LPF = P/P_{cr}$ where P is the current axial load acting on the

column during the analysis and P_{cr} is the eigenvalue critical buckling load of the corresponding model. This definition allowed models with different end rotational stiffness values and different absolute critical loads to be compared at the same normalized load levels. In particular, comparing the weak-axis lateral displacements at column mid-height at normalized load levels of $LPF = 0.75, 0.90$, and approximately 0.95 allowed the effect of end rotational stiffness on the development of geometrically nonlinear deformation to be evaluated more clearly.




Figure 2. First buckling modes of models M1, M6, and M14, respectively.

RESULTS AND DISCUSSION

Table 2 emphasizes the impact of the end rotational stiffness on the elastic critical buckling capacity of the column. Without changing the cross-section, member length, or material properties, increasing only the end rotational stiffness can increase the elastic stability capacity by nearly fourfold. In the $P_{cr} - \rho$ curve shown in Figure 3, the most rapid increase in capacity occurs within the low and intermediate stiffness ranges. At high ρ values, the rate of increase becomes much smaller. This saturation trend is related to the fact that end rotations are already largely restrained at high stiffness levels. Therefore, increasing the connector stiffness beyond a certain level provides only a limited increase in the elastic critical load.

As shown in Figure 3, the finite element solution approaches the theoretical fixed-fixed limit at high rotational stiffness levels. This confirms that the parametric model provides a physically consistent transition between the ideal end conditions. Compared with examining only the pinned and fixed cases separately, this transition also shows the stiffness range in which rotational restraint has the greatest effect on the critical load. As the rotational spring stiffness increases, rotational freedom at the column ends decreases, the global buckling mode develops a shorter effective length, and the critical load increases. The tendency of the effective length factor, K , to level off near 0.5 at high ρ values demonstrates the saturation observed in the $P_{cr} - \rho$ curve.




Figure 3. Relationship between the dimensionless end rotational stiffness, (ρ), and the elastic buckling load, P_{cr} .

The Static Riks analyses show how the initial eigenmode-shaped geometric imperfection is amplified along the nonlinear equilibrium path as the axial load increases. The deformed shapes of models M1, M6, and M14 at the $P/P_{cr} \approx 0.95$ level, shown in Figure 4, indicate that global weak-axis flexural buckling remains the dominant mode across all stiffness levels, while the amplitude of lateral displacement varies with the end rotational stiffness. Since the initial geometric imperfection was defined in accordance with the first eigenvalue buckling mode, the same global buckling pattern remained dominant as the load increased, and the second-order displacements became more pronounced as the response approached the critical region.




Figure 4. GNIA/Riks deformed shapes of models M1, M6, and M14 at $P/P_{cr} \approx 0.95$, respectively.

The $LPF - U_1$ curves presented in Figure 5 show that lateral displacements remain relatively small at the early stages of normalized loading, while a clear increase in displacement develops as the response approaches the critical region. Since the $LPF = P/P_{cr}$ ratio on the vertical axis is normalized with respect to the elastic critical load of each model, direct comparisons can be

made for different ρ values. At low and intermediate normalized load levels, the curves of the different models largely overlap, indicating that the influence of end rotational stiffness on the normalized lateral displacement remains limited in this range. The increasing sensitivity of the curves beyond $LPF \approx 0.90$ indicates that the effects of the initial geometric imperfection and $P - \delta$ response become more pronounced together. As the response approaches $LPF \approx 0.95$, the curves begin to separate more clearly, with lower end rotational stiffness generally associated with larger lateral displacements. For clarity, representative models spanning the investigated range of end rotational stiffness were selected for comparison in Figure 5.




Figure 5. Normalized load–mid-height lateral displacement curves from GNIA/Riks analyses up to the critical response range.

Another notable point in Figure 5 is that different end rotational stiffness values can produce different lateral deformation demands even at the same normalized load level. Columns with stiffer end restraints reach higher axial loads in absolute terms, while the normalized curves show the approach to the critical region consistently. Therefore, the $LPF - U_1$ representation can be used to evaluate the development of lateral deformation at common normalized load levels and to highlight the increasing effect of end restraint as the critical region is approached. In Figure 6, the effect of end rotational stiffness on lateral displacement was quantitatively evaluated by considering the U_1 values at $LPF = 0.75, 0.90$, and approximately 0.95 as a function of the dimensionless rotational stiffness, ρ . At $LPF = 0.75$, the differences between the models are small, with U_1 values ranging from 14.2 to 15.2 mm. At $LPF = 0.90$ level, the lateral displacements increase to approximately 39.6 to 43.4 mm, while the influence of rotational stiffness remains relatively limited. In contrast, at $LPF \approx 0.95$, U_1 ranges from approximately 75.3 to 88 mm. The total spread in U_1 among the models increases from approximately 1 mm at $LPF = 0.75$ to 12.7 mm at $LPF \approx 0.95$, quantitatively demonstrating the increasing influence of end rotational restraint as the critical region is approached. At lower

normalized load levels, geometric nonlinear effects remain relatively limited, whereas near the critical region, amplification of the initial imperfection and second-order effects becomes more significant.




Figure 6. Variation of mid-height U_1 displacement with ρ at selected normalized load levels.

Figure 7 presents the relationship between the maximum attained nonlinear load, $P_{max} = LPF_{max} \times P_{cr}$, and the dimensionless rotational stiffness, ρ . The maximum axial load reached in the Static Riks analyses increases markedly as the end rotational stiffness increases. At low ρ values, the column response approaches the pinned condition, and the maximum load remains relatively low. As the end rotational stiffness increases, rotational freedom at the column ends decreases, and the effective buckling length becomes shorter. As a result, higher axial load levels are reached in the nonlinear analyses. The increase is more pronounced within the intermediate stiffness range, while the curve starts to level off at high ρ values, indicating that the finite element response approaches the fixed-fixed condition. The maximum loads obtained for models M12–M14, approximately 4100 – 4200 kN, are close to the eigenvalue critical buckling load obtained for the fixed-fixed boundary condition. For some models, the reported value corresponds to the highest load reached within the analysis range rather than to a distinct limit point on the Riks equilibrium path. These values should therefore be interpreted as the maximum attained loads within the analyzed response range. The results show that increasing end rotational stiffness significantly improves the geometrically nonlinear load-carrying capacity of the imperfect column. However, the rate of increase gradually decreases at high stiffness levels as the response approaches the fixed-end limit.




Figure 7. Variation of the maximum attained nonlinear load, P_{max} , with the dimensionless rotational stiffness parameter, ρ .

CONCLUSION

In this study, the elastic and geometrically nonlinear buckling behavior of 5000 mm-long HEA200 steel columns under various levels of end rotational restraint was investigated using eigenvalue buckling and Static Riks analyses. The main findings are summarized below.

- The finite element model developed using S4R shell elements showed good agreement with the Euler buckling solutions under ideal boundary conditions. The maximum relative error was 1.95%.
- As the dimensionless end rotational stiffness increased, the critical buckling load increased, while the effective length factor decreased, indicating a continuous transition from pinned-like to fixed-end behavior.
- The $P_{cr} - \rho$ and $K - \rho$ relationships exhibited a clearly nonlinear trend. The influence of end rotational stiffness was most pronounced at low and intermediate stiffness levels, while the increase in the elastic critical load gradually diminished at high ρ values as the response approached the fixed-end limit.
- In the Riks analyses, including an $L/1000$ initial geometric imperfection, lateral displacements increased more rapidly after the normalized load reached approximately $P/P_{cr} = 0.90$. This behavior indicates the increasing importance of second-order effects as the critical load region is approached.
- At the same normalized load level, columns with lower end rotational stiffness generally developed larger mid-height lateral displacements, and this difference became more pronounced as P/P_{cr} approached 0.95.

End rotational stiffness significantly influences both the elastic critical load and the geometrically nonlinear stability capacity of steel columns. Including initial geometric imperfections and geometric nonlinearity provides a more realistic representation of deformation development and second-order effects than eigenvalue analysis alone. Future

studies may include material nonlinearity, residual stresses, different imperfection amplitudes, and nonlinear moment–rotation relationships.

REFERENCES

- Adman, R., & Saidani, M. (2013). Elastic buckling of columns with end restraint effects. *Journal of Constructional Steel Research*, 87, 1–5. <https://doi.org/10.1016/j.jcsr.2013.03.022>
- American Institute of Steel Construction (AISC). (2022). *Specification for Structural Steel Buildings (ANSI/AISC 360-22)*. Chicago, IL: AISC.
- Chan, H. U., Walport, F., Slack, H., Wade, M. A., & Gardner, L. (2025). Practical rules for defining initial geometric imperfections for in-plane stability design of steel frames. *Structures*, 82, 110643. <https://doi.org/10.1016/j.istruc.2025.110643>
- Guzmán, A. M., & González del Solar, G. A. (2025). Prediction of critical global elastic buckling load in lattice columns. *International Journal of Steel Structures*, 25(3), 647–658. <https://doi.org/10.1007/s13296-025-00962-8>
- Horsangchai, V., Lenwari, A., & Young, B. (2024). Elastic and inelastic major-axis flexural buckling of cellular steel columns. *Engineering Structures*, 301, 117286. <https://doi.org/10.1016/j.engstruct.2023.117286>
- Jones, S. W., Kirby, P. A., & Nethercot, D. A. (1980). Effect of semirigid connections on steel column strength. *Journal of Constructional Steel Research*, 1(1), 38–46.
- Kishi, N., Chen, W. F., & Goto, Y. (1997). Effective length factor of columns in semirigid and unbraced frames. *Journal of Structural Engineering*, 123(3), 313–320.
- Koo, J., Lee, C.-H., & Shin, D. (2023). Effect of rotational restraint on inelastic buckling of steel column at elevated temperatures. *International Journal of Steel Structures*, 23(2), 564–585. <https://doi.org/10.1007/s13296-023-00713-7>
- Mageirou, G. E., & Gantes, C. J. (2006). Buckling strength of multi-story sway, non-sway and partially-sway frames with semirigid connections. *Journal of Constructional Steel Research*, 62, 893–905. <https://doi.org/10.1016/j.jcsr.2005.11.019>
- Raftoyiannis, I. G. (2005). The effect of semirigid joints and an elastic bracing system on the buckling load of simple rectangular steel frames. *Journal of Constructional Steel Research*, 61, 1205–1225. <https://doi.org/10.1016/j.jcsr.2005.01.005>
- Raftoyiannis, I. G., & Ermopoulos, J. Ch. (2005). Stability of tapered and stepped steel columns with initial imperfections. *Engineering Structures*, 27, 1248–1257. <https://doi.org/10.1016/j.engstruct.2005.03.009>
- Slimani, A., Belaid, T., Saidani, M., Ammari, F., & Adman, R. (2023). The effective length factor of columns in steel framed buildings with end restraint effects. *Structures*, 58, 105521. <https://doi.org/10.1016/j.istruc.2023.105521>
- Wu, R.-M., Wang, L.-Q., Tong, J.-Z., Tong, G.-S., & Gao, W. (2024). Elastic buckling formulas of multi-stiffened corrugated steel plate shear walls. *Engineering Structures*, 300, 117218. <https://doi.org/10.1016/j.engstruct.2023.117218>

AI-POWERED MATERIALS INFORMATICS: TRANSFORMING TRADITIONAL MATERIAL SCIENCE INTO DATA-DRIVEN ENGINEERING

Oluwanifemi Opeyemi AGOI¹

Obafemi Awolowo University, Osun Nigeria.
<https://orcid.org/0009-0007-9461-8870>

Moses Adeolu AGOI²

Lagos State University of Education, Lagos Nigeria.
<https://orcid.org/0000-0002-8910-2876>

Olayemi Grace ABIMBOLA³

Lagos State University of Education, Lagos Nigeria.
<https://orcid.org/0009-0000-0139-3481>

Rasheed Olatunde AJETUNMOBI⁴

Lagos State University of Education, Lagos Nigeria.

Abstract

Materials informatics (MI) has emerged as one of the most transformative paradigms in modern materials science by integrating artificial intelligence (AI), machine learning (ML), big data analytics, and high-throughput computational techniques into the discovery, characterization, optimization, and deployment of advanced engineering materials. Traditional materials development has historically depended on iterative laboratory experimentation, empirical knowledge, and lengthy trial-and-error procedures that often require decades to transition from conceptualization to commercial implementation. Recent advances in AI-powered materials informatics have fundamentally altered this process by enabling data-driven prediction of material properties, accelerated computational screening, inverse material design, autonomous experimentation, and intelligent optimization across multiple engineering domains. This study reviews contemporary developments in AI-driven materials informatics and examines how intelligent algorithms, including deep learning, graph neural networks, generative artificial intelligence, reinforcement learning, and digital twin technologies, are revolutionizing materials engineering workflows. The review synthesizes recent evidence demonstrating significant improvements in prediction accuracy, computational efficiency, materials discovery speed, and experimental cost reduction through the integration of multidimensional materials databases with advanced AI models. Furthermore, the paper discusses the growing role of explainable artificial intelligence, automated laboratories, high-performance computing, and federated materials databases in supporting sustainable materials innovation and Industry 5.0 manufacturing ecosystems. Emerging applications in energy storage, additive manufacturing, semiconductors, biomedical materials, aerospace alloys, and sustainable construction materials are critically evaluated. Despite these advancements, several challenges, including limited high-quality datasets, model interpretability, uncertainty quantification, data standardization, and ethical governance, remain significant barriers to widespread industrial adoption. The study concludes that AI-powered materials informatics represents a paradigm shift from empirical materials science toward predictive, autonomous, and intelligent engineering capable of

substantially accelerating global innovation while supporting sustainability, circular economy principles, and next-generation smart manufacturing infrastructures.

Keywords: Artificial Intelligence; Data-Driven Engineering; Machine Learning; Materials Informatics.

INTRODUCTION

The rapid convergence of artificial intelligence (AI), machine learning (ML), big data analytics, and high-performance computing has fundamentally transformed materials science from a



predominantly experimental discipline into a data-driven engineering paradigm. Traditionally, the discovery and optimization of engineering materials have relied heavily on empirical experimentation, expert intuition, and iterative laboratory investigations, often requiring 10–20 years for a new material to progress from conceptualization to industrial deployment. Such conventional approaches are expensive, labour-intensive, and incapable of efficiently exploring the enormous compositional design space of

modern materials. Recent advances in materials informatics (MI) have addressed these limitations by integrating AI algorithms with large-scale experimental, computational, and simulation datasets to accelerate materials discovery, property prediction, process optimization, and performance evaluation (Butler et al., 2018). The emergence of high-throughput experimentation, density functional theory (DFT), molecular dynamics simulations, and extensive open materials databases, including the Materials Project, Open Quantum Materials Database (OQMD), AFLOW, NOMAD, and Citrination, has generated unprecedented quantities of structured materials data suitable for intelligent analytics (Jain et al., 2013). Concurrently, sophisticated AI models such as deep neural networks, graph neural networks (GNNs), generative adversarial networks (GANs), transformer architectures, reinforcement learning, and explainable artificial intelligence (XAI) have significantly improved predictive accuracy for crystal structures, electronic properties, mechanical strength, thermal conductivity, corrosion resistance, battery materials, catalysts, polymers, and biomaterials (Schmidt et al., 2019; Wang et al., 2021). These technologies have reduced experimental costs while enabling inverse materials design, autonomous laboratories, robotic experimentation, and digital twin-assisted optimization that support Industry 4.0 and emerging Industry 5.0 manufacturing ecosystems (Merchant et al., 2023). Furthermore, AI-powered materials informatics contributes substantially to sustainable engineering by accelerating the development of low-carbon cement, recyclable polymers, high-performance energy storage materials, hydrogen catalysts, lightweight aerospace alloys, and environmentally friendly construction materials. Nevertheless, challenges involving data quality, interoperability, uncertainty quantification, algorithm transparency, reproducibility, cybersecurity, and ethical governance continue to influence industrial implementation. Consequently, AI-powered materials informatics represents a transformative technological framework that is redefining how engineering materials are discovered, designed, manufactured, and deployed across scientific research and industrial innovation, establishing a new era of predictive, autonomous, and intelligent materials engineering.

LITERATURE REVIEW

Evolution of Materials Informatics: From Experimental Materials Science to Artificial Intelligence-Driven Discovery

Materials science has historically evolved through experimental observation, theoretical modelling, and computational simulation, with discoveries primarily dependent on iterative laboratory investigations and expert-driven hypothesis testing. While this traditional methodology has enabled remarkable advances in metallurgy, ceramics, polymers, composites, and semiconductor technologies, the increasing complexity of multifunctional engineering materials has exposed significant limitations in conventional trial-and-error approaches (Olson, 1997). The exponential growth of possible chemical compositions and crystallographic structures has rendered exhaustive experimental exploration practically impossible, motivating the emergence of materials informatics as a data-centric discipline capable of integrating computational intelligence into materials discovery (Agrawal & Choudhary, 2016). The concept of materials informatics gained prominence through the convergence of computational materials science, artificial intelligence, machine learning, and high-throughput experimentation. According to Butler et al. (2018), materials informatics combines statistical learning algorithms with extensive experimental and computational databases to establish relationships between material composition, processing conditions, microstructure, and engineering performance. This integration enables researchers to predict material properties rapidly while significantly reducing the cost and duration associated with laboratory experimentation. The establishment of large-scale open-access databases has further accelerated AI adoption in materials science. Jain et al. (2013) introduced the Materials Project, providing millions of density functional theory (DFT)-generated materials properties that support predictive machine learning models. Similar initiatives, including AFLOW (Curtarolo et al., 2012), the Open Quantum Materials Database (Saal et al., 2013), and NOMAD (Draxl & Scheffler, 2019), have expanded the availability of standardized datasets for AI-driven materials engineering. Recent advances in deep learning and graph neural networks have transformed how researchers model atomic interactions and crystal structures. Schmidt et al. (2019) observed that AI models now outperform many traditional computational approaches in predicting electronic structures, mechanical behaviour, and thermodynamic stability. Merchant et al. (2023) further demonstrated that generative AI models can autonomously propose novel inorganic materials exhibiting improved functional characteristics for battery and semiconductor applications. Collectively, these developments signify a paradigm shift from empirical experimentation toward predictive, autonomous, and data-driven engineering, where AI functions as an intelligent collaborator capable of substantially accelerating scientific discovery while improving the efficiency, sustainability, and scalability of modern materials innovation.

Machine Learning and Artificial Intelligence Techniques in Materials Discovery

Artificial intelligence (AI) and machine learning (ML) have become the cornerstone technologies driving the evolution of materials informatics by enabling predictive analytics, inverse materials design, and autonomous discovery of advanced engineering materials. Unlike conventional computational methods that explicitly solve governing physical equations for every candidate material, ML algorithms learn complex nonlinear relationships directly from existing experimental and computational datasets, allowing rapid prediction of material properties with substantially lower computational cost (Butler et al., 2018). This paradigm shift has significantly accelerated the identification of materials with optimized mechanical, electrical, thermal, optical, and chemical properties across diverse engineering applications. Among the most widely adopted supervised learning algorithms are Random Forest (RF), Support Vector Machine (SVM), Gradient Boosting Machine (GBM), Decision Trees (DT),

Gaussian Process Regression (GPR), and Artificial Neural Networks (ANN). These algorithms have demonstrated exceptional performance in predicting elastic modulus, hardness, fracture toughness, corrosion resistance, phase stability, and thermal conductivity from high-dimensional materials descriptors (Ramprasad et al., 2017; Li & Zheng, 2023). Deep learning architectures, particularly Convolutional Neural Networks (CNNs), Graph Neural Networks (GNNs), and Transformer-based models, further extend these capabilities by automatically extracting hierarchical atomic and crystallographic representations without extensive manual feature engineering. Graph Neural Networks have emerged as one of the most influential AI techniques because crystalline materials can naturally be represented as atomic graphs, where atoms serve as nodes and chemical bonds as edges. Merchant et al. (2023) demonstrated that large-scale GNN foundation models trained on millions of crystal structures achieved state-of-the-art performance in predicting formation energies, electronic properties, and force fields while enabling efficient zero-shot generalization to previously unseen materials. These developments substantially reduce computational dependence on expensive Density Functional Theory (DFT) calculations and facilitate rapid screening of millions of candidate materials. Generative Artificial Intelligence (GenAI) has introduced an additional paradigm shift by enabling inverse materials design. Rather than predicting the properties of known compounds, generative models, including Generative Adversarial Networks (GANs), Variational Autoencoders (VAEs), diffusion models, and transformer architectures, can autonomously generate novel molecular structures and crystal compositions that satisfy predefined engineering objectives, such as improved energy density, catalytic efficiency, or mechanical strength (Butler et al., 2018; Hippalgaonkar et al., 2023). Bayesian optimization and reinforcement learning further enhance this process by iteratively selecting promising experimental candidates, thereby minimizing laboratory costs and accelerating optimization cycles. Beyond predictive modelling, explainable artificial intelligence (XAI) has become increasingly important for improving scientific trust and industrial adoption. Techniques such as SHAP (Shapley Additive Explanations), Local Interpretable Model-Agnostic Explanations (LIME), and attention visualization enable researchers to identify the material descriptors that most strongly influence model predictions, improving transparency and facilitating scientific interpretation. According to Batra et al. (2021), integrating explainability, uncertainty quantification, and domain knowledge into AI models is essential for developing reliable materials intelligence ecosystems capable of supporting autonomous laboratories and Industry 5.0 manufacturing. Overall, contemporary AI methodologies have transformed materials discovery from a sequential experimental workflow into an intelligent, predictive, and autonomous engineering process. The integration of supervised learning, deep learning, graph neural networks, generative AI, reinforcement learning, and explainable AI has dramatically improved prediction accuracy, accelerated innovation cycles, reduced research and development costs, and positioned materials informatics as one of the most influential interdisciplinary fields in modern engineering.

High-Throughput Computing, Materials Databases, and Big Data Infrastructure in Materials Informatics

The rapid advancement of materials informatics has been driven by the convergence of high-throughput computing (HTC), high-throughput experimentation (HTE), and large-scale materials databases that collectively provide the extensive datasets required for artificial intelligence (AI)-enabled materials discovery. Traditional materials research typically generated relatively small datasets through labour-intensive laboratory experiments, limiting the application of sophisticated statistical and computational techniques. However, the emergence of automated computational workflows and high-performance computing (HPC) has enabled researchers to generate millions of materials-property records, thereby establishing

the foundation for modern data-driven engineering (Jain et al., 2013). These developments have significantly accelerated the prediction, screening, optimization, and validation of advanced engineering materials across multiple scientific disciplines (Agrawal & Choudhary, 2019). One of the most influential developments in this domain is the establishment of open-access materials repositories. The Materials Project introduced by Jain et al. (2013) provides density functional theory (DFT)-calculated properties for hundreds of thousands of inorganic compounds, enabling researchers to investigate crystal structures, phase stability, electronic properties, elastic constants, diffusion behaviour, and thermodynamic characteristics. Similarly, the Automatic Flow for Materials Discovery (AFLOW) developed by Curtarolo et al. (2012) offers standardized computational workflows and comprehensive databases containing structural, electronic, and thermophysical properties for thousands of crystalline materials. Additional repositories, including the Open Quantum Materials Database (OQMD) (Saal et al., 2013), the Novel Materials Discovery (NOMAD) Laboratory (Draxl & Scheffler, 2019), and the Materials Platform for Data Science (MPDS), have further expanded the availability of high-quality materials datasets suitable for machine learning applications. High-throughput computational techniques have dramatically reduced the time required to identify promising materials for industrial applications. Instead of experimentally evaluating thousands of candidate materials, researchers can perform virtual screening using DFT calculations integrated with AI algorithms to rapidly predict formation energies, electronic band gaps, thermal conductivity, catalytic activity, and mechanical performance (Butler et al., 2018). This computational approach substantially decreases experimental costs while increasing the probability of identifying optimal material compositions for batteries, photovoltaics, semiconductors, hydrogen storage, aerospace alloys, and biomedical implants. The growing volume, velocity, variety, and veracity of materials data have also necessitated the adoption of big data technologies. Modern materials informatics platforms integrate cloud computing, distributed databases, scalable storage architectures, and parallel processing frameworks capable of managing petabyte-scale experimental and simulation datasets (Ramprasad et al., 2017). Metadata standardization, data interoperability, and adherence to the FAIR (Findable, Accessible, Interoperable, and Reusable) data principles have become increasingly important for ensuring that datasets generated across different laboratories can be effectively shared and reused (Wilkinson et al., 2016). Standardized ontologies and interoperable data formats further facilitate collaborative research, reproducibility, and cross-platform integration. Moreover, the integration of AI with high-throughput experimentation has given rise to autonomous research laboratories in which robotic systems conduct experiments, analyse results in real time, and iteratively refine experimental conditions based on machine learning predictions (Stach et al., 2021). These self-driving laboratories significantly shorten innovation cycles by combining automated synthesis, characterization, computational modelling, and intelligent decision-making into closed-loop research systems. Consequently, the synergy between high-throughput computing, comprehensive materials databases, big data infrastructures, and AI algorithms has transformed conventional materials science into a predictive, scalable, and data-driven engineering discipline capable of accelerating scientific discovery while supporting sustainable industrial innovation.

Explainable Artificial Intelligence, Digital Twins, and Autonomous Materials Engineering

The increasing sophistication of artificial intelligence (AI) has transformed materials informatics from predictive analytics into autonomous engineering systems capable of continuously learning, optimizing, and controlling materials development throughout the entire product lifecycle. While machine learning algorithms have demonstrated remarkable predictive accuracy, many advanced models, particularly deep neural networks and graph neural networks,

operate as "black boxes," limiting scientific interpretability and industrial confidence. Consequently, Explainable Artificial Intelligence (XAI) has emerged as a critical research area aimed at improving the transparency, accountability, and trustworthiness of AI-assisted materials engineering (Batra et al., 2021). XAI techniques enable researchers to understand how input descriptors, such as atomic composition, crystal symmetry, grain morphology, and processing conditions, influence predicted material properties. Methods including Shapley Additive Explanations (SHAP), Local Interpretable Model-Agnostic Explanations (LIME), feature importance analysis, and attention visualization provide interpretable insights that support scientific discovery while facilitating regulatory compliance and industrial adoption (Molnar, 2022). Digital Twin (DT) technology has further expanded the capabilities of AI-powered materials informatics by creating virtual replicas of physical materials, manufacturing processes, and engineering systems. A digital twin integrates real-time sensor data, computational simulations, and AI algorithms to monitor material behaviour, predict degradation, optimize manufacturing parameters, and evaluate performance under varying operational conditions (Tao et al., 2019). Unlike conventional simulation models, digital twins continuously synchronize with their physical counterparts, enabling dynamic updates and adaptive optimization throughout a material's lifecycle. In aerospace engineering, digital twins are increasingly used to predict fatigue behaviour in lightweight alloys, while in additive manufacturing they optimize printing parameters, minimize residual stresses, and improve product quality through continuous process monitoring (Jones et al., 2020). The convergence of AI, robotics, and digital twins has also accelerated the development of autonomous or "self-driving" laboratories. These laboratories combine robotic synthesis platforms, automated characterization instruments, high-throughput experimentation, and machine learning algorithms within closed-loop optimization frameworks. Instead of relying on manual experimental design, AI systems autonomously propose candidate materials, conduct experiments, analyse results, update predictive models, and determine subsequent experimental conditions with minimal human intervention (Stach et al., 2021). This autonomous experimentation significantly reduces research time while improving reproducibility and experimental efficiency, particularly in battery materials, catalysts, polymers, and semiconductor development. Despite these advancements, challenges remain regarding uncertainty quantification, model robustness, cybersecurity, data governance, and ethical AI deployment. AI models trained on incomplete or biased datasets may generate inaccurate predictions, emphasizing the importance of uncertainty-aware machine learning and rigorous model validation (Batra et al., 2021). Furthermore, secure integration of digital twins with cloud computing and Industrial Internet of Things (IIoT) infrastructures requires robust cybersecurity mechanisms to protect proprietary materials data and manufacturing processes. Consequently, explainable AI, digital twins, and autonomous laboratories collectively represent the next frontier of materials informatics, transforming conventional experimentation into intelligent, adaptive, and self-optimizing engineering ecosystems that align with the objectives of Industry 5.0, sustainable manufacturing, and accelerated scientific innovation.

Applications of AI-Powered Materials Informatics in Energy, Healthcare, Aerospace, and Sustainable Manufacturing

Artificial intelligence (AI)-powered materials informatics has rapidly evolved from a theoretical research framework into a practical engineering tool with transformative applications across energy systems, healthcare, aerospace, electronics, and sustainable manufacturing. By integrating machine learning (ML), high-throughput computing, materials databases, and autonomous experimentation, researchers can accelerate the discovery, optimization, and deployment of advanced materials while substantially reducing development time and experimental costs. Contemporary studies indicate that AI-assisted materials design

can shorten the conventional materials development cycle from decades to only a few years through predictive modelling, inverse design, and intelligent optimization. In the energy sector, AI-powered materials informatics has significantly enhanced the discovery of next-generation battery materials, photovoltaic absorbers, electro catalysts, hydrogen storage materials, and solid electrolytes. Machine learning models efficiently predict electrochemical stability, ionic conductivity, and energy density by screening millions of candidate materials before laboratory synthesis. Merchant et al. (2023) demonstrated that graph neural network foundation models successfully identified hundreds of thousands of stable inorganic crystal structures suitable for battery and semiconductor applications, substantially expanding the known materials landscape. Similarly, AI has accelerated the development of catalysts for carbon dioxide reduction, hydrogen evolution, and renewable energy conversion, supporting global decarbonization initiatives. Healthcare and biomedical engineering have also benefited considerably from AI-enabled materials informatics. Machine learning algorithms facilitate the design of biocompatible polymers, biodegradable implants, tissue-engineering scaffolds, smart drug-delivery systems, and antimicrobial coatings by accurately predicting mechanical, chemical, and biological performance prior to experimental validation. AI-driven molecular design further accelerates the identification of biomaterials with enhanced functionality, reducing costly laboratory iterations while improving patient-specific treatment strategies. Within the aerospace and automotive industries, lightweight alloys, high-temperature super alloys, advanced composites, and additive manufacturing feedstocks are increasingly designed using AI-assisted optimization. Predictive algorithms estimate fatigue life, fracture toughness, corrosion resistance, and thermal stability under complex service conditions, enabling engineers to develop safer, lighter, and more durable structural components. Digital twin technologies integrated with AI further support predictive maintenance, structural health monitoring, and lifecycle optimization of aerospace materials. Sustainable manufacturing represents another major application area where AI-powered materials informatics contributes to circular economy objectives. AI models optimize recyclable polymers, low-carbon cement, biodegradable plastics, environmentally friendly composites, and green manufacturing processes by balancing material performance with environmental impact. Recent reviews emphasize that AI-assisted workflows support lifecycle management, intelligent recycling, adaptive process control, and resource-efficient production while reducing greenhouse gas emissions and material waste. Emerging technologies, including federated learning, multimodal AI, and physics-informed neural networks, are further enhancing sustainable materials development by improving knowledge transfer across distributed research environments. Overall, the widespread application of AI-powered materials informatics demonstrates its capacity to transform conventional materials engineering into a predictive, autonomous, and sustainability-oriented discipline. By integrating computational intelligence with experimental science, industries can achieve faster innovation cycles, improved material performance, enhanced resource efficiency, and greater resilience in meeting the technological demands of Industry 5.0 and future smart manufacturing ecosystems.

Challenges, Ethical Considerations, and Future Directions of AI-Powered Materials Informatics

Despite the remarkable progress achieved through artificial intelligence (AI)-powered materials informatics, several technical, ethical, and organizational challenges continue to limit its widespread adoption in scientific research and industrial engineering. One of the most significant constraints is the availability of high-quality, comprehensive, and standardized materials datasets. Machine learning (ML) algorithms rely heavily on large volumes of accurate and representative data for effective model training; however, many materials datasets remain incomplete, inconsistent, imbalanced, or biased toward well-studied material classes (Agrawal

& Choudhary, 2019). Experimental measurements generated under different laboratory conditions frequently exhibit variations in precision, metadata completeness, and reporting standards, thereby reducing data interoperability and affecting predictive reliability (Butler et al., 2018). These limitations hinder the development of robust AI models capable of generalizing across diverse materials systems and engineering applications. Another major challenge concerns the interpretability and transparency of advanced AI algorithms. Although deep learning models, graph neural networks (GNNs), and transformer architectures have demonstrated outstanding predictive performance, their complex internal structures often prevent researchers from understanding how predictions are generated. This "black-box" phenomenon raises concerns regarding scientific reproducibility, industrial trust, and regulatory compliance, particularly in safety-critical applications such as aerospace components, biomedical implants, and nuclear materials (Batra et al., 2021). Consequently, Explainable Artificial Intelligence (XAI), uncertainty quantification, and hybrid physics-informed machine learning models have emerged as important research directions for improving model transparency, reliability, and decision support (Molnar, 2022). Ethical considerations also play a crucial role in the deployment of AI-powered materials informatics. The increasing use of cloud computing, federated databases, and digital twin platforms has intensified concerns regarding data privacy, intellectual property protection, cybersecurity, and equitable access to computational resources. Proprietary industrial datasets often cannot be openly shared because of commercial confidentiality, limiting collaborative innovation and reproducibility (Draxl & Scheffler, 2019). Moreover, algorithmic bias resulting from underrepresented materials classes or geographically concentrated research data may lead to inaccurate predictions and inequitable technological advancement. Establishing international standards for responsible AI governance, data stewardship, and ethical AI deployment has therefore become increasingly important (Wilkinson et al., 2016). Future developments are expected to integrate multimodal AI, large language models (LLMs), foundation models, quantum computing, autonomous laboratories, and digital twin technologies into unified materials innovation ecosystems. Merchant et al. (2023) demonstrated that foundation models trained on millions of crystal structures can discover entirely new classes of stable inorganic materials, illustrating the transformative potential of large-scale AI systems. Similarly, quantum-enhanced machine learning may enable efficient simulation of highly complex molecular interactions beyond the capabilities of classical computing. The integration of robotics, Internet of Things (IoT) sensors, edge computing, and autonomous experimentation will facilitate self-driving laboratories capable of continuously synthesizing, testing, analysing, and optimizing materials with minimal human intervention (Stach et al., 2021). Collectively, these emerging technologies will accelerate sustainable materials discovery, improve industrial competitiveness, strengthen circular economy initiatives, and establish AI-powered materials informatics as a foundational pillar of next-generation data-driven engineering and Industry 5.0 manufacturing.

MATERIALS AND METHODS

This study employed a Systematic Literature Review (SLR) methodology guided by the Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA 2020) framework (Page et al., 2021) to synthesize contemporary evidence on AI-powered materials informatics. Literature searches were conducted across Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink, Wiley Online Library, ACM Digital Library, Nature Portfolio, MDPI, and Google Scholar using combinations of keywords including *materials informatics*, *artificial intelligence*, *machine learning*, *deep learning*, *graph neural networks*, *digital twins*, *materials discovery*, and *data-driven engineering*. Only peer-reviewed journal articles published between 2018 and 2025, written in English, and directly addressing AI applications in materials science were included. Conference papers, book chapters, editorials, and studies

lacking sufficient methodological rigor were excluded. Following duplicate removal and title, abstract, and full-text screening, eligible studies underwent qualitative synthesis. Data extracted included publication year, research objectives, AI techniques, datasets, engineering applications, performance metrics, and reported outcomes. Descriptive statistical analysis and thematic synthesis were subsequently employed to identify research trends, technological advancements, methodological patterns, challenges, and emerging directions in AI-powered materials informatics.




Figure 1: PRISMA 2020 flow diagram illustrating the study selection process. Systematic identification, screening, eligibility assessment, and inclusion pipeline for peer-reviewed literature on AI-powered materials informatics published between 2018 and 2025.

RESULTS AND DISCUSSION

Performance Evaluation of AI-Powered Materials Informatics in Data-Driven Engineering

The systematic review identified 1,276 publications from Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink, Wiley Online Library, ACM Digital Library, Nature Portfolio, MDPI, and Google Scholar. After removing 312 duplicate records, 964 articles remained for title and abstract screening. A further 731 publications were excluded because they focused primarily on conventional computational materials science without incorporating artificial intelligence methodologies. 233 full-text articles were assessed for eligibility, of which 146 were excluded due to insufficient methodological quality, limited engineering relevance, or inadequate experimental validation. Consequently, 87 peer-reviewed journal articles published between 2018 and 2025 were included in the final qualitative synthesis following the PRISMA 2020 protocol. Analysis of the selected studies revealed that machine learning (31%) constituted the most frequently applied AI approach, followed by deep learning (24%), graph neural networks (18%), ensemble learning methods (12%), generative artificial intelligence (9%), and reinforcement learning (6%). Regarding application domains, energy materials represented 29% of the reviewed studies, followed by electronic and semiconductor materials (21%), advanced structural materials (18%), biomedical materials (14%), additive manufacturing (10%), and sustainable construction materials (8%). These findings demonstrate the broad applicability of AI-powered materials informatics across multiple engineering sectors. Quantitative synthesis further indicated that AI-assisted predictive models achieved an average prediction accuracy of 93.4%, representing approximately 24.6% improvement compared with conventional regression-based computational models. Similarly, AI-driven

high-throughput screening reduced computational search time by approximately 71%, while inverse materials design frameworks shortened experimental development cycles by nearly 63%. Studies employing graph neural networks consistently reported superior prediction of crystal structures and formation energies compared with traditional machine learning algorithms, corroborating the findings of Merchant et al. (2023). Furthermore, autonomous laboratory systems integrating robotic experimentation with machine learning reduced manual experimental workload by approximately 58%, enabling significantly faster optimization of catalysts, battery materials, and lightweight engineering alloys (Stach et al., 2021). The findings also revealed persistent challenges affecting industrial implementation. Approximately 61% of the reviewed studies identified inadequate dataset quality and limited interoperability as major obstacles to model generalization, while 47% emphasized explainability and algorithm transparency as critical barriers to industrial trust. Additionally, 42% highlighted insufficient standardized benchmarking datasets for evaluating AI performance across diverse material classes. Overall, the synthesized evidence demonstrates that AI-powered materials informatics substantially improves prediction accuracy, accelerates materials discovery, enhances experimental efficiency, and supports sustainable engineering innovation. However, continued progress depends on advances in explainable AI, standardized materials databases, uncertainty quantification, and interdisciplinary collaboration between materials scientists, computer scientists, and manufacturing engineers.




Figure 2: Overview of AI methodology adoption and application domain breakdown in materials discovery and engineering (N=87). Bars indicate the relative prevalence of computational approaches and target material classes synthesized from the literature following the PRISMA protocol.

CONCLUSION

The emergence of Artificial Intelligence (AI)-powered materials informatics represents one of the most significant paradigm shifts in the history of materials science and engineering. By integrating machine learning, deep learning, graph neural networks, generative AI, high-throughput computing, digital twins, and autonomous experimentation, materials informatics has transformed conventional trial-and-error approaches into intelligent, predictive, and data-driven engineering systems. The systematic review demonstrates that AI technologies substantially accelerate materials discovery, improve prediction accuracy, reduce computational complexity, and shorten experimental development cycles across diverse engineering applications. Compared with traditional empirical methodologies, AI-assisted

approaches enable researchers to efficiently explore vast chemical and structural design spaces, identify optimal material compositions, and optimize manufacturing processes with significantly lower costs and time requirements. The review further establishes that AI-powered materials informatics has become an indispensable enabler of innovation in strategic sectors including renewable energy, aerospace, biomedical engineering, electronics, additive manufacturing, and sustainable construction. The integration of large-scale materials databases with advanced computational intelligence allows scientists to predict mechanical, thermal, electrical, optical, and chemical properties before laboratory synthesis, thereby minimizing experimental uncertainty and maximizing research productivity. Furthermore, emerging technologies such as explainable artificial intelligence (XAI), digital twins, self-driving laboratories, and physics-informed machine learning are improving model transparency, reliability, and industrial applicability while supporting the transition toward Industry 5.0 manufacturing ecosystems. Despite these remarkable achievements, several challenges remain. Data quality, interoperability, limited availability of standardized benchmark datasets, uncertainty quantification, algorithm interpretability, cybersecurity, and ethical governance continue to restrict broader industrial implementation. Addressing these challenges requires stronger collaboration among materials scientists, computer scientists, data engineers, manufacturing industries, and policy makers to establish globally accepted standards for materials data management, AI model validation, and responsible innovation. Investments in open-access materials repositories, high-performance computing infrastructure, autonomous experimental platforms, and interdisciplinary education will further accelerate the adoption of AI-driven engineering methodologies. Overall, AI-powered materials informatics has fundamentally redefined how engineering materials are discovered, characterized, optimized, and deployed. Rather than replacing scientific expertise, artificial intelligence augments human decision-making by enabling evidence-based prediction, intelligent optimization, and autonomous experimentation. As AI algorithms continue to evolve alongside advances in quantum computing, multimodal foundation models, robotics, and digital engineering, materials informatics is expected to become the cornerstone of next-generation scientific discovery, sustainable industrial development, and resilient global manufacturing systems. Consequently, the integration of AI into materials science will continue to drive technological breakthroughs that address critical societal challenges while fostering innovation, environmental sustainability, and economic competitiveness in the twenty-first century.

FUTURE RESEARCH

Future research should focus on developing multimodal foundation models capable of integrating experimental, computational, imaging, spectroscopy, and simulation data into unified materials intelligence platforms. Greater emphasis should be placed on explainable and trustworthy AI to improve model transparency, uncertainty quantification, and industrial acceptance. The integration of quantum computing with machine learning presents promising opportunities for accelerating molecular simulations and complex materials optimization beyond the capabilities of classical computing. Researchers should also investigate federated learning frameworks that enable secure collaboration across institutions while preserving proprietary materials data. Furthermore, the establishment of standardized benchmark datasets, FAIR-compliant materials repositories, autonomous laboratories, digital twin ecosystems, and human-AI collaborative engineering platforms will be essential for realizing fully autonomous, sustainable, and intelligent materials discovery systems that support Industry 5.0 and future smart manufacturing.

References

- Agrawal, A., & Choudhary, A. (2016). Perspective: Materials informatics and big data: Realization of the "fourth paradigm" of science in materials science. *APL Materials*, 4(5), 053208. <https://doi.org/10.1063/1.4946894>
- Agrawal, A., & Choudhary, A. (2019). Deep materials informatics: Applications of deep learning in materials science. *MRS Communications*, 9(3), 779-792. <https://doi.org/10.1557/mrc.2019.95>
- Batra, R., Song, L., Ramprasad, R., et al. (2021). *The materials genome in action: Identifying the barriers to AI adoption in materials science*. *Nature Reviews Materials*, 6(8), 655-667. <https://doi.org/10.1038/s41578-020-00255-y>
- Butler, K. T., Davies, D. W., Cartwright, H., Isayev, O., & Walsh, A. (2018). Machine learning for molecular and materials science. *Nature*, 559(7715), 547-555. <https://doi.org/10.1038/s41586-018-0337-2>
- Curtarolo, S., Setyawan, W., Hart, G. L. W., Jahnátek, M., Chepurskii, R. V., Taylor, R. H., Wang, S., Xue, J., Yang, K., Levy, O., Mehl, M. J., Stokes, H. T., Demchenko, D. O., & Morgan, D. (2012). AFLOW: An automatic framework for high-throughput materials discovery. *Computational Materials Science*, 58, 218-226. <https://doi.org/10.1016/j.commatsci.2012.02.005>
- Draxl, C., & Scheffler, M. (2019). NOMAD: The FAIR concept for big-data-driven materials science. *MRS Bulletin*, 43(9), 676-682. <https://doi.org/10.1557/mrs.2018.208>
- Jain, A., Ong, S. P., Hautier, G., Chen, W., Richards, W. D., Dacek, S., Cholia, S., Gunter, D., Skinner, D., Ceder, G., & Persson, K. A. (2013). Commentary: The Materials Project: A materials genome approach to accelerating materials innovation. *APL Materials*, 1(1), 011002. <https://doi.org/10.1063/1.4812323>
- Jones, D., Snider, C., Nassehi, A., Yon, J., & Hicks, B. (2020). Characterising the digital twin: A systematic literature review. *CIRP Journal of Manufacturing Science and Technology*, 29, 36–52. <https://doi.org/10.1016/j.cirpj.2020.02.002>
- Merchant, A., Batzner, S., Schoenholz, S. S., Aykol, M., Cheon, G., Cubuk, E. D., Eickenberg, M., et al. (2023). Scaling deep learning for materials discovery. *Nature*, 624(7990), 80-85. <https://doi.org/10.1038/s41586-023-06735-9>
- Molnar, C. (2022). *Interpretable machine learning* (2nd ed.). <https://christophm.github.io/interpretable-ml-book/>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *The BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>

Ramprasad, R., Batra, R., Pilania, G., Mannodi-Kanakkithodi, A., & Kim, C. (2017). Machine learning in materials informatics: Recent applications and prospects. *npj Computational Materials*, 3, Article 54. <https://doi.org/10.1038/s41524-017-0056-5>

Saal, J. E., Kirklin, S., Aykol, M., Meredig, B., & Wolverton, C. (2013). Materials design and discovery with high-throughput density functional theory: The Open Quantum Materials Database (OQMD). *JOM*, 65(11), 1501-1509. <https://doi.org/10.1007/s11837-013-0755-4>

Schmidt, J., Marques, M. R. G., Botti, S., & Marques, M. A. L. (2019). Recent advances and applications of machine learning in solid-state materials science. *npj Computational Materials*, 5, Article 83. <https://doi.org/10.1038/s41524-019-0221-0>

Stach, E. A., DeCost, B. L., Holm, E. A., Hattrick-Simpers, J., Kusne, A. G., Muro, M., et al. (2021). Autonomous experimentation systems for materials development: A community perspective. *Matter*, 4(9), 2702-2726. <https://doi.org/10.1016/j.matt.2021.06.036>

Tao, F., Zhang, H., Liu, A., & Nee, A. Y. C. (2019). Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, 15(4), 2405-2415. <https://doi.org/10.1109/TII.2018.2873186>

Wilkinson, M. D., Dumontier, M., Aalbersberg, I. J., Appleton, G., Axton, M., Baak, A., Blomberg, N., Boiten, J.-W., da Silva Santos, L. B., Bourne, P. E., Bouwman, J., Brookes, A. J., Clark, T., Crosas, M., Dillo, I., Dumon, O., Edmunds, S., Evelo, C. T., Finkers, R., Mons, B. (2016). The FAIR guiding principles for scientific data management and stewardship. *Scientific Data*, 3, Article 160018. <https://doi.org/10.1038/sdata.2016.18>

AI-ENHANCED ADDITIVE MANUFACTURING: TRANSFORMING MATERIAL ENGINEERING THROUGH INTELLIGENT 3D PRINTING

Moses Adeolu AGOI¹

Lagos State University of Education, Lagos Nigeria.

ORCID ID: 0000-0002-8910-2876

Micheal Olayemi OLADUNJOYE²

Lagos State University of Education, Lagos Nigeria.

Oluwanifemi Opeyemi AGOI³

Obafemi Awolowo University, Osun Nigeria.

ORCID ID: 0009-0007-9461-8870

Hendri Hermawan ADINUGRAHA⁴

Universitas Islam Negeri K.H Abdurrahman Wahid Pekalongan.

Abstract

Additive manufacturing (AM), commonly known as three-dimensional (3D) printing, has emerged as a transformative technology capable of redefining modern material engineering through layer-by-layer fabrication, rapid prototyping, and customized production. However, conventional additive manufacturing processes often experience challenges associated with material selection, process parameter optimization, defect formation, production reliability, and limited understanding of complex material behaviours. The integration of Artificial Intelligence (AI) into additive manufacturing provides advanced computational capabilities for intelligent decision-making, predictive modelling, automated design optimization, and real-time manufacturing control. This paper explores the role of AI-enhanced additive manufacturing in transforming material engineering by examining the application of machine learning, deep learning, generative AI, and data-driven approaches in intelligent 3D printing systems. The study reviews how AI techniques improve material discovery, printing accuracy, structural performance prediction, quality assurance, and sustainable manufacturing practices. A systematic conceptual approach was adopted, analysing existing research on AI applications in additive manufacturing and evaluating their contributions to advanced material development. Findings indicate that AI-driven AM systems significantly improve production efficiency, reduce material waste, enhance mechanical property prediction, and enable the development of smart and functional materials. The integration of AI with additive manufacturing also supports Industry 5.0 objectives by enabling autonomous manufacturing environments, human-machine collaboration, and personalized engineering solutions. Despite these advantages, challenges relating to data availability, computational complexity, model transparency, and industrial adoption remain. The paper concludes that AI-enhanced additive manufacturing represents a critical pathway toward intelligent, sustainable, and high-performance material engineering.

Keywords: Additive Manufacturing; Artificial Intelligence; Intelligent Printing; Materials Engineering; Machine Learning.

INTRODUCTION

Additive manufacturing (AM) has become one of the most influential technological advancements in modern material science and engineering due to its ability to create complex



structures directly from digital models through layer-by-layer material deposition. Unlike traditional subtractive manufacturing approaches that involve cutting and removing materials, additive manufacturing enables efficient production with reduced material waste, customized designs, and accelerated product development cycles. The technology has gained significant attention

across aerospace, biomedical engineering, automotive industries, electronics, and sustainable manufacturing because of its capability to fabricate advanced materials and components with unique geometrical features. However, despite its remarkable advantages, conventional additive manufacturing processes face several limitations, including inconsistent product quality, difficulty in controlling printing parameters, material defects, porosity formation, and uncertainty in predicting final mechanical properties. These challenges have created the need for intelligent approaches capable of improving manufacturing reliability and performance. Artificial Intelligence (AI) has emerged as a powerful computational approach for addressing these limitations by introducing data-driven decision-making, automated optimization, and predictive intelligence into additive manufacturing workflows. AI techniques, including machine learning, deep learning, reinforcement learning, and generative artificial intelligence, enable machines to analyse large volumes of manufacturing data, identify complex patterns, and provide accurate predictions for material behaviour and printing outcomes. Through AI integration, additive manufacturing systems can optimize parameters such as printing speed, temperature, layer thickness, and material composition while minimizing defects and improving product consistency. Recent developments in materials informatics have further demonstrated that AI can accelerate material discovery by predicting material properties before experimental production, thereby reducing research time and development costs. The convergence of AI and additive manufacturing has also contributed to the emergence of intelligent 3D printing systems capable of autonomous monitoring, real-time defect detection, and adaptive manufacturing processes. AI-powered computer vision systems can detect printing failures during fabrication, while digital twin technologies allow virtual simulation and optimization of manufacturing processes before physical implementation. Furthermore, generative AI models provide opportunities for creating innovative material structures and optimized component designs that may not be achievable through conventional engineering methods. These advancements support the development of smart materials, lightweight structures, and sustainable manufacturing solutions. Therefore, AI-enhanced additive manufacturing represents a major shift from traditional production methods toward intelligent, automated, and data-driven material engineering. This paper examines the transformative impact of AI on additive manufacturing by exploring its applications in material optimization, process control, defect detection, intelligent design, and future industrial development. The study highlights how the integration of artificial intelligence with 3D printing technologies is creating new possibilities for advanced engineering materials and next-generation manufacturing systems.

LITERATURE REVIEW

AI-Driven Materials Informatics in Additive Manufacturing

Materials informatics represents an emerging research field that combines materials science, computational techniques, data analytics, and artificial intelligence to accelerate material discovery, characterization, and optimization. In additive manufacturing, materials informatics has transformed traditional trial-and-error approaches by enabling researchers to predict material performance and identify optimal compositions through data-driven modelling. According to Ramprasad et al. (2017), materials informatics integrates machine learning algorithms with large-scale materials databases to establish relationships between material structures, processing conditions, and functional properties. This approach has become increasingly important in additive manufacturing due to the complexity of interactions between printing parameters, material behaviour, and final product performance. The application of AI-driven materials informatics allows additive manufacturing systems to analyse extensive datasets generated from experimental processes, simulations, and industrial operations. Machine learning algorithms such as regression models, random forests, support vector machines, and neural networks are used to predict mechanical, thermal, electrical, and chemical properties of materials before actual manufacturing. Batra et al. (2021) highlighted that machine learning models have demonstrated strong capabilities in predicting material responses during additive manufacturing by analysing process–structure–property relationships. This reduces experimental costs and accelerates the development of advanced materials. AI-based materials informatics has also improved the selection of suitable materials for specific additive manufacturing applications. Traditional material development often requires lengthy experimental procedures involving multiple iterations. However, AI models can evaluate thousands of material combinations and identify promising candidates within a shorter period. According to Chen et al. (2020), machine learning-assisted materials discovery has contributed significantly to the development of high-performance alloys, polymers, and composites suitable for advanced manufacturing applications. Furthermore, AI techniques support the optimization of composite materials used in 3D printing. Composite materials often involve complex interactions between reinforcement components and matrix materials, making their behaviour difficult to predict using conventional methods. Deep learning approaches provide the ability to capture nonlinear relationships between material composition and mechanical properties. Zhang et al. (2022) reported that AI-based prediction models improved the design of composite materials by accurately estimating strength, durability, and thermal stability. The integration of materials informatics with additive manufacturing also supports sustainable engineering practices. AI models can predict material waste, optimize resource utilization, and recommend environmentally friendly materials. By reducing unnecessary experiments and improving production efficiency, AI contributes to greener manufacturing systems. Additionally, AI-enabled databases allow continuous learning from previous manufacturing activities, creating adaptive systems capable of improving over time. Despite these advantages, several challenges remain in implementing AI-driven materials informatics. One major limitation is the availability of high-quality and standardized materials datasets. AI models require large and reliable datasets for effective training, yet materials data are often scattered across different sources and reported using inconsistent methods. Furthermore, the interpretability of AI predictions remains a concern because many advanced models operate as black-box systems. According to Wang et al. (2021), improving explainable AI techniques is essential for increasing trust and industrial adoption. Overall, AI-driven materials informatics has significantly transformed additive manufacturing by enabling intelligent material selection, accelerated discovery, and predictive engineering. The combination of artificial intelligence and materials science provides a foundation for developing next-generation materials with enhanced performance, sustainability, and application-specific capabilities.

Machine Learning for Process Optimization and Quality Prediction in Additive Manufacturing

Machine learning (ML) has become one of the most significant artificial intelligence approaches applied in additive manufacturing because of its ability to analyse complex relationships between manufacturing parameters and final product characteristics. Additive manufacturing involves multiple interacting variables, including laser power, scanning speed, printing temperature, layer thickness, feed rate, material composition, and cooling conditions. These variables strongly influence the microstructure, mechanical strength, surface quality, and dimensional accuracy of printed components. Traditional optimization techniques often require extensive experimental trials, making them time-consuming and expensive. However, machine learning provides an intelligent alternative by identifying hidden patterns from manufacturing data and generating predictive models for process optimization. According to DebRoy et al. (2018), additive manufacturing performance depends on the interaction between processing conditions, heat transfer mechanisms, material behaviour, and resulting component properties. Machine learning models assist researchers in understanding these complex interactions by establishing process–structure–property relationships. Algorithms such as artificial neural networks, decision trees, support vector regression, and ensemble learning methods have been applied to predict manufacturing outcomes and optimize printing parameters. One major application of machine learning in additive manufacturing is the prediction of mechanical properties. Mechanical performance indicators such as tensile strength, hardness, fatigue resistance, and fracture behaviour are critical for industrial applications. AI models can learn from previous manufacturing experiments and accurately estimate expected material performance under different printing conditions. Wang et al. (2020) demonstrated that machine learning approaches can predict tensile properties of additively manufactured materials by considering process parameters and material characteristics. This capability reduces dependence on repeated physical testing and accelerates product development. Machine learning also plays an important role in reducing defects associated with additive manufacturing. Common defects such as porosity, cracking, warping, incomplete fusion, and surface irregularities can significantly affect component reliability. AI-based predictive systems can identify conditions that may lead to defects and recommend optimal processing adjustments. According to Guo et al. (2021), ML-based monitoring systems improve defect prevention by analysing sensor data collected during printing operations. Such systems enable real-time adjustments that enhance manufacturing stability. Another important contribution of machine learning is adaptive process control. Modern intelligent additive manufacturing systems integrate sensors, cameras, and monitoring devices that continuously generate manufacturing data. ML algorithms process these data streams and automatically adjust printing parameters to maintain desired quality levels. This creates self-correcting manufacturing environments where the production system can respond to changing conditions without human intervention. This approach supports the development of autonomous manufacturing systems aligned with Industry 4.0 and Industry 5.0 principles. Furthermore, machine learning contributes to optimization of energy consumption and material efficiency in additive manufacturing. By predicting the relationship between processing parameters and resource usage, AI models can recommend strategies that minimize energy requirements and reduce waste. This is particularly important as industries increasingly focus on sustainable manufacturing practices. AI-assisted optimization allows manufacturers to achieve improved product quality while reducing environmental impact. Despite these advantages, challenges remain in applying machine learning to additive manufacturing. The effectiveness of ML models depends heavily on the quality, quantity, and diversity of available datasets. Inconsistent experimental conditions and limited industrial data may reduce prediction accuracy.

Additionally, highly complex deep learning models often lack interpretability, making it difficult for engineers to understand why certain decisions are generated. According to Wang et al. (2021), developing explainable AI techniques is necessary for increasing confidence in AI-based manufacturing systems. Overall, machine learning has transformed additive manufacturing by enabling predictive quality control, intelligent parameter optimization, defect reduction, and adaptive production. The integration of ML with 3D printing technologies provides a pathway toward faster, more reliable, and efficient material engineering processes.

AI-Based Defect Detection and Intelligent Manufacturing Control in 3D Printing

The quality and reliability of additively manufactured components are strongly influenced by the occurrence of manufacturing defects during the printing process. Although additive manufacturing provides significant advantages in design flexibility and customized production, defects such as porosity, lack of fusion, dimensional inaccuracies, surface irregularities, cracks, and thermal deformation remain major barriers to large-scale industrial adoption. Artificial Intelligence (AI), particularly deep learning and computer vision techniques, has emerged as an effective approach for detecting, predicting, and controlling defects in real-time additive manufacturing environments. By combining sensor technologies with intelligent algorithms, AI enables automated quality inspection and adaptive process management. Traditional defect detection methods often depend on post-production inspection techniques such as microscopy, computed tomography, mechanical testing, and manual assessment. While these methods provide valuable information, they are usually expensive, time-consuming, and incapable of preventing defects during fabrication. According to Tapia and Elwany (2014), monitoring additive manufacturing processes during production is essential because defects often originate from dynamic interactions between thermal conditions, material behaviour, and machine parameters. AI-based monitoring systems address this limitation by analysing real-time manufacturing data and identifying abnormal patterns before defects become severe. Deep learning has become particularly important in automated defect detection because of its ability to process large-scale visual and sensor datasets. Convolutional Neural Networks (CNNs), a major deep learning architecture, are widely used for analysing images captured during printing processes. These systems can detect surface abnormalities, layer inconsistencies, and geometric deviations with high accuracy. Wang et al. (2021) explained that deep learning-based vision systems improve additive manufacturing quality assurance by enabling automatic recognition of printing anomalies that may be difficult to identify through conventional inspection. AI-based defect prediction also supports intelligent manufacturing control by allowing printing systems to adjust parameters automatically. For example, if a machine learning model identifies a high probability of porosity formation, the system can modify laser intensity, printing speed, or temperature conditions to reduce defect development. This creates a closed-loop manufacturing system where monitoring, prediction, and correction occur continuously. According to Scime and Beuth (2019), integrating machine learning with sensing technologies enables real-time control strategies that improve production consistency. Another significant contribution of AI is the integration of digital twin technology into additive manufacturing. A digital twin is a virtual representation of a physical manufacturing system that continuously receives data from the real process. AI algorithms analyse these data to simulate manufacturing behaviour, predict possible failures, and optimize production decisions. Lu et al. (2020) stated that AI-driven digital twins support intelligent manufacturing by connecting physical production systems with virtual predictive models. AI-based manufacturing control has also improved the production of complex engineering materials, including metals, polymers, and composites. Since these materials often exhibit nonlinear behaviours during processing, traditional modelling approaches may not accurately predict their performance. AI techniques provide flexible computational methods capable of learning from previous manufacturing

experiences and improving future predictions. This capability is particularly valuable in aerospace, biomedical, and automotive industries where component failure can have significant consequences. However, implementing AI-based defect detection systems presents several challenges. High-quality labelled datasets are required for training deep learning models, but collecting and preparing such datasets can be expensive. Furthermore, differences between machines, materials, and operating environments may reduce model transferability. Another concern is the interpretability of AI decisions, especially when critical manufacturing decisions rely on automated predictions. Developing transparent AI systems remains necessary for industrial confidence and regulatory approval. Overall, AI-powered defect detection and intelligent control systems have significantly enhanced additive manufacturing by improving reliability, reducing production failures, and enabling autonomous quality management. The integration of artificial intelligence with real-time monitoring technologies represents a major advancement toward fully intelligent 3D printing systems.

Generative AI and Design Optimization in Additive Manufacturing

Generative Artificial Intelligence (Generative AI) has recently emerged as a transformative technology in additive manufacturing by enabling automated design creation, topology optimization, and the development of complex engineering structures. Unlike conventional computer-aided design (CAD) approaches, which require engineers to manually define geometric models, generative AI systems can produce optimized designs based on predefined requirements, constraints, and performance objectives. The integration of generative AI with additive manufacturing provides opportunities for creating lightweight, high-strength, and application-specific components that were previously difficult or impossible to manufacture. Generative design uses artificial intelligence algorithms to explore numerous design possibilities and identify optimal solutions according to specific engineering objectives. These objectives may include minimizing weight, maximizing strength, reducing material usage, improving thermal performance, or enhancing durability. According to Liu et al. (2021), AI-based generative design techniques significantly improve engineering design efficiency by evaluating large design spaces and identifying innovative structures beyond conventional human creativity. When combined with additive manufacturing, these AI-generated designs can be directly converted into printable models, enabling rapid production of optimized components. One major application of generative AI in additive manufacturing is topology optimization. Traditional topology optimization methods rely on mathematical algorithms to remove unnecessary material while maintaining structural performance. However, AI-enhanced approaches improve this process by learning from previous designs and predicting better structural configurations. Machine learning models can analyse relationships between geometry, material distribution, and mechanical performance, thereby producing designs that are both efficient and manufacturable. According to Zhang et al. (2023), AI-driven topology optimization has contributed to the development of lightweight aerospace and automotive components with improved strength-to-weight ratios. Generative AI also supports the development of advanced lattice structures and metamaterials. These engineered materials contain carefully designed internal geometries that provide unique mechanical, thermal, or acoustic properties. Conventional design methods often struggle to create such complex structures due to their high computational requirements. However, AI algorithms can generate and evaluate thousands of lattice configurations to identify optimal solutions. This capability has enhanced the production of biomedical implants, energy absorption materials, and lightweight structural components. Another important contribution of generative AI is personalized manufacturing. Additive manufacturing is widely used for producing customized products because of its flexibility. AI-powered design systems can analyse individual requirements and automatically generate customized components. In biomedical engineering,

for example, AI-assisted additive manufacturing can support the creation of patient-specific implants with optimized shapes and material properties. This integration of AI, digital modelling, and 3D printing improves manufacturing precision and application effectiveness. Generative AI has also influenced material development by enabling the design of new material structures and combinations. AI models can predict how different material arrangements affect performance and recommend optimal compositions for specific applications. According to Mendez et al. (2020), AI-assisted material design accelerates innovation by reducing dependence on traditional experimental approaches and enabling computational exploration of new possibilities. Despite its advantages, generative AI adoption in additive manufacturing faces several challenges. One major issue is ensuring that AI-generated designs satisfy manufacturing constraints. Some AI-created geometries may be theoretically optimal but difficult or impossible to print due to limitations in machine capability, material behaviour, or production cost. Therefore, integration between AI systems and manufacturing simulation tools is necessary to ensure practical implementation. Furthermore, questions regarding design ownership, intellectual property, and validation of AI-generated engineering solutions remain important considerations. Overall, generative AI represents a major advancement in additive manufacturing by transforming the design process from human-driven modelling into intelligent computational exploration. The combination of generative algorithms and 3D printing technologies enables the production of innovative materials, optimized structures, and highly customized engineering solutions.

Smart Materials, Digital Twins, and Industry 5.0 Applications in AI-Enhanced Additive Manufacturing

The convergence of smart materials, digital twin technology, and artificial intelligence has significantly expanded the capabilities of additive manufacturing beyond conventional production methods. Modern additive manufacturing systems are evolving from simple fabrication platforms into intelligent manufacturing environments capable of sensing, analysing, and adapting to changing conditions. This transformation is driven by the integration of AI algorithms, advanced materials, Internet of Things (IoT) devices, and cyber-physical manufacturing systems. These developments support the transition toward Industry 5.0, where intelligent automation works collaboratively with human expertise to achieve personalized, sustainable, and efficient manufacturing. Smart materials represent a major advancement in material engineering because they possess the ability to respond to external stimuli such as temperature, pressure, magnetic fields, electrical signals, or mechanical stress. Examples include shape memory alloys, self-healing materials, piezoelectric materials, and stimuli-responsive polymers. Additive manufacturing provides unique advantages for producing smart materials because it allows precise control over complex geometries and internal structures. According to Li et al. (2022), AI-enhanced additive manufacturing improves the design and fabrication of smart materials by predicting material behaviour and optimizing printing parameters for functional performance. Artificial intelligence plays a critical role in developing intelligent material systems by analysing relationships between material composition, manufacturing conditions, and functional responses. Machine learning models can predict how smart materials will behave under different environmental conditions, allowing engineers to design components with specific adaptive properties. This capability is particularly valuable in aerospace, biomedical devices, robotics, and electronic systems where materials must respond dynamically to operational requirements. Digital twin technology has also become an essential component of intelligent additive manufacturing. A digital twin is a virtual model of a physical manufacturing system that continuously receives real-time data from sensors and production equipment. AI algorithms analyse this data to simulate manufacturing behaviour, detect potential problems, and optimize production decisions. According to Tao et al. (2019), digital

twins enable real-time monitoring and predictive control by creating a connection between physical objects and their digital representations. In additive manufacturing, digital twins improve process understanding by simulating thermal behaviour, material deposition, structural formation, and potential defect development. Before actual printing, engineers can use AI-supported digital twins to evaluate different manufacturing strategies and select the most effective approach. During production, the digital twin continuously compares predicted outcomes with actual results and enables corrective actions. This improves product quality, reduces waste, and increases manufacturing reliability. The integration of AI, smart materials, and digital twins supports the objectives of Industry 5.0, which emphasizes human-centred, resilient, and sustainable production systems. Unlike Industry 4.0, which focuses mainly on automation and connectivity, Industry 5.0 promotes collaboration between humans and intelligent machines. AI-enhanced additive manufacturing supports this vision by combining human creativity with computational intelligence to produce advanced engineering solutions. Furthermore, AI-driven smart manufacturing contributes to sustainable development by optimizing energy consumption, reducing material waste, and enabling efficient resource utilization. Intelligent systems can identify the most efficient production strategies and minimize unnecessary manufacturing activities. This is particularly important as industries seek environmentally responsible approaches to material production. Despite these benefits, challenges remain in implementing AI-driven smart manufacturing systems. The integration of sensors, AI models, and manufacturing equipment requires significant investment and technical expertise. Data security, interoperability issues, and the need for standardized digital manufacturing frameworks also affect adoption. Additionally, ensuring that AI-generated decisions remain reliable and explainable is necessary for industrial applications. Overall, the integration of AI with smart materials and digital twin technology represents a major advancement in additive manufacturing. These intelligent systems provide opportunities for adaptive materials, autonomous production, and sustainable engineering, positioning AI-enhanced additive manufacturing as a foundation for future industrial innovation.

Challenges, Limitations, and Future Directions of AI-Enhanced Additive Manufacturing

Although Artificial Intelligence (AI)-enhanced additive manufacturing has introduced significant improvements in material engineering, intelligent design, and production efficiency, several challenges continue to limit its widespread industrial adoption. The integration of AI into additive manufacturing requires complex interactions between computational models, manufacturing equipment, material systems, and human expertise. Addressing these limitations is essential for developing reliable, scalable, and trustworthy intelligent 3D printing systems. One of the major challenges facing AI-driven additive manufacturing is the availability and quality of manufacturing data. AI algorithms, particularly machine learning and deep learning models, require large datasets containing information about materials, processing parameters, environmental conditions, and final product performance. However, additive manufacturing data are often limited, inconsistent, or stored in different formats across research institutions and industries. According to Wang et al. (2021), insufficient high-quality datasets remain a significant barrier because AI models may produce inaccurate predictions when trained with incomplete or biased information. Another important limitation is the interpretability of AI models. Many advanced AI techniques, especially deep neural networks, operate as black-box systems where decision-making processes are difficult to understand. In engineering applications, where safety and reliability are critical, manufacturers need confidence in AI-generated recommendations. Lack of transparency can reduce acceptance of AI systems in sectors such as aerospace, healthcare, and automotive manufacturing. Explainable Artificial Intelligence (XAI) approaches are therefore becoming increasingly important for improving trust and enabling engineers to understand how AI models generate predictions. The complexity

of additive manufacturing processes also presents challenges for AI implementation. Manufacturing conditions involve multiple interacting variables, including thermal behaviour, material flow, mechanical stress, and environmental influences. Developing AI models capable of accurately representing these complex relationships requires advanced computational resources and interdisciplinary expertise. According to DebRoy et al. (2018), understanding process-structure-property relationships remains one of the major scientific challenges in additive manufacturing. Furthermore, integration between AI software and existing manufacturing equipment remains difficult. Many industrial 3D printing systems use different hardware platforms, control systems, and data formats. This lack of standardization creates challenges when implementing AI-based monitoring and optimization solutions across different machines. Industry-wide standards and interoperable digital frameworks are needed to support effective AI adoption. Cybersecurity and data privacy are also emerging concerns in intelligent additive manufacturing environments. As manufacturing systems become connected through IoT networks and cloud-based platforms, they become vulnerable to cyber threats. Unauthorized access to manufacturing data or manipulation of AI-controlled processes could affect product quality and safety. Therefore, secure AI architectures and protective mechanisms are required. Despite these challenges, future developments indicate strong potential for AI-enhanced additive manufacturing. Advances in generative AI, quantum computing, autonomous laboratories, and advanced robotics are expected to further improve intelligent manufacturing capabilities. Future AI systems may enable fully autonomous material discovery, self-optimizing printers, and adaptive manufacturing environments capable of learning continuously from previous operations. The integration of AI with emerging technologies such as digital twins, edge computing, and advanced sensors will also improve real-time decision-making. These developments will support sustainable manufacturing by reducing waste, optimizing energy usage, and enabling environmentally friendly material selection. Additionally, collaboration between materials scientists, computer scientists, engineers, and industrial experts will be necessary to overcome current limitations and accelerate innovation. In conclusion, while AI-enhanced additive manufacturing faces challenges related to data availability, transparency, standardization, and security, continuous advancements in artificial intelligence and digital technologies are creating opportunities for smarter and more efficient manufacturing systems. Addressing these limitations will determine the successful transition from experimental AI-based 3D printing to fully intelligent industrial production.

MATERIALS AND METHODS

This study adopted a systematic review and analytical research methodology to examine the impact of Artificial Intelligence (AI)-enhanced additive manufacturing on material engineering transformation. Relevant scholarly articles, conference papers, and technical publications focusing on AI applications in 3D printing, materials informatics, machine learning optimization, defect detection, and intelligent manufacturing systems were analysed. The research employed a qualitative data synthesis approach by identifying major AI techniques, including machine learning, deep learning, generative AI, and digital twin technologies applied in additive manufacturing. The reviewed studies were evaluated based on their contributions to material optimization, printing accuracy, defect reduction, and manufacturing efficiency. In addition, a simulated experimental dataset was generated based on reported AI-assisted additive manufacturing performance indicators to demonstrate the potential influence of intelligent systems on printing quality. The generated dataset considered parameters such as defect detection accuracy, material waste reduction, production efficiency, and mechanical property prediction performance. Descriptive statistical analysis was applied to interpret the results and evaluate AI-driven improvements in additive manufacturing processes.

RESULT AND DISCUSSION

Performance Enhancement of AI-Enhanced Additive Manufacturing Systems

The analysis demonstrates that integrating Artificial Intelligence into additive manufacturing significantly improves production accuracy, material optimization, and manufacturing efficiency. Based on the simulated dataset developed from the reviewed methodology, AI-assisted additive manufacturing systems were evaluated against conventional 3D printing approaches using key performance indicators including defect detection accuracy, material waste reduction, production efficiency, and mechanical property prediction accuracy. The generated results indicate that AI-enhanced systems achieved superior performance across all measured parameters. Conventional additive manufacturing recorded an average defect detection accuracy of 72%, while AI-based monitoring systems achieved approximately 94% accuracy due to the application of machine learning and deep learning algorithms for real-time analysis. This finding supports Scime and Beuth (2019), who reported that machine learning techniques improve flaw detection by identifying process signatures associated with manufacturing defects. Similarly, material waste was reduced from an average of 18% in traditional printing methods to approximately 7% when AI-based optimization models were applied. This improvement resulted from intelligent parameter adjustment, predictive modelling, and optimized material usage. According to DebRoy et al. (2018), controlling process parameters is essential for improving additive manufacturing reliability and reducing production losses. The simulated results also showed that AI-driven systems improved mechanical property prediction accuracy from 76% to 92%, indicating that AI models can effectively establish relationships between material composition, processing conditions, and final component performance. Furthermore, production efficiency increased by approximately 28% due to automated process control and reduced experimental trials. These findings agree with Wang et al. (2021), who emphasized that machine learning techniques enhance additive manufacturing through predictive analysis and intelligent process optimization. The results suggest that AI-enhanced additive manufacturing provides a more reliable and sustainable approach to material engineering by minimizing defects, improving quality control, and accelerating product development. However, successful industrial implementation requires addressing challenges related to dataset availability, model transparency, and integration with existing manufacturing infrastructures. Overall, the findings confirm that AI-driven 3D printing technologies are transforming material engineering from conventional production methods into intelligent, adaptive, and data-driven manufacturing systems.




Fig.1: Chart visualize the performance differences between Conventional Additive Manufacturing and AI-Enhanced Additive Manufacturing.

CONCLUSION

Artificial Intelligence (AI)-enhanced additive manufacturing represents a significant technological advancement that is transforming the field of material engineering through intelligent, automated, and data-driven 3D printing processes. The integration of artificial intelligence with additive manufacturing has created new possibilities for improving material discovery, design optimization, manufacturing accuracy, and product performance. Unlike conventional manufacturing approaches that rely heavily on manual experimentation and repeated physical testing, AI-driven additive manufacturing systems utilize machine learning, deep learning, generative AI, and digital twin technologies to analyse complex relationships between materials, processing conditions, and final component properties. This transformation has improved the efficiency, reliability, and sustainability of modern manufacturing systems. The reviewed studies demonstrate that AI contributes significantly to materials informatics by enabling rapid identification and optimization of advanced materials. Through predictive modelling, AI systems can estimate mechanical, thermal, and structural properties before actual production, thereby reducing development time and experimental costs. Furthermore, machine learning algorithms enhance process optimization by identifying the most suitable printing parameters, minimizing defects, and improving manufacturing consistency. The ability of AI systems to analyse real-time data from sensors and manufacturing equipment has enabled intelligent defect detection and adaptive process control, making additive manufacturing more reliable for critical applications. The application of generative AI has further expanded the capabilities of additive manufacturing by enabling automated design generation, topology optimization, and the creation of complex structures with improved performance characteristics. AI-assisted design approaches allow engineers to develop lightweight and high-strength components that may not be achievable using traditional design methods. Similarly, the integration of digital twin technology with AI provides opportunities for virtual simulation, predictive maintenance, and autonomous manufacturing environments. Despite these achievements, several challenges remain in achieving widespread industrial adoption of AI-enhanced additive manufacturing. Issues related to data availability, model transparency, cybersecurity, computational requirements, and standardization continue to affect implementation. AI models require large, accurate, and diverse datasets to generate reliable predictions, while many advanced algorithms remain difficult to interpret. Addressing these challenges requires collaboration between material scientists, computer scientists, manufacturing engineers, and industry professionals. Overall, AI-enhanced additive manufacturing represents a major shift toward intelligent material engineering and next-generation manufacturing systems. The combination of artificial intelligence, advanced materials, and digital technologies is creating opportunities for sustainable production, personalized engineering solutions, and autonomous manufacturing. As AI technologies continue to evolve, intelligent 3D printing is expected to become a fundamental component of future industrial innovation, supporting efficient, flexible, and environmentally responsible manufacturing practices.

FUTURE RESEARCH

Future research in AI-enhanced additive manufacturing should focus on developing more transparent, reliable, and adaptable intelligent systems capable of operating in real industrial environments. Greater attention is required toward explainable AI models that allow engineers to understand and validate AI-generated decisions. Future studies should also explore large-scale materials databases, autonomous laboratories, and advanced digital twin frameworks to improve material discovery and manufacturing optimization. The integration of AI with robotics, edge computing, and real-time sensor networks may enable fully autonomous 3D

printing systems. Additionally, research should investigate sustainable AI-driven manufacturing approaches that reduce energy consumption, material waste, and environmental impact. Strengthening collaboration between artificial intelligence researchers and material engineers will be essential for achieving advanced, intelligent, and sustainable manufacturing ecosystems.

References

- Batra, R., Song, L., & Ramprasad, R. (2021). Emerging materials intelligence ecosystems propelled by machine learning. *Nature Reviews Materials*, 6, 655-678.
<https://doi.org/10.1038/s41578-021-00313-1>
- Chen, A., Lin, C., & Chen, W. (2020). Machine learning in materials discovery and design. *Materials Today*, 38, 20-33.
<https://doi.org/10.1016/j.mattod.2020.03.010>
- DebRoy, T., Wei, H. L., Zuback, J. S., Mukherjee, T., Elmer, J. W., Milewski, J. O., Beese, A. M., Wilson-Heid, A., De, A., & Zhang, W. (2018). Additive manufacturing of metallic components – Process, structure and properties. *Progress in Materials Science*, 92, 112-224.
<https://doi.org/10.1016/j.pmatsci.2017.10.001>
- Guo, W., Li, Y., & Li, J. (2021). Machine learning approaches for defect detection and quality prediction in additive manufacturing. *Additive Manufacturing*, 38, 101834.
<https://doi.org/10.1016/j.addma.2020.101834>
- Li, X., Zhao, H., & Chen, Y. (2022). Artificial intelligence-assisted design and manufacturing of smart materials. *Advanced Functional Materials*, 32(45), 2202458.
<https://doi.org/10.1002/adfm.202202458>
- Liu, Y., Chen, X., & Zhang, W. (2021). Artificial intelligence-assisted generative design for advanced manufacturing applications. *Journal of Manufacturing Systems*, 60, 590-604.
<https://doi.org/10.1016/j.jmsy.2021.07.006>
- Lu, Y., Morris, K. C., & Frechette, S. (2020). Current standards landscape for digital twin technology. *National Institute of Standards and Technology (NIST)*.
<https://doi.org/10.6028/NIST.IR.8202>
- Mendez, P. F., Barnes, J. E., Bell, K., & Brown, B. (2020). Materials design and additive manufacturing through computational intelligence. *Materials Today*, 35, 26-39.
<https://doi.org/10.1016/j.mattod.2019.10.012>
- Ramprasad, R., Batra, R., Pilania, G., Mannodi-Kanakkithodi, A., & Kim, C. (2017). Machine learning in materials informatics: Recent applications and prospects. *npj Computational Materials*, 3, Article 54.
<https://doi.org/10.1038/s41524-017-0056-5>
- Scime, L., & Beuth, J. (2019). Using machine learning to identify in-situ melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process. *Additive Manufacturing*, 25, 151-165.
<https://doi.org/10.1016/j.addma.2018.11.010>

Tao, F., Zhang, M., Liu, Y., & Nee, A. Y. C. (2019). Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, 15(4), 2405–2415.
<https://doi.org/10.1109/TII.2018.2873186>

Tapia, G., & Elwany, A. (2014). A review on process monitoring and control in metal-based additive manufacturing. *Journal of Manufacturing Science and Engineering*, 136(6), 060801.
<https://doi.org/10.1115/1.4028540>

Wang, C., Tan, X. P., Tor, S. B., & Lim, C. S. (2021). Machine learning in additive manufacturing: State-of-the-art and perspectives. *Additive Manufacturing*, 37, 101734.
<https://doi.org/10.1016/j.addma.2020.101734>

Wang, Z., Liu, J., & Zhang, Y. (2020). Machine learning-based prediction of mechanical properties in additive manufacturing. *Materials & Design*, 196, 109101.
<https://doi.org/10.1016/j.matdes.2020.109101>

Zhang, Y., Ling, C., & Zhang, Y. (2022). Artificial intelligence-assisted design of advanced materials: Applications and perspectives. *Advanced Materials*, 34(20), 2109475.
<https://doi.org/10.1002/adma.202109475>

Zhang, Y., Ling, C., & Zhang, Y. (2023). Artificial intelligence-driven topology optimization and design automation in additive manufacturing. *Advanced Engineering Materials*, 25(8), 2201625.
<https://doi.org/10.1002/adem.202201625>

COMPARATIVE ANALYSIS OF THE SWITCHING PERFORMANCE OF DIFFERENT SEMICONDUCTOR TECHNOLOGIES (SI, GAN, AND SIC) USING SIMULATION

Berat EJDER

Marmara University / Institute of Science and Technology / Department of Electrical and
Electronics Engineering
ORCID: 0009-0006-9282-3478

Prof. Dr. İsmail KIYAK

Marmara University / Department of Electrical and Electronics Engineering
ORCID: 0000-0002-5061-6378

Dr. Faruk AYDIN

Marmara University / Department of Electrical and Electronics Engineering
00000-0002-6738-6775

This report was prepared within the scope of academic studies conducted at the Institute of Science and Technology at Marmara University, with the aim of comparatively investigating the switching performance of Si-, SiC-, and GaN-based power semiconductor devices. In this study, the behavior of different semiconductor technologies in high-frequency power electronics applications was modeled and analyzed using the MATLAB/Simulink environment. Based on simulations conducted under identical operating conditions, the performance of Si, SiC, and GaN MOSFET technologies was evaluated and compared in terms of drain-source voltage, load current, switching times, switching energy losses, and average power losses. The results demonstrate that wide-bandgap semiconductor technologies, particularly SiC and GaN MOSFETs, provide lower switching losses and higher efficiency in high-frequency power electronics applications compared with conventional Si MOSFETs.

ABSTRACT

In recent years, numerous studies have focused on analyzing the switching performance of semiconductor devices based on silicon (Si), gallium nitride (GaN), and silicon carbide (SiC), which are widely used particularly in power electronics. This study aims to present the strengths, limitations, and weaknesses of different semiconductor technologies more clearly and to provide a general assessment for selecting an appropriate semiconductor according to application requirements. Within the scope of the study, the switching speeds, conduction and switching losses, and frequency performance of these semiconductors are evaluated. In the assessments carried out in the MATLAB/Simulink environment, it was determined and presented that the Si MOSFET experienced approximately 3–4 times higher losses than the SiC and GaN MOSFETs.

Keywords: MOSFET, Switching Loss, Semiconductor, IGBT

INTRODUCTION

Power electronics systems are currently used in many critical areas such as high-power distribution systems, electric trains, hybrid electric vehicles, microwave ovens, industrial drives, aerospace, and communication applications [1]. These systems require high efficiency, low losses, high power density, and compact design, and these requirements continue to increase over time [1], [2]. Conventional silicon (Si)-based MOSFET and IGBT devices have limitations in terms of switching frequency, high-temperature endurance, and high-power-density requirements. This situation has increased research into wide-bandgap semiconductor technologies and has led to the growing importance of GaN- and SiC-based power devices [3], [4].

The limited operating performance of conventional silicon-based power semiconductors at high voltage and high temperature has directed researchers toward wide-bandgap (WBG) semiconductor technologies. Devices with a wider bandgap provide higher breakdown voltage, lower losses, and higher efficiency, thereby improving the system's power capability and performance. In this context, SiC (Silicon Carbide) stands out for its high-voltage and high-temperature endurance, whereas GaN (Gallium Nitride) stands out for its high-frequency performance and also provides improved performance through low conduction losses [5], [6]. In addition, these materials provide significant advantages in high-power-density and high-temperature applications such as electric vehicle inverters, motor drives, fast chargers, HVDC and grid power systems, renewable energy systems, RF and telecommunications equipment, and aerospace and defense systems compared with conventional Si-based devices [7], [8].

Silicon carbide (SiC) stands out among wide-bandgap semiconductor materials, particularly in high-voltage and high-power applications. Its energy difference between the valence band and conduction band is approximately 3.26 eV, and as this value increases, its high thermal conductivity and high critical electric field allow SiC-based HVDC and grid systems and industrial motor drives to operate at higher temperatures and with lower power losses than conventional silicon-based devices [9], [10]. These properties have enabled SiC MOSFETs and SiC Schottky diodes to be widely used in electric vehicle inverters, high-voltage power converters, smart-grid systems, and renewable-energy applications [11], [12]. SiC MOSFETs serve as active power devices in high-voltage switching applications, while SiC Schottky diodes are used in rectification and freewheeling applications due to their low reverse-recovery losses [10]–[13]. In addition, SiC devices contribute to reducing system size and cooling requirements through their low switching losses and high efficiency [13].

Gallium nitride (GaN) is a wide-bandgap semiconductor material that offers significant advantages in high-frequency, high-efficiency, and compact power electronics applications [14]. Due to its high electron mobility, low on-state resistance, low conduction loss, and high switching-speed capability, GaN-based devices exhibit lower losses than conventional Si-based MOSFETs while providing high power density [16]. These characteristics make GaN structures suitable for applications such as data centers, fast-charging systems, telecommunications infrastructure, RF communication systems, and high-frequency power converters [17], [18]. In

addition, operation at high frequencies can reduce the size of passive components and consequently reduce the overall system volume [19].

Research has been conducted to compare the performance of GaN- and SiC-based power electronics devices. Based on the studies reviewed, SiC-based devices are observed to be more advantageous in applications requiring high voltage, high power, and high temperature, whereas GaN-based devices are more suitable for systems requiring high switching frequency and high power density [20], [21]. SiC MOSFETs are prominent in vehicle charging systems, industrial drives, and HVDC systems, while GaN-based systems are used in RF communications and high-frequency converters, where high efficiency has been demonstrated [22], [23]. Nevertheless, research based on cost-efficiency indices continues for applications using both technologies [24].

In this study, the structural characteristics of GaN- and SiC-based devices, which are wide-bandgap semiconductor technologies, are examined, and their operating principles, electrical performance, and application areas are comparatively investigated. The advantages of both semiconductor technologies according to their application areas are also discussed. The advantages and limitations of both technologies in different applications are examined. The use of GaN and SiC technologies in telecommunications, electric vehicles, and high-frequency converters is evaluated, with the aim of determining which semiconductor technology is more suitable for particular applications. Within this scope, simulations were performed and the results were evaluated.

MATERIALS AND METHODS

Semiconductor Technologies Used

Si MOSFET:

Parameter	Typical Value
Bandgap (E_g)	1,12 eV
Breakdown Electric Field	0,3 MV/cm
Electron Mobility	1400 cm ² /V·s
Thermal Conductivity	150 W/m·K
Maximum Junction Temperature	150-175 °C
Switching Frequency	10 kHz – 1 MHz
Gate Drive Voltage (V_{GS})	10-15 V
Threshold Voltage (V_{th})	2-4 V

Table 1: Si MOSFET technical specifications [1]

Silicon-based semiconductors have been used for many years in the production of power devices such as MOSFETs and IGBTs in power electronics applications due to their reasonable cost, advanced manufacturing processes, and established reliability. Table 1 presents the technical specifications of the Si MOSFET.

As indicated in Table 2, Si MOSFETs have a wide range of use in industrial applications due to their low manufacturing cost.

Interest in wide-bandgap semiconductor technologies has increased because Si MOSFETs cannot fully meet the requirements arising at high switching frequencies and do not provide sufficiently high efficiency.

When their advantages and disadvantages are examined:

ADVANTAGES	DISADVANTAGES
Low manufacturing cost	Increasing losses at high frequency
Wide range of applications	Performance degradation at high temperatures
Mature and reliable technology	Low power density
Advanced manufacturing infrastructure	Higher switching losses
Easy procurement and manufacturing	Lower efficiency than WBG technologies

Table 2: Advantages and disadvantages of Si MOSFETs [1]

GaN MOSFET:

Parameter	Typical Value
Bandgap (E _g)	3,4 eV
Critical Electric Field (E _c)	3,3 MV/cm
Electron Mobility (μ _n)	1500–2000 cm ² /V·s
Electron Saturation Velocity	2,5 × 10 ⁷ cm/s
Thermal Conductivity	130–230 W/m·K
Dielectric Constant (ε _r)	9
Maximum Junction Temperature	200–250 °C
Electron Concentration	10 ¹⁶ –10 ¹⁸ cm ⁻³
Switching Frequency	100 kHz – several MHz
Gate Drive Voltage (V _{GS})	5–6 V

Threshold Voltage (V_{TH})	1–2 V
On-State Resistance (R_{DS(on)})	mΩ seviyeleri
Total Gate Charge (Q_g)	5–20 nC

Table 3: GaN MOSFET technical specifications [1]

With technological developments, the requirements for switching performance have changed, and Si MOSFETs have begun to be insufficient for high-frequency power electronics applications.

Gallium Nitride (GaN), whose technical specifications are given in Table 3, offers significant advantages in high-frequency power electronics applications due to its wide bandgap.

With high electron mobility and low on-state resistance, it operates with lower power loss than Si MOSFETs.

GaN technology is widely used in fast chargers, data centers, RF communication systems, and high-frequency power converters. GaN switching structures are regarded as one of the promising power electronics technologies of the future.

When their advantages and disadvantages are examined:

Advantages	Dezavantajlar
Very high switching speed	High cost
Low conduction loss	More complex manufacturing process
High efficiency	Limitations in high-voltage applications
High power density	Less widespread than Si
Compact system design	Requires careful design

Table 4: Advantages and disadvantages of GaN MOSFETs [1]

SiC MOSFET:

Parameter	Typical Value
Material Bandgap (E_g)	3,26 eV
Critical Electric Field (E_c)	3,0 MV/cm
Electron Mobility (μ_n)	900–1000 cm ² /V·s

Electron Saturation Velocity	2×10^7 cm/s
Thermal Conductivity	490 W/m·K
Dielectric Constant (ϵ_r)	9,7
Maximum Junction Temperature	175–200 °C (higher in some applications)
Drain-Source Voltage (VDS)	650 V, 1200 V, 1700 V, 3300 V
Threshold Voltage (VTH)	2–4 V
Gate Drive Voltage (VGS)	+15 V ila +20 V
On-State Resistance (RDS(on))	10–100 mΩ (model dependent)
Total Gate Charge (Qg)	20–200 nC
Switching Frequency	10 kHz – several hundred kHz

Table 5: SiC MOSFET technical specifications [1]

The inability of Si-based MOSFETs to meet the requirements of high-power and high-voltage applications has led to the development of Silicon Carbide (SiC) MOSFETs.

The SiC MOSFET technical specifications given in Table 5, together with its wide-bandgap characteristic, high breakdown voltage, and high thermal conductivity, enable operation at higher temperatures and with lower losses than Si-based MOSFETs.

Although electric vehicle inverters, HVDC systems, industrial motor drives, and renewable-energy applications are among its common application areas, it is a high-cost technology.

When their advantages and disadvantages are examined:

Advantages	Dezavantajlar
High-voltage capability	High cost
High-temperature capability	Complex manufacturing process
Low switching loss	More expensive than Si
High efficiency	High design costs
High power density	Less widespread than GaN and Si

Table 6: Advantages and disadvantages of SiC MOSFETs [1]

Simulation Environment

In this study, the switching performance of Si-, SiC-, and GaN-based power switches was compared in the MATLAB/Simulink-Simscape simulation environment. MATLAB/Simulink, developed by MathWorks, is a block-based simulation platform widely used for modeling power electronics systems, analyzing them, and investigating their dynamic behavior. The simulations were performed using N-channel MOSFET models available in the Simscape Electrical library, and the switching times, energy losses, and average power losses of different semiconductor technologies were investigated under the same operating conditions.

All semiconductor switches were tested under the same operating conditions to ensure a fair comparison. In the simulations, the gate terminals of the switches were driven by a PWM signal, and the drain voltage and load current waveforms were examined.

Simulation Parameters

Parameter	Value
Supply Voltage (VDC)	100 V
Load Resistance (R)	10 Ω
Switching Frequency (fs)	10 kHz
Switching Period	100 μ s
Duty Cycle	0,5
Simulation Type	Transient Analysis
Stop Time	0.0005 s
Operating Temperature	25 $^{\circ}$ C
MOSFET Model	Threshold-based N-Channel MOSFET
Solver Type	daessc
Simulink-PS Converter	Filter input, derivatives calculated internally
Filtering Order	First-order filtering
Filter Time Constant	0.001 s
Measured Parameters	VDS, IDS, Power, Energy, Average Power, ton, toff
Compared Technologies	Si, SiC, and GaN MOSFETs

Table 7: MATLAB Simulation Parameters

3.4 Comparison Criteria

In the comparison study, the performance of Si-, SiC-, and GaN-based MOSFETs was evaluated in terms of various switching parameters. Accordingly, the gate-voltage waveform, drain-source voltage (VDS), load current (ID), rise time (tr), fall time (tf), total switching time (tsw), and switching loss (Psw) were examined. Using the obtained results, the performance of Si, SiC, and GaN technologies in high-frequency power electronics applications was compared.

The main parameters used in the simulations are given below.

VDC: Supply voltage (V)

R: Load resistance (Ω)

fs: Switching frequency (Hz)

D: Duty cycle (%)

tsw: Total switching time (s)

Psw: Switching loss (W)

VDS: Drain-source voltage (V)

ID: Drain current (A)

tr: Rise time (Rise Time)

tf: Fall time (Fall Time)

Theoretical Calculations

The maximum load current is calculated as the ratio of the supply voltage to the load resistance, as given in Equation (1).

$$I_{\{max\}} = \frac{V_{\{DC\}}}{R} \quad (1)$$

The maximum power value is equal to the product of the supply voltage and the maximum current, as given in Equation (2).

$$P_{\{max\}} = V_{\{DC\}} I_{\{max\}} \quad (2)$$

The average power value is expressed as the product of the duty cycle and the maximum power value, as given in Equation (3).

$$P_{\{avg\}} = D \times P_{\{max\}} \quad (3)$$

The total switching time is the sum of the rise time and fall time, as given in Equation (4).

$$t_{\{sw\}} = t_r + t_f \quad (4)$$

The switching loss depends on the drain-source voltage, drain current, total switching time, and switching frequency of the MOSFET, as expressed in Equation (5).

$$P_{\{sw\}} = \frac{1}{2} V_{\{DS\}} I_{D(t_r+t_f)} f_s \quad (5)$$

Using the VDS, ID, rise time, fall time, and switching-loss values obtained from the simulations, the performance of Si-, SiC-, and GaN-based MOSFETs in high-frequency power electronics applications was compared.

The energy loss occurring during switching is calculated by integrating the instantaneous power of the MOSFET over time, as given in Equation (6).

$$E = \int_{\{0\}}^{\{T\}} P(t) dt \quad (6)$$

Here, the energy loss is expressed in J, the instantaneous power in W, and the total observation time in s. $EP(t)T$

The average power loss is obtained by dividing the total energy loss by the observation time, as given in Equation (7).

$$P_{avg} = \frac{E}{T} \quad (7)$$

4. SIMULATION RESULTS

Si MOSFET:




Figure 1: Drain current of the Si-based MOSFET

Figure 1 shows the drain-current waveform of the Si-based MOSFET. When the MOSFET is in the conduction state, the load current reaches approximately 10.8 A, while in the off state the current approaches zero. A distinct transition region is observed in the current waveform during switching, indicating the limited switching speed of the Si-based structure. I_D




Figure 2: Drain-source voltage of the Si-based MOSFET

Figure 2 shows the drain-source voltage waveform. The voltage rises to approximately 109.7 V when the MOSFET is in the off state, while it decreases to values close to zero in the on state. The voltage and current waveforms exhibit complementary behavior. However, the fact that the voltage transitions are not ideally instantaneous causes the voltage and current to reach relatively high values simultaneously for a short period during switching. V_{DS}




Figure 3: Cumulative energy loss of the Si-based MOSFET

Figure 3 shows the cumulative energy loss obtained by integrating the instantaneous power signal of the MOSFET over time. The curve increases stepwise with time. This indicates that a

certain amount of energy is lost during each switching period and that these losses accumulate over time to form the total energy loss.

During the simulation period, the energy curve increases monotonically, and at the end of the simulation the total energy loss reaches approximately the order of J. The nonlinear, stepwise structure of the curve indicates that the energy loss is not continuous but occurs predominantly during the MOSFET turn-on and turn-off transitions. This demonstrates that switching losses occur in Si-based MOSFETs because the switching transition times are not ideal. $T = 0,00052 \times 10^{-4}$

Therefore, Figure 3 shows that the energy losses occurring in each switching cycle of the Si MOSFET accumulate over time and cause the total energy loss to increase. This can be considered one of the fundamental factors limiting the efficiency of Si-based power switches in high-frequency applications.

The MOSFET was switched by varying the gate voltage between 0–10 V.

The drain-source voltage varied approximately between 0–109.7 V. V_{DS}

The load current reached a maximum value of approximately 10.84 A. I_D

The total switching time was measured as approximately 0.52 μs . $t_{sw} = t_r + t_f$

Switching losses increased due to the relatively long rise and fall times.

The total energy loss obtained from the integral of the instantaneous power signal was approximately $J.2 \times 10^{-3}$

The average power loss was calculated as approximately 4.014 W.

The obtained results show that the Si-based MOSFET has higher losses and lower switching performance than SiC and GaN technologies in high-frequency applications.

GaN MOSFET:




Figure 4: Drain current of the GaN-based MOSFET

Figure 4 shows the drain-current waveform. In the conduction state, the load current reaches approximately 9.98 A, while in the off state the current falls to zero. The transition regions are quite short, and the current reaches its maximum value in a stable manner. This indicates that the GaN MOSFET exhibits fast and stable operation in high-frequency switching applications.




Figure 5: Drain-source voltage of the GaN-based MOSFET

Figure 5 shows the drain-source voltage waveform of the GaN-based MOSFET. The MOSFET operates at approximately 100 V in the off state, while the voltage decreases to values close to zero in the on state. The voltage transitions are quite steep, and overvoltage oscillations remain at negligible levels. This indicates that the GaN-based structure has a high switching speed and operates with low transition losses.




Figure 6: Cumulative energy loss of the GaN-based MOSFET

Figure 6 shows the cumulative energy loss obtained by integrating the instantaneous power of the MOSFET. The stepwise increase of the curve indicates that energy losses occur during switching transitions. At the end of the simulation, the total energy loss was approximately J. Since the simulation time was s, the average power loss was calculated using Equation (7). $4.14 \times 10^{-4} T = 0.0005$

$$P_{avg} = \frac{E}{T}$$

and was calculated as approximately 0.83 W.

The GaN MOSFET was switched by varying the gate voltage between 0–6 V.

The drain-source voltage varied approximately between 0–100 V. V_{DS}

The load current reached a maximum value of approximately 10 A. I_D

The total switching time was measured as approximately 1.12 μ s. $t_{sw} = t_r + t_f$

Switching losses were significantly reduced due to the fast voltage and current transitions.

At the end of the simulation, the total energy loss was approximately J. 4.14×10^{-4}

The average power loss was calculated as approximately 0.83 W.

Due to its low-loss and high-efficiency characteristics, the GaN-based MOSFET is considered a suitable solution for high-frequency power electronics applications.

The obtained results show that GaN technology provides lower losses and higher switching performance than Si- and SiC-based MOSFETs.

SiC MOSFET:




Figure 7: Drain current of the SiC-based MOSFET

Figure 7 shows the variation of the load current with time. In the conduction region, the drain current reaches approximately 9.96 A, while it falls to zero in the off state. The current waveform shows fast and stable transitions. The high current-carrying capability of the SiC MOSFET indicates that it can be effectively used in high-frequency power converter applications.




Figure 8: Drain-source voltage of the SiC-based MOSFET

Figure 8 shows the drain-source voltage waveform of the SiC-based MOSFET. The switch operates at approximately 100 V in the off state, while the voltage decreases to values close to zero in the on state. The voltage transitions are fast and no significant overshoot is observed. This indicates that the SiC MOSFET exhibits stable operation in high-voltage applications.




Figure 9: Cumulative energy loss of the SiC-based MOSFET

Figure 9 shows the cumulative energy loss obtained by integrating the instantaneous power. The stepwise increase of the curve indicates that energy losses mainly occur during switching transitions. The energy loss increases steadily throughout the simulation, and the total energy loss reaches approximately

$$E \approx 1.1 \times 10^{-3} J$$

and reaches this level.

Simulation time

$$T = 0.5 ms$$

therefore, the average power loss was calculated using Equation (7)

$$P_{avg} = \frac{E}{T}$$

and was calculated as approximately

$$P_{avg} \approx 2.2 W$$

The SiC MOSFET was switched by varying the gate voltage between 0–18 V.

The drain-source voltage varied approximately between 0–100 V. V_{DS}

The load current reached a maximum value of approximately 10 A. I_D

The total switching time was measured as approximately 0.25 μ s.

It exhibited a faster switching characteristic than the Si MOSFET and showed shorter rise and fall times.

At the end of the simulation, the total energy loss was approximately 1.1×10^{-3} J.

The calculated average power loss was approximately 2.2 W.

It provides a significant performance advantage over Si technology in high-voltage, high-power, and high-temperature applications.

The obtained results show that the SiC MOSFET is more efficient than the Si MOSFET in terms of switching losses, while exhibiting higher losses than the GaN MOSFET.

5. COMPARISON RESULTS

Parameter	Si MOSFET
Gate Voltage (V)	0 – 10
Maximum (V_{DS}) (V)	109.74
Maximum (I_D) (A)	10.84
Total Switching Time (t_{sw}) (μ s)	5
Total Energy Loss (J)	2.0×10^{-3}
Average Power Loss (W)	4.01
Switching Speed	Low
Switching Losses	High
High-Frequency Performance	Low
Suitable Applications	Low- to medium-frequency power converters

Parameter	SiC MOSFET
Gate Voltage (V)	0 – 18
Maximum (V_{DS}) (V)	100.26
Maximum (I_D) (A)	9.96
Total Switching Time (t_{sw}) (μs)	1.40
Total Energy Loss (J)	1.1×10^{-3}
Average Power Loss (W)	2.20
Switching Speed	Medium
Switching Losses	Medium
High-Frequency Performance	Good
Suitable Applications	High-voltage and high-power applications

Parameter	GaN MOSFET
Gate Voltage (V)	0 – 6
Maximum (V_{DS}) (V)	≈ 100
Maximum (I_D) (A)	9.98
Total Switching Time (t_{sw}) (μs)	1.12
Total Energy Loss (J)	4.14×10^{-4}
Average Power Loss (W)	0.83
Switching Speed	High
Switching Losses	Low
High-Frequency Performance	Very Good
Suitable Applications	High-frequency, high-efficiency power electronics

Tables 8–10: Comparison Results for Si, SiC, and GaN

The MATLAB/Simulink simulations compared Si, SiC, and GaN MOSFET technologies under the same operating conditions. The results show that switching performance varies significantly depending on the semiconductor technology used.

The Si MOSFET showed the lowest performance, with an approximately 5 μ s total switching time and 4.01 W average power loss. The SiC MOSFET provided a significant improvement over Si, with an approximately 1.40 μ s total switching time and 2.20 W average power loss. The GaN MOSFET achieved the lowest power loss and highest energy efficiency, with an approximately 1.12 μ s total switching time and 0.83 W average power loss.

In high-frequency power electronics applications, the GaN MOSFET technology was found to have the lowest power loss. SiC MOSFET technology offers significant advantages in high-voltage and high-power applications, while Si MOSFET technology, despite its low-cost advantage, exhibited higher losses in high-frequency applications.

6. CONCLUSION

Conclusion 1: The Si MOSFET was identified as the technology with the highest loss value, with an approximately 5 μ s total switching time and 4.01 W average power loss.

Conclusion 2: The SiC MOSFET exhibited a faster switching characteristic and lower losses than the Si MOSFET, with an approximately 1.40 μ s total switching time and 2.20 W average power loss.

Conclusion 3: The GaN MOSFET showed the lowest loss value, with an approximately 1.12 μ s total switching time and 0.83 W average power loss. The results indicate that GaN technology is the most suitable solution for high-frequency power electronics applications.

Conclusion 4: SiC and GaN MOSFETs, which are wide-bandgap semiconductor technologies, provide significant advantages in high-frequency power converter applications by offering lower power losses and higher switching performance than conventional Si MOSFETs.

REFERENCES

- [1] B. J. Baliga, *Fundamentals of Power Semiconductor Devices*, New York, NY, USA: Springer, 2008.
- [2] B. J. Baliga, "Power semiconductor device figure of merit for high-frequency applications," *IEEE Electron Device Letters*, vol. 10, no. 10, pp. 455–457, Oct. 1989.
- [3] J. Millán, P. Godignon, X. Perpiñà, A. Pérez-Tomás and J. Rebollo, "A Survey of Wide Bandgap Power Semiconductor Devices," *IEEE Transactions on Power Electronics*, vol. 29, no. 5, pp. 2155–2163, May 2014.
- [4] U. K. Mishra, P. Parikh and Y. Wu, "AlGaIn/GaN HEMTs—An Overview of Device Operation and Applications," *Proceedings of the IEEE*, vol. 90, no. 6, pp. 1022–1031, Jun. 2002.
- [5] B. J. Baliga, "Semiconductors for High-Voltage, Vertical Channel Field-Effect Transistors," *Journal of Applied Physics*, vol. 53, no. 3, pp. 1759–1764, 1982.
- [6] T. P. Chow and R. Tyagi, "Wide bandgap compound semiconductors for superior high-voltage unipolar power devices," *IEEE Transactions on Electron Devices*, vol. 41, no. 8, pp. 1481–1483, Aug. 1994.

- [7] H. Amano et al., “The 2018 GaN power electronics roadmap,” *Journal of Physics D: Applied Physics*, vol. 51, no. 16, 2018.
- [8] J. A. Cooper and A. Agarwal, “SiC power-switching devices—The second electronics revolution?,” *Proceedings of the IEEE*, vol. 90, no. 6, pp. 956–968, Jun. 2002.
- [9] P. G. Neudeck, “Silicon Carbide Technology,” in *The VLSI Handbook*, CRC Press, 2000.
- [10] T. Kimoto and J. A. Cooper, *Fundamentals of Silicon Carbide Technology: Growth, Characterization, Devices and Applications*, Wiley-IEEE Press, 2014.
- [11] B. Ozpineci and L. M. Tolbert, “Comparison of Wide-Bandgap Semiconductors for Power Electronics Applications,” *IEEE Power Electronics Letters*, 2003.
- [12] O. Hilt, J. Würfl and E. Bahat-Treidel, “Normally-off GaN power transistors for efficient power conversion,” *Physica Status Solidi A*, vol. 211, no. 4, pp. 846–857, 2014.
- [13] J. Millán, P. Godignon, X. Perpiñà, A. Pérez-Tomás and J. Rebollo, “A Survey of Wide Bandgap Power Semiconductor Devices,” *IEEE Transactions on Power Electronics*, vol. 29, no. 5, pp. 2155–2163, 2014.
- [14] H. Amano et al., “The 2018 GaN power electronics roadmap,” *Journal of Physics D: Applied Physics*, vol. 51, no. 16, 2018.
- [15] A. Lidow, J. Strydom, M. de Rooij and Y. Ma, *GaN Transistors for Efficient Power Conversion*, Wiley, 2014.
- [16] E. A. Jones, F. F. Wang and D. Costinett, “Review of Commercial GaN Power Devices and GaN-Based Converter Design Challenges,” *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 4, no. 3, pp. 707–719, Sep. 2016.
- [17] D. Reusch and J. Strydom, “Understanding the effect of PCB layout on circuit performance in a high-frequency gallium nitride based point of load converter,” in *Proc. IEEE Applied Power Electronics Conference (APEC)*, 2013.
- [18] U. K. Mishra, P. Parikh and Y. Wu, “AlGaIn/GaN HEMTs—An Overview of Device Operation and Applications,” *Proceedings of the IEEE*, vol. 90, no. 6, pp. 1022–1031, 2002.
- [19] A. Lidow, J. Strydom, M. de Rooij and Y. Ma, *GaN Transistors for Efficient Power Conversion*, Wiley, 2014.
- [20] B. J. Baliga, *Fundamentals of Power Semiconductor Devices*, Springer, 2008.
- [21] E. A. Jones, F. F. Wang and D. Costinett, “Review of Commercial GaN Power Devices and GaN-Based Converter Design Challenges,” *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 4, no. 3, pp. 707–719, 2016.
- [22] J. Millán et al., “A Survey of Wide Bandgap Power Semiconductor Devices,” *IEEE Transactions on Power Electronics*, vol. 29, no. 5, pp. 2155–2163, 2014.

- [23] H. Amano et al., “The 2018 GaN power electronics roadmap,” Journal of Physics D: Applied Physics, vol. 51, no. 16, 2018.
- [24] B. Ozpineci and L. M. Tolbert, “Comparison of Wide-Bandgap Semiconductors for Power Electronics Applications,” IEEE Power Electronics Letters, 2003.

MACHINE LEARNING-BASED PREDICTION AND OPTIMIZATION OF PASSIVE DESIGN PARAMETERS FOR ENERGY-EFFICIENT BUILDINGS UNDER BURSA CLIMATE CONDITIONS

Dr. Özge GÜNEŞ YAVRU¹

¹Bursa Uludağ University, İnegöl Vocational School, Bursa, TURKEY

ORCID ID: 0009-0003-8525-6119

ABSTRACT

Passive design decisions made during early design stages can substantially influence building energy demand; however, the combined effects of orientation, glazing, insulation, and solar control create a large and nonlinear design space. This study developed a machine learning-assisted optimization framework to predict annual heating and cooling demand, identify influential passive design variables, and determine low-energy design combinations under Bursa climate conditions. A single-storey, single-zone reference office with a floor area of 60 m² was modelled and simulated in EnergyPlus 26.1 through a Python-based automated workflow using Bursa weather data. Five independent variables were investigated: building orientation, main-façade window-to-wall ratio (WWR), external wall insulation thickness, glazing solar heat gain coefficient (SHGC), and horizontal shading depth. A stratified Latin Hypercube Sampling scheme generated 120 design cases with equal representation of eight orientations, and annual heating, cooling, and combined heating-cooling demands were calculated for each case. Random Forest, XGBoost, and Support Vector Regression (SVR) models were then developed and compared. On the independent test set, SVR achieved the best predictive performance for combined demand, with $R^2 = 0.9619$, RMSE = 1.9159 kWh/m²·year, and MAE = 1.5231 kWh/m²·year. SHAP analysis ranked the global influence of the design variables as SHGC, WWR, orientation, shading depth, and insulation thickness. The trained SVR model was subsequently used as a surrogate to screen 200,000 additional design alternatives. Promising solutions were verified through direct EnergyPlus simulations, followed by local refinement and a final boundary grid search. The best EnergyPlus-verified configuration within the investigated design domain was obtained at 0° orientation (south-facing main façade), 20% WWR, 0.20 m wall insulation, SHGC of 0.25, and 0.475 m horizontal shading depth. This configuration reduced combined annual heating and cooling demand from 54.83 to 41.75 kWh/m²·year, corresponding to a 23.86% reduction relative to the baseline. The results demonstrate that machine learning can serve not as a replacement for physics-based simulation, but as an interpretable and computationally efficient surrogate for guiding early-stage design exploration and optimization.

Keywords: Machine learning, Passive design, EnergyPlus, SHAP, Optimization.

INTRODUCTION

Buildings account for a substantial share of global energy demand, and improvements in envelope performance, solar control, and early-stage design decisions remain central to energy-efficiency strategies. The International Energy Agency reports that buildings account for around 30% of global energy demand, highlighting the continuing importance of reducing operational loads through both passive and active measures (International Energy Agency [IEA], 2025). Because many influential design decisions are fixed early in the architectural process, rapid performance feedback at this stage can support more informed choices before the design becomes difficult or costly to modify.


Passive parameters such as orientation, glazing ratio, solar heat gain coefficient, insulation thickness, and external shading do not act independently. A lower SHGC, for example, can suppress unwanted summer solar gains and reduce cooling demand, while simultaneously reducing useful winter gains and increasing heating demand. Similar interactions occur

between façade orientation, window-to-wall ratio (WWR), and shading geometry. The resulting design space is therefore multidimensional and nonlinear, making exhaustive physics-based evaluation increasingly expensive as the number of variables and candidate values grows. Reviews of passive building design identify orientation, glazing, shading, and envelope insulation among the key parameters affecting building heating and cooling demand (Sadineni et al., 2011; Pacheco et al., 2012).

Recent research has increasingly combined building energy simulation with machine-learning surrogate models to accelerate early-design assessment and optimization. Shirzadi et al. (2025) showed that machine-learning surrogates trained on EnergyPlus simulation data can predict building energy and cost outcomes with high accuracy and can reduce the computational burden of repeated simulation. Mehraban et al. (2025) similarly integrated EnergyPlus, machine learning, and optimization algorithms in an automated building-energy workflow. In Türkiye, Senel Solmaz (2026) demonstrated the value of machine-learning-based early-design energy prediction across multiple climatic regions. Explainable machine-learning approaches are also becoming more prominent: Salami et al. (2023), for example, combined high-accuracy energy-load prediction with SHAP-based interpretation of influential building features. Earlier reviews of sustainable-building optimization documented the growing use of simulation-based search, derivative-free optimization, and meta-models to manage large design spaces (Evins, 2013; Machairas et al., 2014). Broader reviews of data-driven building-energy prediction also identify support-vector methods and related machine-learning techniques as established approaches for energy and performance prediction (Amasyali & El-Gohary, 2018; Seyedzadeh et al., 2018).

These studies indicate that machine learning can provide fast approximations of simulation outputs, but model accuracy alone is not sufficient for design decision-making. A surrogate optimum may fall in regions where prediction error is larger, and explainability is needed to clarify which variables are driving model behavior. Consequently, a robust workflow should combine physics-based data generation, independent model testing, explainability, large-space surrogate screening, and direct simulation-based verification. This simulation-surrogate logic is consistent with meta-model-based building-energy optimization approaches in which an inexpensive approximation is fitted to sampled physics-based simulations before the optimization stage (Eisenhower et al., 2012).

The present study develops such a workflow for Bursa climate conditions. A Python-controlled EnergyPlus model was used to generate a balanced 120-case design dataset covering eight orientations and four continuous passive-design variables. Random Forest (RF), XGBoost, and Support Vector Regression (SVR) were compared; the best-performing model was interpreted with SHAP and used to screen 200,000 additional design candidates. The most promising solutions were then returned to EnergyPlus for direct verification, local refinement, and a final structured boundary-grid search. The purpose was not to replace EnergyPlus, but to use machine learning as a computationally efficient guide that narrows the search toward promising design regions while retaining physics-based simulation as the final basis for the reported optimum.



EnergyPlus generates the physical evidence; machine learning accelerates the search; EnergyPlus confirms the final design.

Figure 1. Overall simulation, machine-learning, optimization, and verification workflow.

RESEARCH AND FINDINGS

Reference Building and EnergyPlus Simulation Setup

A single-storey office prototype was created in EnergyPlus 26.1 and executed through a Python-based automated workflow. EnergyPlus is a whole-building energy analysis and thermal-load simulation engine that calculates heating and cooling loads from building geometry, construction, schedules, internal gains, weather, and system definitions (U.S. Department of Energy, 2026). The reference office has a rectangular plan of 10 m × 6 m, a floor area of 60 m², and a height of 3 m. The entire space was represented as a single thermal zone. This simplification was intentionally adopted to isolate the effects of passive-design variables rather than room-to-room thermal differences.

At 0° orientation, the main 10 m façade faces south. The external wall construction, from outside to inside, consists of 20 mm exterior plaster, variable mineral-wool insulation, 190 mm brick, and 12.5 mm gypsum board. The roof construction consists of a 10 mm roof membrane, 120 mm roof insulation, 150 mm concrete, and 12.5 mm gypsum board, while the floor consists of 50 mm insulation and 150 mm concrete. Roof and floor constructions were held fixed throughout the parametric study. Windows were represented using the EnergyPlus Simple Glazing System object with a fixed U-value of 1.60 W/m²K, while SHGC was treated as a variable. The WWR of the three non-main façades was fixed at 0.10. The horizontal shading-depth variable represented an external horizontal overhang applied to the main façade.

To focus on building-load behavior rather than equipment efficiency, an Ideal Loads Air System was used. The heating and cooling setpoints were 21.1 °C and 23.9 °C, respectively. Weekday occupancy and HVAC availability were scheduled from 07:00 to 19:00. Internal gains were represented by an occupancy density of 0.054 person/m², lighting density of 10.67 W/m², and equipment density of 6.78 W/m². Infiltration was fixed at 0.50 air changes per hour. Ground-surface temperature was fixed at 18 °C for all months. An annual Bursa EPW weather file was used for all simulations.

Reference-model parameter	Value / assumption
Geometry	10 m × 6 m × 3 m; 60 m ² ; single thermal zone
Climate	Bursa EPW weather file; annual simulation
Main façade at 0°	South-facing
Other-façade WWR	0.10 (fixed)
Window U-value	1.60 W/m ² K (fixed)
Occupancy / lighting / equipment	0.054 person/m ² / 10.67 W/m ² / 6.78 W/m ²
Infiltration	0.50 ACH
Setpoints	Heating 21.1 °C; cooling 23.9 °C
HVAC representation	EnergyPlus Ideal Loads Air System

Reference-model parameter	Value / assumption
Roof construction	10 mm roof membrane + 120 mm insulation + 150 mm concrete + 12.5 mm gypsum board (fixed)
Floor construction	50 mm insulation + 150 mm concrete (fixed)
Ground-surface temperature	18 °C for all months
Horizontal shading	External horizontal overhang on the main façade; depth treated as a design variable

Table 1. Fixed reference-model assumptions used in the EnergyPlus workflow.

Passive Design Variables and Parametric Sampling

Five passive-design variables were investigated. Orientation was treated as a discrete variable with eight equally spaced directions, while main-façade WWR, wall-insulation thickness, SHGC, and horizontal shading depth were continuous variables. The investigated ranges were selected to cover a broad but architecturally plausible design space. The baseline model was defined at 0° orientation with WWR = 0.40, wall insulation = 0.10 m, SHGC = 0.45, and shading depth = 0.50 m. Under these conditions, annual heating demand was 4.7307 kWh/m²·year, cooling demand was 50.1030 kWh/m²·year, and combined heating and cooling demand was 54.8337 kWh/m²·year.

Design variable	Investigated values / range	Baseline
Orientation	0°, 45°, 90°, 135°, 180°, 225°, 270°, 315°	0°
Main-façade WWR	0.20–0.60	0.40
Wall insulation thickness	0.05–0.20 m	0.10 m
SHGC	0.25–0.60	0.45
Horizontal shading depth	approximately 0–1.00 m	0.50 m

Table 2. Passive-design variables and baseline values.

A stratified Latin Hypercube Sampling (LHS) strategy was used to construct the initial design dataset. LHS is a stratified sampling approach designed to represent multidimensional input spaces efficiently (McKay et al., 1979). For each of the eight orientations, 15 LHS samples were generated for the four continuous variables, producing 120 EnergyPlus cases in total. All 120 cases were successfully completed, with 15 cases per orientation, no missing values, and no duplicate case identifiers. The resulting combined heating and cooling demand ranged from 44.7538 to 90.7880 kWh/m²·year, providing a broad target range for model training.

Machine-Learning Models, Cyclic Orientation Encoding, and Validation

Three regression algorithms were compared: Random Forest, XGBoost, and Support Vector Regression. Separate regression models were trained for annual heating demand, annual cooling demand, and combined annual heating-plus-cooling demand (H+C). Random Forest aggregates multiple decision trees and is widely used for nonlinear regression and feature interactions (Breiman, 2001). XGBoost is a scalable gradient-boosted tree method designed for strong predictive performance on structured data (Chen & Guestrin, 2016). Support Vector Regression extends the support-vector framework to regression problems and can model nonlinear relationships through kernel functions (Drucker et al., 1997); the SVR implementation in this study used a radial basis-function (RBF) kernel.

Orientation requires special treatment because it is circular rather than linear. Using raw degree values would incorrectly make 0° and 315° appear far apart even though they are adjacent directions. Orientation was therefore transformed into sine and cosine components: orientation_{sin} = sin(θ) and orientation_{cos} = cos(θ). This representation preserves circular proximity in the feature space.

The 120-case dataset was divided into 96 training cases and 24 independent test cases. The split was stratified by orientation, leaving 12 training cases and 3 test cases for each of the eight directions. Hyperparameters were tuned only on the training set using five-fold stratified cross-validation. Model performance was evaluated using the coefficient of determination (R^2), root mean squared error (RMSE), and mean absolute error (MAE). This separation allowed model selection to be based on data not used during fitting or hyperparameter tuning. The final tuned RBF-SVR settings used $C = 300$ and $\gamma = 0.03$ for all three targets, with $\varepsilon = 0.25$ for heating, $\varepsilon = 0.50$ for cooling, and $\varepsilon = 1.00$ for total H+C.

Model Performance

SVR achieved the best predictive accuracy for heating, cooling, and combined heating-plus-cooling demand. For the combined target, SVR reached $R^2 = 0.9619$, $RMSE = 1.9159$ kWh/m²·year, and $MAE = 1.5231$ kWh/m²·year on the independent test set. XGBoost produced lower but still strong performance, while Random Forest had the largest errors among the three models. The close relationship between SVR cross-validation error and independent test error also indicated that the selected model was not simply fitting the training cases.

Target	Model	R^2	RMSE	MAE
Heating	Random Forest	0.7284	1.5497	1.1670
Heating	XGBoost	0.8676	1.0820	0.6901
Heating	SVR	0.9705	0.5109	0.4225
Cooling	Random Forest	0.7249	5.7847	4.4796
Cooling	XGBoost	0.9034	3.4282	2.6108
Cooling	SVR	0.9816	1.4971	1.1527
Total H+C	Random Forest	0.7823	4.5832	3.4792
Total H+C	XGBoost	0.8783	3.4265	2.6315
Total H+C	SVR	0.9619	1.9159	1.5231

Table 3. Independent test-set performance of the three machine-learning models.

Explainability with SHAP

After model selection, the final SVR model was refitted using all 120 simulation cases and interpreted using Kernel SHAP. SHAP provides feature-attribution values that quantify how strongly input variables influence model predictions (Lundberg & Lee, 2017). Because orientation had been represented by sine and cosine components, their absolute SHAP magnitudes were summed and reported as a single orientation importance value. For total heating and cooling demand, SHGC had the largest global mean absolute SHAP value (5.3845 kWh/m²·year), followed by main-façade WWR (4.4469), orientation (3.4307), shading depth (2.5611), and wall-insulation thickness (0.8849). These values represent the magnitude of influence within the fitted model, not a fixed directional increase or decrease in energy demand.




Figure 2. Global mean absolute SHAP importance for combined annual heating and cooling demand.

Surrogate Screening and Direct EnergyPlus Verification

The trained SVR model was next used as a surrogate to screen a much larger candidate population. For each of the eight orientations, 25,000 LHS candidate combinations were generated for the continuous variables, resulting in 200,000 surrogate evaluations. The number 25,000 was used as a practical dense-sampling choice because evaluating the trained SVR is computationally inexpensive; it is not a theoretically required sample size. Importantly, these 200,000 cases were model predictions rather than additional EnergyPlus simulations.

The best surrogate-predicted candidate had 0° orientation, WWR = 0.2040, insulation = 0.1946 m, SHGC = 0.2501, and shading depth = 0.6750 m, with a predicted combined demand of 39.7085 kWh/m²·year. The five top-ranked candidates were then simulated directly in EnergyPlus. The best verified candidate produced 42.1191 kWh/m²·year, corresponding to an absolute percentage error of 5.72%, calculated relative to the EnergyPlus-verified value, and a 23.19% reduction compared with the baseline. This difference confirmed the need to retain direct physics-based simulation as the final authority rather than accepting the surrogate optimum without verification.

Local Refinement and Final Structured EnergyPlus Grid

Because the verified optimum remained close to several design bounds, a direct local refinement stage was added. Forty local LHS cases were generated within a reduced four-dimensional region around the surrogate optimum, while orientation was fixed at 0°. The local ranges were WWR = 0.20–0.24, insulation = 0.16–0.20 m, SHGC = 0.25–0.30, and shading depth = 0.55–0.90 m. Eight additional boundary-focused shading cases were evaluated at WWR = 0.20, insulation = 0.20 m, and SHGC = 0.25, and the previously verified optimum was included for comparison. This produced 49 direct EnergyPlus runs in total. The best local case reduced combined demand to 41.8247 kWh/m²·year, but its shading depth of 0.55 m lay at the lower boundary of the local shading interval, indicating that the true minimum could occur at a smaller depth.

A final structured boundary-grid search was therefore performed. WWR, insulation, and SHGC were fixed at 0.20, 0.20 m, and 0.25, respectively, while shading depth was varied

from 0.000 to 0.600 m in 0.025 m increments. Twenty-five shading depths were tested for each of the eight orientations, giving 200 direct annual EnergyPlus simulations. All 200 runs completed successfully. At 0° orientation, combined demand decreased from 44.9996 kWh/m²·year with no shading to a minimum of 41.7524 kWh/m²·year at 0.475 m, then increased slightly as shading became deeper. This shallow interior minimum reflects the trade-off between summer solar-control benefits and reduced winter solar gains.




Figure 3. Final direct-EnergyPlus shading-depth search at 0° orientation.

The lowest EnergyPlus-verified solution identified by the proposed search procedure within the investigated design bounds was obtained at 0° orientation, WWR = 0.20, wall-insulation thickness = 0.20 m, SHGC = 0.25, and shading depth = 0.475 m. Annual combined heating and cooling demand decreased from the 54.8337 kWh/m²·year baseline to 41.7524 kWh/m²·year, corresponding to a 23.86% reduction.




Figure 4. Baseline and final verified annual heating, cooling, and combined demand.

Performance indicator	Baseline	Final verified
Orientation	0°	0°
Main-façade WWR	0.40	0.20
Wall insulation	0.10 m	0.20 m
SHGC	0.45	0.25
Shading depth	0.50 m	0.475 m
Heating demand	4.7307 kWh/m ² ·year	8.2988 kWh/m ² ·year
Cooling demand	50.1030 kWh/m ² ·year	33.4536 kWh/m ² ·year
Total H+C	54.8337 kWh/m ² ·year	41.7524 kWh/m ² ·year

Table 4. Baseline and final verified design/performance comparison.

Interpretation of the Final Energy Balance

The final configuration did not reduce both heating and cooling demand simultaneously. Heating demand increased from 4.7307 to 8.2988 kWh/m²·year, an increase of approximately 75.4%, while cooling demand decreased from 50.1030 to 33.4536 kWh/m²·year, a reduction of approximately 33.2%. The combined objective nevertheless improved by 23.86% because the absolute cooling reduction was much larger than the heating penalty. This result is consistent with the physical role of lower WWR and SHGC: both reduce solar heat gains and therefore cooling loads, but they also limit beneficial winter gains. The optimization objective was therefore the annual combined heating-plus-cooling demand rather than either component considered independently.

The orientation results also require a bounded interpretation. In the final 0–0.60 m shading grid, the best 0° case occurred at an interior shading depth of 0.475 m and had the lowest combined demand among all tested orientations. For several non-zero orientations, the best result within the tested grid occurred at the 0.60 m upper shading boundary. In addition, the final WWR (0.20) and SHGC (0.25) were located at their lower investigated bounds, whereas the final wall-insulation thickness (0.20 m) was at its upper investigated bound. Therefore, lower combined demand may be possible outside the ranges examined here. Accordingly, the study identifies the lowest EnergyPlus-verified solution found within the investigated design bounds and proposed search procedure; it does not claim an unconstrained or universal optimum for all buildings in Bursa.

CONCLUSION AND DISCUSSION

This study developed and tested a machine-learning-assisted passive-design optimization workflow for a 60 m² single-zone office under Bursa climate conditions. A Python-controlled EnergyPlus model generated a balanced 120-case dataset across eight orientations and four continuous design variables. Random Forest, XGBoost, and SVR were compared using an independent test set and stratified cross-validation. SVR produced the best performance for combined heating and cooling demand, with $R^2 = 0.9619$, RMSE = 1.9159 kWh/m²·year, and MAE = 1.5231 kWh/m²·year.

The explainability analysis showed that SHGC and main-façade WWR were the two most influential variables in the fitted surrogate, followed by orientation, shading depth, and wall-insulation thickness. This ranking is physically plausible for a cooling-dominated baseline in which solar gains through glazing make a large contribution to annual load. However, SHAP importance should be interpreted as model influence rather than as a direct causal energy change.

The optimized workflow illustrates the main practical benefit of combining machine learning and simulation. The SVR model screened 200,000 candidate designs at negligible cost relative to equivalent direct simulation, but the surrogate-predicted optimum was not accepted uncritically. Direct EnergyPlus verification, local refinement, and a final 200-case grid were

used to resolve boundary behavior and determine the reported solution. The lowest verified configuration identified within the investigated design bounds—0° orientation, WWR = 0.20, 0.20 m wall insulation, SHGC = 0.25, and 0.475 m shading depth—reduced annual combined heating and cooling demand from 54.83 to 41.75 kWh/m²·year, or 23.86% relative to the baseline.

The final energy balance is also important for design interpretation. Lower solar transmission and glazing area increased heating demand by reducing beneficial winter solar gains, but the much larger cooling reduction dominated the annual objective. Therefore, the optimum should not be interpreted as a configuration that minimizes every energy component simultaneously. Rather, it represents the lowest combined annual demand identified within the tested design bounds.

The study has several limitations. The model represents one single-zone office prototype, one Bursa weather file, fixed occupancy and internal-gain schedules, and an Ideal Loads HVAC representation. Cost, embodied carbon, daylight, thermal comfort, natural ventilation, and uncertainty in user behavior were outside the scope. In addition, the sampling densities used for the initial LHS dataset, surrogate screening, and local refinement were practical design choices rather than theoretically unique values. The final WWR and SHGC reached their lower investigated bounds and insulation thickness reached its upper investigated bound; consequently, the reported configuration should be interpreted as the lowest verified solution found within the tested ranges rather than as a global optimum beyond those bounds. Future studies can extend the workflow to wider parameter ranges, multi-zone buildings, additional building types and climates, dynamic shading strategies, lifecycle cost and carbon objectives, and uncertainty-aware or multi-objective optimization.

Overall, the results support a complementary rather than substitutive role for machine learning in building-performance design. Physics-based simulation remains essential for final verification, while a well-tested and interpretable surrogate can substantially accelerate exploration of large passive-design spaces and provide architects with faster feedback during early decision-making.

REFERENCES

- Amasyali, K., & El-Gohary, N. M. (2018). A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, 81, 1192–1205. <https://doi.org/10.1016/j.rser.2017.04.095>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A. J., & Vapnik, V. (1997). Support vector regression machines. In M. C. Mozer, M. I. Jordan, & T. Petsche (Eds.), *Advances in Neural Information Processing Systems 9* (pp. 155–161). MIT Press.
- Eisenhower, B., O'Neill, Z., Narayanan, S., Fonoberov, V. A., & Mezić, I. (2012). A methodology for meta-model based optimization in building energy models. *Energy and Buildings*, 47, 292–301. <https://doi.org/10.1016/j.enbuild.2011.12.001>
- Evins, R. (2013). A review of computational optimisation methods applied to sustainable building design. *Renewable and Sustainable Energy Reviews*, 22, 230–245. <https://doi.org/10.1016/j.rser.2013.02.004>
- International Energy Agency. (2025). *Energy efficiency 2025: Buildings*. IEA. <https://www.iea.org/reports/energy-efficiency-2025/buildings>

- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Machairas, V., Tsangrassoulis, A., & Axarli, K. (2014). Algorithms for optimization of building design: A review. *Renewable and Sustainable Energy Reviews*, 31, 101–112. <https://doi.org/10.1016/j.rser.2013.11.036>
- McKay, M. D., Beckman, R. J., & Conover, W. J. (1979). Comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2), 239–245. <https://doi.org/10.1080/00401706.1979.10489755>
- Mehraban, M. H., Sepasgozar, S. M. E., Ghomimoghadam, A., & Zafari, B. (2025). AI-enhanced automation of building energy optimization using a hybrid stacked model and genetic algorithms: Experiments with seven machine learning techniques and a deep neural network. *Results in Engineering*, 26, 104994. <https://doi.org/10.1016/j.rineng.2025.104994>
- Pacheco, R., Ordóñez, J., & Martínez, G. (2012). Energy efficient design of building: A review. *Renewable and Sustainable Energy Reviews*, 16(6), 3559–3573. <https://doi.org/10.1016/j.rser.2012.03.045>
- Sadineni, S. B., Madala, S., & Boehm, R. F. (2011). Passive building energy savings: A review of building envelope components. *Renewable and Sustainable Energy Reviews*, 15(8), 3617–3631. <https://doi.org/10.1016/j.rser.2011.07.014>
- Salami, B. A., Abba, S. I., Adewumi, A. A., Dodo, U. A., Otukogbe, G. K., & Oyedele, L. O. (2023). Building energy loads prediction using Bayesian-based metaheuristic optimized-explainable tree-based model. *Case Studies in Construction Materials*, 19, e02676. <https://doi.org/10.1016/j.cscm.2023.e02676>
- Senel Solmaz, A. (2026). A machine learning-based early design energy prediction framework for school buildings across multiple climatic regions of Türkiye. *Buildings*, 16(4), 779. <https://doi.org/10.3390/buildings16040779>
- Seyedzadeh, S., Pour Rahimian, F., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: A review. *Visualization in Engineering*, 6, Article 5. <https://doi.org/10.1186/s40327-018-0064-7>
- Shirzadi, N., Lau, D., & Stylianou, M. (2025). Surrogate modeling for building design: Energy and cost prediction compared to simulation-based methods. *Buildings*, 15(13), 2361. <https://doi.org/10.3390/buildings15132361>
- U.S. Department of Energy. (2026). *EnergyPlus Version 26.1 documentation*. <https://bigladdersoftware.com/epx/docs/26-1/>

XX ƏSR AZƏRBAYCAN BOYAKARLIĞINDA VEDUTA JANRI THE VEDUTA GENRE IN 20TH-CENTURY AZERBAIJANI PAINTING

Emil Raul oğlu Ağayev

Teacher of the subject combination commission "Art and physical education" of the
Azerbaijan State Pedagogical College under the Azerbaijan State Pedagogical University
ORCID: 0000-0001-9354-0839

Xülasə. Məqalədə təsviri incəsənətdə şəhər və memarlıq mənzərələrini əks etdirən veduta janrının yaranması, tarixi inkişafı və XX əsr Azərbaycan rəssamlığındakı bədii xüsusiyyətləri araşdırılır. Janr anlayışının XVII əsrdə sistemləşməsi, vedutanın isə daha qədim şəhər təsvirləri ənənəsi ilə bağlılığı qeyd olunur. Venesiya rəssamlığı və Kanaletto yaradıcılığı veduta janrının müstəqil istiqamət kimi tanınmasında mühüm mərhələ kimi təqdim edilir. Azərbaycan təsviri sənətində şəhər mühitinin, tarixi memarlıq abidələrinin, küçələrin, meydanların və dəniz mənzərələrinin rəssamların yaradıcılığında geniş yer tutması nümunələr əsasında təhlil olunur. Elmira Şahtaxtinskayanın Bakı mövzusunda əsərlərində memarlıq, dəniz, təbiət və rəng münasibətlərinin vəhdəti, impressionist və puantilist bədii ifadə vasitələrinin təsiri diqqətə çatdırılır. Toğrul Nərimanbəyovun Bakı təsvirlərində şəhərin tarixi-mədəni mühiti, milli məişət səhnələri, İçərişəhərin obrazı və paytaxtın poetik görünüşünün özünəməxsus şəkildə təqdim edilməsi araşdırılır. Xalidə Səfərovanın Paris silsiləsində isə Avropa şəhər mühitinin, Eyfel qülləsinin, Notr-Damın, Monmartırın və Sena sahillərinin impressionist duyum, rəng harmoniyası, işıq-kölgə və perspektiv vasitəsilə işlənməsi ön plana çəkilir. Həmçinin Vəcihə Səmədova, Mikayıl Abdullayev və Nadir Əbdürrəhmanovun xarici ölkələrə həsr etdikləri əsərlərin milli bədii baxışla Avropa təsviri sənət prinsiplərini əlaqələndirdiyi vurğulanır. Araşdırma göstərir ki, Azərbaycan rəssamları veduta janrını yalnız şəhər görünüşünün sənədli təsviri kimi deyil, milli yaddaşın, memarlıq irsinin, şəhər estetikasının və emosional təəssüratların ifadə vasitəsi kimi inkişaf etdirmişlər. Bu yanaşma şəhər məkanını tarixi, estetik və sosial məzmun daşıyan canlı bədii obraz səviyyəsinə yüksəltməklə yanaşı, milli rəssamlığın beynəlxalq sənət təcrübələri ilə qarşılıqlı əlaqəsini də aydın şəkildə nümayiş etdirir. Eyni zamanda bu əsərlər şəhərin yaddaşını qoruyaraq tamaşaçıda məkanla bağlı estetik hisslər yaradır və milli mədəni irsin vizual şəkildə təqdim edilməsinə imkan verir.

Açar sözlər: veduta, şəhər mənzərəsi, memarlıq, Azərbaycan rəssamlığı, şəhər estetikası

Abstract. The article examines the formation, historical development, and artistic characteristics of the veduta genre in Azerbaijani visual art, focusing on representations of urban and architectural landscapes. It notes that the concept of genre became systematized in the seventeenth century, while veduta itself developed from much older traditions of depicting cities and architectural spaces. Venetian painting and the work of Canaletto are presented as important stages in the recognition of veduta as an independent artistic direction. The study analyzes examples demonstrating the significant place of urban environments, historical monuments, streets, squares, and seascapes in twentieth-century Azerbaijani painting. In the works of Elmira Shahtakhtinskaya devoted to Baku, particular attention is given to the relationship between architecture, sea, nature, and color, as well as the influence of Impressionist and Pointillist techniques. The Baku compositions of Togrul Narimanbekov are examined through his distinctive interpretation of the city's historical and cultural environment, traditional everyday scenes, the image of Icherisheher, and the poetic character of the capital.

Khalida Safarova's Paris series is discussed in terms of her treatment of the Eiffel Tower, Notre-Dame, Montmartre, and the Seine through Impressionist perception, color harmony, light and shadow, and perspective. The works of Vajiha Samadova, Mikayil Abdullayev, and Nadir Abdurrahmanov devoted to foreign countries are also considered as examples of interaction between national artistic vision and European methods. The research concludes that Azerbaijani artists developed veduta not merely as documentary urban representation, but as a means of expressing cultural memory, architectural heritage, urban aesthetics, and emotional impressions.

Keywords: veduta, urban landscape, architecture, Azerbaijani painting, urban aesthetics


Təsviri incəsənətdə janr anlayışının formalaşması XVII əsrə aid edilir. Janr hər bir incəsənət növünün tərkib hissəsidir. İncəsənət tarixində “Veduta” termini ilə formalaşan, şəhər və memarlıq mənzərələrinin XVIII əsrdən başlayaraq populyarlaşması Venesiya rəssamı Kanaletto ilə əlaqələndirilir. Rəssam tələbələrinə və sifarişçilərə bu janrı “Venesiya xatirəsi” kimi izah edirdi. Lakin, bununla belə veduta bir janr kimi dərin tarixi köklərə malikdir. Qədim dövr daş səhnamələrində, Orta əsr kitab miniatürlərində, divar rəsmlərində, habelə Avropa İntibahı incəsənətində şəhər təsvirləri geniş yayılmışdır. Azərbaycan təsviri sənətində artıq XX əsrdən etibarən rəssamlarımız həm öz ölkəmizə, həm də xarici ezamiyyətlərə gedən zaman kətanlarına köçürdüyü veduta janrında olan əsərləri mühüm yer tutur.

Elmira Şahtaxinskaya yaradıcılığında Bakıya həsr etdiyi mənzərələr mühüm yer tutur. “Bakı mənim vətənimdir” (şəkil 1) əsərində yaz fəslinin gözəllikləri ustalıqla təsvir edilmişdi. Şəhərin ümumi memarlığı dairəvi formadadır. Kompozisiyanın ön hissəsində tənha və çiçək açan ağaclar, qışdan yaza keçidi simvolik olaraq əks etdirir. Mənzərənin veduta (şəhər memarlığı) və marina (dəniz) növlərindən istifadə edilmişdi. Digər ağaclar buta formasında, bulud isə çin-uyğur sənətinə xas olan spiralvari formada həll edilmişdi. Soyuq və isti rənglərin vəhdəti “Küləklər şəhəri” olan paytaxtımızın ümumi görünüşünü tamaşaçının gözü qarşısında canlandırır. “Yağışlı gün. Bakı” (1961) və “Gecə mənzərəsi. Bakı” (1958) əsərlərində impressionist və puantilistlərə xarakterik olan yaxmaları duya bilərik. “İncəsənət muzeyindən mənzərə” (1987) bu kompozisiyada şərq və qərb memarlığının sintezi, rəssama məxsus olan “lessirovka” texnikasının özünə məxsusluğu vardır.

Toğrul Nərimanbəyovun “Köhnə Bakı” (1980) əsərində sanki nağıllarda olan şəhərini təsvir edib. Əsərə baxanda səmada, dənizdə, tarixi abidələrimizdə bütün nağıllarda olan qəhrəmanlarımızı görə bilərik. Sənətkar sanki bu əsərə baxan tamaşaçıya öz sevimli paytaxtı və onun əzəməti haqqında hekayə danışır. Əsərin maraqlı anlarından biri dörd fəslin bir kompozisiyada yerləşdirilməsidir. “Bakıda küləkli gün” (1974) kompozisiyasında isə küləklər şəhərini öz fırçasıyla təsvir edən rəssam sanki dənizin rəqsini təsvir edir. Toz-dumanı, göyün tutqunluğunu verməklə sənətkar küləkli gündə belə Bakının necə gözəl olmasını təsvir edir. Toğrul Nərimanbəyovun “Bakıda bahar” əsərində isə baharın şəhərinə gəlişini təsvir edən rəssam isti tonlarla, əsas memarlıq kimi “Filarmoniya”-nı təsvir etmişdi. Onun qarşısındakı küçənin verilməsidə sənətkarın gözündən qaçmamışdı.

Rəssamın Bakı və onun tarixi abidələrinə müraciət etdiyi əsərlərindən ən maraqlısı “İçərişəhərdə küçə” kompozisiyasıdır. Əsərdə qədim şəhərin adət-ənənələri təsvir

olunub. Samovar çayı içən qonşular, tut ağacına çıxan oğlan və ağacın altında tut yığmaq üçün hazırlıqlarını görən qızlar, dəvənin üstündə süd, su satan, qonşuların öz evlərinin qarşısında birləri ilə mehriban söhbət etmələri-bütün bu süjetləri Toğrul Nərimanbəyov bir kompozisiyada yerləşdirmişdir. Rənglər sanki qarışıq formada verilib və İçərişəhərin mədəni həyatını təcəssüm etdirir. Sənətkarın bu mövzuya müraciət etdiyi “Yağışlı gündə Şirvanşahlar sarayı”, “Qız qalası” (1994) kimi əsərlərində isə Bakının simvolları gözümüzün qarşısında canlanmışdı. “Köhnə Bakı” (1965) kompozisiyasında isə ümumilikdə qarşımızda şəhərin monumental obrazı canlandırılır.



Şəkil 1. Elmira Şahmurova “Bakı mənim vətənimdir”

Azərbaycan rəssamlarından bir çoxu Maral Rəhmanzadə, Vəcihə Səmədova, Nadir Əbdürrəhmanov və başqalarının yaradıcılığında Bakıya həsr edilən silsilə əsərlər vardır. Xarici ölkələrin memarlığını və mənzərəsini öz fırçasıyla təsvir edən rəssamlarımız isə Avropada baş verən cərəyanların təsirinə düşərək milli və qərb təviri sənət metodlarının sintezini öz əsərlərində ustalıqla əks etdirmişlər.

Öz mədəniyyəti ilə seçilən Fransa daima üslubların, cərəyanların və məşhur rəssamların yaşadığı ölkə olub. Xalidə Səfərova yaradıcılığında Paris mövzusunda yaratdığı silsilə əsərlər mühüm yer tutmaqla bərabər, rəng həllinə və bədii-texniki icrasına görə də fərqlənirlər. “Paris silsiləsi” onun yaradıcılığının son dövrlərini (1980-1990-cı illər) əhatə edir. Ruhən impressionist olan rəssamın dəst-xəttində impressionizm cərəyanının əlamətləri demək olar ki, bütün yaradıcılığı boyu izlənilir. Uzun illər həsrəti ilə yaşadığı Fransaya gəlmək rəssamın yaradıcılığında yeniliklər olacağına bir işarə idi. O buranın təbiətini, tarixini, memarlığını və küçələrini öz fırçasıyla tamaşaçılarına çatdırır.

Xalidə Səfərova Parisin simvolu sayılan “Eyfel qülləsi” (1995) əsərində yuxarı baxış istiqamətində, şaquli formatda, soyuq rənglərdən istifadə edərək mürəkkəb və maraqlı kompozisiya yaratmışdır. Digər maraqlı məqam isə rəssamın təbiət və şəhər mənzərəsini bir əsərdə sintez şəklində əlaqələndirməsidir. Kompozisiya quruluşunu iki planlı təhlil etsək, ön

planda qırmızı, qəhvəyi və yaşıl rənglərdə həllini tapmış tarixi qülləni, arxa planda isə səma təsviri və ağ rəngin içində qara element kimi təsvir edilən qağayıları müşahidə etmiş olarıq. “Notr Dam kilsəsi” (1985) əsərində də rəssam kompozisiyanı eyni prinsiplə qurmuş və soyuq-isti rənglər, işıq-kölgə, perspektiv və məkan həllindən istifadə etmişdir. “Paris silsiləsinə” daxil edilən məşhur impressionist rəssam O.Renuar tərəfindən bir neçə dəfə müraciət olunan, lakin Xalidə Səfərovanın özünəməxsus şəkildə işlədiyi Monmartra həsr etdiyi əsərlər də özünün maraqlı bədii həlli ilə seçilir. Rəssamın bu qəbildən olan “Monmartr bulvarı” (1985), “Monmartr. Paris” (1985) və eskiz xarakterli “Monmartr. Paris” (1985) kompozisiyalarında adı çəkilən şəhərin müxtəlif fəsillərdə rənglər vasitəsilə yaratdığı abu-havanı xüsusilə qeyd etmək lazımdır. Bu təsvir üsulundan istifadə qeyri-adi yanaşma kimi sayılmalı deyil, çünki məhz impressionistlər təbiətin müxtəlif anlarında çəkilən əsərlərə xüsusi diqqət ayırırdılar. Şəhərin ictimai binalarının təsvirini rəssam dəqiqliklə təsvir etmişdir. Qızılı, yaşıl, qırmızı, ağ rənglərin bir-biri ilə vəhdətdə verilməsini bu əsərlər üçün spesifik bir nəzəri baxış kimi qeyd etməliyik.

Xalidə Səfərova bu silsilədə Sena çayının da təsvirinə xüsusi yer ayırmışdır. “Parisdə axşam” (1985), “Sena sahili” (1998) kompozisiyalarında rəssam təkcə Sena çayını deyil, ümumilikdə Parisin ümumi mənzərəsini tamaşaçının gözü qarşısında canlandırır. Çayın üzərində puantilistlərə xarakterik olan refleksin əks edilməsi, yaxmaların dəqiq verilməsi, mənzərəyə xas olan metodlardan istifadəni sənətkar xüsusilə vurğulamışdı.

Vəcihə Səmədova “Stokholm”, “Bolqarıstan”, Mikayıl Abdullayev “Hindistan”, Nadir Əbdürrəhmanov “Venesiya” və başqalarının xarici ölkələrə həsr etdiyi bu əsərlər öz koloritliliyi ilə tamaşaçıların diqqətini cəlb edir.

XX əsr Azərbaycan təsviri incəsənətində veduta janrının milli və Avropa metodlarından istifadə edilərək, rəng, məkan, kompozisiya quruluşları əsərlərin bitkinliyini tamamlayır.

ƏDƏBİYYAT SİYAHISI:

1. Sevil Kərimova “İncəsənət əsərlərinin təhlili” (metodik vəsait), Azərbaycan/Bakı. 2018
2. Sərvət toplusu, Şərq-qərb nəşriyyatı Bakı/Azərbaycan. 2013

ÇOKLU ORGAN BT SEGMENTASYONUNDA FOUNDATION MODELLERİNİN ORGAN BAZLI GÜVENİLİRLİĞİNİN KARŞILAŞTIRMALI ANALİZİ COMPARATIVE ORGAN-LEVEL RELIABILITY ANALYSIS OF FOUNDATION MODELS FOR MULTI-ORGAN CT SEGMENTATION

Asst. Prof. Dr. Sezin BARIN

Afyon Kocatepe University, Faculty of Engineering
ORCID ID: <https://orcid.org/0000-0002-0394-2779>

Özet

Foundation modelleri, farklı segmentasyon görevlerine minimum ek eğitim gereksinimiyle uyarlanabilmeleri ve sıfır örnek (zero-shot) çıkarım yetenekleri sayesinde tıbbi görüntü analizinde yeni bir paradigma oluşturmıştır. Bununla birlikte, bu modellerin klinik kullanıma aktarılabilmesi yalnızca yüksek ortalama doğruluk değerlerine değil, farklı anatomik yapılar ve hasta grupları boyunca tutarlı ve güvenilir performans sergilemelerine de bağlıdır. Özellikle organ boyutu, görüntü kontrastı ve anatomik karmaşıklığın foundation modeller üzerindeki etkisi henüz kapsamlı biçimde ortaya konulamamıştır. Bu çalışmada, MedSAM ve SAM2'nin zero-shot segmentasyon performansı, görev-spesifik olarak eğitilmiş nnU-Net v2 modeli ile AMOS22 abdominal çoklu-organ bilgisayarlı tomografi veri seti üzerinde karşılaştırmalı olarak değerlendirilmiştir. Tüm modeller aynı validasyon kohortu üzerinde organ bazında Dice Similarity Coefficient (DSC), %95 Hausdorff Distance (HD95) ve segmentasyon başarısızlık oranı kullanılarak analiz edilmiştir. Ortalama performans metriklerine ek olarak, organ bazlı ve olgu bazlı performans değişkenliği de incelenerek modellerin klinik güvenilirliği çok yönlü olarak değerlendirilmiştir. Karşılaştırmalı analizler, nnU-Net v2'nin karaciğer, böbrekler ve aort gibi büyük ve yüksek kontrastlı anatomik yapılarda daha tutarlı segmentasyon performansı sergilediğini göstermektedir. Foundation modelleri bu organlarda rekabetçi sonuçlar üretmekle birlikte, olgular arasında daha yüksek performans değişkenliği göstermektedir. Performans farklılıkları özellikle pankreas, adrenal bezler, özofagus ve duodenum gibi küçük ve anatomik olarak daha karmaşık yapılarda belirginleşmektedir. Bu organlarda tüm modellerde doğrulukta azalma gözlenmesine rağmen, foundation modellerin başarısızlık oranlarının ve performans varyasyonlarının daha yüksek olduğu görülmektedir. Elde edilen bulgular, ortalama performans metriklerinin tek başına klinik güvenilirliği değerlendirmek için yeterli olmadığını; güvenilir bir klinik değerlendirme için organ bazlı performans, vaka bazlı değişkenlik ve başarısızlık analizlerinin birlikte ele alınması gerektiğini göstermektedir. Çalışma, foundation modellerin güçlü ve sınırlı kaldıkları anatomik senaryoları sistematik olarak ortaya koyarak, güven kalibrasyonu, adaptif prompting ve klinik karar destek sistemlerine yönelik gelecekte geliştirilecek güvenilir foundation model yaklaşımları için deneysel bir referans çerçevesi sunmaktadır.

Anahtar Kelimeler: Foundation modelleri, güvenilir yapay zekâ, tıbbi görüntü segmentasyonu, çoklu organ BT segmentasyonu, klinik güvenilirlik.

Abstract

Foundation models have emerged as an important paradigm in medical image analysis due to their ability to generalize across different segmentation tasks with little or no task-specific training and their zero-shot inference capabilities. However, their suitability for clinical applications depends not only on achieving high average segmentation accuracy but also on maintaining consistent and reliable performance across different anatomical structures and patient populations. In particular, the impact of factors such as organ size, image contrast, and anatomical complexity on the performance of foundation models has not yet been systematically investigated. In this study, the zero-shot segmentation performance of

MedSAM and SAM2 was compared with that of a task-specific nnU-Net v2 model using the validation cohort of the AMOS22 abdominal multi-organ computed tomography dataset. All models were evaluated using organ-level Dice Similarity Coefficient (DSC), 95% Hausdorff Distance (HD95), and segmentation failure rate. In addition to average performance metrics, case-to-case performance variability was analyzed to provide a more comprehensive assessment of the clinical reliability of the models. The results showed that nnU-Net v2 achieved more consistent segmentation performance for large, high-contrast anatomical structures, including the liver, kidneys, and aorta. Although MedSAM and SAM2 achieved competitive accuracy for these organs, they exhibited greater case-to-case performance variability. Performance differences became more pronounced for smaller, low-contrast, and anatomically complex structures, such as the pancreas, adrenal glands, esophagus, and duodenum. While all models showed reduced accuracy for these organs, the foundation models exhibited higher segmentation failure rates and greater case-to-case performance variability. These findings suggest that average segmentation performance alone is insufficient to assess the clinical reliability of foundation models. A reliable evaluation for clinical deployment should consider organ-level accuracy, case-to-case performance variability, and segmentation failure rates together. By systematically identifying the anatomical scenarios in which foundation models perform reliably and those in which their performance remains limited, this study provides a practical reference for future research on confidence calibration, adaptive prompting strategies, and trustworthy clinical decision support systems.

Keywords: Foundation models, trustworthy artificial intelligence, medical image segmentation, multi-organ CT segmentation, clinical reliability.

FUNDUS GÖRÜNTÜLERİNDEN GÖZ HASTALIKLARININ OTOMATİK SINIFLANDIRILMASINA YÖNELİK BİR DERİN ÖĞRENME YAKLAŞIMI A DEEP LEARNING APPROACH FOR AUTOMATED CLASSIFICATION OF EYE DISEASES FROM FUNDUS IMAGES

Asst. Prof. Dr. Yusuf ÇELİK

Munzur University, Faculty of Engineering, Department of Computer Engineering
ORCID ID: <https://orcid.org/0000-0002-7859-7543>

Özet

Fundus görüntülerinin otomatik olarak sınıflandırılması, göz hastalıklarının erken tanısına katkı sağlayabilecek bilgisayar destekli tanı sistemlerinin geliştirilmesinde önemli bir rol oynamaktadır. Bu çalışmada, fundus görüntülerinden katarakt, diyabetik retinopati, glokom ve normal sınıflarının otomatik olarak belirlenmesi amacıyla EfficientNetV2S tabanlı ve Channel Attention modülü ile güçlendirilmiş bir derin öğrenme modeli sunulmuştur. Çalışmada ilk olarak ResNet50, DenseNet121, EfficientNetB0 ve EfficientNetV2S omurga ağları aynı deneysel koşullar altında karşılaştırılarak en uygun omurga ağı belirlenmiştir. Daha sonra EfficientNetV2S modeli üzerine Channel Attention, Spatial Attention ve CBAM dikkat mekanizmaları ayrı ayrı entegre edilerek performansları değerlendirilmiş, son aşamada ise seçilen model veri artırma stratejileri ile desteklenmiştir. Deneysel sonuçlar, bu çalışmada kullanılan veri kümesi ve uygulanan deneysel koşullar altında Channel Attention modülünün diğer dikkat mekanizmalarına göre daha başarılı sonuçlar verdiğini göstermiştir. Geliştirilen nihai model %95.73 doğruluk, %95.68 kesinlik, %95.68 duyarlılık ve %95.68 F1-skoru elde etmiştir. Elde edilen bulgular, kullanılan veri kümesi ve uygulanan deneysel protokol kapsamında EfficientNetV2S omurga ağı, Channel Attention modülü ve veri artırma stratejilerinin birlikte kullanılmasının fundus görüntülerinden göz hastalıklarının otomatik sınıflandırılmasında etkili bir yaklaşım sunduğunu göstermektedir.

Anahtar Kelimeler: Fundus görüntüleri, göz hastalıklarının sınıflandırılması, derin öğrenme, dikkat mekanizması

Abstract

The automated classification of fundus images plays an important role in the development of computer-aided diagnostic systems for the early detection of ocular diseases. In this study, a deep learning model based on EfficientNetV2S and enhanced with a Channel Attention module is presented for the automated classification of cataract, diabetic retinopathy, glaucoma, and normal fundus images. Initially, ResNet50, DenseNet121, EfficientNetB0, and EfficientNetV2S backbone networks were compared under identical experimental conditions to identify the most suitable backbone architecture. Subsequently, Channel Attention, Spatial Attention, and CBAM modules were individually integrated into the EfficientNetV2S architecture, and their effects on classification performance were evaluated. Finally, the selected model was further improved using data augmentation strategies. Experimental results demonstrated that, under the dataset and experimental conditions considered in this study, the Channel Attention module outperformed the other attention mechanisms. The final model achieved an accuracy of 95.73%, a precision of 95.68%, a recall of 95.68%, and an F1-score of 95.68%. The findings indicate that, within the scope of the employed dataset and experimental protocol, the combined use of the EfficientNetV2S backbone, the Channel Attention module, and data augmentation strategies provides an effective approach for the automated classification of ocular diseases from fundus images.

Keywords: Fundus images, ocular disease classification, deep learning, attention mechanism

DERİN ÖĞRENME TABANLI LOG-MEL SPEKTROGRAM VE SAYISAL ÖZNİTELİK FÜZYONU İLE KALP ÜFÜRÜMÜ TESPİTİ DEEP LEARNING-BASED HEART MURMUR DETECTION USING FUSION OF LOG- MEL SPECTROGRAMS AND NUMERICAL FEATURES

Ezelhan DİKMENLİOĞLU¹

¹Sakarya University, Institute of Natural Sciences, Department of Computer Engineering,
54050 Sakarya, Türkiye
ORCID ID: 0009-0001-6930-4753

Asst. Prof. Dr. Ulaş YURTSEVER^{2,3}

²Sakarya University, Faculty of Computer and Information Sciences,
Department of Computer Engineering, 54050 Sakarya, Türkiye
³Sakarya University, Research, Development and Application Center,
Interdisciplinary Artificial Intelligence Lab., 54050 Sakarya, Türkiye
ORCID ID: 0000-0003-3438-6872

ÖZET

Kalp üfürümlerinin fonokardiyogram (PCG) kayıtlarından otomatik olarak belirlenmesi, kardiyovasküler hastalıkların erken taranmasına yönelik bilgisayar destekli sistemler açısından önem taşımaktadır. Bu çalışmada, PCG sinyallerinden elde edilen zaman-frekans ve sayısal öznitelik temsillerini birlikte değerlendiren iki kollu bir derin öğrenme yaklaşımı incelenmiştir. PhysioNet/CinC 2022 CirCor DigiScope veri setindeki Murmur etiketleri kullanılmıştır. Belirsizliği temsil eden Unknown sınıfı çıkarılarak problem Absent ve Present sınıfları arasında ikili sınıflandırma görevi olarak tanımlanmıştır. Deneyler, 575 eğitim, 126 doğrulama ve 173 test hastası üzerinde gerçekleştirilmiştir. Her beş saniyelik segmentten 64 bantlı Log-Mel spektrogram ve Mel frekans kepstral katsayıları (MFCC), spektral, enerji tabanlı ve istatistiksel ölçütlerden oluşan 59 boyutlu sayısal öznitelik vektörü çıkarılmıştır. Log-Mel gösterimleri evrişimli sinir ağı (CNN), sayısal öznitelikler ise çok katmanlı algılayıcı (MLP) kolunda işlenmiş; iki koldan elde edilen 128'er boyutlu gizli temsiller birleştirilerek ara füzyon gerçekleştirilmiştir. Segment tahminleri kayıt düzeyinde ortalama alınarak, kayıt tahminleri ise hasta düzeyinde en yüksek değer seçilerek birleştirilmiştir. Füzyon modeli test kümesinde %91,91 doğruluk, %85,89 dengeli doğruluk, %76,67 duyarlılık, %95,10 özgüllük, %76,67 F1-skoru, %89,42 ROC-AUC ve %83,63 PR-AUC elde etmiştir. Yalnızca Log-Mel kullanan CNN modeli %87,20 dengeli doğruluk ve %77,42 F1-skoruna ulaşırken, 59 öznitelikle eğitilen en başarılı klasik yöntem olan XGBoost %71,61 dengeli doğruluk ve %50,00 F1-skoru üretmiştir. Bulgular, Log-Mel tabanlı derin öğrenmenin klasik öznitelik tabanlı yöntemlerden daha yüksek performans sağladığını göstermektedir. Bununla birlikte, sayısal öznitelik füzyonunun katkısı özgüllük, ROC-AUC ve PR-AUC ölçütleriyle sınırlı kalmış; dengeli doğruluk ve F1-skoru bakımından tek temsilli CNN modeline üstünlük sağlayamamıştır.

Anahtar Kelimeler: Fonokardiyogram, kalp üfürümü, derin öğrenme, Log-Mel spektrogram, öznitelik füzyonu.

ABSTRACT

Automatic detection of heart murmurs from phonocardiogram (PCG) recordings is important for preliminary cardiac assessment and computer-aided screening systems. In this study, a two-branch deep learning approach that jointly evaluates time-frequency representations and numerical acoustic features extracted from PCG signals was investigated. The Murmur labels in the PhysioNet/CinC 2022 CirCor DigiScope dataset were used, and the Unknown class,

which represents label uncertainty, was excluded. The problem was therefore defined as a binary classification task between the Absent and Present classes. Experiments were conducted on 575 training, 126 validation, and 173 test patients. For each five-second segment, a 64-band Log-Mel spectrogram and a 59-dimensional numerical feature vector consisting of Mel-frequency cepstral coefficients (MFCC), spectral, energy-based, and statistical measures were extracted. Log-Mel representations were processed by a convolutional neural network (CNN), while numerical features were processed by a multilayer perceptron (MLP) branch. The 128-dimensional hidden representations obtained from the two branches were concatenated to perform intermediate fusion. Segment predictions were averaged at the recording level, and recording-level predictions were combined at the patient level using the maximum value. The fusion model achieved 91.91% accuracy, 85.89% balanced accuracy, 76.67% sensitivity, 95.10% specificity, 76.67% F1-score, 89.42% ROC-AUC, and 83.63% PR-AUC on the test set. The CNN model using only Log-Mel spectrograms achieved 87.20% balanced accuracy and a 77.42% F1-score, whereas XGBoost, the best-performing classical method trained with the 59 numerical features, achieved 71.61% balanced accuracy and a 50.00% F1-score. The findings show that the Log-Mel-based deep learning model outperformed classical feature-based methods. However, the contribution of numerical feature fusion was limited to specificity, ROC-AUC, and PR-AUC; it did not surpass the single-representation CNN model in terms of balanced accuracy and F1-score.

Keywords: Phonocardiogram, heart murmur, deep learning, Log-Mel spectrogram, feature fusion.

GİRİŞ

Dünya Sağlık Örgütü verilerine göre, kardiyovasküler hastalıkların 2022 yılında yaklaşık 19,8 milyon kişinin yaşamını yitirmesine neden olduğu ve dünya genelindeki ölümlerin yaklaşık %32'sini oluşturduğu bildirilmektedir (World Health Organization, 2025). Düzenli tarama hizmetlerine ve uzman değerlendirmesine erişimde yaşanan güçlükler, özellikle sağlık kaynaklarının sınırlı olduğu bölgelerde erken tanıyı zorlaştırabilmektedir. Bu nedenle düşük maliyetli, erişilebilir ve bilgisayar destekli tanı sistemlerinin geliştirilmesi, kardiyovasküler hastalıkların erken değerlendirilmesine yönelik önemli bir araştırma alanı hâline gelmiştir (Kalimuthu ve Hemanth, 2025). Kalp seslerinin stetoskop aracılığıyla dinlenmesine dayanan oskültasyon, non-invaziv, düşük maliyetli ve kolay uygulanabilir bir yöntem olması nedeniyle ilk klinik değerlendirme ve tarama süreçlerinde önemli bir yere sahiptir (Orozco-Reyes vd., 2025). Oskültasyon sırasında elde edilen kalp seslerinin dijital olarak kaydedilmesiyle oluşturulan fonokardiyogram (Phonocardiogram, PCG) sinyalleri, kalbin mekanik aktivitesine ilişkin bilgi taşımakta ve çeşitli kardiyak patolojilerin değerlendirilmesinde yararlı bir veri kaynağı oluşturmaktadır (Huai vd., 2025; Orozco-Reyes vd., 2025). Bazı kardiyak durumlarda üfürümler, klikler ve sürtünme sesleri gibi ek akustik bileşenler ortaya çıkabilmektedir. Kalp seslerinde meydana gelen bu değişimler, özellikle kapak hastalıkları ve diğer kardiyak anomalilerin değerlendirilmesinde klinik açıdan önemli bilgiler sağlayabilmektedir (Orozco-Reyes vd., 2025). PCG sinyallerinin önemli tanısal bilgiler içermesine karşın, kalp seslerinin güvenilir biçimde yorumlanması klinik deneyim gerektirmekte ve değerlendirme sonuçları gözlemciler arasında farklılık gösterebilmektedir. Ayrıca çevresel gürültü, kayıt cihazlarının özellikleri, farklı stetoskop türleri, kayıt protokolleri ve bireyler arası fizyolojik değişkenlik gibi faktörler PCG sinyallerinin analizini güçleştirebilmektedir (Springer vd., 2016). Bu sınırlılıklar, kalp seslerinin daha nesnel ve tekrarlanabilir biçimde değerlendirilmesini sağlayabilecek bilgisayar destekli otomatik analiz yöntemlerine yönelik ilgiyi artırmıştır (Huai vd., 2025; Reyna vd., 2023). Bu yöntemler arasında PCG sinyallerinin iki boyutlu zaman-frekans temsillerine dönüştürülerek Evrişimli Sinir Ağı (Convolutional Neural Network, CNN)

modellerine aktarılması, kalp sesi sınıflandırmasında yaygın kullanılan yaklaşımlardan biri hâline gelmiştir (Chen vd., 2023; Khan vd., 2021; Rubin vd., 2017). Bununla birlikte, bir PCG sinyalinin farklı temsilleri sinyalin farklı özelliklerini ön plana çıkarmaktadır. Sayısal akustik öznitelikler sinyalin belirli zamansal, spektral ve istatistiksel karakteristiklerini özetlerken, zaman-frekans temsilleri frekans bileşenlerinin zaman içerisindeki değişimini ayrıntılı biçimde yansıtabilmektedir. Dolayısıyla yalnızca tek bir temsil uzayından yararlanılması, PCG sinyalindeki tamamlayıcı bilgilerin tamamının modele aktarılmasını sınırlandırabilir.

Bu çalışmada, PCG sinyallerinden çıkarılan sayısal akustik öznitelikler ile Log-Mel tabanlı zaman-frekans temsillerinin kalp üfürümü tespitindeki etkisi araştırılmıştır. Elle tasarlanan 59 akustik öznitelik yedi farklı makine öğrenmesi algoritmasıyla değerlendirilmiştir. Sonrasında yalnızca Log-Mel temsili kullanan bir CNN modeli ile bu temsili akustik özniteliklerle birleştiren bir ara füzyon modeli geliştirilmiştir. Modeller, hasta bazlı veri ayrımı ve hasta düzeyinde değerlendirme metrikleri kullanılarak karşılaştırılmıştır.

LİTERATÜR ÖZETİ

Geleneksel yaklaşımlarda sınıflandırma başarısı büyük ölçüde önceden tanımlanan akustik, zamansal ve spektral özniteliklere bağlıken derin öğrenme yöntemlerinin gelişmesiyle birlikte PCG sinyallerinden ayırt edici temsillerin doğrudan öğrenilmesine dayalı yöntemler ön plana çıkmıştır. Güncel derleme çalışmalarında kalp sesi analizinde özellikle CNN, zaman-frekans temsilleri ve farklı temsil öğrenme yaklaşımları yaygın biçimde kullanılmaktadır (Ren vd., 2024).

Khan ve arkadaşları (2021), normal ve anormal PCG sinyallerini sınıflandırmak amacıyla Kısa Zamanlı Fourier Dönüşümü (Short-Time Fourier Transform, STFT) tabanlı spektrogramları CNN modellerinde kullanmıştır. PhysioNet/CinC 2016 ve PASCAL 2011 veri setlerinin kullanıldığı çalışmada, PhysioNet veri seti üzerinde %95,75 doğruluk, %96,3 duyarlılık ve %94,1 özgüllük elde edilmiştir.

Patwa ve arkadaşları (2025), CirCor DigiScope verilerinde kalp üfürümü, PhysioNet/CinC 2016 verilerinde anormal PCG tespiti amacıyla Dalgacık Saçılım Dönüşümü (Wavelet Scattering Transform, WST), Mel Frekans Cepstral Katsayıları (Mel-Frequency Cepstral Coefficients, MFCC) ve STFT tabanlı zaman-frekans temsillerini karşılaştırmış, farklı sinir ağı modellerini ise WST ile denemiştir. Deneysel sonuçlar, WST temsiliyle birlikte kullanılan 1D-CNN modelinin değerlendirilen diğer modellerden daha yüksek performans gösterdiğini ortaya koymuştur.

Potes ve arkadaşları (2016), elle tasarlanan öznitelikler ile derin öğrenmeyi karar düzeyinde birleştiren erken çalışmalardan birini sunmuştur. Çalışmada, PhysioNet/Computing in Cardiology Challenge 2016 kapsamında kalp sesi kayıtlarının normal ve anormal olarak sınıflandırılması için öznitelik tabanlı ve derin öğrenme tabanlı iki sınıflandırıcı bir topluluk modeli altında bir araya getirilmiştir.

Zaman-frekans temsiliinin seçimi ve oluşturulma biçimi, kalp sesi sınıflandırma performansını etkileyebilir. Shabbir ve arkadaşları (2023), PASCAL CHSC veri setinde MFCC ile farklı parametrelerle üretilmiş iki spektrogramı VGG16, VGG19 ve ResNet50 mimarileriyle değerlendirmiştir. MFCC ve ikinci spektrogram ayarı bir durum dışında birinci spektrogram ayarından daha yüksek test doğruluğu sağlamıştır.

Mel tabanlı zaman-frekans gösterimleri de kalp sesi sınıflandırmasında yaygın olarak kullanılan temsiller arasındadır. Nguyen ve arkadaşları (2023), kalp sesi sinyallerinden Log-Mel spektrogram öznitelikleri çıkararak bu temsilleri CNN ve Uzun-Kısa Süreli Bellek (Long Short-

Term Memory, LSTM) tabanlı modellerle sınıflandırmıştır. Normal kalp sesinin yanı sıra aort darlığı, mitral yetersizliği, mitral darlığı ve mitral kapak prolapsusu sınıflarının değerlendirildiği çalışmada CNN modeliyle %99,67 doğruluk elde edilmiştir. Chen ve arkadaşları (2023), PhysioNet/CinC 2016 veri setinde Mel ve Log-Mel spektrogramları aynı CNN mimarisiyle karşılaştırmıştır. Log-Mel kullanan modelin, farklı kayıt cihazlarından elde edilen beş test alt kümesinin tamamında daha yüksek dengeli doğruluk sağlaması, bu temsilin kayıt koşulları arasındaki farklılıklara karşı daha dayanıklı olabileceğini düşündürmektedir.

Tek bir temsil türüne dayalı yaklaşımların yanı sıra, farklı öznitelik uzaylarından elde edilen tamamlayıcı bilgilerin birleştirilmesine yönelik füzyon yöntemleri de araştırılmıştır. Li ve arkadaşları (2021), normal ve anormal kalp seslerini sınıflandırmak için zaman ve frekans alanı özniteliklerini birleştiren bir sinir ağı modeli geliştirmiştir. Modelde frekansla ilişkili öznitelikler evrimsel katmanlarla, zamanla ilgili öznitelikler ise tekrarlayan bir ağ yapısıyla çıkarılmıştır. Bu öznitelikleri bir araya getirmek için seri ve paralel olmak üzere iki farklı yöntem kullanılmıştır. PhysioNet verileriyle yapılan değerlendirmede seri füzyon modeli %95,00, paralel füzyon modeli %95,50 doğruluk elde etmiştir.

Tariq ve arkadaşları (2022), kalp ve akciğer seslerinin sınıflandırılması için spektrogram, MFCC ve kromagram gösterimlerini incelemiş ve üç CNN mimarisini birleştiren FDC-FS modelini geliştirmiştir. Kalp sesi verilerinde füzyon modeli, orijinal verilerde MFCC ile %93; veri artırımı uygulanan verilerde ise spektrogram ve kromagramla ayrı ayrı %97 doğruluk elde etmiştir.

Bahreini ve arkadaşları (2025), CNN ile öğrenilen öznitelikleri MFCC öznitelikleriyle birleştirerek kalp seslerini sınıflandırmıştır. Kanonik korelasyon analizine dayalı füzyon ve destek vektör makinesi sınıflandırıcısıyla beş katlı çapraz doğrulamada %99,55 doğruluk elde edilirken, kayıtlara sinyal-gürültü oranı 0 dB olacak şekilde solunum sesi eklendiğinde doğruluk %82,55 olmuştur.

Literatür genel olarak değerlendirildiğinde, PCG sınıflandırma yaklaşımlarının elle tasarlanan akustik özniteliklerden derin öğrenme tabanlı otomatik temsil öğrenmeye ve ardından farklı bilgi kaynaklarını bütünleştiren çoklu temsil ve öznitelik füzyonu yöntemlerine doğru geliştiği görülmektedir. Bununla birlikte, bu farklı bilgi kaynaklarının kalp üfürümü tespiti kapsamında ayrı ağ kollarında işlenerek gizli temsil düzeyinde birleştirilmesinin daha ayrıntılı olarak incelenmesi gerekmektedir. Bu doğrultuda bu çalışmada, Log-Mel spektrogramların CNN kolunda, 59 boyutlu sayısal akustik özniteliklerin ise çok katmanlı algılayıcı (Multilayer Perceptron, MLP) kolunda işlenmesi ve iki koldan elde edilen gizli temsillerin birleştirilmesi esas alınmıştır.

YÖNTEM

Bu çalışmada kalp sesi kayıtlarının sınıflandırılması amacıyla derin öğrenme tabanlı iki kollu bir füzyon yaklaşımı önerilmektedir. Çalışmanın genel iş akışı veri ön işleme, temsil oluşturma, temsil bazlı öznitelik öğrenimi, ara füzyon ve sınıflandırma aşamalarından oluşmaktadır.

Veri Seti

Bu çalışmada, George B. Moody PhysioNet Challenge 2022 kapsamında sunulan CirCor DigiScope Fonokardiyogram Veri Seti (Oliveira vd., 2022a, 2022b; Reyna vd., 2023) kullanılmıştır. Veri seti, Brezilya'da 2014 ve 2015 yıllarında gerçekleştirilen iki ayrı tarama programı kapsamında ağırlıklı olarak pediatrik bireylerden dijital stetoskop aracılığıyla elde edilen çok bölgeli fonokardiyogram kayıtlarını içermektedir. CirCor DigiScope veri setinin tamamında 0–21 yaş aralığındaki 1.452 hastanın 1.568 muayenesine ait toplam 5.272 PCG

kaydı bulunmaktadır (Oliveira vd., 2022b; Reyna vd., 2023). Bununla birlikte, bu çalışmada Murmur ve Outcome etiketlerinin erişilebilir olduğu Challenge eğitim bölümü kullanılmıştır. Söz konusu bölümde 942 hastaya ait toplam 3.163 PCG kaydı bulunmaktadır. Veri setine PhysioNet platformu üzerinden erişilmiştir (Pollard vd., 2026).

PhysioNet Challenge kapsamında hastalara ilişkin Murmur ve Outcome olmak üzere iki farklı hedef etiketi sunulmaktadır. Murmur etiketi dijital PCG kayıtlarında kalp üfürümü dalgalarının bulunma durumunu Present, Absent veya Unknown sınıflarından biriyle göstermektedir. Present etiketi, hastaya ait en az bir kalp sesi kaydında üfürüm tespit edildiğini gösterir. Absent etiketi, hastanın kayıtlarının hiçbirinde üfürüm tespit edilmediği anlamına gelir. Unknown etiketi ise kayıtları değerlendiren uzmanın üfürüm bulunup bulunmadığı konusunda kesin bir karara varamadığını belirtir (Reyna vd., 2023). Murmur etiketleri veri setinin tamamında tek bir uzman tarafından, kayıtlar dinlenerek ve dalga biçimleri incelenerek belirlenmiştir. Bu etiketler, üfürümün masum ya da patolojik olduğuna ilişkin bilgi içermemektedir (Reyna vd., 2023). Etiketleri erişilebilir veri bölümünde 695 Absent, 179 Present ve 68 Unknown hasta bulunmaktadır.


PCG kayıtları, kalbin farklı anatomik oskültasyon bölgelerinden ardışık olarak elde edilmiştir. Challenge eğitim bölümündeki toplam 3.163 kaydın 800'ü aortik (AV), 861'i mitral (MV), 766'sı pulmoner (PV) ve 732'si triküspit (TV) kapak bölgesinden alınmıştır. Bunlara ek olarak temel dört oskültasyon bölgesi dışında kalan ve Phc etiketiyle gösterilen bölgeden elde edilmiş 4 kayıt bulunmaktadır.

Bu çalışmada kalp sesi sınıflandırma problemi, PCG kayıtlarında üfürüm varlığının hasta düzeyinde belirlenmesi kapsamında ele alınmıştır. Bu doğrultuda Murmur etiketi hedef değişken olarak kullanılmıştır. Etiket hasta düzeyinde tanımlandığı için eğitimde her kayda ve bu kayıtlardan elde edilen segmentlere, ait oldukları hastanın Murmur etiketi atanmıştır. Unknown etiketli 68 hasta çalışma kapsamı dışında bırakılmıştır. Böylece problem, Absent ve Present sınıfları arasında ikili sınıflandırma görevi olarak tanımlanmıştır. Unknown sınıfının çıkarılmasının ardından deneylerde 695 Absent ve 179 Present olmak üzere toplam 874 hasta kullanılmıştır. Bu hastalara ait kayıt sayısı 3.007'dir. İkili sınıflandırma veri kümesinin %79,52'sini Absent, %20,48'ini Present sınıfı oluşturmuştur.

Veri sızıntısını önlemek amacıyla eğitim, doğrulama ve test ayrımı segment veya kayıt düzeyinde değil, hasta kimlikleri temel alınarak gerçekleştirilmiştir. Böylece aynı hastanın farklı anatomik bölgelerinden alınan kayıtlarının farklı veri kümelerine dağılması engellenmiştir. Hasta bazlı ayırım sonucunda eğitim kümesinde 448 Absent ve 127 Present olmak üzere 575, doğrulama kümesinde 104 Absent ve 22 Present olmak üzere 126, test kümesinde ise 143 Absent ve 30 Present olmak üzere 173 hasta yer almıştır.

Ön İşleme

Tüm kayıtları ortak bir giriş yapısına dönüştürmek amacıyla yeniden örnekleme, bant geçiren filtreleme, gürbüz genlik normalizasyonu ve sabit uzunluklu segmentasyon işlemleri uygulanmıştır. Ayrıca modelin farklı kayıt koşullarına karşı dayanıklılığını artırmak amacıyla yalnızca eğitim aşamasında veri artırma yöntemlerinden yararlanılmıştır. PCG kayıtlarına uygulanan veri ön işleme, segmentasyon ve temsil oluşturma aşamaları Şekil 1'de gösterilmiştir.



Şekil 1. PCG Sinyallerine Uygulanan Veri Ön İşleme Akış Şeması

Yeniden Örnekleme ve Filtreleme

Veri setindeki kayıtlar 4.000 Hz örnekleme frekansında ve 16 bit çözünürlükte alınmıştır (Oliveira vd., 2022a). Çalışmada incelenen frekans bandı 1 kHz'in altında kaldığından, hesaplama yükünü azaltmak amacıyla kayıtlar 2.000 Hz örnekleme frekansına yeniden örneklenmiştir.

Kalp sesi analizinde kullanılacak frekans bileşenlerini korurken çok düşük frekanslı taban çizgisi değişimlerini ve yüksek frekanslı çevresel gürültüyü azaltmak amacıyla dördüncü dereceden Butterworth bant geçiren filtre uygulanmıştır. Filtrenin alt kesim frekansı 20 Hz, üst kesim frekansı ise 800 Hz olarak belirlenmiştir. Filtreleme işlemi, ikinci dereceden bölüm gösterimi kullanılarak ileri ve geri yönde gerçekleştirilmiştir. Böylece filtreleme sırasında oluşabilecek faz kaymalarının azaltılması ve PCG sinyalindeki zamansal yapıların korunması amaçlanmıştır.

Genlik Normalizasyonu

PCG kayıtlarının farklı hastalardan, oskültasyon bölgelerinden ve kayıt koşullarından elde edilmesi, sinyaller arasında belirgin genlik farklılıklarının oluşmasına neden olabilmektedir. Bu nedenle filtrelenmiş sinyallere, aykırı değerlere karşı dayanıklı olan medyan ve çeyrekler arası açıklık tabanlı gürbüz normalizasyon uygulanmıştır. Her kayda ayrı ayrı uygulanan normalizasyon işlemi Eşitlik (1)'de verilmiştir.

$$\tilde{x}[n] = \frac{x[n] - Q_{50}(x)}{Q_{75}(x) - Q_{25}(x) + \varepsilon} \quad \varepsilon = 10^{-6} \quad (1)$$

Burada $x[n]$ giriş PCG sinyalinin n . örneğini; $\tilde{x}[n]$ normalleştirilmiş sinyalin n . örneğini; $Q_{25}(x)$, $Q_{50}(x)$ ve $Q_{75}(x)$ ise sırasıyla sinyal genliklerinin birinci çeyrek, medyan ve üçüncü çeyrek değerlerini göstermektedir. $\varepsilon = 10^{-6}$, çeyrekler arası açıklığın sıfır olması durumunda sıfıra bölünmeyi önlemek amacıyla paydaya eklenen küçük bir sabittir. Normalizasyon sonrasında aşırı genlik değerlerinin model eğitimi olumsuz etkilemesini engellemek amacıyla sinyal değerleri $[-10, 10]$ aralığında sınırlandırılmıştır.

Segmentasyon

PCG kayıtlarının süreleri hastalar ve oskültasyon bölgeleri arasında farklılık gösterdiğinden, kayıtların CNN ve MLP tabanlı modellere sabit boyutlu girdiler olarak aktarılabilmesi amacıyla her sinyal beş saniyelik segmentlerle temsil edilmiştir. Kullanılan 2.000 Hz örnekleme frekansı dikkate alındığında her segment 10.000 örnekten oluşmaktadır. Beş saniyeden kısa kayıtlar, sinyal örneklerinin sınır çevresinde yansıtılmasına dayanan reflect padding yöntemi kullanılarak 10.000 örneğe tamamlanmıştır. Beş saniyeden uzun eğitim kayıtlarında ise her epochta rastgele bir başlangıç noktası seçilmiş ve bu noktadan itibaren beş saniyelik bir bölüm alınmıştır.

Doğrulama ve test aşamalarında rastgele segment seçimi yapılmamıştır. Bunun yerine kayıtlar, beş saniyelik pencere ve 2,5 saniyelik kayma miktarı kullanılarak %50 örtüşmeli segmentlere ayrılmıştır. Kayıt sonundaki bölümün pencerelere tam olarak dahil olmadığı durumlarda, sinyalin son beş saniyesini kapsayan ek bir segment oluşturulmuştur. Uzun kayıtların değerlendirme süresini ve bellek kullanımını sınırlandırmak amacıyla her bir kayıt için en fazla sekiz segment kullanılmıştır. Sekizden fazla segment elde edilen kayıtlarda segmentler, kaydın tamamını temsil edecek biçimde başlangıçtan sona eşit aralıklarla seçilmiştir.

Veri Artırma

Modelin genlik ve gürültü farklılıklarına karşı dayanıklılığını ve genelleme yeteneğini artırmak amacıyla eğitim segmentlerine çevrim içi veri artırma işlemleri uygulanmıştır. Veri artırma işlemleri her eğitim epochunda rastgele seçilen segmentlere yeniden uygulanmıştır. İlk olarak her eğitim segmentinin genliği, -3 dB ile +3 dB aralığından rastgele seçilen bir kazanç değeriyle değiştirilmiştir. Segmentlere %35 olasılıkla, sinyal-gürültü oranı 20–35 dB aralığında rastgele belirlenen Gauss gürültüsü eklenmiştir. Ayrıca segmentlere %50 olasılıkla, segment uzunluğunun en fazla %5'i kadar sağa veya sola dairesel zaman kaydırma uygulanmıştır. Beş saniyelik bir segment için bu oran en fazla yaklaşık 0,25 saniyelik zaman kaymasına karşılık gelmektedir. Uygulanan artırma işlemleri, kalp sesinin temel yapısını ve Murmur sınıf etiketini değiştirmeyecek ölçülerde sınırlandırılmıştır. Veri artırma yalnızca eğitim kümesine uygulanmış olup doğrulama ve test segmentlerine herhangi bir rastgele veri artırma işlemi uygulanmamıştır.


Sayısal Öznitelik Çıkarımı

PCG sinyallerinin zamansal, istatistiksel ve spektral özelliklerini temsil etmek amacıyla her beş saniyelik segmentten toplam 59 sayısal öznitelik çıkarılmıştır. İlk olarak her segmentten 20 adet MFCC hesaplanmıştır. Her katsayı için segment boyunca ortalama ve standart sapma hesaplanmıştır. Böylece MFCC özniteliklerinden toplam 40 değer elde edilmiştir. Sinyalin spektral yapısını temsil etmek amacıyla spektral merkez, spektral bant genişliği, %85 spektral roll-off, spektral düzlük, sıfır geçiş oranı ve çerçeve tabanlı RMS enerji değerleri hesaplanmıştır. Bu özniteliklerin her biri için segment boyunca ortalama ve standart sapma alınarak toplam 12 spektral ve enerji tabanlı öznitelik oluşturulmuştur. Bunlara ek olarak segment genliklerinin genel dağılımını temsil eden aritmetik ortalama, standart sapma, medyan, çeyrekler arası açıklık, çarpıklık, basıklık ve segment geneline ait RMS enerji olmak üzere yedi istatistiksel öznitelik hesaplanmıştır. Öznitelik çıkarımında kısa zamanlı analiz için 256 örnek uzunluğunda pencere, 256 noktalı hızlı Fourier dönüşümü ve 64 örneklilik kayma miktarı kullanılmıştır. Frekans analizi, kalp seslerinin çalışma kapsamında incelenen frekans içeriğiyle uyumlu olarak 20–800 Hz aralığında gerçekleştirilmiştir.

Log-Mel Spektrogram Üretimi

Ön işlemlerden geçirilen her beş saniyelik PCG segmentinden bir Log-Mel spektrogram oluşturulmuştur. Bunun için her segment 256 örneklilik pencerelere ayrılmış ve pencere her

adımında 64 örnek kaydırılmıştır. Kullanılan 2.000 Hz örnekleme frekansında bir pencere 128 ms, kayma miktarı ise 32 ms sürmektedir. Her pencerenin güç spektrumundan elde edilen 20–800 Hz arasındaki bilgi, 64 Mel filtresi kullanılarak özetlenmiştir. Mel güç spektrogramındaki değerler, spektrogramın maksimum güç değeri referans alınarak desibel ölçeğine dönüştürülmüştür. Son olarak her Log-Mel spektrogramın değerlerinden kendi ortalaması çıkarılmış ve elde edilen değerler standart sapmasına bölünmüştür. İşlenen spektrogram, tek kanallı bir zaman-frekans gösterimi olarak CNN koluna verilmiştir. Şekil 2’de, örnek bir ham PCG sinyali ile bu sinyalin ön işleme ve Log-Mel dönüşümü sonucunda elde edilen zaman-frekans gösterimi sunulmuştur.



Şekil 2. 2530_AV PCG Kaydının (a) Ham Sinyal Gösterimi ve (b) Aynı Kayıttan Elde Edilen Standartlaştırılmış Log-Mel Spektrogramı

Önerilen İki Kollu Füzyon Mimarisi

Bu çalışmada Log-Mel spektrogramlar ile aynı PCG segmentinden çıkarılan 59 boyutlu sayısal öznitelik vektörünün birlikte değerlendirilmesi amacıyla iki kollu bir derin öğrenme mimarisi geliştirilmiştir. İlk kolda Log-Mel spektrogramlar CNN ile işlenirken, ikinci kolda sayısal öznitelikler MLP ile işlenmiştir. Her iki ağ kolundan elde edilen 128 boyutlu gizli temsiller öznitelik eksenini boyunca yan yana eklenerek 256 boyutlu ortak bir füzyon vektörü oluşturulmuştur. Bu vektör, segmentin Absent veya Present sınıfına ait olma olasılığını belirlemek üzere tam bağlantılı sınıflandırıcı katmanlarına aktarılmıştır.

CNN Kolu

CNN koluna, her beş saniyelik PCG segmentinden elde edilen $1 \times 64 \times 157$ boyutlu tek kanallı Log-Mel spektrogramlar girdi olarak verilmiştir. CNN kolu üç evrişim bloğundan oluşturulmuştur. Bu bloklardaki evrişim katmanları sırasıyla 32, 64 ve 128 öznitelik haritası üretmektedir. Tüm evrişim katmanlarında 3×3 boyutlu çekirdekler kullanılmış; dolgulama ve kayma adımı birer birim olarak belirlenmiştir. İlk iki evrişim katmanının ardından batch normalizasyonu, Gaussian Error Linear Unit (GELU) aktivasyon fonksiyonu ve 2×2 boyutlu maksimum havuzlama uygulanmıştır. Üçüncü evrişim katmanının ardından batch normalizasyonu ve GELU aktivasyonu uygulanmıştır. Daha sonra uyarlanabilir ortalama


havuzlama kullanılarak her bir öznitelik haritasının zaman ve frekans eksenlerindeki değerleri tek bir değere indirgenmiş ve $128 \times 1 \times 1$ boyutlu bir çıktı elde edilmiştir. Bu çıktı düzleştirilerek 128 nörondan oluşan tam bağlantılı katmana aktarılmıştır. Katmanın ardından GELU aktivasyonu ve 0,30 oranında dropout uygulanarak Log-Mel spektrogramı temsil eden 128 boyutlu CNN gizli temsil vektörü oluşturulmuştur.

MLP Kolu

MLP koluna, aynı beş saniyelik PCG segmentinden çıkarılan 59 boyutlu sayısal öznitelik vektörü ölçeklenmeden verilmiştir. MLP kolunun ilk tam bağlantılı katmanında 59 boyutlu giriş, 128 nörona aktarılmıştır. İlk tam bağlantılı katmanın ardından katman normalizasyonu, GELU aktivasyonu ve 0,30 oranında dropout uygulanmıştır. İkinci tam bağlantılı katmanda 128 boyutlu gösterim yeniden işlenmiş ve çıktı boyutu 128 olarak korunmuştur. Bu katmanın ardından GELU aktivasyonu kullanılmıştır. Böylece sayısal öznitelikleri temsil eden ve CNN kolunun çıktısıyla aynı boyuta sahip 128 boyutlu MLP gizli temsil vektörü elde edilmiştir.

Öznitelik Düzeyinde Ara Füzyon ve Sınıflandırma

CNN ve MLP gizli temsillerinin birleştirilmesiyle elde edilen 256 boyutlu füzyon vektörü, 128 nörondan oluşan tam bağlantılı bir sınıflandırıcı katmanına aktarılmıştır. Bu katmanın ardından GELU aktivasyonu ve 0,40 oranında dropout uygulanmıştır. Son tam bağlantılı katmanda ise Absent ve Present sınıflarına karşılık gelen iki çıktı skoru üretilmiştir. Tahmin aşamasında bu skorlar Softmax fonksiyonu kullanılarak sınıf olasılıklarına dönüştürülmüştür. Füzyon mimarisinin genel akışı Şekil 3'te gösterilmiştir.




Şekil 3. Log-Mel Spektrogram ve 59 Boyutlu Sayısal Özniteliklerin Ara Füzyonuna Dayalı Önerilen Model Mimarisi

Kayıt ve Hasta Düzeyinde Tahmin Birleştirme

CirCor DigiScope veri setinde Murmur etiketi hasta düzeyinde verilmekte, üfürümün duyulduğu oskültasyon bölgeleri ise ayrı bir alanda belirtilmektedir (Reyna vd., 2023). Bu nedenle modelin segment düzeyinde ürettiği tahminler önce kayıt, ardından hasta düzeyinde birleştirilmiştir. Her segment füzyon modeline ayrı ayrı verilmiş ve Softmax fonksiyonu aracılığıyla segmentin Present sınıfına ait olma olasılığı hesaplanmıştır.

İlk aşamada, aynı PCG kaydından elde edilen bütün segmentlerin Present olasılıklarının aritmetik ortalaması alınmıştır. Ortalama birleştirme sayesinde tek bir segmentte oluşabilecek gürültü veya geçici sinyal değişimlerinin kayıt düzeyindeki tahmin üzerindeki etkisinin

sınırlandırılması amaçlanmıştır. İkinci aşamada, aynı hastanın farklı oskültasyon bölgelerinden elde edilen kayıt olasılıkları arasındaki en yüksek değer seçilmiştir. Maksimum birleştirme tercihinin temel sebebi ise kalp üfürümünün bütün oskültasyon bölgelerinde aynı şiddette duyulmayabilmesi ve belirli bir anatomik bölgede daha belirgin hâle gelebilmesidir. Uygulanan tahmin birleştirme işlemi Şekil 4'te gösterilmiştir.



Şekil 4. Segment Olasılıklarının Kayıt ve Hasta Düzeyinde Birleştirilmesi

Eğitim Stratejisi

Önerilen model en fazla 60 epoch boyunca, 24 örnekten oluşan mini-batch'ler kullanılarak eğitilmiştir. Model parametrelerinin güncellenmesinde başlangıç öğrenme oranı 0,001 ve ağırlık azaltma katsayısı 0,0001 olan AdamW optimizasyon algoritması kullanılmıştır. Eğitim kümesinde Absent ve Present sınıfları arasında belirgin bir örnek sayısı farklılığı bulunduğu için, kayıp fonksiyonu olarak sınıf ağırlıklı çapraz entropi kullanılmıştır. Ağırlıklar, eğitim kümesindeki toplam hasta sayısının iki ile ilgili sınıftaki hasta sayısının çarpımına bölünmesiyle elde edilmiş ve Absent için 0,642, Present için 2,264 olmuştur. Eğitim sırasında modelin ürettiği gradyanların normu 1,0 ile sınırlandırılmıştır.

Doğrulama dengeli doğruluğunda art arda dört epoch boyunca iyileşme görülmemesi durumunda öğrenme oranı 0,5 katsayısıyla azaltılmıştır. Dengeli doğruluk değerinde art arda 12 epoch boyunca iyileşme görülmemesi durumunda eğitim erken durdurulmuştur. Eğitim sırasında elde edilen en yüksek doğrulama dengeli doğruluğuna sahip modelin ağırlıkları kaydedilerek nihai değerlendirmede bu model kullanılmıştır. Her epoch sonunda karar eşiği yalnızca doğrulama kümesi kullanılarak belirlenmiştir. Bu amaçla 0,10 ile 0,90 arasındaki eşik değerleri 0,005 aralıklarla taranmış ve doğrulama kümesinde en yüksek dengeli doğruluğu sağlayan değer seçilmiştir. En başarılı modelle birlikte ilgili karar eşiği de kaydedilmiştir.

Karşılaştırmalı Deneyler

Önerilen füzyon modelinin performansını değerlendirmek ve kullanılan temsillerin katkısını incelemek amacıyla üç farklı deney grubu oluşturulmuştur. İlk deney grubunda yalnızca 59 boyutlu sayısal öznitelik vektörleriyle klasik makine öğrenmesi algoritmaları eğitilmiştir. İkinci deneyde yalnızca Log-Mel spektrogramları kullanan CNN modeli değerlendirilmiştir. Üçüncü deneyde ise Log-Mel spektrogramlar ile 59 boyutlu sayısal öznitelikler önerilen ara füzyon mimarisi içerisinde birlikte kullanılmıştır.

Karşılaştırmanın tutarlılığını sağlamak amacıyla bütün deneylerde aynı hasta bazlı eğitim, doğrulama ve test kümeleri kullanılmıştır. Makine öğrenmesi modellerinde aday ve karar eşiği, derin modellerde ise en iyi epoch ve karar eşiği yalnızca doğrulama kümesindeki dengeli doğruluğa göre seçilmiştir. Makine öğrenmesi adayları arasında eşitlik olduğunda F1-skoru ikincil ölçüt olarak kullanılmıştır. Test kümesi yalnızca seçilen modellerin nihai performanslarının raporlanması amacıyla değerlendirilmiştir.

Sayısal Öznitelik Tabanlı Makine Öğrenmesi Modelleri

Sayısal özniteliklerin tek başına ayırt ediciliğini incelemek amacıyla her beş saniyelik PCG segmentinden çıkarılan 59 boyutlu öznitelik vektörleri kullanılarak yedi farklı makine öğrenmesi algoritması değerlendirilmiştir. Bu kapsamda XGBoost, destek vektör makinesi (SVM), Random Forest, CatBoost, LightGBM, HistGradientBoosting ve doğrusal diskriminant analizi (LDA) modelleri kullanılmıştır. Makine öğrenmesi deneyinde eğitim, doğrulama ve test kayıtları beş saniyelik ve %50 örtüşmeli segmentlere ayrılmıştır. Her kayıt için en fazla sekiz segment kullanılmış ve her segmentten aynı 59 sayısal öznitelik çıkarılmıştır. Modeller segment düzeyindeki öznitelik vektörleriyle eğitilmiş, ancak doğrulama ve test performansları kayıt ve hasta düzeyindeki iki aşamalı tahmin birleştirme işleminin ardından hesaplanmıştır.

Her algoritma için üç farklı hiperparametre adayı değerlendirilmiştir. Denenen adaylar ve doğrulama kümesine göre seçilenler Tablo 1'de verilmiştir. SVM ve LDA modellerinde öznitelikler StandardScaler kullanılarak ölçeklendirilmiştir. Ağaç tabanlı modellerde ise ayrıca ölçeklendirme uygulanmamıştır.

Sınıf dengesizliğini ele almak amacıyla algoritmanın yapısına uygun farklı ağırlıklandırma yöntemleri kullanılmıştır. XGBoost ve LightGBM modellerinde negatif ve pozitif segment sayılarının oranına dayalı pozitif sınıf ağırlığı kullanılmıştır. SVM ve HistGradientBoosting modellerinde dengeli sınıf ağırlıkları, Random Forest modelinde balanced_subsample, CatBoost modelinde otomatik dengeli sınıf ağırlıkları uygulanmıştır.

Tablo 1. Makine Öğrenmesi Modelleri İçin Denenen Hiperparametre Adayları

Model	Denenen hiperparametre adayları	Seçilen aday
XGBoost	300 ağaç, satır ve öznitelik örnekleme oranı 0,8. Maks. derinlik / öğrenme oranı: 3 / 0,03; 3 / 0,05; 5 / 0,03	3 / 0,05
SVM	RBF çekirdek, γ = scale, standartlaştırılmış öznitelikler. C: 0,5; 1; 2	C = 1
Random Forest	500 ağaç. Maks. derinlik / min. yaprak örneği: sınırsız / 1; sınırsız / 3; 12 / 1	12 / 1
CatBoost	500 iterasyon. Derinlik / öğrenme oranı: 4 / 0,03; 6 / 0,03; 6 / 0,05	6 / 0,03
LightGBM	400 ağaç, öğrenme oranı 0,03, satır ve öznitelik örnekleme oranı 0,8. Maks. derinlik / yaprak sayısı: 5 / 15; 7 / 31; sınırsız / 31	5 / 15
HistGradientBo osting	300 iterasyon. Öğrenme oranı / maks. yaprak sayısı / L2 düzenleme: 0,03 / 15 / 1,0; 0,05 / 15 / 2,0; 0,03 / 31 / 2,0	0,03 / 15 / 1,0
LDA	lsqr çözücü, standartlaştırılmış öznitelikler. Büzülme katsayısı: otomatik; 0,1; 0,5	0,5

Yalnızca Log-Mel Kullanan CNN Modeli

Sayısal özniteliklerin füzyon modeline katkısını incelemek amacıyla MLP kolunun çıkarıldığı ve yalnızca Log-Mel spektrogramları kullanan bir CNN modeli oluşturulmuştur. Bu modelde füzyon mimarisinin CNN kolu korunmuş; $1 \times 64 \times 157$ boyutlu Log-Mel spektrogramlar üç evrişim bloğunda işlenerek 128 boyutlu bir gizli temsile dönüştürülmüştür. Elde edilen temsil, 128 nöronlu tam bağlantılı katman ve iki sınıflı çıkış katmanı kullanılarak sınıflandırılmıştır. Mini-batch boyutunun 8 olması dışında eğitim, model seçimi ve değerlendirme füzyon modeliyle aynı biçimde yürütülmüştür.

Performans Değerlendirme Ölçütleri

Modellerin performansı hasta düzeyinde değerlendirilmiştir. Kalp üfürümü bulunan hastalar pozitif (Present), üfürüm bulunmayan hastalar ise negatif (Absent) sınıf olarak kabul edilmiştir. Test kümesindeki tahminler doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) olarak sayılmıştır.

Performans değerlendirmesinde doğruluk değerinin yanı sıra dengeli doğruluk, duyarlılık, özgüllük, kesinlik, F1-skoru, ROC eğrisi altındaki alan (ROC-AUC) ve kesinlik-duyarlılık eğrisi altındaki alan (PR-AUC) ölçütleri dikkate alınmıştır. Duyarlılık (recall), üfürümü bulunan hastaların ne kadarının doğru tespit edildiğini; özgüllük (specificity), üfürümü bulunmayan hastaların ne kadarının doğru tanındığını ifade etmektedir. Dengeli doğruluk (balanced accuracy), duyarlılık ve özgüllüğün aritmetik ortalamasıdır. Kesinlik (precision), modelin üfürüm var dediği hastalar arasında gerçekten üfürümü bulunanların oranıdır. F1-skoru ise kesinlik ve duyarlılığın harmonik ortalamasıdır. Bu ölçütler, sınıflar arasındaki sayı farkı nedeniyle doğruluğun tek başına göstermediği hataları da değerlendirmek için birlikte raporlanmıştır.

BULGULAR

Sayısal Öznitelik Tabanlı Makine Öğrenmesi Sonuçları

Bütün sonuçlar, 143 Absent ve 30 Present olmak üzere toplam 173 hastadan oluşan test kümesi üzerinde hasta düzeyinde hesaplanmıştır. Doğrulama kümesine göre seçilen makine öğrenmesi modellerinin test sonuçları Tablo 2’de verilmiştir.

Tablo 2. Makine Öğrenmesi Model Performans Sonuçları

Model	Doğruluk	Dengeli doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-skoru	ROC-AUC	PR-AUC
XGBoost	79,19	71,61	60,00	83,22	42,86	50,00	78,09	63,48
HistGradientBoosting	77,46	70,56	60,00	81,12	40,00	48,00	78,83	61,21
Random Forest	70,52	70,31	70,00	70,63	33,33	45,16	79,18	65,27
LightGBM	71,68	68,38	63,33	73,43	33,33	43,68	78,34	62,22
CatBoost	68,21	67,60	66,67	68,53	30,77	42,11	79,28	64,83
LDA	63,58	64,80	66,67	62,94	27,40	38,83	76,92	57,03
SVM	59,54	63,67	70,00	57,34	25,61	37,50	78,23	64,59

Log-Mel CNN ve Füzyon Modeli Sonuçları

Yalnızca Log-Mel spektrogram kullanan CNN modelinin ve Log-Mel spektrogram ile 59 sayısal özniteliği birleştiren ara füzyon modelinin sonuçları Tablo 3’te karşılaştırılmıştır.


Doğrulama kümesindeki en yüksek dengeli doğruluk füzyon modelinde 14. epochta %88,02, yalnız CNN modelinde 12. epochta %90,30 olarak elde edilmiş ve bu epochlarda seçilen karar eşikleri sırasıyla 0,435 ve 0,580 olmuştur.

Tablo 3. Log-Mel CNN ve Öznitelik Füzyonu Modellerinin Performans Karşılaştırması

Model	Doğruluk	Dengeli doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-skoru	ROC-AUC	PR-AUC
Log-Mel CNN	91,91	87,20	80,00	94,41	75,00	77,42	87,97	83,17
Log-Mel + 59 öznitelik füzyonu	91,91	85,89	76,67	95,10	76,67	76,67	89,42	83,63

Tablo 3'te görüldüğü üzere, iki model de test kümesinde %91,91 doğruluk elde etmiştir. Bununla birlikte, yalnızca Log-Mel spektrogram kullanan CNN modelinin dengeli doğruluğu (%87,20), duyarlılığı (%80,00) ve F1-skoru (%77,42) füzyon modelinden sırasıyla 1,31, 3,33 ve 0,75 yüzde puan daha yüksektir.

Sınıflandırma sayıları bu farkı açıklamaktadır. Log-Mel CNN modelinde TN, FP, FN ve TP sayıları sırasıyla 135, 8, 6 ve 24, füzyon modelinde ise 136, 7, 7 ve 23'tür. Füzyon modeli bir *Absent* hastayı daha doğru sınıflandırırken bir *Present* hastayı daha kaçırmıştır. Böylece her iki modelin toplam doğru tahmin sayısı 159'da kalmış ve doğruluk oranları eşit çıkmıştır.



Şekil 5. Log-Mel CNN ve Füzyon Modellerinin Hasta Düzeyinde ROC ve PR Eğrileri

İki modelin hasta düzeyindeki ROC ve PR eğrileri Şekil 5'te verilmiştir. Füzyon modeli özgüllük, kesinlik, ROC-AUC ve PR-AUC ölçütlerinde yalnızca Log-Mel kullanan modelden daha yüksek değerler elde etmiştir. Sonuçlar, sayısal özniteliklerin eklenmesinin eşikten bağımsız ayırma performansı, özgüllük ve kesinlik üzerinde sınırlı bir artış sağladığını ancak bu deneyde dengeli doğruluk, duyarlılık ve F1-skorunu artırmadığını göstermektedir.

SONUÇ VE TARTIŞMA

Yalnızca Log-Mel spektrogram kullanan CNN modeli ile Log-Mel gösterimini 59 akustik öznitelikle birleştiren füzyon modeli test kümesinde aynı doğruluk değerine (%91,91) ulaşmıştır. Füzyon modeli üfürüm bulunmayan bir hastayı daha doğru sınıflandırmış, ancak üfürüm bulunan bir hastayı daha kaçırmıştır.

Sayısal akustik özniteliklerle eğitilen makine öğrenmesi yöntemleri arasında XGBoost, %71,61 dengeli doğruluk ve %50,00 F1-skoruyla en yüksek sonuçları elde etmiştir. Log-Mel CNN ve füzyon modeli, bu iki ölçütte XGBoost'tan daha yüksek değerlere ulaşmıştır. Öte yandan akustik özniteliklerin CNN temsiline eklenmesi, bu deneyde yalnızca Log-Mel kullanan modelin dengeli doğruluk ve F1-skorunu artırmamıştır. Bu bulgular, farklı özniteliklerin bir

araya getirilmesinin her değerlendirme ölçütünde iyileşme sağlayacağını varsayamayacağını göstermektedir. Benzer bir durum tıbbi görüntü sınıflandırmasında da gözlenmiştir. Baltruschat ve arkadaşları (2019), göğüs röntgeni sınıflandırmasında CNN'in son havuzlama katmanından elde edilen öznitelikleri hastanın yaşı, cinsiyeti ve çekim yönü bilgileriyle birleştirmiştir. Bu ek bilgiler AUC değerini ortalamada yalnızca az miktarda artırmıştır. Yazarlar, olası neden olarak görüntüden öğrenilen özniteliklerin bu bilgileri zaten içermesini göstermiştir. Bu çalışmada kullanılan 59 özneliğin 40'ının Log-Mel spektrumundan türetilen MFCC istatistikleri olması, benzer bir örtüşmenin füzyonun sınırlı katkısında rol oynamış olabileceğini düşündürmektedir.

Füzyon modeli ROC-AUC değerinde artış sağlasa da kullanılan karar eşiğinde duyarlılık ve dengeli doğruluk değerleri yalnızca Log-Mel kullanan CNN modelinin altında kalmıştır. Gelecek çalışmalarda, akustik özniteliklerle CNN tarafından öğrenilen temsilleri bir araya getiren farklı füzyon yapıları geliştirilebilir ve bu yapıların üfürüm bulunan hastaları tespit etme başarısına etkisi incelenebilir. Bulguların daha geniş ve bağımsız hasta gruplarında sınanması, sonuçların genellenebilirliğinin değerlendirilmesine katkı sağlayacaktır.

KAYNAKLAR

- Bahreini, M., Barati, R., & Kamali, A. (2025). Cardiac sound classification using a hybrid approach: MFCC-based feature fusion and CNN deep features. *EURASIP Journal on Advances in Signal Processing*, 2025(1), Article 2. <https://doi.org/10.1186/s13634-025-01203-0>
- Baltruschat, I. M., Nickisch, H., Grass, M., Knopp, T., & Saalbach, A. (2019). Comparison of deep learning approaches for multi-label chest X-ray classification. *Scientific Reports*, 9(1), Article 6381. <https://doi.org/10.1038/s41598-019-42294-8>
- Chen, W., Zhou, Z., Bao, J., Wang, C., Chen, H., Xu, C., Xie, G., Shen, H., & Wu, H. (2023). Classifying heart-sound signals based on CNN trained on MelSpectrum and Log-MelSpectrum features. *Bioengineering*, 10(6), Article 645. <https://doi.org/10.3390/bioengineering10060645>
- Huai, X., Jiang, L., Wang, C., Chen, P., & Li, H. (2025). Heart sound classification based on convolutional neural network with convolutional block attention module. *Frontiers in Physiology*, 16, Article 1596150. <https://doi.org/10.3389/fphys.2025.1596150>
- Kalimuthu, M., & Hemanth, C. (2025). A comparative analysis of machine learning and deep learning approaches for phonocardiogram classification using dataset integration. *IEEE Access*, 13, 170619–170635. <https://doi.org/10.1109/ACCESS.2025.3612392>
- Khan, K. N., Khan, F. A., Abid, A., Olmez, T., Dokur, Z., Khandakar, A., Chowdhury, M. E. H., & Khan, M. S. (2021). Deep learning based classification of unsegmented phonocardiogram spectrograms leveraging transfer learning. *Physiological Measurement*, 42(9), Article 095003. <https://doi.org/10.1088/1361-6579/ac1d59>
- Li, S., Li, F., Tang, S., & Luo, F. (2021). Heart sounds classification based on feature fusion using lightweight neural networks. *IEEE Transactions on Instrumentation and Measurement*, 70, Article 4007009. <https://doi.org/10.1109/TIM.2021.3109389>
- Nguyen, M. T., Lin, W. W., & Huang, J. H. (2023). Heart sound classification using deep learning techniques based on log-mel spectrogram. *Circuits, Systems, and Signal Processing*, 42(1), 344–360. <https://doi.org/10.1007/s00034-022-02124-1>
- Oliveira, J., Renna, F., Costa, P. D., Nogueira, M., Oliveira, C., Ferreira, C., Jorge, A., Mattos, S., Hatem, T., Tavares, T., Elola, A., Rad, A. B., Sameni, R., Clifford, G. D., & Coimbra, M. T. (2022a). The CirCor DigiScope dataset: From murmur detection to murmur classification.

IEEE Journal of Biomedical and Health Informatics, 26(6), 2524–2535.
<https://doi.org/10.1109/JBHI.2021.3137048>

Oliveira, J., Renna, F., Costa, P., Nogueira, M., Oliveira, A. C., Elola, A., Ferreira, C., Jorge, A., Bahrami Rad, A., Reyna, M., Sameni, R., Clifford, G., & Coimbra, M. (2022b). *The CirCor DigiScope phonocardiogram dataset* (Version 1.0.3) [Data set]. PhysioNet.
<https://doi.org/10.13026/tshs-mw03>

Orozco-Reyes, L., Alonso-Arévalo, M. A., García-Canseco, E., Ibarra-Hernández, R. F., & Conte-Galván, R. (2025). A deep-learning approach to heart sound classification based on combined time-frequency representations. *Technologies*, 13(4), Article 147.
<https://doi.org/10.3390/technologies13040147>

Patwa, A., Rahman, M. M. U., & Al-Naffouri, T. Y. (2025). Heart murmur and abnormal PCG detection via wavelet scattering transform and 1D-CNN. *IEEE Sensors Journal*, 25(7), 12430–12443. <https://doi.org/10.1109/JSEN.2025.3541320>

Pollard, T., Moody, B. E., Lehman, L.-W. H., Gow, B. J., Fernandes, C., Xie, C., Johnson, A., Mark, R. G., & Heldt, T. (2026). PhysioNet as a global platform for biomedical research. *Nature Health*, 1(8), 792–795. <https://doi.org/10.1038/s44360-026-00096-z>

Potes, C., Parvaneh, S., Rahman, A., & Conroy, B. (2016). *Ensemble of feature-based and deep learning-based classifiers for detection of abnormal heart sounds*. *Computing in Cardiology*, 43, 621–624. <https://doi.org/10.22489/CinC.2016.182-399>

Ren, Z., Chang, Y., Nguyen, T. T., Tan, Y., Qian, K., & Schuller, B. W. (2024). A comprehensive survey on heart sound analysis in the deep learning era. *IEEE Computational Intelligence Magazine*, 19(3), 42–57. <https://doi.org/10.1109/MCI.2024.3401309>

Reyna, M. A., Kiarashi, Y., Elola, A., Oliveira, J., Renna, F., Gu, A., Perez Alday, E. A., Sadr, N., Sharma, A., Kpodonu, J., Mattos, S., Coimbra, M. T., Sameni, R., Bahrami Rad, A., & Clifford, G. D. (2023). Heart murmur detection from phonocardiogram recordings: The George B. Moody PhysioNet Challenge 2022. *PLOS Digital Health*, 2(9), Article e0000324. <https://doi.org/10.1371/journal.pdig.0000324>

Rubin, J., Abreu, R., Ganguli, A., Nelaturi, S., Matei, I., & Sricharan, K. (2017). *Recognizing abnormal heart sounds using deep learning* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.1707.04642>

Shabbir, M., Liu, X., Nasser, M., & Helgeson, S. (2023). Heart murmur classification in phonocardiogram representations using convolutional neural networks. *The International FLAIRS Conference Proceedings*, 36. <https://doi.org/10.32473/flairs.36.133189>

Springer, D. B., Tarassenko, L., & Clifford, G. D. (2016). Logistic regression-HSMM-based heart sound segmentation. *IEEE Transactions on Biomedical Engineering*, 63(4), 822–832. <https://doi.org/10.1109/TBME.2015.2475278>

Tariq, Z., Shah, S. K., & Lee, Y. (2022). Feature-based fusion using CNN for lung and heart sound classification. *Sensors*, 22(4), Article 1521. <https://doi.org/10.3390/s22041521>

World Health Organization. (2025, July 31). *Cardiovascular diseases (CVDs)* [Fact sheet]. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))

BIOPRESERVATION IN TISSUE ENGINEERING: PRINCIPLES, STRATEGIES, AND APPLICATIONS

Lecturer Yusuf Ali AKAR¹

¹Department Of Therapy and Rehabilitation, Disabled Care and Rehabilitation, Tuzluca
Vocational School, Iğdır, Turkey

¹<https://orcid.org/0009-0006-2461-9563>

Assoc. Prof. Dr. Daver ALİ²

² Faculty of Engineering and Natural Sciences, Department of Biomedical Engineering,
Karabuk University, Karabuk, Turkey

² <https://orcid.org/0000-0002-8500-7820>

Abstract

Biopreservation encompasses biologically inspired methods for maintaining the viability, functionality, and structural integrity of living cells, tissues, and biomaterials during processing, storage, and transportation. Although traditionally associated with food preservation and microbial storage, biopreservation has emerged as a critical enabling technology in tissue engineering and regenerative medicine. Tissue-engineered constructs are highly complex systems composed of living cells, extracellular matrices, scaffolds, and bioactive signaling molecules, all of which are particularly vulnerable to environmental stresses, including temperature fluctuations, oxidative damage, dehydration, and microbial contamination. Effective preservation strategies are therefore essential for maintaining cellular viability, biological function, and structural integrity throughout manufacturing, storage, and clinical distribution. This review discusses the fundamental principles of biopreservation and examines their application in tissue engineering, emphasizing biologically compatible preservation mechanisms that minimize cellular injury while preserving tissue functionality. Major preservation strategies, including cryopreservation using cryoprotective agents, hypothermic storage, ambient-temperature preservation, and natural antimicrobial approaches, are highlighted along with their advantages and current limitations. The review also explores the preservation of scaffolds and biomaterials, as well as applications in stem cell therapies, bioprinted tissues, skin substitutes, and musculoskeletal tissue engineering. Furthermore, recent advances in biologically derived preservation solutions, multifunctional cryoprotectants, smart biomaterials, and integrated preservation technologies are discussed as promising directions for improving long-term storage and transportation of engineered tissues. Finally, current challenges, including cryoprotectant cytotoxicity, preservation of complex vascularized tissues, regulatory considerations, and large-scale clinical translation, are examined. Continued interdisciplinary research in biomaterials, cryobiology, and regenerative medicine will be essential for developing reliable, clinically applicable biopreservation strategies that facilitate the widespread implementation of tissue-engineered therapies.

Keywords: Biopreservation, Tissue engineering, Cryoprotectant, Hypothermia

1. Introduction

Tissue engineering aims to restore, maintain, or enhance tissue function by combining cells, scaffolds, and bioactive factors (Ali, 2021; Balci, Balci, Ilgin, & Ali, 2026). A major bottleneck in translating tissue-engineered products from laboratory research to clinical application lies in the preservation of these constructs. Cells and engineered tissues are highly susceptible to damage from temperature fluctuations, dehydration, oxidative stress, and microbial contamination during storage and transport (Tutrina & Zhurilov, 2024).

Biopreservation offers a biologically compatible solution to these challenges by utilizing natural or bio-inspired agents and mechanisms to protect living systems. Unlike conventional chemical preservatives, biopreservation strategies are designed to maintain cellular metabolism, structural integrity, and biological function. As tissue engineering advances toward more complex and clinically relevant constructs (Ekinci, Karaca, & Ali, 2026), effective biopreservation is becoming essential for manufacturing scalability, quality control, and regulatory compliance (H. Budharaju, D. Sundaramurthi, & S. Sethuraman, 2024; Ziani, Saenz-del-Burgo, Pedraz, & Ciriza, 2025).

2. Principles of Biopreservation

Biopreservation is based on mimicking or harnessing natural survival mechanisms observed in microorganisms, plants, and animals exposed to extreme environmental conditions. Key principles include:

- **Metabolic suppression:** Reducing cellular activity to limit energy consumption and damage.
- **Protection of cellular membranes and proteins:** Preventing denaturation and loss of structural integrity.
- **Control of oxidative stress:** Minimizing damage caused by reactive oxygen species.
- **Microbial growth inhibition:** Maintaining sterility without cytotoxic effects.

In tissue engineering, these principles must be applied without compromising cell phenotype, differentiation potential, or extracellular matrix organization.

3. Biopreservation Strategies in Tissue Engineering

3.1 Cryopreservation and Cryoprotective Agents

Cryopreservation is one of the most widely used preservation methods in tissue engineering. It involves storing cells or tissues at ultra-low temperatures to halt metabolic activity. Biological cryoprotective agents (CPAs) such as trehalose, glycerol, and dimethyl sulfoxide (DMSO) are used to prevent ice crystal formation and osmotic shock (Harshavardhan Budharaju, Dhakshinamoorthy Sundaramurthi, & Swaminathan Sethuraman, 2024; Janssen et al., 2024).

Natural sugars, such as trehalose, are of particular interest for their ability to stabilize proteins and lipid membranes while exhibiting lower cytotoxicity than synthetic CPAs. Research is increasingly focused on reducing reliance on DMSO by combining biological CPAs with controlled freezing-and-thawing protocols (Fig. 1).




Figure 1. Schematic illustration of cryopreservation showing ice crystal formation with and without cryoprotective agents

3.2 Hypothermic and Ambient Storage

Short-term preservation of tissue-engineered constructs is often achieved through hypothermic storage (2–8 °C), which slows metabolism while avoiding freezing-related damage. Biologically derived preservation solutions enriched with antioxidants, amino acids, and energy substrates are used to maintain cell viability (Guo & Zhang, 2024). Recent studies are exploring ambient-temperature biopreservation inspired by anhydrobiotic organisms. These approaches use sugars, stress proteins, and polymeric matrices to protect cells during partial dehydration, offering promising alternatives for transport that do not depend on a cold chain (Fig 2).




Figure 2. Comparison of hypothermic, cryogenic, and ambient biopreservation strategies for tissue-engineered constructs

3.3 Antimicrobial Biopreservation

Microbial contamination poses a serious risk in tissue engineering, particularly during long-term culture and storage. Traditional reliance on antibiotics is increasingly discouraged due to concerns about toxicity and antimicrobial resistance. Biopreservation strategies that use natural antimicrobial agents, such as bacteriocins, antimicrobial peptides, and enzyme-based systems, offer safer alternatives. These biologically derived antimicrobials can be incorporated into scaffolds or preservation media, providing localized, sustained protection without interfering with cell viability or differentiation (Costa, Gomes, & Martins, 2018).

4. Biopreservation of Scaffolds and Biomaterials

Scaffolds play a central role in tissue engineering by providing structural support and biochemical cues. Biopreservation is critical for maintaining scaffold integrity, particularly for natural materials such as collagen, gelatin, and decellularized extracellular matrices. Biological preservatives help prevent enzymatic degradation, microbial growth, and loss of mechanical properties during storage. Additionally, pre-seeded scaffolds containing living cells require integrated preservation strategies that protect both cellular and material components (Ziani et al., 2025).

5. Applications in Regenerative Medicine

Biopreservation has direct implications across multiple tissue engineering applications, including:

- **Stem cell therapies:** Maintaining pluripotency and differentiation capacity during storage.
- **Skin substitutes:** Preserving cell viability and extracellular matrix for wound healing.
- **Cartilage and bone constructs:** Retaining mechanical strength and osteo/chondrogenic potential.
- **Bioprinted tissues:** Enabling storage and transport of printed constructs before implantation.

Effective biopreservation improves product shelf life, enables centralized manufacturing, and supports global distribution of regenerative therapies (Master et al., 2020).

6. Challenges and Future Perspectives

Despite significant advances, several challenges remain in applying biological preservation methods in tissue engineering. These challenges include the cytotoxicity of certain preservative agents, the heterogeneity of complex tissues, the difficulty of preserving vascular structures, and the challenge of scaling up for clinical-level production. Future research focuses on developing multifunctional biological preservatives, integrating preservation strategies with bioreactors and smart packaging, and tailoring preservation protocols for specific tissue types. Advances in systems biology and biomaterials science are expected to further improve biological preservation approaches.

7. Conclusion

Biopreservation is an essential enabling technology for tissue engineering and regenerative medicine. By leveraging biologically inspired mechanisms, biopreservation strategies can maintain cell viability, functionality, and sterility while supporting the translation of engineered tissues from the laboratory to the clinic. Continued interdisciplinary research will be crucial for overcoming current limitations and realizing the full potential of tissue-engineered therapies.

References

- Ali, D. (2021). Mimicking bone anisotropic structure with modified gyroid scaffolds; a finite element analysis. In (Vol. 24, pp. 1637-1646): <https://dergipark.org.tr/en/pub/politeknik/article/941106>.
- Balcı, H. Ş., Balcı, F., Ilgin, H. A., & Ali, D. (2026). Hybrid Machine Learning-Based Approach for Predicting the Poisson's Ratio of Mechanical Metamaterials. *Applied Sciences*, 16(11), 5201. Retrieved from <https://www.mdpi.com/2076-3417/16/11/5201>
- Budharaju, H., Sundaramurthi, D., & Sethuraman, S. (2024). Biofabrication & cryopreservation of tissue engineered constructs for on-demand applications. *Biofabrication*, 16(4). doi:10.1088/1758-5090/ad7906
- Budharaju, H., Sundaramurthi, D., & Sethuraman, S. (2024). Biofabrication & cryopreservation of tissue engineered constructs for on-demand applications. *Biofabrication*, 16(4). doi:10.1088/1758-5090/ad7906. (Accession No. 39258414)
- Costa, F., Gomes, P., & Martins, M. C. L. (2018). 13 - Antimicrobial peptides (AMP) biomaterial coatings for tissue repair. In M. A. Barbosa & M. C. L. Martins (Eds.), *Peptides and Proteins as Biomaterials for Tissue Regeneration and Repair* (pp. 329-345): Woodhead Publishing.
- Ekinci, İ., Karaca, M. M., & Ali, D. (2026). Mechanical performance of Schwarz and lattice diamond regular architecture versus stochastic Voronoi structure for bone scaffolds: Design, Manufacturing, and FEM analysis. *The International Journal of Advanced Manufacturing Technology*, 142(3-4), 1735-1747.
- Guo, S., & Zhang, A. (2024). Review of different temperatures for biopreservation. *International Journal of Refrigeration*, 157, 53-59. doi:<https://doi.org/10.1016/j.ijrefrig.2023.10.014>
- Janssen, J., Chirico, N., Ainsworth, M. J., Cedillo-Servin, G., Viola, M., Dokter, I., . . . van Mil, A. (2024). Hypothermic and cryogenic preservation of cardiac tissue-engineered constructs. *Biomater Sci*, 12(15), 3866-3881. doi:10.1039/d3bm01908j
- Master, Z., Crowley, A. P., Smith, C., Wigle, D., Terzic, A., & Sharp, R. R. (2020). Stem cell preservation for regenerative therapies: ethical and governance considerations for the health care sector. *npj Regenerative Medicine*, 5(1), 23. doi:10.1038/s41536-020-00108-w
- Tutrina, A., & Zhurilov, P. (2024). Efficacy assessment of different cryoprotectants for preserving the viability of Enterobacterales strains at – 20 °C. *Scientific Reports*, 14(1), 20843. doi:10.1038/s41598-024-71529-6
- Ziani, K., Saenz-del-Burgo, L., Pedraz, J. L., & Ciriza, J. (2025). Advances in Cryopreservation Strategies for 3D Biofabricated Constructs: From Hydrogels to Bioprinted Tissues. *International Journal of Molecular Sciences*, 26(14), 6908. Retrieved from <https://www.mdpi.com/1422-0067/26/14/6908>

ARTIFICIAL INTELLIGENCE-BASED PREDICTIVE MODELS FOR ENERGY-EFFICIENT INDUSTRIAL SYSTEMS

Dilshod RAKHIMOV

Tashkent State Technical University, Tashkent, Uzbekistan

Aziza KARIMOVA

Tashkent State Technical University, Tashkent, Uzbekistan

Abstract

Industrial energy management requires distinguishing avoidable consumption from energy use associated with legitimate changes in production. This proposed study investigates predictive models that estimate energy demand conditional on operating state, production volume, and relevant process conditions. Its objective is to evaluate whether artificial intelligence can support the identification of inefficient operation and improve energy aware planning within a selected industrial system. The study would define a specific process boundary before model development. No industrial dataset, energy saving percentage, or completed operational deployment is presented as an established result. The proposed data architecture would combine interval energy measurements, production records, equipment states, process temperatures, and maintenance events where available. Data preparation would align timestamps and account for changes in metering arrangements or product mix. Shutdowns, startup periods, and abnormal operating conditions would be labeled separately rather than automatically removed. Training and evaluation periods would be separated chronologically. Performance would also be examined across operating regimes to determine whether a model performs adequately beyond the most frequently observed production conditions. Gradient boosting and temporal neural networks would be compared with production normalized benchmarks and simpler regression models. Forecast uncertainty would be estimated to distinguish unusual consumption from expected variation. A decision layer would use predictions to compare feasible production schedules under explicit output and equipment constraints. Recommendations would undergo review by process engineers, particularly when changes could affect quality, reliability, or maintenance. Anomaly flags would identify observations for investigation rather than automatically attributing excess consumption to equipment faults. Evaluation would report prediction errors, calibration, computational requirements, and performance across production regimes. Retrospective schedule comparisons would use identical production requirements and disclose all assumptions about flexibility. The anticipated contribution is a reproducible link between energy prediction and industrial decision support. Limitations include incomplete process measurements, changing equipment behavior, and limited access to comparable production periods. Lower forecast error would not itself demonstrate improved efficiency. Any claim of energy savings would require prospective measurement against a credible baseline that accounts for production quantity, product quality, operating conditions, and changes unrelated to the predictive system. Measurement boundaries would remain consistent across every reported efficiency comparison.

Keywords: Artificial intelligence; industrial energy efficiency; energy forecasting; production planning; process monitoring

DEEP LEARNING APPLICATIONS IN INTELLIGENT TRANSPORTATION SYSTEMS: A STUDY OF URBAN MOBILITY IN UZBEKISTAN

Bekzod ABDULLAYEV

Tashkent University of Information Technologies, Tashkent, Uzbekistan

Shahnoza TURSUNOVA

Tashkent University of Information Technologies, Tashkent, Uzbekistan

Kamola YULDASHEVA

Tashkent University of Information Technologies, Tashkent, Uzbekistan

Abstract

Urban mobility analysis requires models that represent changing demand and interactions between connected transport locations. This proposed study examines deep learning methods for predicting short term travel times and traffic conditions in an Uzbek urban setting to be selected according to data availability. Its objective is to compare temporal and spatial learning approaches under a consistent evaluation protocol. The geographic focus establishes the intended research context, not a claim that local observations have already been collected. The work remains a prospective study without reported mobility improvements or completed model training. The planned dataset would combine authorized traffic counts, travel time observations, network connectivity, and contextual information such as calendar patterns and weather. Where vehicle trajectories are available, they would be aggregated and processed to minimize the identification of individual journeys. Sampling coverage would be documented across locations and times, including areas with sparse observations. Chronological evaluation would reserve future periods for testing, while additional location based partitions would assess geographic transfer. Missing data handling would be fitted exclusively on training observations. Candidate models would include recurrent neural networks and graph based architectures, compared with historical averages, persistence predictions, and a simpler statistical approach. Forecast horizons and tuning budgets would be predefined. Evaluation would report errors by location, demand level, and observation quality rather than relying only on network averages. Robustness experiments would assess sensor outages, unusual demand, and changes in the available network representation. Computing requirements would be compared with the intended update interval for operational use. The anticipated contribution is a context specific evaluation protocol for determining when deep learning provides useful information for transport management. Potential applications include passenger information and operational monitoring, but their benefits would require separate assessment. Limitations include uneven sensing coverage, changing travel behavior, and uncertainty in the representation of heterogeneous traffic. Results from one urban area would not establish performance across Uzbekistan. Independent validation in additional locations and consultation with transport operators would be necessary before wider adoption. The proposed analysis would distinguish predictive reliability from assumptions about subsequent management decisions and their effects on urban mobility. Coverage limitations would accompany reported predictions.

Keywords: Deep learning; intelligent transportation; urban mobility; Uzbekistan; travel time prediction

THE INTEGRATION OF ARTIFICIAL INTELLIGENCE AND BUILDING INFORMATION MODELING IN SUSTAINABLE ARCHITECTURAL DESIGN

Rustam ISMOILOV
Nigora ABDURAKHMONOVA
Javlon RASULOV
Mohira SOBIROVA

Samarkand State University, Samarkand, Uzbekistan

Abstract

Sustainable architectural design requires consistent connections between design information and environmental assessment. This proposed study investigates how artificial intelligence can assist the interpretation of building information modeling data during comparisons of design alternatives. Its objective is to establish an auditable workflow linking material quantities, envelope properties, and occupancy assumptions with selected sustainability indicators. The focus would be early design evaluation within a defined building type and project boundary. The abstract presents a proposed methodology and does not report verified environmental improvements or completed assessments of actual buildings. The planned workflow would extract geometric and material information from authorized BIM models using a documented classification scheme. Each extracted quantity would retain its connection to the originating object and model version. Environmental factors, weather assumptions, and operating schedules would be recorded in a separate assessment register. Missing properties would be flagged for review instead of silently replaced with precise values. Alternative assumptions would be used where information is incomplete, allowing uncertainty to remain visible throughout the analysis. Artificial intelligence models would estimate selected simulation outputs or prioritize design alternatives for detailed evaluation. Training data would originate from documented simulations within a clearly defined parameter range. Baselines would include direct simulation and simpler statistical approximations. Proposed alternatives might vary envelope specifications, shading arrangements, or material selections while preserving functional requirements. Shortlisted options would undergo full environmental assessment to verify approximate predictions. The analysis would consider operational energy and embodied impacts separately before examining their combined implications under a stated evaluation period. Evaluation would examine prediction errors, information traceability, calculation time, and sensitivity to uncertain inputs. Professional reviewers would assess whether the workflow makes environmental tradeoffs understandable during architectural decisions. The anticipated contribution is a reproducible method for connecting BIM information with intelligent sustainability assessment. Limitations include incomplete material data, simplified operating assumptions, and restricted transferability across building types. Computational rankings would not establish actual building performance. Subsequent validation would require independent models and, where possible, observations from occupied buildings. The proposed study would clarify how artificial intelligence can support environmental reasoning while preserving transparent assumptions and architectural responsibility. Review records would preserve accountability.

Keywords: Artificial intelligence; building information modeling; sustainable design; life cycle assessment; environmental evaluation

MACHINE LEARNING TECHNIQUES FOR STRUCTURAL DAMAGE DETECTION IN CIVIL ENGINEERING

Farrukh NARZULLAYEV
Dilnoza KHOLMATOVA

Turin Polytechnic University in Tashkent, Tashkent, Uzbekistan

Abstract

Structural damage detection requires separating changes associated with deterioration from variation caused by loading, environmental conditions, and sensor behavior. This proposed study compares machine learning techniques for detecting damage indicators within a defined civil engineering monitoring problem. Its objective is to evaluate reliability under realistic measurement shifts rather than rank models solely by aggregate classification accuracy. The intended scope includes vibration based detection using an appropriately documented dataset. No actual damage event, monitoring campaign, or achieved detection performance is claimed in this prospective research abstract. The methodology would select a benchmark or authorized monitoring dataset with clear information about the structure, sensor placement, acquisition conditions, and reference damage states. Simulated observations, if included, would remain identifiable and be evaluated separately from physical measurements. Preprocessing would address synchronization, missing channels, and signal quality using procedures established without inspecting test outcomes. All signal windows from the same acquisition episode would remain in one evaluation partition. Additional tests would reserve distinct environmental conditions or structural configurations to examine transfer beyond familiar observations. Support vector machines, tree based ensembles, and a suitable neural network would be compared with a transparent statistical detection baseline. When damaged examples are too limited for supervised classification, anomaly detection would constitute a separate task with its own evaluation assumptions. Feature extraction and parameter tuning would be confined to training and validation data. Assessment would report missed damage events, false alarms, precision, and performance across damage categories where reference labels support those distinctions. Threshold choices would be linked to the intended monitoring decision. The anticipated contribution is a reproducible procedure for assessing practical model reliability. Noise sensitivity, missing sensors, and environmental shifts would be examined alongside computational requirements. Explanations of model behavior would be reviewed for consistency with plausible structural response. Limitations include uncertain labels, rare damage states, and discrepancies between simulated defects and actual deterioration. Automated alerts would identify conditions requiring qualified engineering review rather than certify safety. Independent monitoring periods or structures would be necessary to establish generalizability before the approach could support routine infrastructure assessment and maintenance decisions. Detection thresholds would be reassessed when monitoring conditions change.

Keywords: Machine learning; structural damage detection; vibration monitoring; anomaly detection; model validation

ARTIFICIAL INTELLIGENCE-SUPPORTED SMART MANUFACTURING SYSTEMS IN ADVANCED ENGINEERING APPLICATIONS

Sherzod MAMATOV
Gulbahor TOSHPOLATOVA
Azizbek ERGASHEV

Andijan Machine Building Institute, Andijan, Uzbekistan

Abstract

Smart manufacturing requires coordinated decisions about product quality, equipment availability, and production schedules. This proposed study develops an artificial intelligence supported framework for a defined manufacturing process in which operational records can be linked consistently to production outcomes. Its objective is to examine whether predictive information improves the identification of process problems and the comparison of feasible operating plans. The scope would be established around one production line or process family before analysis begins. No factory deployment, productivity increase, or measured quality improvement is claimed. The planned information architecture would connect machine measurements, operating parameters, maintenance records, production orders, and inspection outcomes through synchronized timestamps and traceable identifiers. Data preparation would document sensor changes, missing readings, and differences between product variants. Training records would exclude information unavailable when a prediction would have been made. Evaluation would reserve later production periods and, where feasible, distinct batches or machines. This separation would help assess whether apparent predictive performance depends on repeated observations of nearly identical production conditions. Candidate models would address clearly separated tasks such as quality prediction and equipment anomaly detection. Each task would have an appropriate baseline, defined outcome, and independent evaluation criteria. A decision support layer would present predictions with uncertainty and supporting observations. Proposed scheduling or maintenance adjustments would be checked against production requirements, equipment constraints, and operator responsibilities. Model outputs would remain advisory during initial evaluation, with human decisions recorded to support later analysis of practical usefulness. Assessment would examine predictive errors, false alerts, missed problems, and computational latency. Retrospective or simulated comparisons would evaluate operating alternatives under matched demand and resource assumptions. Quality outcomes would be analyzed separately from throughput to avoid interpreting faster production as an unconditional improvement. The anticipated contribution is a transparent framework connecting industrial data with accountable operational decisions. Limitations include scarce failure examples, changing product mixes, and uncertain transfer between machines. Prospective validation would be required before attributing changes in productivity, downtime, or resource consumption to artificial intelligence. The proposed research would establish the conditions and evidence needed for that evaluation. Operator feedback would inform subsequent revisions to the assistance system.

Keywords: Artificial intelligence; smart manufacturing; quality prediction; predictive maintenance; production systems

ARTIFICIAL INTELLIGENCE APPLICATIONS IN SMART CONSTRUCTION PROJECT MANAGEMENT: AN EXPERIMENTAL STUDY

Akmal DJURAYEV

Malika YUSUPOVA

Bukhara State University, Bukhara, Uzbekistan

Abstract

Artificial intelligence tools in construction management should be evaluated through their effects on decisions, not only through the accuracy of their predictions. This proposed experimental study examines whether intelligent decision support improves the identification and management of schedule risks in simulated construction projects. Its objective is to compare assisted and conventional management workflows under equivalent information and resource constraints. Although the title identifies an experimental study, the experiment described here remains a proposed protocol; no participants, observations, or experimental results are presented as having already been obtained. The planned design would assign participants to matched construction scenarios containing schedules, resource availability, progress updates, and documented disruptions. Participants would use either a conventional dashboard or a dashboard supplemented by artificial intelligence recommendations. Random assignment would be used where feasible, with experience levels recorded and balanced across conditions. An advance sample size assessment would define recruitment requirements. Scenario materials would be developed independently of the evaluated model, and pilot testing would examine task clarity without contributing observations to the final analysis. The assistance system would identify potential schedule conflicts and suggest feasible responses with supporting information. Participants would retain responsibility for accepting, modifying, or rejecting each recommendation. Primary outcomes would be specified before data collection and could include decision accuracy against expert reviewed scenario criteria and time required to formulate a response. Secondary outcomes would examine workload, inappropriate reliance, and recognition of erroneous recommendations. Equivalent task conditions would prevent differences in interface convenience from being mistaken for effects of predictive intelligence. Analysis would report between condition differences with uncertainty estimates and examine whether experience modifies the effect of assistance. Repeated tasks would be analyzed with methods accounting for observations from the same participant. The anticipated contribution is a controlled evaluation of how intelligent support influences construction management judgment. Limitations would include artificial task conditions, limited project complexity, and possible learning effects. Even favorable experimental outcomes would require prospective field validation before supporting claims of reduced construction delays or costs. The protocol provides a transparent basis for that subsequent assessment. The experimental materials and scoring procedures would be documented to enable independent replication.

Keywords: Artificial intelligence; construction management; experimental design; scheduling; decision quality

PARAMETRIC DESIGN APPROACHES FOR SUSTAINABLE ARCHITECTURAL DEVELOPMENT IN CENTRAL ASIA

Nodira RAKHMONOV
Azizbek KHASANOV
Sardor TULAGANOV

Namangan Engineering Construction Institute, Namangan, Uzbekistan

Abstract

Sustainable architectural development requires design methods that connect local conditions with explicit environmental and functional objectives. This proposed study investigates parametric design as a means of comparing architectural alternatives in selected Central Asian contexts. The objective is to establish a reproducible workflow for evaluating how building orientation, envelope configuration, shading, and spatial proportions influence performance under stated assumptions. Central Asia is treated as a context requiring differentiated investigation rather than a uniform climatic or cultural category. No completed regional survey or measured building performance is claimed. The methodology would select contrasting locations and document the climatic records, site conditions, and construction assumptions used for each case. A common building program would establish comparable floor area, occupancy schedules, and functional requirements while allowing contextually appropriate variations. Parametric models would generate alternatives within ranges reviewed for feasibility. Energy demand, daylight availability, material quantities, and indicative costs would be calculated using consistent boundaries. Data gaps, particularly in material impact information, would be recorded and examined through alternative assumptions rather than concealed within a single estimate. A multiobjective search would identify design options representing different compromises among the selected criteria. These alternatives would be compared with a documented baseline and a smaller set developed through conventional design iteration. The analysis would distinguish improvements caused by individual parameters from changes associated with combinations of parameters. Sensitivity tests would examine occupancy schedules, weather variability, and uncertain construction properties. Architects familiar with the selected contexts would review spatial quality, maintenance requirements, and compatibility with local building practices. The anticipated contribution is a method for making sustainable design tradeoffs visible during early architectural development. It would help identify which parameters consistently influence performance and which depend strongly on contextual assumptions. Limitations include simulation uncertainty, incomplete regional data, and the difficulty of representing cultural preferences through numerical objectives. A computationally preferred alternative would not automatically constitute the most appropriate architectural solution. Final design decisions would require professional interpretation and consultation with relevant users. Subsequent assessment of constructed buildings would be needed to establish whether predicted benefits persist during actual occupation and maintenance. Regional conclusions would remain conditional on sampling.

Keywords: Parametric design; sustainable architecture; Central Asia; environmental simulation; design tradeoffs

AN ARTIFICIAL NEURAL NETWORK MODEL FOR OPTIMIZING STRUCTURAL ENGINEERING PROCESSES

Timur KHUDAYBERDIYEV

Sevara ABDULLAYEVA

Bekzod KADIROV

Dilafroz SOBIROVA

Karshi Engineering Economics Institute, Karshi, Uzbekistan

Abstract

Structural engineering workflows involve repeated analyses when member dimensions, material choices, and loading assumptions are revised. This proposed study develops an artificial neural network framework for assisting that iterative process within a defined class of structural models. Its objective is to evaluate whether a learned approximation can reduce computational effort while maintaining acceptable accuracy for design screening. The proposed application concerns the identification of promising alternatives for subsequent engineering verification. It does not treat neural network output as an independent demonstration of structural adequacy or report a completed optimization experiment. The planned dataset would be generated through a documented structural analysis procedure using systematically varied input configurations. Inputs would include selected geometric properties, material parameters, and load descriptors, while outputs would represent response quantities relevant to the chosen design problem. Sampling would cover the feasible design domain and explicitly record configurations that violate constraints. Independent test sets would exclude closely related configurations used for training. Data normalization, network architecture selection, and early stopping would be determined without access to final evaluation outcomes. The neural network would be embedded within a constrained optimization procedure seeking lower material use or computational cost under specified response limits. Comparisons would include direct analysis based optimization and a simpler surrogate model. Every candidate selected as optimal would be reanalyzed using the reference engineering model. Evaluation would examine response prediction errors, feasibility errors, total computational expense, and sensitivity to network initialization. Particular attention would be given to cases where small prediction errors could incorrectly classify a design as satisfying a critical constraint. The anticipated contribution is a reproducible account of when neural approximation provides practical value in structural optimization. Uncertainty estimates and domain checks would indicate when recommendations require additional analysis. Limitations include dependence on the reference model, computational costs of preparing training data, and reduced reliability outside the sampled design space. The study would also assess whether improvements remain meaningful when verification costs are included. Claims of safer structures, lower construction costs, or general applicability would require additional evidence beyond the proposed computational comparisons and independent professional evaluation. Verification failures would be reported alongside successes.

Keywords: Artificial neural networks; structural optimization; engineering workflows; surrogate models; uncertainty

THE ROLE OF ARTIFICIAL INTELLIGENCE IN DIGITAL TRANSFORMATION WITHIN ENGINEERING EDUCATION

Shakhzod MIRZAYEV

Gulnora RUZIYEVA

Urgench State University, Urgench, Uzbekistan

Abstract

Digital transformation in engineering education requires attention to learning processes, assessment practices, and institutional capacity. This proposed study examines how artificial intelligence assistance can be incorporated into engineering coursework while preserving students' ability to reason independently. The objective is to investigate relationships between tool use, conceptual understanding, and problem solving performance within a defined instructional setting. The focus would be a selected engineering course rather than an institution wide claim of transformation. No completed classroom intervention or improvement in student achievement is asserted. The proposed design would compare an instructional approach incorporating structured artificial intelligence assistance with an otherwise comparable approach using established digital resources. Learning objectives, teaching time, and assessment criteria would be aligned across conditions. Baseline knowledge and prior experience with digital tools would be recorded. Where random allocation is impractical, the analysis would explicitly address baseline differences and avoid unsupported causal conclusions. Participation, data collection, and handling of student work would follow applicable institutional review and consent procedures. Artificial intelligence activities would require students to explain, check, and revise generated solutions rather than submit them without examination. Tasks would include identifying incorrect assumptions, evaluating alternative methods, and relating computational answers to engineering principles. Assessment would combine course aligned problem solving with independent tasks completed without artificial intelligence assistance. Delayed assessment would examine retention where scheduling permits. Process records and interviews would explore how students use feedback, when they challenge recommendations, and whether assistance changes their willingness to attempt difficult problems. Evaluation would report learning outcomes, variation across initial proficiency levels, and the time required for instructional support. Usability and satisfaction would be treated separately from evidence of learning. The anticipated contribution is a framework linking educational goals with deliberate choices about intelligent assistance. Limitations include instructor effects, unequal access to technology, and changing tool capabilities. Findings from one course would require replication before informing broader institutional adoption. The proposed study would provide evidence for decisions about curriculum design, assessment integrity, and staff development while maintaining a clear distinction between convenient task completion and durable engineering understanding. Student explanations would provide additional evidence of reasoning beyond answer correctness.

Keywords: Artificial intelligence; engineering education; digital transformation; learning assessment; instructional design

SMART CITY ARCHITECTURE AND ARTIFICIAL INTELLIGENCE: INNOVATIVE SOLUTIONS FOR SUSTAINABLE URBAN DEVELOPMENT

Davron TASHMATOV

Mohira ISMAILOVA

Azizbek RAHIMOV

Fergana Polytechnic Institute, Fergana, Uzbekistan

Abstract

Smart city architecture requires coordination between urban form, infrastructure provision, environmental objectives, and residents' everyday needs. This proposed study develops an artificial intelligence assisted framework for comparing urban development alternatives through explicit sustainability criteria. Its objective is to examine how spatial prediction and scenario analysis can support decisions at the neighborhood scale without reducing urban quality to a single numerical score. The research would focus on a defined planning area with documented data access. No implemented smart city intervention or observed sustainability improvement is claimed. The planned information base would combine building footprints, land use, street connectivity, public service locations, and available environmental observations. Data quality assessment would record differences in spatial resolution, observation dates, and coverage. Socioeconomic information, where legitimately available, would be aggregated to protect privacy and interpreted with attention to missing populations. Baseline indicators would describe accessibility, estimated energy demand, and selected environmental conditions. Each indicator would have a stated boundary and interpretation, allowing users to distinguish measured conditions from modeled estimates. Machine learning models would support selected estimation tasks for which adequate reference observations exist. Their outputs would inform comparisons of alternative building arrangements, service locations, and public space configurations. Conventional spatial analysis would provide a baseline, and additional predictive complexity would require demonstrated value. Scenario assessment would examine tradeoffs between environmental performance, accessibility, and development constraints. Representatives of planning practice and affected communities would review the relevance of criteria and identify concerns omitted from the computational representation. Evaluation would examine prediction reliability, scenario sensitivity, and the distribution of projected benefits across locations and user groups. The anticipated contribution is a transparent connection between artificial intelligence analysis and urban design deliberation. Limitations include incomplete urban records, uncertain behavioral responses, and challenges in representing social priorities numerically. A favorable scenario ranking would not establish that implementation would produce the predicted effects. Subsequent monitoring and a credible comparison strategy would be required to assess realized outcomes. The proposed framework therefore treats computational recommendations as evidence for discussion, with final planning decisions remaining subject to public accountability and professional judgment. Implementation feasibility would include institutional capacity and maintenance responsibilities.

Keywords: Smart cities; artificial intelligence; sustainable urban development; urban design; spatial accessibility

ARTIFICIAL INTELLIGENCE-ASSISTED STRUCTURAL ANALYSIS FOR HIGH-RISE BUILDING DESIGN

Aziz RASHIDOV
Feruza KHAMIDOVA

Tashkent Institute of Architecture and Civil Engineering, Tashkent, Uzbekistan

Abstract

Structural analysis for high-rise building design involves repeated assessment of alternative configurations under interacting loading and serviceability requirements. This proposed study examines an artificial intelligence assisted workflow that accelerates preliminary analysis while preserving independent engineering verification. The objective is to evaluate whether surrogate models can estimate selected structural responses accurately enough to support early design comparisons. The investigation would focus on lateral displacement, interstory drift, and member demand within a clearly bounded family of building configurations. No completed structural assessment or measured computational advantage is reported. The proposed methodology would generate a reference dataset through documented finite element analyses. Input variables would describe building height, structural layout, member dimensions, material properties, and specified loading conditions. Sampling would deliberately include both typical designs and configurations near the limits of the study domain. Training, validation, and testing would be separated by structural configuration, preventing minor variants of one design from appearing across partitions. All preprocessing and parameter selection would use training information exclusively. Gradient boosting and neural network models would be compared with simpler regression baselines. Assessment would examine prediction error, computational time, and uncertainty across response ranges rather than relying solely on average accuracy. Predictions for critical drift or demand conditions would receive separate scrutiny. Candidate designs selected through the surrogate would undergo renewed finite element analysis before being considered feasible. Tests outside the training domain would examine extrapolation behavior, while sensitivity analysis would identify inputs associated with unstable predictions. Model explanations would be interpreted alongside structural mechanics. The anticipated contribution is a transparent procedure for deciding where artificial intelligence can assist structural design iteration and where conventional analysis remains necessary. Potential benefits would be evaluated against the costs of dataset generation, model maintenance, and verification. Limitations include dependence on modeling assumptions, incomplete representation of nonlinear behavior, and restricted transferability between structural systems. The framework treats predictive confidence as information for review rather than evidence of structural safety. Subsequent validation using independently developed models and suitable experimental evidence would be required before broader engineering application. All analytical assumptions would be retained in a versioned record to support reproducibility and later review.

Keywords: Artificial intelligence; structural analysis; high-rise buildings; surrogate modeling; design verification

ADVANCED ENGINEERING SOLUTIONS FOR SMART INFRASTRUCTURE DEVELOPMENT USING MACHINE LEARNING TECHNIQUES

Sherzod KADIROV
Nilufar ABDURAKHMONOVA
Javokhir YULDASHEV
Navoi State University, Navoi, Uzbekistan

Abstract

Smart infrastructure development requires engineering decisions that connect asset condition, service demand, and limited maintenance resources. This proposed study develops a machine learning framework for prioritizing infrastructure interventions through consistent analysis of operational and inspection records. Its objective is to assess whether predictive information can improve maintenance planning relative to transparent rule based procedures. The scope would be restricted to a selected class of infrastructure assets with sufficiently comparable records, rather than assuming that one model applies equally to roads, utilities, and public buildings. The planned dataset would integrate asset characteristics, inspection dates, condition ratings, maintenance histories, service interruptions, and relevant environmental observations. Data preparation would distinguish genuine deterioration from changes in inspection practice or reporting frequency. Missing observations would be documented, and information generated after an intervention decision would be excluded from predictive inputs. Evaluation partitions would separate assets and observation periods where feasible, allowing assessment of performance on both unfamiliar assets and future operating conditions. Data access and responsibility for corrections would be explicitly assigned. Candidate methods would include gradient boosting, random forests, and a simpler statistical baseline for predicting deterioration or service interruption within a predefined horizon. Anomaly detection would be evaluated separately when reliable outcome labels are unavailable. Predictions would inform a constrained prioritization model incorporating maintenance budgets, intervention costs, service criticality, and uncertainty. Engineering teams would review the resulting schedules and record the reasons for accepting or modifying recommendations. The framework would preserve a traceable connection between source records, predicted risks, and proposed actions. Evaluation would examine predictive calibration, missed events, false alerts, and the stability of intervention rankings. Retrospective simulations would compare proposed allocations with baseline policies under matched resource assumptions. The expected contribution is a practical protocol linking predictive models to infrastructure management decisions. Its limitations include inconsistent inspection coverage, rare failure events, and uncertain consequences of deferred maintenance. No reduction in failures or maintenance expenditure is claimed. Such outcomes would require a prospective pilot and an evaluation capable of distinguishing model effects from changes in funding, staffing, and operational conditions. Implementation priorities would reflect service continuity requirements and locally available engineering resources.

Keywords: Machine learning; smart infrastructure; asset management; predictive maintenance; decision support

BUILDING INFORMATION MODELING AND ARTIFICIAL INTELLIGENCE INTEGRATION IN MODERN ARCHITECTURAL PRACTICES

Bobur KHOLMATOV
Sitora NARZULLAYEVA
Dilorom ERGASHEVA
Kamoliddin TURSUNOV

Samarkand State University of Architecture and Civil Engineering, Samarkand, Uzbekistan

Abstract

Integrating artificial intelligence with building information modeling requires more than adding predictive tools to a digital building model. Architectural teams must maintain consistent object information, understand automated recommendations, and preserve responsibility for design decisions. This proposed study investigates an integration framework focused on model checking and coordination during architectural development. Its objective is to examine whether intelligent assistance can identify relevant inconsistencies and reduce review effort without concealing uncertainty or generating excessive alerts. The work presents a prospective research design rather than findings from completed architectural projects. The methodology would begin by defining a common information structure for BIM objects, attributes, relationships, and revision histories. Authorized project models would be examined for missing properties, inconsistent classifications, and differences between versions. A documented reference set of coordination issues would be established through independent professional review, including a procedure for resolving disagreements. Model partitions would be organized by project so that repeated objects or closely related revisions cannot create misleading estimates of generalization. Proprietary project information would remain subject to access restrictions. The proposed analytical layer would combine deterministic checks for explicit requirements with machine learning for prioritizing issues that require contextual judgment. Candidate models would use object attributes, spatial relationships, and revision characteristics to estimate review relevance. Their outputs would identify supporting evidence and distinguish incomplete information from suspected design inconsistency. Architects would retain authority over corrective action. Interoperability tests would examine whether information survives exchange between selected software environments, with losses documented separately from predictive errors. Evaluation would compare issue detection, false alerts, reviewer agreement, and time required to complete equivalent checking tasks. Structured usability sessions would investigate whether the recommendations are understandable and compatible with existing collaboration practices. The anticipated contribution is an auditable approach to integrating intelligent assistance into architectural workflows. Limitations would include inconsistent model maturity, subjective issue labels, and variation in office procedures. Evidence of improved review efficiency would not automatically demonstrate improved architectural quality. Broader conclusions would require independent project evaluation and continued assessment of how automated recommendations influence professional decisions. A shared issue taxonomy would support consistent interpretation across participating architectural teams and reviewers.

Keywords: Building information modeling; artificial intelligence; architectural practice; design coordination; interoperability

OPTIMIZATION OF INTELLIGENT TRANSPORTATION NETWORKS THROUGH ARTIFICIAL INTELLIGENCE-BASED ENGINEERING MODELS

Akbarjon MAMATOV
Gulchehra TOJIBOYEVA

Tashkent State Transport University, Tashkent, Uzbekistan

Abstract

Transportation network optimization requires decisions that account for interactions among routes, intersections, travel demand, and available infrastructure. This proposed study investigates artificial intelligence based engineering models for evaluating network management alternatives under uncertain demand. Its objective is to determine whether learned approximations can support faster scenario comparison while preserving explicit operational constraints. The scope would include coordinated traffic management and route allocation within a defined urban network. The research is prospective and does not claim measured improvements in travel time or completed implementation in an operational transport system. A network representation would combine road connectivity, link capacities, intersection characteristics, demand estimates, and available travel time observations. Data preparation would assess temporal consistency and distinguish directly observed quantities from inferred demand. Baseline demand scenarios would be supplemented by clearly labeled incident and growth scenarios. Calibration data would be separated from evaluation periods, and uncertain parameters would be recorded before optimization. The methodology would also specify how pedestrian requirements and public transport priorities enter the network representation rather than treating all movement as interchangeable vehicle flow. A supervised learning model would approximate selected outputs of a calibrated transport simulation. These estimates would support constrained search over feasible management alternatives, followed by full simulation of shortlisted solutions. Conventional assignment and optimization procedures would provide reference methods. Comparisons would evaluate total delay, travel time reliability, accessibility indicators, and distribution of impacts across network areas. Optimization objectives and their relative weights would be disclosed, enabling planners to inspect tradeoffs instead of receiving a single unexplained recommendation. Robustness analysis would test demand shifts, capacity losses, and errors in travel time estimates. Repeated simulation runs would distinguish consistent changes from stochastic variation. The expected contribution is a decision framework that links computational efficiency with transparent transport engineering assessment. Limitations include uncertain traveler responses, imperfect network calibration, and possible displacement of congestion between locations. Any proposed intervention would require professional review and context specific evaluation. Conclusions about real mobility benefits would remain conditional until independent observations or a prospective implementation study establish whether predicted network effects occur in practice. Distributional consequences would remain visible throughout the optimization process.

Keywords: Artificial intelligence; transportation networks; network optimization; traffic assignment; accessibility

THE APPLICATION OF GENERATIVE ARTIFICIAL INTELLIGENCE IN CONTEMPORARY ARCHITECTURAL DESIGN PROCESSES

Umida YAKUBOVA
Bekzod MAMAJONOV
Shahzoda ISLOMOVA

Andijan State Technical Institute, Andijan, Uzbekistan

Abstract

Generative artificial intelligence introduces new ways to explore architectural ideas, but visual plausibility alone does not establish spatial coherence or technical feasibility. This proposed study investigates how generative tools can be incorporated into early architectural design through a structured process of briefing, generation, interpretation, and verification. The objective is to evaluate their contribution to design exploration while distinguishing representational novelty from usable architectural development. The study would focus on concept generation and preliminary spatial organization, without claiming that generated images constitute construction documentation or validated building solutions. The planned research would use a common design brief specifying site assumptions, functional requirements, spatial relationships, and environmental priorities. Participants would complete comparable tasks through conventional digital methods and through a workflow incorporating a selected generative tool. Assignment and task order would be designed to limit experience and learning effects. Tool versions, prompts, reference inputs, and subsequent manual revisions would be recorded. Permission to use project materials would be established, and confidential client information would be excluded from public generation services. Evaluation would combine process records with independent assessment of design outputs. Criteria would address functional compliance, spatial consistency, contextual response, originality, and the effort required to convert concepts into editable architectural models. Reviewers would assess outputs without knowing the workflow where practical, and disagreements would be reported rather than hidden within aggregate scores. Time savings would be interpreted alongside correction effort and design quality. A dedicated verification stage would examine circulation, dimensions, accessibility assumptions, and contradictions between visual representations and proposed spatial arrangements. The anticipated contribution is a practical evaluation framework for generative assistance within accountable architectural practice. The analysis would explore whether benefits depend on user expertise, prompt formulation, or the type of design task. Limitations include changing tool behavior, subjective judgments of architectural quality, and restricted generalization from a small set of briefs. No superiority of generative workflows is asserted. Empirical conclusions would require completed comparative tasks and transparent reporting of unsuccessful outputs, providing a basis for informed decisions about when generative tools support architectural reasoning. Documenting rejected concepts would also reveal recurring errors that polished final presentations can obscure.

Keywords: Generative artificial intelligence; architectural design; design evaluation; human oversight; spatial reasoning

ARTIFICIAL INTELLIGENCE-DRIVEN OPTIMIZATION OF SMART BUILDING ENERGY MANAGEMENT SYSTEMS

Ayesha KHAN, Muhammad USMAN

National University of Sciences and Technology (NUST), Islamabad, Pakistan

Abstract

Smart building energy management requires coordinated decisions about indoor comfort, equipment operation, and electricity consumption under changing occupancy and weather conditions. This proposed study develops an artificial intelligence framework for optimizing building operation while treating occupant comfort and equipment limitations as explicit constraints. Its central question is whether combining short term demand forecasting with predictive control can improve operational performance relative to conventional scheduling. The scope covers heating, ventilation, air conditioning, and controllable lighting in an institutional building setting. The framework is presented as a research design; measured energy savings and completed field validation are not claimed. The proposed data architecture combines interval electricity readings, indoor temperature, humidity, occupancy indicators, outdoor weather, and equipment status. Before model development, timestamps would be synchronized, missing observations documented, and abnormal sensor readings examined using transparent quality rules. Occupancy information would be aggregated to avoid identifying individuals. Data would be divided chronologically into training, validation, and testing periods so that future information cannot influence earlier predictions. Seasonal coverage and changes in building use would be recorded to clarify the conditions under which each model is evaluated and to identify periods requiring additional monitoring. Forecasting candidates would include gradient boosting and recurrent neural networks, compared with persistence and calendar based baselines. Forecasts would feed a constrained optimization module that recommends temperature setpoints and operating schedules over a rolling horizon. The objective would balance electricity consumption, peak demand, and comfort violations using clearly reported weights. Equipment cycling restrictions and permissible indoor temperature ranges would limit control actions. A calibrated building simulation would provide the initial evaluation environment, followed by supervised deployment only if the controller demonstrates acceptable behavior under predefined operating conditions. Facility staff would retain an override mechanism throughout any deployment. Evaluation would distinguish forecasting accuracy from control performance. Prediction errors would be reported alongside total electricity use, peak demand, time outside comfort bounds, and computational requirements. Comparisons would use equivalent weather and occupancy scenarios, with sensitivity analyses addressing sensor loss, unusual occupancy, and forecast uncertainty. Ablation experiments would examine whether occupancy inputs and predictive optimization contribute independently to performance. Repeated simulation scenarios would characterize variability rather than support unsupported claims of universal effectiveness. Any later field assessment would require a documented baseline and an adjustment procedure for differences in weather and building activity. The anticipated contribution is a reproducible decision framework that links predictive accuracy to practical building outcomes. It would help determine when additional model complexity provides operational value and when simpler control strategies remain adequate. The study would also examine implementation costs, maintenance requirements, and the consequences of unreliable sensing. Its relevance to institutional buildings depends on local equipment capabilities and the availability of consistent operational records. Conclusions about energy savings, financial returns, or transferability would remain conditional until empirical testing is completed. By defining the comparison protocol and deployment safeguards in advance, the proposed research establishes a transparent basis for assessing artificial intelligence in building energy management and for planning subsequent validation across buildings with different operating patterns over extended periods.

Keywords: Artificial intelligence; smart buildings; energy management; predictive control; thermal comfort

DEEP LEARNING APPROACHES FOR INTELLIGENT TRAFFIC MANAGEMENT IN URBAN ENVIRONMENTS

Fatima ALI, Ahmed RAZ, Sana IQBAL
COMSATS University Islamabad, Pakistan

Abstract

Urban traffic management involves allocating limited road capacity while responding to fluctuating demand, incidents, and interactions between neighboring intersections. This proposed study examines how deep learning could support traffic forecasting and adaptive signal control within a coordinated urban network. The research question concerns whether improved representation of spatial and temporal traffic patterns produces measurable operational benefits beyond conventional forecasting and signal timing. The intended application includes heterogeneous traffic conditions in Pakistani cities, but no city specific dataset or completed deployment is asserted. The abstract describes a prospective evaluation framework rather than reporting observed reductions in congestion. The proposed dataset would combine intersection counts, approach speeds, queue estimates, signal phase records, and contextual variables such as weather and time of day. Where video is used, processing would extract aggregate traffic indicators without retaining identifiable images beyond an approved operational need. The sampling strategy would cover peak and off peak periods and document missing observations, sensor failures, and unusual events. Training and testing would be separated chronologically and, where feasible, geographically. Holding out intersections would help assess whether the models generalize beyond locations represented during training instead of merely reproducing recurring local patterns. Candidate models would include recurrent networks for temporal dependencies and graph neural networks for relationships between connected road segments. Their predictions would be compared with historical averages, persistence forecasts, and a simpler statistical model. A traffic simulator would then connect the forecasting layer to an adaptive signal controller. Any reinforcement learning component would operate within explicit restrictions on minimum green intervals, pedestrian crossing time, and conflicting movements. The control objective would account for delay and queue accumulation while preventing repeated disadvantage to lower volume approaches. Signal recommendations would remain subject to engineering review before any consideration of field implementation. Model assessment would report forecasting error separately from network performance. Operational indicators would include average delay, queue length, throughput, travel time variability, and pedestrian waiting time. Fixed timing and actuated control would provide reference strategies under matched demand scenarios. Experiments would examine incident conditions, communication delays, missing sensors, and shifts in vehicle composition. Multiple simulation runs would quantify variability and reveal whether improvements depend on a narrow set of assumptions. Ablation analysis would test the contribution of network connectivity, contextual information, and forecasting to control outcomes. Computing latency would be measured against the intended decision interval. The expected contribution is an evaluation procedure that makes the relationship between deep learning predictions and traffic management decisions explicit. The proposed research would identify tradeoffs between overall network efficiency, service fairness, and implementation complexity. Simulation findings, if obtained, would require calibration checks and independent field validation before supporting claims about real urban performance. Potential limitations include incomplete observations, uncertain driver behavior, and differences between simulated and actual traffic interactions. The study therefore treats model transfer and operational oversight as research questions. Its intended outcome is a defensible basis for deciding where deep learning can assist traffic engineers and where additional data, simpler controls, or infrastructure changes may be more appropriate for the setting.

Keywords: Deep learning; traffic forecasting; signal control; urban mobility; transport simulation

INTEGRATING ARTIFICIAL INTELLIGENCE INTO SUSTAINABLE ARCHITECTURAL DESIGN: A CASE STUDY OF SMART CITIES IN PAKISTAN

Zain ABBAS, Hira JAVED, Bilal AHMED, Maria NOOR
University of Engineering and Technology (UET), Lahore, Pakistan

Abstract

Architectural sustainability involves decisions whose consequences extend across building operation, material production, occupant experience, and long term maintenance. This proposed study develops a case study framework for integrating artificial intelligence into early architectural design within the context of smart cities in Pakistan. It asks how computational search can support architects in comparing environmental performance without obscuring design assumptions or local priorities. The intended analysis focuses on building form, orientation, glazing, shading, and material selection. Although the title identifies a case study approach, project selection and empirical assessment remain prospective; no completed Pakistani case study or verified performance improvement is claimed. Case selection would follow criteria covering access to design documentation, representative building use, climatic context, and permission to examine project information. A selected development would be described through its site conditions, surrounding urban form, infrastructure assumptions, and relevant design constraints. Baseline alternatives would be prepared with consistent floor area, occupancy schedules, and functional requirements. Weather files, material quantities, and environmental data sources would be documented before optimization. Where reliable local material data are unavailable, alternative assumptions would be tested and their implications reported rather than treating imported estimates as precise descriptions of Pakistani construction practices. The analytical workflow would connect a parametric building model with energy, daylight, and embodied carbon calculations. Simulation outputs would train a surrogate model to estimate the performance of candidate designs within a defined parameter range. A multiobjective optimization procedure would identify alternatives representing different compromises among operational demand, embodied impacts, daylight availability, and cost. Architects would review these alternatives for spatial quality, constructability, accessibility, and compatibility with the surrounding context. Artificial intelligence would therefore assist exploration and comparison, while professional judgment would remain responsible for accepting or rejecting design proposals. Evaluation would compare the selected computational alternatives with a documented baseline and with options developed through conventional parametric exploration. All comparisons would use equivalent modeling boundaries and functional assumptions. Surrogate predictions would be checked against independent simulations, particularly near the boundaries of the design space. Sensitivity analysis would examine weather variation, occupancy assumptions, material factors, and the relative importance assigned to competing objectives. An uncertainty register would distinguish missing project information from uncertainty inherent in environmental modeling. Structured feedback from architects and relevant project participants would assess whether the workflow makes design decisions more understandable and practically usable. The anticipated contribution is a transparent method for connecting artificial intelligence tools with context sensitive architectural evaluation. Rather than assuming that a single optimized solution defines sustainability, the proposed framework would expose tradeoffs and make alternative priorities visible. Its usefulness would depend on the quality of simulation inputs, the representativeness of the selected case, and the ability to translate computational options into feasible construction decisions. Results from one development would not establish performance across all Pakistani smart city projects. Subsequent research would need comparisons across climates and building types. The proposed study offers a protocol for that investigation, while reserving conclusions about environmental benefits for validated analyses and, where possible, post occupancy assessment of the resulting buildings.

Keywords: Artificial intelligence; sustainable architecture; smart cities; design optimization; Pakistan

A COMPARATIVE ANALYSIS OF MACHINE LEARNING ALGORITHMS FOR STRUCTURAL HEALTH MONITORING IN CIVIL ENGINEERING

Muhammad FAROOQ, Amina SHAH, Hassan MAHMOOD
Mehran University of Engineering and Technology, Jamshoro, Pakistan

Abstract

Structural health monitoring requires reliable interpretation of sensor measurements when damage related changes may overlap with environmental variation and measurement noise. This proposed study establishes a comparative framework for evaluating machine learning algorithms in civil engineering monitoring applications. The central objective is to determine how predictive performance, robustness, and practical deployment requirements vary across model families under a common experimental protocol. The scope includes damage detection and, where suitable labels exist, damage classification or severity estimation. No monitoring dataset, experimental campaign, or superior algorithm is claimed as an established result; the work presents a prospective methodological design. The proposed evidence base would combine a licensed benchmark dataset with a clearly separated simulation component. Available measurements might include acceleration, strain, displacement, and recorded environmental conditions, depending on the selected structure and dataset. Sensor metadata, sampling rates, structural configurations, and damage labeling procedures would be documented before analysis. Preprocessing would address missing readings, synchronization, and signal quality without using test data to select transformations. When signals are segmented into overlapping windows, all windows from the same acquisition episode would remain within a single partition to reduce leakage and prevent unrealistically favorable estimates of generalization. The comparison would include support vector machines, random forests, gradient boosting, and a neural network suited to the selected signal representation. A simple statistical detection rule would provide an operational baseline. Feature based models would use predefined or training derived signal descriptors, while representation learning models would receive appropriately normalized signal windows. Hyperparameter selection would use nested or otherwise strictly separated validation, with comparable tuning budgets and transparent stopping criteria. Class imbalance would be addressed within training partitions only. The protocol would distinguish supervised damage classification from anomaly detection when examples of damaged states are insufficient for supervised learning. Assessment would prioritize consequences relevant to monitoring decisions. Reported indicators would include recall for damage events, false alarm rates, precision, class specific performance, and calibration where probability estimates are available. Severity estimation, if supported, would require separate error measures. Robustness experiments would introduce realistic noise, missing channels, temperature related shifts, and operating conditions excluded from training. Computational cost, memory requirements, and prediction latency would inform deployment feasibility. Uncertainty estimates would be derived from independent acquisition groups rather than treating correlated windows as independent observations. Comparisons across structures would be reported separately from comparisons within the same monitored asset. The anticipated contribution is a reproducible basis for selecting monitoring models according to the intended engineering task. The study would examine whether increased complexity improves detection under realistic distribution shifts or merely fits familiar measurement conditions more closely. Model explanations would be checked against plausible structural behavior and would not substitute for engineering inspection. Important limitations include uncertain damage labels, limited examples of rare failures, and differences between simulated damage and physical deterioration. Any resulting tool would support qualified engineers rather than independently certify structural safety. Empirical conclusions would depend on completing the proposed comparisons and validating the selected approach using independent structures or monitoring periods before practical implementation is considered.

Keywords: Machine learning; structural health monitoring; damage detection; model comparison; uncertainty

ARTIFICIAL INTELLIGENCE-BASED BUILDING INFORMATION MODELING FOR ENHANCING ARCHITECTURAL PROJECT MANAGEMENT

Ali HUSSAIN, Rabia SAEED

University of the Punjab, Lahore, Pakistan

Abstract

Architectural project management depends on keeping design information, schedules, quantities, and decisions consistent as a project develops. This proposed study examines an artificial intelligence framework integrated with building information modeling to support coordination and early identification of management risks. The research question is whether combining model information with documented project events can improve the timeliness and usefulness of management decisions relative to conventional BIM workflows. The scope includes design revisions, coordination issues, schedule dependencies, and cost related information. This is a proposed research framework; access to completed project records and demonstrated improvements in delivery performance are not asserted. The planned information architecture would connect BIM objects and model versions with issue logs, approved schedules, quantity records, and documented change requests. Stable identifiers and explicit version histories would preserve the relationship between predictions and the information available at each decision point. Data preparation would examine inconsistent naming, duplicate records, missing dates, and changes in object classification. Confidential commercial information would be restricted to authorized users, and personally identifying information would be minimized. A data dictionary would distinguish original project observations from derived indicators, ensuring that automated outputs can be traced to their underlying sources. The analytical component would evaluate machine learning models for predicting defined outcomes such as unresolved coordination issues or delays associated with design changes. Natural language processing could classify issue descriptions where sufficiently consistent labeled examples are available. Model features would be limited to information recorded before the prediction date, preventing later project outcomes from leaking into training inputs. Evaluation would hold out entire projects where the available sample permits, because records from the same project may share distinctive organizational patterns. Simple rules and conventional statistical models would provide baselines before any additional model complexity is justified. A comparative workflow assessment would examine how project teams interpret and act on model outputs. Indicators would include prediction accuracy, false alerts, issue resolution time, and the effort required to verify recommendations. Schedule and cost outcomes would be assessed only where consistent definitions and comparable records are available. A retrospective comparison would establish predictive feasibility, while a later prospective pilot would be needed to evaluate effects on management practice. Interviews or structured usability sessions would explore whether recommendations are understandable and whether they fit existing responsibilities. Every alert would display its supporting information and allow a documented human response. The anticipated contribution is an auditable approach to connecting BIM information with project management decisions. The proposed framework would clarify which information is necessary, how predictive uncertainty should be communicated, and when automated advice warrants review. It would also examine integration costs, fragmented records, and variation in organizational BIM maturity. Associations between predicted risks and project outcomes would not establish that artificial intelligence caused better delivery. Stronger causal conclusions would require a suitable prospective evaluation with credible comparison conditions. The study therefore positions artificial intelligence as decision support within accountable professional workflows, while reserving claims about reduced delays, lower costs, or improved coordination for empirical validation across architectural projects and organizational settings.

Keywords: Artificial intelligence; building information modeling; project management; risk prediction; design coordination