
BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ DEĞERLENDİRMELERİ

Editör: Doç.Dr. Fatih YÜCALAR

Bilgisayar Bilimleri ve Mühendisliği Değerlendirmeleri

Editör

Doç.Dr. Fatih YÜCALAR

yaz
yayınları

2025

**Bilgisayar Bilimleri ve Mühendisliği
Değerlendirmeleri**

Editör: Doç.Dr. Fatih YÜCALAR

© YAZ Yayınları

Bu kitabın her türlü yayın hakkı Yaz Yayınları'na aittir, tüm hakları saklıdır. Kitabın tamamı ya da bir kısmı 5846 sayılı Kanun'un hükümlerine göre, kitabı yayınlayan firmanın önceden izni alınmaksızın elektronik, mekanik, fotokopi ya da herhangi bir kayıt sistemiyle çoğaltılamaz, yayınlanamaz, depolanamaz.

E_ISBN 978-625-5838-79-7

Ekim 2025 – Afyonkarahisar

Dizgi/Mizanpaj: YAZ Yayınları

Kapak Tasarım: YAZ Yayınları

YAZ Yayınları. Yayıncı Sertifika No: 73086

M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar/AFYONKARAHİSAR

www.yazyayinlari.com

yazyayinlari@gmail.com

info@yazyayinlari.com

İÇİNDEKİLER

Ticari Olarak Satışı Yapılan İnsansız Yüzey Araçlarına Genel Bir Bakış	1
<i>Hüseyin DURAN</i>	
Otonom İnsansız Yüzey Araçlarında Yol Planlaması ve İzlemesinde Yapay Zekâ.....	25
<i>Hüseyin DURAN</i>	
Derin Öğrenme Yöntemleri ile Buğday Yaprak Hastalıklarının Otomatik Tespiti.....	40
<i>Dilan ÖZBİLGİ, Alper Talha KARADENİZ, Zafer CÖMERT, Muammer TÜRKOĞLU</i>	
Makine Öğrenmesi Ajanlarının Temelleri, Türleri ve Kullanım Alanları	60
<i>Faruk AYATA, Ebubekir SEYYARER</i>	
Kısıt Tabanlı Yaklaşımla Modern Web Teknolojileri Kullanılarak Geliştirilen Otomatik Sınav Programlama Sistemi	71
<i>Kadir TOHMA</i>	
Road Defect Detection Using Artificial Intelligence Techniques	92
<i>Firdevs ILGAZ, Ahmet BABALIK</i>	
Categorization of Tea Leaf Disease With Darknet53 CNN Model	116
<i>Rıfat AŞLIYAN</i>	

Kidney Disease Detection Using MLP, SVM and LR Methods.....	135
--	------------

Rıfat AŞLIYAN

3D Point Cloud Registration with Full Affine Transformations Optimized by Evolutionary Algorithms.....	155
---	------------

Tuba ÇAĞLIKANTAR, Erkan BEŞDOK

Biyoinformatik Alanında RNA Dizileme (RNA-SEQ) Analizi: Temeller ve Uygulama Alanları	176
--	------------

Mustafa Özgür CİNGİZ

Yapay Zekâ Destekli Kişiselleştirilmiş Öğrenme Sistemleri.....	188
---	------------

Kadir TURGUT

"Bu kitapta yer alan bölümlerde kullanılan kaynakların, görüşlerin, bulguların, sonuçların, tablo, şekil, resim ve her türlü içeriğin sorumluluğu yazar veya yazarlarına ait olup ulusal ve uluslararası telif haklarına konu olabilecek mali ve hukuki sorumluluk da yazarlara aittir."

TİCARİ OLARAK SATIŞI YAPILAN İNSANSIZ YÜZEY ARAÇLARINA GENEL BİR BAKIŞ

Hüseyin DURAN¹

1. GİRİŞ

Son yıllarda denizcilik sektöründe yaşanan teknolojik dönüşüm, otonom sistemlerin gelişmesiyle yeni bir boyut kazanmış ve bu dönüşümün en dikkat çekici örneklerinden biri de otonom yüzeysel araçlarıdır (USVs) (Liang vd. 2025). Başlangıçta daha çok araştırma prototipleri (Chaysiri vd. 2024) veya askeri uygulamalar (Molina-Molina vd., 2021) için geliştirilen bu araçlar, bugün ticari ürünler olarak farklı sektörlerde kendilerine yer edinmiş durumdadır. Otonom yüzeysel araçları, su yüzeyinde insan bulunmaksızın görev yapabilen ve gelişmiş sensörler ile kontrol algoritmaları sayesinde uzaktan veya otonom şekilde çalışabilen deniz taşıtlarıdır (Wang vd. 2020). Bu yönüyle insanlı gemilerin yerine geçmekten ziyade onların görev yükünü hafifletmekte, tehlikeli ortamlarda insan riskini azaltmakta ve maliyetleri düşürerek operasyonel verimliliği artırmaktadır.

USV'ler teknolojik açıdan farklı düzeylerde otonomiye sahiptir. Bazıları tamamen uzaktan kontrol edilen, insan operatörün komutlarıyla hareket eden sistemlerdir. Bu tür araçlar, genellikle liman içi, göl ve kıyı operasyonlarında tercih edilmekte, Wi-Fi, LTE ya da uydu iletişimiyle kısa veya orta menzilde görev yapmaktadır. Daha gelişmiş modellerde yarı otonom görevler öne çıkmaktadır. Bu araçlar, operatörün belirlediği rotaları takip edebilmekte, istasyon tutma veya temel

¹ Öğr. Gör. Dr., Akdeniz Üniversitesi Elmalı Meslek Yüksekokulu Bilgisayar Programcılığı, huseyinduran@akdeniz.edu.tr, ORCID: 0000-0002-9006-9540.

çarpışma önleme gibi özelliklere sahip olmaktadır. En üst düzeyde ise tamamen otonom sistemler yer almakta ve bu araçlar, radar, LiDAR, AIS ve kamera sistemleriyle çevresel algılama yaparak karar alabilmekte, karmaşık görevleri insan müdahalesine gerek duymadan yerine getirebilmektedir. Ancak piyasada bulunan modellerin büyük çoğunluğu halen orta seviyede otonomiye sahip olup, waypoint takibi ve temel seyrüsefer görevleriyle sınırlıdır. Bu durum, araştırmalarda gösterilen ileri düzey otonom kabiliyetlerle ticari ürünler arasında bir boşluk bulunduğunu göstermektedir.

Kullanım alanları açısından bakıldığında, USV'ler günümüzde çok geniş bir yelpazeye hitap etmektedir. Çevresel izleme bu uygulamaların başında gelmektedir. Özellikle su kalitesi ölçümlerinde sıcaklık, pH, çözünmüş oksijen, iletkenlik ve tuzluluk gibi parametrelerin takibi, göl, nehir ve kıyı bölgelerindeki ekosistemlerin korunması açısından büyük önem taşımaktadır. (Chen vd. 2025) Bu bağlamda USV'ler, geleneksel araştırma gemilerine kıyasla daha düşük maliyetli, daha güvenli ve uzun süreli veri toplama imkânı sunmaktadır (Ryu 2022). Kısa süreli batarya destekli araçlar saatler boyunca ölçüm yapabilirken, güneş, rüzgâr veya dalga enerjisinden yararlanan araçlar aylar boyunca kesintisiz veri sağlayarak iklim değişikliği ve çevresel risklerin izlenmesine katkı sunmaktadır. (Tran vd. 2024)

Savunma ve güvenlik alanı, USV'lerin en kritik kullanım sahalarından biridir. Bu araçlar kıyı güvenliği, liman gözetimi ve sınır devriyelerinde kullanılmakta; böylelikle personelin tehlikeli bölgelere girmesi önlenmektedir. Ayrıca mayın tarama ve imha görevlerinde, yüksek riskli bölgelerde insan hayatını riske atmadan operasyon yürütme imkânı sunmaktadır. Radar ve elektro-optik sensörlerle donatılmış araçlar, istihbarat, gözetleme ve keşif faaliyetlerinde etkin şekilde kullanılmakta, bazı modeller ise sürü konseptiyle koordineli hareket ederek deniz harekât

konseptlerine yeni bir boyut kazandırmaktadır. Bu yönüyle USV'ler, askeri stratejilerde hem bağımsız görev birimleri hem de insanlı gemilerin destek unsurları olarak kritik bir rol üstlenmektedir (Wu vd., 2022).

Endüstriyel alanda özellikle offshore enerji sektöründe USV'lerin değeri giderek artmaktadır (Campos vd. 2024). Petrol ve doğal gaz endüstrisinde deniz tabanı haritalama, boru hattı ve altyapı denetimi, rüzgâr türbinlerinin bakım ve kontrol görevleri bu araçlar sayesinde daha düşük maliyetle ve güvenli biçimde yapılabilmektedir. Geleneksel yöntemlerde insanlı gemilerin sefer düzenlemesi gereken operasyonlar, USV'ler ile otomatik veya yarı otomatik olarak gerçekleştirilebilmekte ve bu da endüstriye önemli zaman ve maliyet tasarrufu sağlamaktadır. Benzer şekilde bilimsel araştırmalarda da USV'ler yaygın olarak kullanılmaktadır. Deniz tabanı haritalama, meteorolojik ve okyanus verilerinin toplanması, balıkçılık araştırmaları ve ekosistem gözlemleri bu görevler arasında yer almaktadır. Sığ sularda küçük boyutlu araçlar tercih edilirken, okyanus ortamında daha büyük ve uzun dayanıklılığa sahip modeller kullanılmaktadır.

Son olarak lojistik ve destek operasyonları da USV'lerin yükselen bir kullanım alanıdır. Henüz başlangıç aşamasında olmakla birlikte, küçük ölçekli yük taşıma, acil durumlarda tıbbi malzeme ulaştırma veya insanlı gemilere ikmal desteği sağlama gibi görevlerde kullanılabilecek USV modelleri geliştirilmiştir (Nair ve Pillai 2019). Gelecekte bu tür uygulamaların daha da yaygınlaşması ve insansız lojistik operasyonların deniz taşımacılığına entegre olması beklenmektedir.

Bütün bu kullanım alanları, otonom yüzey araçlarının artık sadece deneysel platformlar değil, ticari olarak satılan, farklı operasyonel ihtiyaçlara hizmet eden çok yönlü sistemler haline geldiğini göstermektedir. Ancak mevcut modellerin çoğu, halen

sınırlı otonomi düzeyinde görev yapmakta ve üreticiler tarafından sağlanan teknik bilgiler, her zaman yeterince ayrıntılı olmayabilmektedir (de Andrade vd. 2025). Bu durum, piyasada bulunan araçların teknik profiline dair bütüncül bir resim çizmenin önemini artırmaktadır.

Bu çalışma, ticari olarak satışı yapılan USV’lerin teknik özelliklerini, kullanım alanlarını ve teknolojik eğilimlerini ortaya koymayı amaçlamaktadır. Çalışmada modeller arasında karşılaştırma yapmaktan veya en iyi sistemi belirlemekten ziyade, mevcut ticari çözümlerin genel karakteristiklerini betimlemek hedeflenmiştir. Böylelikle hem araştırmacılar hem de sektör profesyonelleri için ticari USV pazarının güncel durumuna ilişkin açıklayıcı bir çerçeve sunulmaktadır.

2. USV TEKNOLOJİSİNİN ARKA PLANI

Otonom yüzey araçlarının günümüzde ticari birer ürün haline gelmesinin arkasında, birbirini tamamlayan çok sayıda teknolojik, bilimsel ve endüstriyel gelişme bulunmaktadır. İlk dönemlerde su üstü insansız araçları, esasen insanlı teknelerin küçük ölçekte uyarlanmış versiyonlarıydı ve daha çok uzaktan kumandalı platformlar olarak görev yapmaktaydı. Zamanla bilgisayar teknolojilerinin, haberleşme altyapılarının, sensör sistemlerinin ve enerji depolama çözümlerinin gelişmesi, bu araçların kendi başına karar verebilen, daha uzun süreli ve çok amaçlı görevler icra edebilen platformlara dönüşmesini sağlamıştır (Barrera vd. 2021).

Bu dönüşümde kontrol sistemlerindeki ilerlemeler kritik rol oynamıştır. Başlangıçta yalnızca uzaktan kontrol edilen USV’ler, günümüzde yarı otonom ve tam otonom operasyon modlarına kavuşmuştur (Sun vd. 2018). Otomatik rota takibi (Wu vd. 2024), istasyon tutma (Erfianto vd. 2021), çarpışma önleme (Fan vd. 2022) ve sürü halinde hareket etme gibi kabiliyetler (Bae

ve Hong, 2023), modern kontrol algoritmalarının ve yapay zekâ tabanlı yazılımların ürünüdür. Özellikle makine öğrenmesi ve yapay zekâ yöntemleri, çevresel verileri gerçek zamanlı işleyerek karar verme süreçlerini desteklemekte ve araçların beklenmedik durumlara uyum sağlamasına imkân vermektedir.

Enerji sistemlerindeki gelişmeler de USV'lerin ticari hayata geçişinde belirleyici olmuştur. Geleneksel dizel motorlar hâlâ bazı modellerde kullanılmakla birlikte, günümüzde elektrikli ve hibrit sistemler giderek yaygınlaşmıştır. Lityum-iyon bataryalar, yakıt hücreleri, güneş panelleri, rüzgâr türbinleri ve dalga enerjisi dönüştürücüleri sayesinde USV'ler hem daha çevre dostu hale gelmiş hem de uzun süreli görev kabiliyetine ulaşmıştır. Özellikle yenilenebilir enerji destekli platformlar, aylarca kesintisiz veri toplayabilme imkânı sunarak araştırma ve çevresel izleme görevlerinde devrim niteliğinde katkılar sağlamaktadır (Wang vd. 2024).

Bir diğer kritik unsur ise malzeme teknolojilerindeki ilerlemelerdir. Hafif ve dayanıklı kompozit malzemeler, alüminyum alaşımlar ve polietilen gibi seçenekler, USV'lerin hem yapısal sağlamlığını artırmış hem de taşınabilirliğini kolaylaştırmıştır. Bu malzemeler aynı zamanda düşük bakım gereksinimiyle operasyonel maliyetlerin düşmesine katkı sunmuştur. Gövde tasarımında hidrodinamik optimizasyon çalışmaları, sürtünmeyi azaltarak hız ve enerji verimliliğini artırmış, böylelikle küçük boyutlu araçların bile uzun mesafelerde etkili olmasını mümkün kılmıştır (Huang vd. 2025).

USV teknolojisinin arka planında haberleşme sistemleri de önemli bir yer tutmaktadır. Başlangıçta yalnızca kısa menzilli radyo frekanslarıyla kontrol edilen bu araçlar, günümüzde 4G/5G ağları, uydu iletişim sistemleri (Iridium, Starlink gibi) ve mesh tabanlı çözümler sayesinde küresel ölçekte görev yapabilmektedir. Haberleşme altyapısındaki bu ilerlemeler hem

gerçek zamanlı veri iletimini hem de uzaktan komuta imkânını güçlendirmiştir (Zolic vd. 2019). Böylece USV'ler yalnızca kıyı bölgelerinde değil, okyanus ötesi görevlerde de kullanılabilir hale gelmiştir.

Tüm bu teknik gelişmelerin yanı sıra, USV'lerin yaygınlaşmasını şekillendiren bir diğer faktör de düzenleyici çerçeveler ve hukuki düzenlemeler olmuştur. Uluslararası denizcilik sözleşmeleri ve kuralları, esasen insanlı gemiler için hazırlanmıştır ve insansız araçlara uygulanmasında birçok belirsizlik barındırmaktadır. “Gemi kaptanı”, “mürettebat” veya “denizde çarpışmayı önleme” gibi kavramların insansız platformlara nasıl uyarlanacağı halen tartışmalı bir konudur. Bu nedenle pek çok üretici, araçlarını ticari olarak pazarlarken otonomi seviyelerini sınırlı tutmakta ve insan kontrolünü devrede bırakmaktadır. Ancak Uluslararası Denizcilik Örgütü (IMO) ve çeşitli bölgesel kurumlar, insansız araçlara yönelik yasal düzenlemeler geliştirmeye başlamış, bu da sektörün önünü açan önemli bir adım olmuştur.

Özetle, otonom yüzey araçlarının bugün geldiği nokta, yalnızca tek bir alandaki ilerlemeyle açıklanamaz. Kontrol algoritmalarındaki gelişmeler, enerji depolama ve yenilenebilir kaynakların entegrasyonu, malzeme teknolojilerindeki yenilikler, haberleşme ağlarının küreselleşmesi ve düzenleyici çabalar, hep birlikte bu teknolojiyi laboratuvar prototiplerinden çıkarıp ticari olarak satılabilen güvenilir ürünlere dönüştürmüştür.

3. OPERASYONEL USV'LER

Bu bölüm, son yıllarda faaliyet gösteren çok sayıda USV modelinin verilerini tartışmayı amaçlamaktadır. Bu verileri analiz ederek, kıyı operasyonları için tasarlanmış küçük, çevik USV'ler ile keşif ve veri toplama için inşa edilmiş uzun süreli platformlar arasında belirgin farklılıklar ortaya çıkmaktadır.

Çalışmada, farklı ölçeklerde ve kullanım alanlarında ticari olarak satışı yapılan 27 USV modelini değerlendirilmiş ve bazıları Şekil 1’de gösterilmektedir.² Bazı üreticiler geliştirilen araçlar ile ilgili birçok detaylı bilgi sunarken, diğerlerinde detaylı bilgi paylaşılmamıştır. Sınırlı bilgi nedeniyle, bu bölümde sunulan başlıklar toplanana verilerin sınıflandırması ile oluşturulmuştur. Ayrıca, her USV modeline dair bilgiler mümkün olduğunca taranmış ve değerlendirilmiştir.

Şekil 2’de yıllara göre ticari USV geliştirilme sayıları ile bu sayının kümülatif dağılımı birlikte gösterilmektedir. Elde edilen sonuçlara göre, ticari USV’lerin geliştirilme sürecinde özellikle son yıllarda belirgin bir artış eğilimi gözlenmektedir. İlk dönemlerde sınırlı sayıda üretim yapılırken, ilerleyen yıllarda hem teknolojik altyapının olgunlaşması hem de pazarın genişlemesiyle birlikte yıllık yeni model sayısında artış yaşanmıştır. Bu eğilim, kırmızı kümülatif eğri üzerinde açıkça görülmekte; özellikle 2015 sonrası dönemde eğrinin daha dik bir ivme kazandığı dikkat çekmektedir.

Kümülatif dağılım aynı zamanda ticari USV pazarının olgunlaşma sürecine işaret etmektedir. Belirli dönemlerde artışların yavaşlaması, teknoloji veya düzenlemelerden kaynaklanan geçici durgunlukları yansıtırken; hızlı artışlar ise

² İncelenen USV modellerine ilişkin bilgiler üretici firmaların resmi teknik dokümanlarından elde edilmiştir (Alfabetik Sıralama):

Holos Brasil / USSV (C-400 (2017)), Kongsberg Discovery AS (Sunder USV (2025)), L3Harris (C-Worker 4 ASV (2022), Shadow Fox (2023), C-Worker 5 ASV (2025)), Liquid Robotics (Wave Glider (2025)), Maritime Robotics (The Otter (2024)), Ocean Infinity Group (Armada A8 (2023), Armada A78 (2023)), OceanAlpha Group Ltd. (L25 (2017), M40P (2017), M80 (2018), M75 (2023), ME120 (2024)), Open Ocean Robotics (DataXplorer™ (2025)), Saildrone (Saildrone Explorer (2025)), Seafloor Systems (HydroCat-550 (2025), EchoBoat-240 (2025)), SeaRobotics Corporation (SR-Utility 3.6 (2022), SR-Utility 2.5 (2022), SR-Utility 3.0 (2022), SR-Endurance 7.0 (2025), SR-Endurance 8.0 (2024)), Seasats (The Lightfish (2024)), SeaTrac System, Inc. (SeaTrac SP-48 (2021)), Unique Group (Uni-Pact (2022), Uni-Max (2023)),

pazarın yeni bir ivme kazandığı döneme işaret etmektedir. Örneğin, çevresel izleme ve hidrografik ölçüm alanındaki taleplerin artması, yenilenebilir enerji tabanlı uzun süreli USV'lerin geliştirilmesini teşvik etmiş ve bu da yıllık sayılara doğrudan yansımıştır.



a



b



c




d



e



f



g



h



i



j



k




l

Şekil 1. Çalışmada kullanılan bazı USV'lerin görüntüleri; a) SR-Endurance 8.0 (SR-Endurance 8.0, 2024), b) Shadow Fox Autonomous Surface Vehicle (Shadow Fox, 2023), c) L25 (L25, 2017), d) Uni-Max (Uni-Max, 2023), e) Uni-Pact (Uni-Pact, 2022), f) Armada A78 (Armada A78, 2023), g) C-Worker 5 (C-Worker 5 ASV, 2025), h) SR-Utility 3.0 (SR-Utility 3.0, 2022), i) SeaTrac SP-48 (SeaTrac SP-48, 2021), j) Echoboat-240 USV (EchoBoat-240, 2025), k) HydroCat-550 (HydroCat-550, 2025), l) ME120 (ME120, 2024)


3.1. Gövde Malzemeleri ve Boyutlar

Ticari USV'lerin tasarımında kullanılan gövde malzemeleri, araçların operasyonel kapasitesini ve dayanıklılığını belirleyen temel unsurlardan biridir. Composite ve fiberglass malzemeler, genellikle küçük ve orta boyutlu USV'lerde tercih edilmekte olup hafiflik, kolay taşınabilirlik ve düşük maliyet avantajı sağlamaktadır. Buna karşılık alüminyum ve çelik malzemeler, daha büyük ve dayanıklı platformlarda kullanılmakta, özellikle açık deniz operasyonlarında yüksek güvenlik ve uzun süreli dayanıklılık sunmaktadır. Ticari pazarda kompozit ve alüminyum gövdeli araçların öne çıktığı görülmektedir (Şekil 3a).



Şekil 2. Yıllara göre geliştirilen USV sayıları ve kümülatif değerler

Boyut parametreleri açısından bakıldığında, USV'lerin uzunlukları 1–2 metre aralığındaki küçük araştırma araçlarından, 50 metreyi aşan büyük ölçekli açık deniz platformlarına kadar uzanan geniş bir spektrum göstermektedir (Şekil 3b). Genişlik ve draft değerleri de bu çeşitliliğe paralel olarak farklı operasyonel ihtiyaçlara göre şekillenmektedir (Şekil 3c). Özellikle 0–0.5 metre draft değerine sahip araçlar sığ sularda batimetrik ölçüm ve çevresel izleme için öne çıkarken, daha derin drafta sahip modeller açık denizlerde uzun süreli görevler için tasarlanmıştır.



Şekil 3. a) USV'lerde kullanılan gövde malzemesi, b) USV uzunluk histogram grafiği, c) USV genişlik histogramı

3.2. USV Ağırlık ve Taşıma Kapasiteleri


Ticari USV'lerin tasarımında araç ağırlığı ve taşıma kapasitesi, platformların operasyonel kabiliyetlerini doğrudan etkileyen en önemli parametreler arasında yer almaktadır. Çalışmadan elde edilen verilere göre, USV'lerin büyük çoğunluğu 1000 kg altındaki ağırlık sınıflarında yoğunlaşmaktadır. Özellikle 100–500 kg ve 500–1000 kg aralıkları, çevresel izleme ve hidroğrafik ölçüm amaçlı küçük ve orta ölçekli USV'lerin karakteristik özelliklerini yansıtmaktadır. Daha büyük sınıflarda ise 5000 kg ve üzeri ağırlığa sahip araçlar görece sınırlı sayıda bulunmakla birlikte, bu platformlar genellikle offshore araştırmaları ve uzun süreli görevler için geliştirilmiştir.

Taşıma kapasitesi bakımından incelendiğinde, ticari USV'lerin önemli bir bölümünün 200 kg altı kapasiteye sahip olduğu görülmektedir. Bu değer, sensör yükleri ve hafif ölçüm ekipmanlarıyla donatılan küçük ölçekli USV'lerde yaygındır. Orta ölçekli araçlarda kapasite 200–500 kg seviyesine ulaşırken, büyük ölçekli offshore platformlarında bu değer 1000 kg'ın üzerine çıkabilmektedir. Böylelikle, küçük ölçekli araçlar düşük taşıma kapasitesiyle esneklik sağlarken; büyük platformlar ağır ve çoklu sensör entegrasyonuna imkân tanımaktadır.

Şekil 4'te görüldüğü üzere, ağırlık ve taşıma kapasitesi dağılımları birbirine paralel bir eğilim sergilemektedir. Hafif araçlar genellikle düşük kapasiteyle sınırlı kalırken, ağırlık arttıkça taşıma kapasitesinde de belirgin bir artış gözlenmektedir. Bununla birlikte, bu ilişki her zaman doğrusal değildir; bazı orta ölçekli araçlarda ağırlığa kıyasla sınırlı kapasite değerleri, tasarımda önceliğin dayanıklılık ya da hız parametrelerine verildiğini göstermektedir.

Sonuç olarak, ticari USV'lerin ağırlık ve taşıma kapasitesi dağılımları, araçların hangi kullanım alanlarına odaklandığını


anlamak açısından önemli ipuçları sunmaktadır. Küçük ölçekli hafif USV'ler, batimetri ve çevresel ölçümler için öne çıkarken; büyük ölçekli ve yüksek kapasiteli USV'ler, offshore enerji, savunma ve uzun süreli araştırma görevlerinde kritik bir rol üstlenmektedir.



Şekil 4. USV'lerin ağırlık ve taşıma kapasitelerine göre dağılımları

3.3. Haberleşme Teknolojileri

Ticari USV'lerin operasyonel başarılarında haberleşme altyapıları kritik bir rol oynamaktadır. Kullanılan teknolojiler, araçların kontrol menzilini, veri aktarım hızını ve operasyonel güvenilirliğini doğrudan etkilemektedir. Çalışmada elde edilen veriler, ticari USV'lerde dört ana kategori öne çıktığını göstermektedir: Uydu, GSM tabanlı mobil iletişim, Wi-Fi ve radyo tabanlı sistemler (Şekil 5).



Şekil 5. USV'lerde kullanılan haberleşme teknolojileri

Radyo tabanlı haberleşme (VHF, UHF, RF, mesh ve telemetry çözümleri) en yaygın kullanılan yöntem olarak öne çıkmaktadır. Bu sistemler özellikle kısa ve orta menzilli görevlerde güvenilir ve düşük maliyetli çözümler sunmaktadır. Wi-Fi tabanlı çözümler, liman içi veya kıyıya yakın operasyonlarda tercih edilmekte olup kısa menzilde hızlı veri aktarımı avantajı sağlamaktadır.

GSM tabanlı sistemler (3G/4G/5G, LTE), mobil iletişim teknolojilerindeki gelişime paralel olarak son yıllarda USV'lerde daha fazla kullanılmaya başlanmıştır. 4G ve 5G'nin sunduğu yüksek bant genişliği ve düşük gecikme süreleri, gerçek zamanlı kontrol ve yüksek hacimli veri aktarımı için önemli bir avantaj sağlamaktadır.


Uydu haberleşmesi ise uzun menzilli ve açık deniz operasyonlarında vazgeçilmezdir. Iridium ve Starlink gibi küresel uydu ağları sayesinde USV'ler, kıyıdan yüzlerce kilometre uzakta dahi kontrol edilebilmekte ve veri aktarımı yapabilmektedir. Bu durum, ticari USV endüstrisinin haberleşme teknolojilerindeki küresel dönüşüme hızla uyum sağladığını göstermektedir.

Ticari USV'lerde haberleşme sistemlerinin çeşitliliği, araçlara farklı operasyonel senaryolara uyum sağlama esnekliği kazandırmaktadır. Erken dönemlerde yalnızca RF tabanlı sistemler kullanılırken, günümüzde hibrit çözümler öne çıkmaktadır. Birçok modern USV, aynı anda uydu, GSM ve RF haberleşme sistemlerini kullanarak görev yapabilmekte, bu da operasyonel güvenilirliği ve görev başarısını artırmaktadır.

3.4. Güç ve Enerji Sistemleri

Ticari USV'lerin operasyonel performansını belirleyen en önemli bileşenlerden biri güç ve enerji altyapısıdır. USV'lerde dört ana enerji sistemi öne çıkmaktadır: dizel motorlar, elektrikli tahrik sistemleri, hibrit çözümler ve yenilenebilir enerji destekli sistemler (Şekil 6).


Geliştirilen sistemlerde dizel motorların hâlâ ticari USV pazarında önemli bir yer tuttuğunu göstermektedir. Dizel sistemler, yüksek enerji yoğunlukları sayesinde özellikle uzun menzilli ve açık deniz operasyonlarında tercih edilmektedir. Bununla birlikte, çevresel kaygıların artması ve enerji verimliliğine yönelik eğilimler, elektrikli sistemlerin kullanımını artırmıştır. Elektrikli USV’ler, düşük gürültü seviyeleri ve çevre dostu yapılarıyla kıyıya yakın operasyonlarda yaygın biçimde kullanılmaktadır. Hibrit sistemler, dizel ve elektrikli motorların avantajlarını birleştirerek daha uzun dayanıklılık ve esnek kullanım sağlamaktadır. Son yıllarda öne çıkan bir diğer yaklaşım ise yenilenebilir enerji kaynaklarının entegrasyonu olmuştur. Güneş panelleri, rüzgar kanatları veya dalga enerjisi destekli USV’ler, aylar süren kesintisiz operasyonlar için yeni bir kapı açmaktadır.



Şekil 6. USV’lerde güç ve enerji sistemlerinin dağılımı.


Dayanıklılık, bir USV’nin operasyonel etkinliğini belirleyen en kritik performans ölçütlerinden biridir. Verilere göre küçük ölçekli USV’ler genellikle birkaç saat ile birkaç gün

arasında görev yapabilmekte, orta ölçekli platformlar 3–10 gün sürelerle operasyon gerçekleştirebilmekte, büyük hibrit ve dizel tabanlı USV’ler ise 20–30 günü aşan dayanıklılık değerlerine ulaşabilmektedir. Yenilenebilir enerji destekli modellerde, aylar süren kesintisiz görevler mümkün hale gelmiştir (Şekil 7).



Şekil 7. Ticari USV’lerin dayanıklılık (görev süresi) dağılımları.

Hız, USV’lerin görev profilleriyle doğrudan ilişkilidir. Çevresel izleme ve hidroğrafi amaçlı küçük USV’ler genellikle 5–10 knot aralığında sınırlı hızlara sahiptir. Savunma ve güvenlik amaçlı platformlarda hız 20 knot’un üzerine çıkabilmekte, offshore operasyonlarda ise hızdan çok dayanıklılık ve yük kapasitesi ön planda olduğundan genellikle 6–12 knot seviyeleri yeterli olmaktadır (Şekil 8).



Şekil 8. Ticari USV’lerin maksimum hız dağılımları.

4. SONUÇ

Otonom yüzey araçları, denizcilikte ve deniz araştırmalarında son yıllarda hızla yükselen bir teknoloji alanı haline gelmiştir. Başlangıçta araştırma prototipleri ve askeri uygulamalar için geliştirilen bu araçlar, bugün ticari ürünler olarak piyasada farklı sektörlerin ihtiyaçlarına hizmet etmektedir. Çevresel izleme, hidroğrafik ölçümler, savunma ve güvenlik, offshore enerji operasyonları, bilimsel araştırmalar ve lojistik destek gibi çok çeşitli görevlerde kullanılan USV’ler, insanlı gemilerin yerine geçmekten ziyade onların görev yükünü hafifleten, riskleri azaltan ve maliyetleri düşüren platformlar olarak öne çıkmaktadır.

Bu çalışmada, ticari olarak satışı yapılan USV’lerin mevcut teknik profili ortaya konulmuş, boyut, hız, dayanıklılık, malzeme, iletişim ve sensör altyapıları gibi temel özellikler betimlenmiştir. Ayrıca, üretici firmalardan elde edilen bilgiler doğrultusunda çıkış yılları, gövde malzemeleri ve kullanım alanları da tabloya eklenerek ticari USV pazarına ilişkin daha

bütüncül bir çerçeve sunulmuştur. Bulgular, bu araçların homojen bir yapıdan ziyade farklı operasyonel senaryolara hizmet edecek şekilde çeşitlendiğini göstermektedir. Küçük ve hafif modeller kısa süreli kıyı görevleri için uygunken, büyük ve hibrit ya da yenilenebilir enerji destekli araçlar uzun süreli ve açık deniz operasyonlarına olanak tanımaktadır.

Elde edilen sonuçlar, ticari USV pazarında öne çıkan eğilimleri de gözler önüne sermektedir. Hızdan ziyade dayanıklılığa öncelik veren tasarımlar, kıyı ve sığ sularda operasyonlara uygun kompakt sistemlerin yaygınlığı, yenilenebilir enerji kullanımındaki artış ve sensör füzyonuna dayalı otonomi çözümlerinin yükselişi bu eğilimler arasında yer almaktadır. Bununla birlikte, bazı üreticilerin teknik bilgileri sınırlı paylaşması, şeffaflık ve standardizasyon eksikliği gibi zorluklar da dikkat çekmektedir.

Sonuç olarak, ticari USV'ler günümüzde yalnızca teknolojik bir yenilik değil, aynı zamanda denizcilik ekosisteminin ayrılmaz bir parçası haline gelmiştir. Bu araçların gelişimi, hem araştırma faaliyetlerini desteklemekte hem de endüstriyel ve güvenlik operasyonlarına yeni imkânlar sunmaktadır. Gelecekte daha fazla şeffaflık, standartlaştırılmış veri paylaşımı ve ileri düzey otonom çözümlerin ticari ürünlere entegrasyonu ile USV pazarının daha da büyümesi ve çeşitlenmesi beklenmektedir. Bu çalışma, mevcut ticari USV'lerin güncel durumunu ortaya koyarak hem araştırmacılar hem de uygulayıcılar için yol gösterici bir kaynak olmayı amaçlamaktadır.

KAYNAKLAR

- Armada A78. (2023). Ocean Infinity Group. Erişim adresi: <https://oceaninfinity.com/wp-content/uploads/2023/08/OI-ARMADA78-Spec-Sheet-2023.pdf> (Son erişim tarihi: 26 Eylül 2025)
- Armada A8. (2023). Ocean Infinity Group. Erişim adresi: https://oceaninfinity.com/wp-content/uploads/2023/08/OI-ARMADA8_Spec-Sheet-2023.pdf (Son erişim tarihi: 26 Eylül 2025)
- Bae, I., & Hong, J. (2023). Survey on the developments of unmanned marine vehicles: Intelligence and cooperation. *Sensors*, 23(10), 4643.
- Barrera, C., Padron, I., Luis, F. S., & Llinas, O. (2021). Trends and challenges in unmanned surface vehicles (USV): From survey to shipping. *TransNav: International Journal on Marine Navigation and Safety of Sea Transportation*, 15.
- C-400. (2017). Holos Brasil / USSV. Erişim adresi: https://revistapesquisa.fapesp.br/wp-content/uploads/2017/03/080-081_barco-solar_253-1.pdf (Son erişim tarihi: 26 Eylül 2025)
- C-Worker 4 ASV. (2022). L3Harris. Erişim adresi: <https://www.l3harris.com/sites/default/files/2022-10/ims-maritime-C-Worker-4-Sell-Sheet.pdf> (Son erişim tarihi: 26 Eylül 2025)
- C-Worker 5 ASV. (2025). L3Harris. Erişim adresi: <https://www.l3harris.com/resources/c-worker-5-asv-data-sheet> (Son erişim tarihi: 26 Eylül 2025)
- Campos, D. F., Gonçalves, E. P., Campos, H. J., Pereira, M. I., & Pinto, A. M. (2024). Nautilus: An autonomous surface vehicle with a multilayer software architecture for

- offshore inspection. Journal of Field Robotics, 41(4), 966–990.
- Chaysri, P., Spatharis, C., Vlachos, K., & Blekas, K. (2024). Design and implementation of a low-cost intelligent unmanned surface vehicle. Sensors, 24(10), 3254.
- Chen, C. H., Shang, Y. J., Wu, Y. C., & Lin, Y. C. (2025). Development of Autonomous Electric USV for Water Quality Detection. Sensors, 25(12), 3747.
- DataXplorer™. (2025). Open Ocean Robotics. Erişim adresi: https://www.openoceanrobotics.com/_files/ugd/3d6add_84367351a7a44100a7503f8aa2d48362.pdf (Son erişim tarihi: 26 Eylül 2025)
- de Andrade, E. M., Sales Jr, J. S., & Fernandes, A. C. (2025). Operative Unmanned Surface Vessels (USVs): A Review of Market-Ready Solutions. Automation, 6(2), 17.
- EchoBoat-240. (2025). Seafloor Systems. Erişim adresi: https://www.seaflorsystems.com/_files/ugd/f80a79_18df15501251470aaf79793ea1538c0e.pdf (Son erişim tarihi: 26 Eylül 2025)
- Erfianto, B., Adrianne, A., & Arif, R. R. (2021). On the experiment of path planning using multi-way points with A* algorithm for autonomous surface vehicle. Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control.
- Fan, Y., Sun, Z., & Wang, G. (2022). A novel reinforcement learning collision avoidance algorithm for USVs based on maneuvering characteristics and COLREGs. Sensors, 22(6), 2099.
- HydroCat-550. (2025). Seafloor Systems. Erişim adresi: https://www.seaflorsystems.com/_files/ugd/f80a79_854

02eb9ccf8441185185ed6b57d94c8.pdf (Son erişim tarihi: 26 Eylül 2025)

- Huang, Y., Sultan, M. T. H., Łukaszewicz, A., Shahar, F. S., & Oksiuta, Z. (2025). AHP-Based Evaluation of Hybrid Kenaf/Flax/Glass Fiber-Reinforced Biocomposites for Unmanned Maritime Vehicle Applications. *Materials*, 18(16), 3731.
- L25. (2017). OceanAlpha Group Ltd. Erişim adresi: https://www.unmannedsystemstechnology.com/wp-content/uploads/2017/08/L25-OceanAlpha_compressed.pdf (Son erişim tarihi: 26 Eylül 2025)
- Liang, X., Zhang, R., & Qu, X. (2025). Autonomous Marine Vehicle Operations—2nd Edition. *Journal of Marine Science and Engineering*, 13(5), 920.
- ME120. (2024). OceanAlpha Group Ltd. Erişim adresi: <https://nautikaris.com/wp-content/uploads/2024/12/ME120-OceanAlpha.pdf> (Son erişim tarihi: 26 Eylül 2025)
- M75. (2023). OceanAlpha Group Ltd. Erişim adresi: <https://garantsafety.lv/wp-content/uploads/2023/12/M75-OceanAlpha.pdf> (Son erişim tarihi: 26 Eylül 2025)
- M80. (2018). SWALE Oceanographic / OceanAlpha Group Ltd. Erişim adresi: https://swaleocean.co.uk/wp-content/uploads/Swale-USV_M80-Nov18.pdf (Son erişim tarihi: 26 Eylül 2025)
- Molina-Molina, J. C., Salhaoui, M., Guerrero-González, A., & Arioua, M. (2021). Autonomous marine robot based on AI recognition for permanent surveillance in marine protected areas. *Sensors*, 21(8), 2664.

- Nair, A., & Pillai, A. (2019, November). Concept Design of an Unmanned Surface Vessel for Offshore Cargo Delivery. In Conference Proceedings of ICMET (Vol. 2019).
- Saildrone Explorer. (2025). Saildrone. Erişim adresi: <https://www.saildrone.com/technology/vehicles> (Son erişim tarihi: 26 Eylül 2025)
- SeaTrac SP-48. (2021). SeaTrac System, Inc. Erişim adresi: <https://seatrak.wpenginepowered.com/wp-content/uploads/2021/07/seatrak-datasheet-sp48-2021-2.pdf> (Son erişim tarihi: 26 Eylül 2025)
- Shadow Fox. (2023). L3Harris Technologies, Inc. Erişim adresi: https://www.l3harris.com/sites/default/files/2023-09/L3Harrissellsht_ShadowFox_cc3.pdf (Son erişim tarihi: 26 Eylül 2025)
- Sounder USV. (2025). Kongsberg Discovery AS. Erişim adresi: https://www.kongsberg.com/globalassets/kongsberg-discovery/autonomous-and-uncrewed-solutions/sounder/no-gondola/sounder_nogondola_datasheet_449199a.pdf (Son erişim tarihi: 26 Eylül 2025)
- SR-Endurance 7.0. (2025). SeaRobotics Corporation. Erişim adresi: <https://www.searobotics.com/media/attachments/2022/03/22/sr-endurance70-specsheet-2.pdf> (Son erişim tarihi: 26 Eylül 2025)
- SR-Endurance 8.0. (2024). SeaRobotics Corporation. Erişim adresi: https://www.searobotics.com/media/attachments/2024/10/08/sr-80-specsheet_20241004.pdf (Son erişim tarihi: 26 Eylül 2025)

- SR-Utility 2.5. (2022). SeaRobotics Corporation. Erişim adresi: <https://www.searobotics.com/media/attachments/2022/03/22/sr-utility25-specsheet.pdf> (Son erişim tarihi: 26 Eylül 2025)
- SR-Utility 3.0. (2022). SeaRobotics Corporation. Erişim adresi: <https://www.searobotics.com/media/attachments/2022/08/19/sr-utility30-specsheet-2022.pdf> (Son erişim tarihi: 26 Eylül 2025)
- SR-Utility 3.6. (2022). SeaRobotics Corporation. Erişim adresi: <https://www.searobotics.com/media/attachments/2022/03/22/sr-utility36-specsheet.pdf> (Son erişim tarihi: 26 Eylül 2025)
- Sun, X., Wang, G., Fan, Y., Mu, D., & Qiu, B. (2018). An automatic navigation system for unmanned surface vehicles in realistic sea environments. *Applied Sciences*, 8(2), 193.
- The Lightfish. (2024). Seasats. Erişim adresi: <https://seasats.b-cdn.net/wp-content/uploads/2024/04/Seasats-Lightfish-Postcard.pdf> (Son erişim tarihi: 26 Eylül 2025)
- The Otter. (2024). Maritime Robotics. Erişim adresi: <https://maritimerobotics.ams3.digitaloceanspaces.com/static/files/otter-brochure-2024-digital.pdf> (Son erişim tarihi: 26 Eylül 2025)
- Tran, H. D., Nguyen, N. T., Cao, T. N. T., Gia, L. X., Ho, K., Nguyen, D. D., ... & Truong, V. N. (2024). Unmanned surface vehicle for automatic water quality monitoring. In *E3S Web of Conferences* (Vol. 496, p. 03005). EDP Sciences.
- Uni-Max. (2023). Unique Group. Erişim adresi: <https://www.uniquegroup.com/wp->

- content/uploads/2022/08/Uni-Max_Nov23.pdf (Son erişim tarihi: 26 Eylül 2025)
- Uni-Pact. (2022). Unique Group. Erişim adresi: https://www.uniquegroup.com/wp-content/uploads/2022/08/Uni-Pact_Brochure.pdf (Son erişim tarihi: 26 Eylül 2025)
- Wang, J., Wang, J., Liu, Z. Y., Liang, X. F., & Yi, H. (2024, Nisan). Design and Experiments of a Sustainable Hybrid Power Unmanned Surface Vehicle for Maritime Patrol. In OCEANS 2024–Singapore (pp. 1–5). IEEE.
- Wang, W., Shan, T., Leoni, P., Fernández-Gutiérrez, D., Meyers, D., Ratti, C., & Rus, D. (2020, October). Roboat II: A novel autonomous surface vessel for urban environments. In 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (pp. 1740–1747). IEEE.
- Wave Glider. (2025). Liquid Robotics. Erişim adresi: https://287872.fs1.hubspotusercontent-na1.net/hubfs/287872/website-downloads/WG_SV3_DataSheet_3.2.pdf (Son erişim tarihi: 26 Eylül 2025)
- Wu, G., Xu, T., Sun, Y., & Zhang, J. (2022). Review of multiple unmanned surface vessels collaborative search and hunting based on swarm intelligence. *International Journal of Advanced Robotic Systems*, 19(2), 17298806221091885.
- Wu, Y., Wang, T., & Liu, S. (2024). A review of path planning methods for marine autonomous surface vehicles. *Journal of Marine Science and Engineering*, 12(5), 833.
- Zolich, A., Palma, D., Kansanen, K., Fjørtoft, K., Sousa, J., Johansson, K. H., ... & Johansen, T. A. (2019). Survey on communication and networks for autonomous marine

systems. Journal of Intelligent & Robotic Systems, 95(3), 789–813.

OTONOM İNSANSIZ YÜZEY ARAÇLARINDA YOL PLANLAMASI VE İZLEMESİNDE YAPAY ZEKA

Hüseyin DURAN¹

1. GİRİŞ

Su kaynaklarının sürdürülebilir yönetimi, günümüzde çevresel koruma, kamu sağlığı ve ekonomik faaliyetler açısından stratejik bir öneme sahiptir. Göller, nehirler ve kıyı bölgeleri hem içme suyu kaynağı hem de akuakültür, enerji üretimi ve ekosistem hizmetleri için kritik alanlardır. Ancak bu bölgelerin genişliği, dinamik yapısı ve sürekli değişen koşulları, geleneksel ölçüm ve izleme yöntemlerini yetersiz kılmaktadır. İnsan gücüyle yapılan saha çalışmaları yüksek maliyetli, zaman alıcı ve riskli olabilirken, uydu ve hava tabanlı uzaktan algılama yöntemleri de yalnızca optik aktif parametrelerle sınırlı kalmakta, bulut örtüsü ve çözünürlük gibi kısıtlarla verim kaybı yaşamaktadır (Qadir vd., 2024). Bu bağlamda, Otonom İnsansız Yüzey Araçları (OİYA) çevresel izleme için önemli bir alternatif olarak öne çıkmıştır.

OİYA'lar, batimetri ölçümlerinden su kalitesi parametrelerinin izlenmesine, kirlilik kaynağı tespitinden güvenlik devriyelerine kadar farklı uygulama alanlarında kullanılmaktadır. Örneğin, Powai Gölü'nde geliştirilen düşük maliyetli bir katamaran yapı üzerine kurulu OİYA, yan taramalı sonar ile batimetri haritaları çıkararak göl hacmi ve derinlik dağılımlarını hesaplamış, bu sayede hem çevresel değişimlerin

¹ Öğr. Gör. Dr., Akdeniz Üniversitesi, Elmalı Meslek Yüksekokulu, Bilgisayar Programcılığı, huseyinduran@akdeniz.edu.tr, ORCID: 0000-0002-9006-9540.

hem de hidrografik güvenliğin izlenmesine katkı sağlamıştır (Wilson vd., 2022). Benzer şekilde AquaDrone platformu pH, çözünmüş oksijen, sıcaklık ve iletkenlik gibi su kalitesi parametrelerini ölçerek makine öğrenmesi tabanlı sınıflandırmalarla beş kalite seviyesine ayırmış, gerçek zamanlı veri aktarımıyla halk sağlığı için kritik önemde bulgular sağlamıştır (Qadir vd., 2024). Bu örnekler, OİYA'ların yalnızca ölçüm aracı olmanın ötesine geçerek çevresel yönetim için karar destek sistemleriyle bütünleşebildiğini göstermektedir.

OİYA'ların başarısında yol planlama ve izleme süreçleri temel bir rol oynamaktadır. Yol planlama, aracın görev alanını en verimli şekilde taramasını sağlarken, izleme süreci bu planın sahadaki değişken koşullara göre sürekli güncellenmesini gerektirir. Geleneksel tarama desenleri veya önceden belirlenmiş rotaları, durağan koşullarda uygulanabilir olsa da, akıntılar, rüzgâr ve engeller gibi faktörler karşısında yetersiz kalmaktadır. Bu nedenle son yıllarda yapay zekâ tabanlı yöntemler yol planlama ve izleme süreçlerine entegre edilmiştir. Pekiştirmeli öğrenme algoritmaları, ajanların çevreyle etkileşiminden öğrenerek adaptif kararlar almasını mümkün kılmış; derin pekiştirmeli öğrenme (DRL) ise sinir ağları desteğiyle karmaşık devriye görevlerinde yüksek başarı sağlamıştır. Öte yandan Bayesian optimizasyon (BO) ve Gaussian Process (GP) tabanlı yaklaşımlar, belirsiz çevresel alanlarda en yüksek bilgi kazancını sağlayacak noktaların seçilmesine imkân tanımış, böylece ölçüm maliyetlerini azaltırken veri kalitesini artırmıştır. Evrimsel algoritmalar da küresel optimuma yakın çözümleri hızlı biçimde bulabilme avantajlarıyla geniş ölçekli görevlerde tercih edilmektedir (Yanes Luis vd., 2021).

Bu dönüşüm, çevresel izleme görevlerinde yalnızca daha hızlı ve verimli çözümler üretmekle kalmamakta, aynı zamanda gerçek zamanlı karar destek mekanizmalarıyla sürdürülebilir su yönetimine stratejik katkılar sunmaktadır. Çalışmada, söz konusu

yapay zekâ tekniklerinin ayrıntılı bir değerlendirmesi yapılarak, literatürdeki yaklaşımlar ve saha uygulamaları ışığında geleceğe yönelik araştırma alanları ortaya konulacaktır.

2. YOL PLANLAMASI

Yol planlaması, OİYA'ların en güvenli, en kısa ve en verimli rotayı belirleyerek hedefe ulaşmasını sağlayan temel süreçlerden biridir. Bu süreç yalnızca başlangıç ve hedef noktaları arasındaki mesafeyi minimize etmeyi değil, aynı zamanda çevresel koşulları, engelleri, akıntıları, kıyı yapılarını ve güvenlik bölgelerini de dikkate alır. İyi tasarlanmış bir yol planlama mekanizması, aracın enerji tüketimini azaltır, görev süresini kısaltır ve riskleri en aza indirerek güvenli bir seyir sağlar. Özellikle dinamik su ortamlarında, yol planlama algoritmaları gerçek zamanlı olarak çalışarak çevresel değişimlere (örneğin ani bir engelin belirlenmesi veya hava koşullarının değişmesi) hızlı bir şekilde uyum sağlar. Bu bağlamda yol planlaması, yalnızca bir rota belirleme değil, aynı zamanda sürekli optimizasyon ve adaptasyon süreci olarak değerlendirilmektedir.

Yol planlamasında yaygın olarak kullanılan yöntemler graf tabanlı algoritmalar, örnekleme tabanlı algoritmalar ve yapay zeka tabanlı yaklaşımlar olmak üzere üç ana grupta değerlendirilmektedir (Qin vd. 2023).

2.1. Graf Tabanlı Algoritmalar

Genel olarak bu yaklaşım, çevrenin bir harita veya şebeke (grid) yapısına dönüştürülmesine dayanır. Yani ortam, düğümler ve bu düğümler arasındaki bağlantılarla modellenir. Böylece problem matematiksel bir ağ üzerinde en kısa veya en uygun yolu bulma problemine indirgenir. Bu algoritmalar, özellikle önceden bilinen ve çok fazla değişmeyen ortamlarda oldukça etkilidir.

Bu yöntemler, harita üzerindeki noktaları düğümler ve bağlantıları kenarlar olarak ele alır. En bilinen örneklerden biri Dijkstra algoritmasıdır. Dijkstra, en kısa yolu bulmada oldukça etkilidir, ancak dinamik engel durumlarında esnekliği sınırlıdır. A* algoritması ise Dijkstra'nın geliştirilmiş bir versiyonu olup, sezgisel (heuristic) fonksiyon kullanarak daha hızlı ve etkin rota hesaplaması yapar. Bu tür algoritmalar, bilinen haritalar ve sabit çevre koşulları altında oldukça başarılıdır (Meng ve Fang, 2024).

2.2. Örneklemeye Tabanlı Algoritmalar

Bu yaklaşımda ortam, tümüyle taranmak yerine belirli örnek noktalar üzerinden keşfedilir. Bu yöntemler özellikle yüksek boyutlu, karmaşık ve engelli ortamlarda tercih edilir çünkü tüm çözüm uzayının incelenmesi yerine rastgele veya yönlendirilmiş örnekler alınarak yol bulunur. Böylece hesaplama maliyeti düşerken, uygun yol bulma şansı artar

Daha karmaşık ve dinamik ortamlarda kullanılan bu algoritmalar, rastgele veya yönlendirilmiş örneklemeye yöntemleri ile çözüm uzayını tarar. Rapidly-Exploring Random Tree (RRT) ve Probabilistic Roadmap (PRM) bu yöntemlere örnektir. RRT, engellerin yoğun olduğu veya hareketli engellerin bulunduğu durumlarda etkin bir yol planlaması sağlar. PRM ise önceden oluşturulan olasılıksal yol haritaları ile planlama süresini hızlandırır (Sun vd. 2025).

2.3. Yapay Zeka Tabanlı Yaklaşımlar

Yapay zeka tabanlı yöntemler, klasik matematiksel yöntemlerden farklı olarak öğrenme, optimizasyon ve adaptasyon yeteneklerini öne çıkarır. Bu yöntemler genellikle biyolojik sistemlerden, doğa süreçlerinden veya insan öğrenme biçimlerinden esinlenmiştir. Böylece karmaşık, belirsizlik içeren ve sürekli değişen ortamlarda daha başarılı sonuçlar verebilirler.

Son yıllarda makine öğrenmesi ve evrimsel algoritmalar yol planlamasında önemli bir rol üstlenmektedir. Genetik algoritmalar, evrimsel süreçleri taklit ederek çok sayıda alternatif rota arasından en uygununu seçebilir. Parçacık sürü optimizasyonu (PSO) ve karınca kolonisi optimizasyonu (ACO) gibi yöntemler, özellikle çoklu hedefli ve belirsizlik içeren görevlerde etkinlik sağlamaktadır. Ayrıca derin öğrenme tabanlı yöntemler, aracın çevresinden aldığı sensör verilerini işleyerek anlık kararlar verebilmekte, böylece sürekli öğrenen ve uyum sağlayan bir yol planlama mekanizması oluşturulmaktadır (Sun vd. 2021).

Tüm bu teknikler, tek başına ya da hibrit yaklaşımlar şeklinde kullanılabilir. Örneğin A* algoritmasının başlangıç rotasını belirlediği, ardından genetik algoritmanın bu rotayı optimize ettiği hibrit sistemler geliştirilmiştir. Bu sayede hem hesaplama hızından hem de optimizasyon gücünden faydalanmak mümkün olmaktadır. Günümüzde yol planlaması yalnızca matematiksel bir problem olarak değil, aynı zamanda sensör verilerinin bütünleştirildiği, çok disiplinli ve gerçek zamanlı bir optimizasyon süreci olarak ele alınmaktadır.

3. YAPAY ZEKÂ YAKLAŞIMLARI İLE YOL PLANLAMA

Yapay zekâ, makinelerin öğrenme, akıl yürütme, algılama ve karar verme gibi bilişsel süreçleri taklit edebilmesini sağlayan disiplinler arası bir araştırma alanıdır. Geleneksel bilgisayar algoritmaları önceden tanımlanmış kurallara dayalı iken, yapay zekâ sistemleri çevreden elde ettikleri verilerden öğrenebilir, yeni durumlara uyum sağlayabilir ve belirsizlik altında karar verebilir. Bu özellikleri nedeniyle YZ, otonom sistemler ve özellikle OİYA'lar için kritik bir teknolojik bileşen hâline gelmiştir.

Yapay zekâ algoritmaları genel olarak üç ana kategori altında incelenebilir: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Denetimli öğrenmede sistem, girdi-çıkı eşleşmelerine dayalı olarak eğitilir; örneğin bir sinir ağı, su kalitesi parametrelerini sınıflandırmak için kullanılabilir. Denetimsiz öğrenmede ise etiketlenmemiş verilerden kümeler veya gizli yapılar çıkarılır; örneğin göl ortamında sensör verilerinden anomali tespiti yapılabilir. Pekiştirmeli öğrenmede ise bir ajan, çevreyle etkileşimi sonucu ödül ve ceza mekanizmasıyla en uygun davranışı öğrenir; bu yöntem yol planlama ve izleme görevleri için en uygun yaklaşım olarak öne çıkmaktadır.

Bu temel kategorilerin yanında, evrimsel algoritmalar (örneğin Parçacık Sürü Optimizasyonu, Genetik Algoritmalar), doğal sistemlerden ilham alan arama yöntemleridir ve karmaşık optimizasyon problemlerinde başarıyla kullanılmaktadır. Ayrıca BO ve GP gibi olasılıksal yöntemler, belirsizlik altında en iyi çözümleri bulmaya odaklanır. Görsel algıya yönelik derin öğrenme tabanlı yöntemler (YOLO, CNN'ler) ise OİYA'ların çevresindeki nesneleri ve engelleri tanımasını mümkün kılarak yol planlamaya dolaylı katkı sağlar.

Bu algoritmaların OİYA'larda kullanılmasının temel nedeni, görevlerin çoğunun dinamik, belirsiz ve değişken çevre koşullarında gerçekleşmesidir. Akıntılar, rüzgâr, engeller ve ölçüm hataları gibi faktörler, önceden tanımlanmış yolların yetersiz kalmasına neden olur. Yapay zekâ yaklaşımları sayesinde OİYA'lar çevresel verileri işleyebilir, gerçek zamanlı olarak rotalarını güncelleyebilir ve görevlerini daha güvenilir şekilde tamamlayabilir. Dolayısıyla yapay zekâ, yalnızca bir yazılım bileşeni değil, aynı zamanda OİYA'ların otonomisini mümkün kılan temel altyapıdır.

OİYA’larda yol planlama ve izleme, görevlerin başarısı açısından en kritik süreçlerden biridir. Bu süreç, aracın çevresel koşullara uyum sağlayarak en verimli rotayı belirlemesini ve bu rotayı görev süresince güvenilir biçimde izlemesini gerektirir. Geleneksel yöntemler, örneğin grid sistemli tarama desenleri veya önceden tanımlanmış ara nokta rotaları, durağan koşullarda etkili çözümler sunabilse de dinamik çevresel belirsizlikler karşısında çoğu zaman yetersiz kalmaktadır. Bu nedenle son yıllarda yapay zekâ tabanlı algoritmalar, yol planlama ve izleme sürecine entegre edilerek çok daha esnek, uyarlanabilir ve bilgiye dayalı çözümler geliştirilmiştir.

OİYA su kaynaklarını izleme görevleri için kullandığı yol planlama, genellikle problemin karmaşıklığı ve yüksek boyutluluğu nedeniyle Evrimsel Algoritmalar (EA), Parçacık Sürü Optimizasyonu (PSO) veya Derin Pekiştirmeli Öğrenme (DRL) gibi optimizasyon tekniklerine dayanmaktadır. Yol planlama alanındaki çalışmalar, OİYA’lar için engel aşma yeteneğine sahip yollar bulmaya odaklanmıştır (Zhang vd., 2022). DRL, ajanın çevrenin görsel bir temsilini yorumlayan bir Derin Sinir Ağı (DNN) aracılığıyla optimal bir davranış politikası öğrenmesini amaçlar.

Ypacaraí Gölü’nün devriye problemi, homojen ve homojen olmayan senaryolar için bir Markov Karar Süreci (MDP) olarak formüle edilmiştir. Yanes Luis vd. (2020) tarafından yapılan çalışmada bu problemi çözmek amacıyla Derin Q-Öğrenme (DQL) ve Çift Derin Q-Öğrenme (DDQL) algoritmaları değerlendirilmiştir. DDQL’nin, öğrenme sürecinde DQL’ye kıyasla daha kararlı olduğu ve performansın aniden kötüleşmesine yol açan unutma sorununu ortadan kaldırdığı gözlemlenmiştir. Homojen olmayan durum için, her hücrenin önemine ve son ziyaret edilme süresine dayanan, özel olarak tasarlanmış bir ödül fonksiyonu kullanılmıştır. Ajanın durumunu

temsil etmek için engelleri ve ziyaret edilebilir bölgeleri gösteren bir RGB görüntü temsili kullanılmıştır.

Yanes Luis vd. (2021) bir başka çalışmalarında, Homojen Olmayan Devriye Problemi'ni (NHPP) çözmek için EA ile DDRL yaklaşımlarını karşılaştırmıştır. DDRL, özellikle harita çözünürlüğü ve araç sayısı gibi problem boyutu arttıkça, daha karmaşık senaryolarda EA'dan %50 ila %70 daha iyi verimlilik göstermiştir. Buna karşın, EA'nın daha az hiper-parametreye ihtiyaç duyması ve düşük çözünürlüklü haritalarda daha verimli olması gibi avantajları. DRL yaklaşımları, kararlılık ve yakınsama için öğrenme oranı gibi hassas parametre ayarları gerektirdiği belirtilmektedir.

BO, değerlendirilmesi maliyetli olan bilinmeyen bir fonksiyonun global maksimumunu bulmak için kullanılan ardışık bir optimizasyon yöntemidir. Çevresel izleme bağlamında, BO tipik olarak bir vekil model olarak GP kullanır. GP'ler, su kalitesi değerleri ile göl içindeki konumlar arasındaki ilişkiyi tahmin eden bir regresyon modelidir. GP'lerin temel bir bileşeni olan çekirdek fonksiyonu, girdi değişkenleri arasındaki benzerlik ölçüsünü sağlar. Su kalitesi parametrelerinin su yüzeyinde pürüzsüz ve sürekli bir şekilde değişmesi beklendiği için, genellikle Radyal Temel Fonksiyon (RBF) çekirdeği tercih edilmiştir (Samaniego vd., 2021).

Kathen vd. (2021) tarafından sunulan yaklaşımla, PSO algoritması, PSO bileşenlerine ek olarak, GP vekil modelinin tahminleri olan iki yeni stokastik ivme bileşenini içerecek şekilde genişletilmiştir. Maksimum belirsizliğe sahip alanlara yönlendirerek keşfi teşvik ederken; maksimum kirliliğe sahip alanlara yönlendirerek sömürüyü hedefler. Bu sayede, algoritmanın kirlilik izleme görevinde keşif ve sömürü arasında uygun bir denge kurmasını sağlar. Bu geliştirilmiş yaklaşım,

orijinal PSO ve yalnızca belirsizlik bileşeni içeren GP tabanlı PSO'ya göre daha iyi MSE değerleri elde etmiştir.

Kathen vd. (2022) tarafından yapılan başka bir çalışmada sistem, izleme görevini Keşif ve Sömürü olmak üzere iki faza ayırır. Keşif fazında, OİYA'lar su kalitesi modelinin güvenilir bir ilk tahminini elde etmek için geniş alanı kapsar. Sömürü fazında ise yüksek kirlilik seviyelerine sahip eylem bölgeleri belirlenir ve araçlar bu bölgelere atanır. Bu ikinci fazda, yerel modellerin kendi verileriyle eğitildiği ve sadece sonuçların merkezi sunucuyla paylaşıldığı Federated Learning (FL) tekniği kullanılır. Bu sistem, diğer yol planlayıcılara kıyasla, kirlilik zirvelerini tespit etmede %4000'den fazla iyileşme göstermiştir.

Huang (2020), çoklu OİYA'lar için kimyasal kirlilik kaynağı arama problemi için Infotaxis algoritmasını PSO ile birleştirerek 'PSO-Infotaxis' algoritmasını önermiştir. Infotaxis, ajanı, bilgi entropisindeki tahmini azalmaya göre bir sonraki konuma yönlendirir. Geleneksel Infotaxis, büyük su alanlarında keşif adımı çok küçük kaldığı için verimsizdir. PSO-Infotaxis'te, çoklu OİYA'lar parçacık olarak ele alınır ve her parçacığın hareketi, kendi geçmiş deneyiminden ve grup bilgisinden öğrenerek ayarlanır. Bu melez yaklaşım, temel Infotaxis'e göre kaynak olasılığını daha hızlı artırır ve keşif adımlarını %75 oranında azaltır. Evrimsel Algoritmalar, biyolojik evrimden esinlenen ve yolu optimize etmek için kullanılan meta-sezgisel yaklaşımlardır. Bu algoritmalar, su izleme görevleri için global yol planlama problemini çözmek amacıyla kullanılmaktadır. Literatürde kullanılan algoritmalar ve kullanım amaçları Tablo 1'de yer almaktadır.

Tablo 1. Yol planlaması için kullanılan algoritmalar

Referans	Algoritma / Yaklaşım	Uygulama Alanı
Yanes Luis vd. (2020)	DQL / DDQL (CNN tabanlı)	OİYA ile Ypacaraí Gölü'nde Homojen ve Homojen Olmayan Devriye Probleminin çözümü.
Huang (2020)	PSO-Infotaxis (Geliştirilmiş Infotaxis + PSO)	İşbirlikçi Çoklu-OİYA'lar kullanılarak göl ortamında kimyasal kirlilik kaynağının aranması.
Samaniego vd. (2021)	BO ve GP (RBF, RQ, Matérn), Uyarlanmış AF'ler (Truncated, Split, Masked)	OİYA ile Ypacaraí Gölü su kaynakları izlemesinde MSE'yi minimize eden IPP (Bilgilendirici Yol Planlama).
Yanes Luis vd. (2021)	DDQL ile -EA	Farklı harita ölçekleri ve OİYA filo boyutları altında Ypacaraí Gölü'ndeki NHPP analizi.
Kathen vd. (2021)	EGP-PSO (PSO + GP)	OİYA sürüsü kullanarak Ypacaraí Gölü izlemesinde keşif ve sömürü dengesini sağlayan IPP.
Kathen vd. (2022)	AquaFeL-PSO (PSO + GP + FL)	Multimodal kirlilik tespiti ve izleme, FL ile dağıtılmış/merkezi öğrenme yaklaşımı (Ypacaraí Gölü).
Zhang vd. (2022)	Gelişmiş A* Algoritması, Voronoi Diagram	Zamana bağlı akıntı ve rüzgar altında OİYA'nın dinamik enerji verimli yol planlaması.
Qu vd. (2022)	SAE (Sensör Füzyonu)	Kıyı/deniz ortamında anormallik tespiti
Yanes Luis vd. (2023)	Sanstürlenmiş DQL (Q-Censoring)	OİYA için navigasyon kısıtlamalarını Q-Sansürleme ile eleyerek öğrenme verimliliğini artıran (Entropi Minim.) IPP.
Pose vd. (2023)	AI Hazırlıklı İzleme (Multibeam Echo Sounder, Fotogrametri)	OİYA ile otonom tatlı su izleme, batimetrik haritalama ve deniz tabanı tespiti.
Usman vd. (2023)	MLP, Oversampling (SMOTE, ADASYN, SMOTE+ENN)	AquaDrone OİYA'sı ile toplanan dengesiz su kalitesi verilerinin MLP kullanılarak sınıflandırılması.
Yanes Luis vd. (2024)	DDQL (Çok Ajanlı), Yerel GP	Çok ajanlı OİYA filoları için Local GP kullanarak su kalitesi ve yosun patlaması (Algae Bloom) izlemesinde bilgi toplama.
Díaz vd. (2024)	YOLOv5 (Görsel Algı), GP	OİYA prototipinde yapay zekâ uygulamaları için platform mimarisi; makro-plastik tespiti ve su kalitesi izleme.
Haijoub vd. (2024)	Gelişmiş YOLOv8 (CNN)	OİYA'lar için gömülü sistemlerde gelişmiş deniz gözetimi ve obje (gemi) tespiti.

4. SONUÇ

Otonom insansız yüzey araçları, su kaynaklarının izlenmesi, çevresel sürdürülebilirliğin sağlanması ve güvenli navigasyon gibi kritik görevlerde giderek daha fazla önem kazanmaktadır. Bu araçların başarısında yol planlama ve izleme süreçleri temel bir rol üstlenmektedir. Yapay zekâ tabanlı teknikler, klasik yöntemlerin ötesine geçerek dinamik çevre koşullarına uyum sağlama, belirsizlikleri yönetme ve görev verimliliğini artırma açısından güçlü çözümler sunmaktadır. Derin pekiştirmeli öğrenme yöntemleri, karmaşık devriye görevlerinde adaptif karar mekanizmalarıyla öne çıkarken; Bayesian optimizasyon ve Gaussian Process tabanlı yaklaşımlar, daha az ölçümle daha güvenilir tahminler üreterek bilgiye dayalı yol planlamasında önemli katkılar sağlamaktadır. Evrimsel algoritmalar ise küresel optimuma yakın çözümleri hızlı biçimde bulma kapasiteleriyle geniş ölçekli görevlerde tercih edilmektedir.

Bununla birlikte, bu yöntemlerin sahadaki uygulanabilirliği hâlen çeşitli sınırlamalarla karşı karşıyadır. Gerçek zamanlı hesaplama yükü, sensör verilerinin gürültüsü ve algoritmaların izah eksikliği, araştırmacıları yeni hibrit çözümler geliştirmeye yöneltmektedir. Mevcut eğilimler, daha hafif ve şeffaf yapay zekâ modellerinin geliştirilmesi, veri işleme süreçlerinin iyileştirilmesi ve sahaya uygun çevrim içi adaptif planlama mekanizmalarının oluşturulması gerektiğini göstermektedir.

Sonuç olarak, otonom insansız yüzey araçlarında yapay zekâ tabanlı yol planlama ve izleme, yalnızca teknolojik bir yenilik değil, aynı zamanda su kaynaklarının korunması, çevresel risklerin azaltılması ve sürdürülebilirlik hedeflerine ulaşılması için stratejik bir gereklilik hâline gelmiştir. Bu alandaki çalışmaların hızla artması, gelecekte otonom sistemlerin daha

güvenilir, verimli ve yaygın biçimde kullanılmasının önünü açacaktır. Böylece otonom yüzey araçları, çevre mühendisliği, su yönetimi ve deniz teknolojileri kesişiminde önemli bir dönüm noktası olarak konumlanacaktır.

KAYNAKLAR

- Haijoub, A., Hatim, A., Hammia, S., Eloualkadi, A., Chougali, K., & Arioua, M. (2024). Enhanced YOLOv8 ship detection empower unmanned surface vehicles for advanced maritime surveillance.
- Huang, X. (2020). Improved 'Infotaxis' algorithm-based cooperative multi-USV pollution source search approach in lake water environment. *Symmetry*, 12(4), 549.
- Kathen, M. J. T., Jurado Flores, I., & Gutiérrez Reina, D. (2021). An informative path planner for a swarm of ASVs based on an enhanced PSO with Gaussian surrogate model components intended for water monitoring applications. *Electronics*, 10(13), 1605.
- Kathen, M. J. T., Johnson, P., & Flores, I. J. (2022). AquaFeL-PSO: A monitoring system for water resources using autonomous surface vehicles based on multimodal PSO and federated learning. arXiv preprint arXiv:2211.15217.
- Meng, X., & Fang, X. (2024). A UGV path planning algorithm based on improved A* with improved artificial potential field. *Electronics*, 13(5), 972.
- Pose, S., Reitmann, S., Licht, G. J., Grab, T., & Fieback, T. (2023). AI-prepared autonomous freshwater monitoring and sea ground detection by an autonomous surface vehicle. *Remote Sensing*, 15(3), 860.
- Qadir, M. I., Mumtaz, R., Manzoor, M., Saleem, M., Khan, M. A., & Charlesworth, S. (2024). Unmanned surface vehicle for intelligent water quality assessment to promote sustainable human health. *Water Supply*, 24(7), 2259–2270. <https://doi.org/10.2166/ws.2024.141>

- Qin, H., Shao, S., Wang, T., Yu, X., Jiang, Y., & Cao, Z. (2023). Review of autonomous path planning algorithms for mobile robots. *Drones*, 7(3), 211.
- Samaniego, F., Gutiérrez Reina, D., Toral Marín, S. L., Arzamendia, M., & Gregor, D. O. (2021). A Bayesian optimization approach for water resources monitoring through an autonomous surface vehicle: The Ypacarai lake case study. *IEEE Access*, 9, 9163–9179.
- Sun, Y., Luo, X., Ran, X., & Zhang, G. (2021). A 2D optimal path planning algorithm for autonomous underwater vehicle driving in unknown underwater canyons. *Journal of Marine Science and Engineering*, 9(3), 252.
- Sun, Z., Xia, B., Xie, P., Li, X., & Wang, J. (2025). NAMR-RRT: Neural Adaptive Motion Planning for Mobile Robots in Dynamic Environments. *IEEE Transactions on Automation Science and Engineering*.
- Usman, M., Mumtaz, R., Anwar, H., Mujahid, M., & Khalid, A. (2023). Unmanned surface vehicle for intelligent water quality assessment to promote sustainable human health. *Water Supply*, 24(7), 2263.
- Wilson, B., Singh, A., & Sethi, A. (2022). Shallow water bathymetry survey using an autonomous surface vehicle. *Indian Institute of Technology Bombay*.
- Yanes Luis, S., Gutiérrez-Reina, D., & Toral Marín, S. (2021). A dimensional comparison between evolutionary algorithm and deep reinforcement learning methodologies for autonomous surface vehicles with water quality sensors. *Sensors*, 21(8), 2862.
- Yanes Luis, S., Gutiérrez Reina, D., & Toral Marín, S. L. (2020). A deep reinforcement learning approach for the patrolling problem of water resources through autonomous surface

vehicles: The Ypacarai lake case. IEEE Access, 8, 204076–204093.

Zhang, T., Shen, T., Yuan, K., Xue, K., & Qian, H. (2022). A Novel Autonomous Robotics System for Aquaculture Environment Monitoring. arXiv preprint arXiv:2211.00917.

Zhang, Y., Shi, G., & Liu, J. (2022). Dynamic energy-efficient path planning of unmanned surface vehicle under time-varying current and wind. Journal of Marine Science and Engineering, 10(6), 759.

DERİN ÖĞRENME YÖNTEMLERİ İLE BUĞDAY YAPRAK HASTALIKLARININ OTOMATİK TESPİTİ

Dilan ÖZBİLGİ¹

Alper Talha KARADENİZ²

Zafer CÖMERT³

Muammer TÜRKOĞLU⁴

1. GİRİŞ

Buğday (*Triticum aestivum* L.), dünya genelinde milyarlarca insanın temel kalori ve protein kaynağıdır (Food and Agriculture Organization, 2022). Ancak artan nüfus, iklim değişikliği ve hem biyotik hem de abiyotik stres faktörleri üretimi ciddi biçimde etkilemektedir (Özdemir Dirik & Sakin, 2025). Biyotik stres faktörleri arasında özellikle fungal hastalıklar öne çıkmaktadır. Buğday patlaması, yaprak yanıklığı, fusarium ayak çürümesi ve siyah nokta, sık görülen ve ciddi ürün kayıplarına neden olan önemli hastalıklardır (Shahbaz ve ark., 2021).

¹ Yüksek Lisans Öğrencisi, Samsun Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Yazılım Mühendisliği Bölümü, 240708003@samsun.edu.tr, ORCID: 0009-0009-2968-2125

² Doktor Öğretim Üyesi, Samsun Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Yazılım Mühendisliği Bölümü, alper.karadeniz@samsun.edu.tr, ORCID: 0000-0003-4165-3932.

³ Doçent Doktor, Samsun Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Yazılım Mühendisliği Bölümü zcomert@samsun.edu.tr, ORCID: 0000-0001-5256-7648.

⁴ Doçent Doktor, Samsun Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Yazılım Mühendisliği Bölümü, muammer.turkoglu@samsun.edu.tr, ORCID: 0000-0002-2377-4979.

Bu hastalıklar farklı koşullarda epidemi yapabilmekte ve önemli verim kayıpları oluşturabilmektedir. Örneğin buğday patlaması sıcak ve nemli bölgelerde hızla yayılırken (Bandyopadhyay & Manickavelu, 2022), yaprak yanıklığı toprak ve tohumda uzun süre canlı kalabilmektedir (Dubin & Duveiller, 2000). Fusarium ayak çürüklüğü serin ve nemli ortamlarda şiddetli epidemilere yol açarken (Fernandez & Chen, 2005), siyah nokta ise hem pazarlanabilirliği hem de un kalitesini düşürmektedir (Mishra ve ark., 2020). Benzer semptomlar göstermeleri nedeniyle doğru teşhis çoğu zaman zordur. Gecikmiş tanı, yalnızca verim değil kalite kayıplarına da yol açmakta ve hızlı, güvenilir otomatik sistemlere ihtiyacı artırmaktadır (Mahlein ve ark., 2020).

Son yıllarda yapay zekâ ve bilgisayarla görme teknolojileri, tarımsal hastalık teşhisinde önemli fırsatlar sunmaktadır. Özellikle derin öğrenme tabanlı CNN mimarileri, manuel özellik çıkarımı gerektirmeden yüksek doğruluk sağlamaktadır (Sladojevic ve ark., 2016). Transfer öğrenme sayesinde büyük veri kümeleri üzerinde eğitilmiş modeller, tarımsal verilerde de başarıyla kullanılabilir ve mobil cihazlarla sahaya entegre edilebilmektedir (Zhang ve ark., 2020; Vignesh ve ark., 2023). Ayrıca sağlıklı ve hastalıklı dokuların güvenilir biçimde ayrılması, bu sistemlerin pratik başarısını artırmaktadır (Rauf ve ark., 2021). Modellerin doğal koşullarda test edilmesi ise saha uyumluluğu açısından kritik önemdedir (Wang ve ark., 2022).

Bölgesel patojen çeşitliliği de sistemlerin başarısını etkileyebilmektedir. Örneğin Trakya'da Fusarium spp. kaynaklı çürüklüklerin %100'e varan oranlarda görülebildiği ve çeşitler arasında direnç farklılıkları bulunduğu rapor edilmiştir (Köycü & Özer, 2019).

Bu çalışma kapsamında, sahadan elde edilmiş görüntülerden oluşan beş sınıflı bir buğday yaprağı veri kümesi üzerinde çeşitli CNN mimarilerinin performansı değerlendirilmiştir. ResNet50, ResNet101, VGG16, VGG19, MobileNet, EfficientNetB0, DenseNet121, ConvNeXt-Tiny, InceptionV3 ve Xception mimarileri önceden eğitilmiş ağırlıklarla test edilmiş; doğruluk, F1 skoru, hassasiyet ve geri çağırma metrikleri kullanılarak karşılaştırılmıştır. Bulgular, tarımsal karar destek sistemlerinde uygun model seçimi için yol gösterici niteliktedir.

2. LİTERATÜR TARAMASI

Son yıllarda buğday yaprak hastalıklarının sınıflandırılmasında derin öğrenme tabanlı yöntemler yaygınlaşmış, farklı CNN mimarileri ve transfer öğrenme teknikleri yüksek doğruluk oranlarıyla öne çıkmıştır (Kamilaris & Prenafeta-Boldú, 2018; Rauf ve ark., 2021; IEEE, 2023).

2010 öncesinde RGB görüntüler HSV dönüşümü, eşikleme ve bölütleme gibi işlemlerden geçirilerek öznitelikler çıkarılmış ve SVM veya karar ağaçlarıyla sınıflandırılmıştır. Ancak bu yöntemler, segmentasyon bağımlılığı nedeniyle karmaşık görüntülerde yetersiz kalmıştır (Shahbaz ve ark., 2021).

Günümüzde CNN'ler otomatik öznitelik çıkarma yetenekleriyle öne çıkmakta; bazı çalışmalarda ise CNN'den elde edilen özellikler SVM gibi yöntemlerle hibrit modellerde kullanılmaktadır. Örneğin, SVM tabanlı hibrit bir model PlantVillage veri setinde %98'in üzerinde doğruluk sağlamıştır (Rauf ve ark., 2021).

Mobil cihazlarla gerçek zamanlı tespit de önem kazanmıştır. Ahmad & Khan (2021), VGG16 modeliyle %98,95 doğruluk elde etmiş, ancak hesaplama maliyetlerinin azaltılması

gerektiğini vurgulamıştır (Mishra ve ark., 2019). Transfer öğrenme ise sınırlı verilerde avantaj sağlamış, ImageNet üzerinde eğitilmiş modellerin uyarlanmasıyla yüksek başarı elde edilmiştir (Albahli & Mohammed, 2020; Vignesh ve ark., 2023). Ayrıca topluluk yöntemleri tekil modellere üstünlük göstermiştir (Rauf ve ark., 2022).

RGB'nin yanı sıra hiperspektral görüntüleme ve spektral yansıma analizleri de kullanılmakta, erken teşhis imkânı sunmasına rağmen yüksek maliyet oluşturmaktadır (Mahlein ve ark., 2020; Mishra ve ark., 2019).

Shahbaz ve ark. (2021), CNN tabanlı modellerin klasik yöntemlerden daha başarılı olduğunu, ancak veri çeşitliliği, etiketleme ve gerçek zamanlı uygulamalarda sorunların sürdüğünü bildirmiştir. Benzer şekilde Malik ve ark. (2021), model optimizasyonu ve cihaz uyumluluğuna dikkat çekmiştir. Ayrıca bazı çalışmalar, başak hastalıklarını da kapsayarak farklı gelişim evrelerinde gözlem yapılabilmesini sağlamaktadır (Wu ve ark., 2022).

Genel olarak, derin öğrenme tarımda hastalık tespitinde yüksek potansiyel taşımakta; ancak saha uyumluluğu, veri standardizasyonu ve kullanıcı dostu sistemler geliştirilmesi hâlen öncelikli araştırma alanlarıdır.

3. MATERYAL VE METOD

3.1. Veri Kümesi

Çalışmanın deneysel sürecinde, buğday yaprağı hastalıklarının sınıflandırılmasında kullanılmak üzere Bangladeş'teki buğday tarlalarından toplanan ve Mendeley Data platformunda yayımlanan "Disease Dataset of Wheat: Original, Augmented, and Balanced for Deep Learning" veri kümesinin orijinal görüntüleri kullanılmıştır (Rahman ve ark., 2023). Veri

kümesi, beş farklı sınıfa ait toplam 1.603 yüksek çözünürlüklü (1920×1080 piksel) görüntü içermektedir. Çalışmada kullanılan buğday yaprak hastalıkları veri setindeki sınıf dağılımı ve her sınıfa ait görüntü sayısı Tablo 1’de gösterilmiştir.

Tablo 1. Buğday yaprak hastalıkları veri kümesinin sınıf dağılımı

Sınıf Adı	Görüntü Sayısı
Buğday Patlaması (<i>Wheat Blast</i>)	400 görüntü
Sağlıklı Yaprak (<i>Healthy Leaf</i>)	250 görüntü
Siyah Nokta (<i>Black Point</i>)	303 görüntü
Yaprak Yanıklığı (<i>Leaf Blight</i>)	400 görüntü
Fusarium Ayak Çürümesi (<i>Fusarium Foot Rot</i>)	250 görüntü

Veri setindeki çeşitli hastalık sınıflarına ait örnek görseller Şekil 1’de sunulmuştur.



Şekil 1. Farklı hastalık sınıflarını temsil eden örnek yaprak görüntüleri

Görüntüler, doğal ışık koşullarında sahada çekilmiş olup, çeşitli açılar ve yaprak pozisyonlarını içermektedir. Bu çalışma

kapsamında ham görüntüler kullanılmıştır. Veri kümesi, eğitim (%70), doğrulama (%10) ve test (%20) olmak üzere üç alt kümeye ayrılmıştır. Görüntüler, derin öğrenme modellerine uygun hale getirilmek üzere 224×224 piksel boyutlarına yeniden ölçeklendirilmiş ve piksel değerleri [0,1] aralığına normalize edilmiştir.

3.2. Derin Öğrenme Mimarileri

Model karşılaştırmalarında toplamda on farklı evrişim tabanlı derin öğrenme mimarisi kullanılmıştır. Bu mimarilerin tamamı ImageNet üzerinde önceden eğitilmiş ağırlıklarla başlatılmış ve son katmanları yeniden düzenlenerek beş sınıflı buğday hastalığı sınıflandırması görevine uyarlanmıştır.

3.2.1. ResNet50 ve ResNet101

Derin katmanlı sinir ağlarında sıklıkla karşılaşılan gradyan sönümlenmesi problemini aşmak amacıyla geliştirilen ResNet mimarileri, artık bağlantılar (residual connections) içeren blok yapısıyla öne çıkar (He ve ark., 2016). Bu blokların matematiksel gösterimi Denklem 1’de verilmiştir:

$$y = F(x, \{W_i\}) + x \quad (1)$$

Burada F , öğrenilmesi gereken dönüşüm fonksiyonu olup,

x giriş vektörünü ve $\{W_i\}$ model parametrelerini temsil eder. Bu yapı hem bilgi kaybını azaltmakta hem de daha derin ağların eğitilebilirliğini kolaylaştırmaktadır (He ve ark., 2016). Aynı prensibe dayanan bir residual blok yaklaşımı, Karadeniz ve ekibi tarafından ceviz yaprağı sınıflandırmasında da etkili biçimde kullanılmıştır (Karadeniz ve ark., 2021). Benzer şekilde, Cömert’in yürüttüğü çalışmalarda da derin mimarilerin sınıflandırma performansı üzerindeki etkisi detaylı olarak incelenmiştir (Cömert & Kocamaz, 2020).

3.2.2. EfficientNet

EfficientNet, ağ genişliği, derinliği ve çözünürlüğünü eşzamanlı olarak optimize eden bileşik ölçekleme (compound scaling) stratejisini kullanır (Tan & Le, 2019). Bu üç faktörün ϕ hiperparametresi ile dengelenmesini sağlayan formül Denklem 2’de verilmiştir:

$$depth \propto \alpha\phi, width \propto \beta\phi, resolution \propto \gamma\phi \quad (2)$$

Burada α, β, γ , katsayıları deneysel olarak belirlenirken, ϕ ölçekleme bütçesini ifade eder (Tan & Le, 2019).

3.2.3. VGG16 ve VGG19

VGG mimarileri, 3×3 boyutundaki küçük filtreler kullanarak derin ağ yapıları oluşturur (Simonyan & Zisserman, 2015). Temel evrişim işlemi Denklem 3’te gösterilmiştir:

$$Conv(x) = \sum_{i=1}^k w_i \cdot x_i + b \quad (3)$$

Burada x_i giriş aktivasyonları, w_i filtre ağırlıkları ve b bias terimidir. VGG16 ve VGG19 arasındaki temel fark, katman sayısının artışıdır (Simonyan & Zisserman, 2015).

3.2.4. MobileNet

Mobil cihazlar için optimize edilmiş MobileNet mimarisi, standart evrişimleri iki ayrı işlem olarak ayırır: derinlik ayrık evrişim (depthwise convolution) ve 1×1 noktasal evrişim (pointwise convolution) (Howard ve ark., 2017). Bu yapı Denklem 4’te gösterilmiştir:

$$DSConv(x) = DepthwiseConv(x) + PointwiseConv(x) \quad (4)$$

Toplam işlem maliyeti Denklem 5 ile tanımlanır:

$$\begin{matrix} D^2 & \cdot & M & \cdot & D^2 & + & M & \cdot & N & \cdot & D^2 \\ K & & & & & & F & & & & F \end{matrix} \quad (5)$$

Burada D_K : filtre boyutu, M : giriş kanalı sayısı, N : çıkış kanalı sayısı, D_F : çıktı boyutudur (Howard ve ark., 2017).

3.2.5. DenseNet121

DenseNet mimarisi, her bir katmanın çıktısını tüm sonraki katmanlara aktararak parametre verimliliğini ve gradyan akışını iyileştirir (Huang ve ark., 2017). Bir katmandaki çıkış Denklem 6'da tanımlanmıştır:

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (6)$$

Burada $[x_0, \dots, x_{l-1}]$ önceki tüm katmanların birleşik çıktısını, H_l ise bu birleşim üzerine uygulanan dönüşüm fonksiyonunu ifade eder (Huang ve ark., 2017).

3.2.6. ConvNeXt-Tiny

ConvNeXt, klasik CNN yapısını modernleştirerek geniş çekirdekli evrişim (7×7), GELU aktivasyon fonksiyonu, tersine çevrilmiş dar boğaz (inverted bottleneck) ve LayerNorm gibi bileşenleri kullanır (Liu ve ark., 2022). Bu yapının genel ifadesi Denklem 7'de verilmiştir:

$$y = \text{LayerNorm}(\text{GELU}(\text{Conv}_{7 \times 7}(x))) \quad (7)$$

Transformer mimarilerinden ilham alan bu yapı, konvolüsyonel modellerin yeniden rekabetçi olmasını sağlamıştır (Liu ve ark., 2022). Cömert ve Türkoğlu'nun bitki hastalıkları üzerinde gerçekleştirdiği çalışmalarda, bu tür modern CNN mimarilerinin sınıflandırma başarısına olan katkısı vurgulanmıştır (Cömert & Türkoğlu, 2020).

3.2.7. Xception

Xception mimarisi, derinlik ayrık evrişimleri sistematik biçimde kullanan bir yaklaşımdır (Chollet, 2017). Bu yapı Denklem 8'de gösterilmiştir.

$$DSConv(x) = \text{DepthwiseConv}(x) + \text{PointwiseConv}(x) \quad (8)$$

Bu yaklaşım, parametre verimliliğini artırırken modelin doğruluk performansını korur (Chollet, 2017).

3.2.8. InceptionV3

Inception mimarisi, çok ölçekli bilgi çıkarımı amacıyla 1×1 , 3×3 ve 5×5 evrişim çekirdeklerini paralel olarak kullanır (Szegedy ve ark., 2016). Paralel yapıların çıktısı Denklem 9'da tanımlanmıştır

$$Output = Concat(Conv_{1 \times 1}(x), Conv_{3 \times 3}(x), Conv_{5 \times 5}(x), MaxPool(x)) \quad (9)$$

Ayrıca model, yardımcı sınıflandırıcılar ve toplu normalizasyon gibi tekniklerle donatılmıştır (Szegedy ve ark., 2016).

3.3. Performans Metrikleri

3.3.1. Doğruluk(accuracy)

Doğruluk, modelin tüm tahminleri içinde doğru sınıflandırdığı örneklerin oranını ifade eder. Genellikle genel başarıyı değerlendirmek için kullanılır. Bu metrik, Denklem 10'da gösterilmiştir (Sokolova & Lapalme, 2009):

$$Accuracy = \frac{TP+TN}{TP + TN + FP + FN} \quad (10)$$

3.3.2. Kesinlik (precision)

Kesinlik, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Bu metrik, Denklem 11'de gösterilmiştir (Sokolova & Lapalme, 2009):

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

3.3.3. Duyarlılık (recall)

Duyarlılık, gerçek pozitif örneklerin ne kadarının model tarafından doğru tahmin edildiğini gösterir. Bu metrik, Denklem 12'de gösterilmiştir (Sokolova & Lapalme, 2009):

3.3.4. F1Skoru (F1-score)

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır ve özellikle sınıf dengesizliğinin olduğu durumlarda kullanılır. Bu metrik, Denklem 13'te gösterilmiştir (Sokolova & Lapalme, 2009):

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

4. DENEYSEL ÇALIŞMALAR

Derin öğrenme tabanlı görüntü sınıflandırma yaklaşımlarının tarımsal hastalık tanısındaki etkinliğini değerlendirmek amacıyla, bu çalışmada farklı konvolüsyonel sinir ağı (CNN) mimarileri karşılaştırmalı olarak analiz edilmiştir. Model performansları, sınıflandırma doğruluğu temel alınarak test edilmiştir ve elde edilen sonuçlar, mimari tercihlerinin tarımsal tanı sistemlerinin başarısı üzerindeki etkisini ortaya koymaktadır.

Çalışma kapsamında, veri kümesindeki tüm görüntüler, modelin giriş boyutlarına uyumlu hale getirilmek amacıyla 224×224 piksele yeniden ölçeklendirilmiş, piksel değerleri [0,1] aralığında normalize edilmiştir. Etiketler, LabelEncoder yöntemiyle sayısal değerlere dönüştürülmüş ve ardından to_categorical ile one-hot vektörlere çevrilmiştir. Modelin sınıf dengesizliğinden etkilenmemesi adına, sınıfların dağılımları StratifiedKFold yöntemi ile her katlamada (fold) eşit olacak

şekilde düzenlenmiştir. Bu kapsamda beş katmanlı çapraz doğrulama (5-fold cross-validation) uygulanmış ve her fold için modelin doğruluk ve F1 skoru hesaplanmıştır.

Model mimarileri olarak, transfer öğrenme yaklaşımıyla aşağıdaki önceden eğitilmiş CNN tabanlı modeller kullanılmıştır: VGG16 ve VGG19 (Simonyan & Zisserman, 2015), ResNet50 ve ResNet101 (He ve ark., 2016), MobileNet (Howard ve ark., 2017), EfficientNetB0 (Tan & Le, 2019), DenseNet121 (Huang ve ark., 2017), ConvNeXt-Tiny (Liu ve ark., 2022), Xception (Chollet, 2017) ve InceptionV3 (Szegedy ve ark., 2016). Bu modellerin tamamı ImageNet veri kümesi üzerinde eğitilmiş ağırlıklarla başlatılmış ve son sınıflandırma katmanları çıkarılarak yerine buğday hastalıkları için özelleştirilmiş sınıflandırıcı eklenmiştir. Modellerin son katmanlarında yalnızca GlobalAveragePooling2D ve softmax aktivasyonuna sahip bir Dense katman kullanılmıştır. Bu yapı, eğitim parametrelerinin azaltılarak aşırı öğrenmenin önlenmesini sağlamıştır.

Model eğitimi için kullanılan hiper parametreler Tablo 2’de gösterilmiştir.

Tablo 2. Model eğitimi için kullanılan hiper parametreler

Hiperparametre	Değer	Açıklama
Optimizasyon Algoritması	Adam	Ağırlıkları güncellemek için kullanılan algoritma
Öğrenme Oranı	0.0001	Ağırlıkların her adımda ne kadar değişeceğini belirler
Epoch Sayısı	500	Modelin eğitim verileri üzerinde kaç kez eğitileceğini belirtir.
Yığın Boyutu	16	Her güncellemede kullanılan örnek sayısı
Kayıp Fonksiyonu	Kategorik Çapraz Entropi	Çok sınıflı sınıflandırmada kullanılan kayıp fonksiyonu
Erken Durdurma Eşiği	75	Doğrulama kaybı gelişmezse eğitimin duracağı epoch sayısı
ReduceLROnPlateau Eşiği	50	Öğrenme oranı düşmeden önceki bekleme süresi
ReduceLROnPlateau Faktörü	0.5	Öğrenme oranını azaltmak için kullanılan çarpan.
Minimum Öğrenme Oranı	1e-6	Öğrenme oranının düşebileceği en düşük seviye.
Kat Sayısı	5	Veri setinin kaç katlı çapraz doğrulamaya bölüneceğini belirtir
Doğrulama Oranı	0.1111	Eğitim verisinden ayrılan doğrulama verisinin oranı


Karşılaştırmalı deneysel analiz sonucunda, farklı derin öğrenme tabanlı CNN mimarilerinin ortalama doğruluk ve F1 skoru performansları Tablo 3'te sunulmuştur.

Tablo 3. Kullanılan CNN modellerinin performans karşılaştırması


Model Adı	Ortalama Doğruluk	Ortalama F1 Skoru
EfficientNetB0	0.9892	0.9892
ResNet50	0.9851	0.9851
ResNet101	0.9864	0.9864
ConvNeXt- Tiny	0.9831	0.9830
DenseNet121	0.9776	0.9776
Vgg16	0.9763	0.9762
Vgg19	0.9675	0.9672
MobileNet	0.9580	0.9578
Xception	0.8841	0.8834
InceptionV3	0.8488	0.8470

Modelleme sürecinin tamamı, Python programlama dili kullanılarak yürütülmüştür. TensorFlow ve Keras kütüphaneleri ile geliştirilen derin öğrenme modelleri, eğitim sürecinde yüksek doğruluk değerlerine ulaşmış, görselleştirme işlemleri için ise Matplotlib ve Seaborn kütüphanelerinden yararlanılmıştır. ROC eğrileri ve karışıklık matrisleri aracılığıyla her bir sınıfın duyarlılığı, özgüllüğü ve sınıflar arası hata durumu detaylı biçimde analiz edilmiştir.

Deneysel çalışmalar sonucunda en yüksek başarıya EfficientNetB0 modeli ulaşmıştır. Bu modele ait karışıklık matrisi ve ROC eğrisi sırasıyla Şekil 2 ve Şekil 3'te sunulmuştur.



Şekil 2. Karışıklık matrisi



Şekil 3. ROC eğrisi

5. TARTIŞMA

Elde edilen bulgular, buğday yaprak hastalıklarının sınıflandırılmasında farklı CNN tabanlı derin öğrenme modellerinin performansını karşılaştırmalı olarak değerlendirme imkânı sunmuştur.

Literatürde önerilen farklı derin öğrenme ve makine öğrenmesi tabanlı yaklaşımların doğruluk oranları ve kullanılan veri setleriyle birlikte karşılaştırmalı bir özeti Tablo 4'te verilmiştir.

Tablo 4. Literatürde kullanılan modellerin doğruluk oranları ve veri setleri

Yazar	Model Türü	Doğruluk (%)	Veri Seti
Rauf ve ark. (2021)	DeepFeature-SVM Hybrid	98.7%	PlantVillage
Vignesh ve ark. (2023)	Attention CNN	98.2%	Custom dataset
Ahmad & Khan (2021)	CNN (Mobile)	95.9%	PlantVillage
Albahli & Mohammed (2020)	Deep Features + Classifier	98.4%	Wheat fungi images
Rauf ve ark. (2022)	Integrated DL + Ensemble	97.5%	Wheat leaves
Wang ve ark. (2022)	Various Models	DL 96.7%	Wheat leaves
Wu ve ark. (2022)	YOLOv3 Improved	94.6%	Wheat leaf & spike
Zhang ve ark. (2020)	Traditional ML	93.4%	Image-based crop images
IEEE (2023)	ResNet50	97.1%	Real-time plant disease dataset
Kamilaris & Prenafeta- Boldú (2018)	CNN (survey)	Varies	Çeşitli
Bu çalışma	CNN (EfficientNetB0 en başarılı)	98.92%	Wheat Disease Dataset (Mendeley Data, 2025)

Literatür taraması tablosu, farklı araştırmalarda kullanılan derin öğrenme tabanlı modellerin doğruluk oranları ve veri setlerine göre karşılaştırmalı bir özeti sunmaktadır. Tablo, özellikle hibrit yaklaşımların (örneğin, DeepFeature-SVM; Rauf ve ark., 2021) ve dikkat mekanizmaları içeren modellerin (Attention CNN; Vignesh ve ark., 2023) yüksek doğruluklara ulaştığını göstermektedir. Ayrıca, CNN tabanlı mobil çözümlerin (Ahmad & Khan, 2021) ve entegrasyon odaklı derin öğrenme modellerinin (Rauf ve ark., 2022) de yüksek başarı sağladığı görülmektedir. Bu bulgular, çalışmamızda elde edilen sonuçlarla

örtüşmekte ve modern mimarilerin buğday yaprak hastalıklarının sınıflandırılmasında etkili olduğunu desteklemektedir.

6. SONUÇ VE ÖNERİLER

Buğday, dünya genelinde temel gıda kaynaklarından biri olup, üretim sürecinde karşılaşılan hastalıklar verimliliği ciddi ölçüde tehdit etmektedir. Bu çalışma kapsamında geliştirilen derin öğrenme tabanlı sınıflandırma modelleri, buğday yaprak hastalıklarının otomatik ve doğru bir şekilde tespitinde yüksek başarı göstermiştir. Elde edilen bulgular, gelecekte geliştirilecek mobil uygulamalar aracılığıyla çiftçilerin erken müdahale imkânına kavuşmasını ve hastalık yönetiminde dijital çözümlerden etkin biçimde yararlanılmasını mümkün kılacaktır.

KAYNAKÇA

- Ahmad, A., & Khan, Z. (2021). Automatic plant disease diagnosis using mobile devices. *Applied Soft Computing*, 103, 107180. <https://doi.org/10.1016/j.asoc.2021.107180>
- Albahli, S., & Mohammed, M. A. (2020). Image-based wheat fungi diseases identification using deep features. *International Journal of Advanced Computer Science and Applications*, 11(5).
- Bandyopadhyay, R., & Manickavelu, A. (2022). Wheat blast: A disease spreading rapidly and its management strategies. *Plant Pathology Journal*, 38(2), 97–108.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1251 -258). <https://doi.org/10.1109/CVPR.2017.195>
- Cömert, Z. (2020). A hybrid classification model using SVM and CNN-based deep features for plant disease detection. *Computers and Electronics in Agriculture*, 175, 105584. <https://doi.org/10.1016/j.compag.2020.105584>
- Dixit, A., & Nema, S. (2018). Wheat leaf disease detection using machine learning method – A review. *International Journal of Computer Science and Mobile Computing*, 7(5), 124–129.
- Dubin, H. J., & Duveiller, E. (2000). *Helminthosporium leaf blights of wheat: Integrated control and prospects for the future*. CIMMYT.
- Fernandez, M. R., & Chen, Y. (2005). Pathogenicity of Fusarium species on roots of wheat and barley in western Canada. *Canadian Journal of Plant Pathology*, 27(3), 280–287.

- Food and Agriculture Organization. (2022). *FAO statistical yearbook*. Food and Agriculture Organization of the United Nations.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*. <https://doi.org/10.48550/arXiv.1704.04861>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4700–4708). <https://doi.org/10.1109/CVPR.2017.243>
- IEEE. (2023). Real-time plant disease dataset development and detection of plant disease using deep learning. In *Proceedings of ICSSIT 2023*.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Karadeniz, A. T., Çelik, Y., & Başaran, E. (2022). Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model. *European Food Research and Technology*, 248, 1179–1188. <https://doi.org/10.1007/s00217-021-03891-y>

- Köycü, N. D., & Özer, N. (2019). Trakya Bölgesi'nde bazı buğday çeşitlerinin *Fusarium* spp. izolatlarına karşı dayanıklılığın tespit edilmesi. *KSÜ Tarım ve Doğa Dergisi*, 22(4), 498–505. <https://doi.org/10.18016/ksutarimdog.vi.494117>
- Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A ConvNet for the 2020s. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11976–11986). <https://doi.org/10.1109/CVPR52688.2022.01168>
- Mahlein, A. K., Steiner, U., Hillnhütter, C., Dehne, H. W., & Oerke, E. C. (2020). Hyperspectral and chlorophyll fluorescence imaging for early detection of wheat diseases. *Remote Sensing*, 12(2), 273. <https://doi.org/10.3390/rs12020273>
- Malik, A. K., Gill, S. S., Singh, A., et al. (2021). Advancements in smart agriculture: A systematic literature review. *Computers and Electronics in Agriculture*, 185, 106153. <https://doi.org/10.1016/j.compag.2021.106153>
- Mishra, A., Manjunatha, S. B., & Nagaraja, K. (2019). Early disease detection in wheat using spectral reflectance. *Precision Agriculture*, 20(2), 381–395. <https://doi.org/10.1007/s11119-018-9591-7>
- Mishra, V. K., Singh, A., Sharma, A., et al. (2020). Black point disease of wheat: Current status and future research directions. *Journal of Cereal Science*, 95, 103058.
- Mundada, P. R., Malviya, A. V., & Thore, S. N. (2019). Wheat disease detection using image processing. *International Research Journal of Engineering and Technology*, 6(3).
- Özdemir Dirik, K., & Sakin, M. A. (2025). Bazı yerel ekmeklik buğday çeşitlerinin sulu koşullarda ve geç kuraklık stresi

- oluşturulan koşullarda bazı kalite parametrelerinin belirlenmesi. *KSÜ Tarım ve Doğa Dergisi*, 28(4), 1025–1042. <https://doi.org/10.18016/ksutarimdog.vi.1589654>
- Rahman Radowan, M. I., & Ayon, R. (2025). Disease dataset of wheat: Original, augmented, and balanced for deep learning [Data set]. *Mendeley Data*. <https://doi.org/10.17632/5gc7hwydwg.1>
- Rauf, H. T., Lali, M. I. U., Mehmood, F., et al. (2021). Deep feature-SVM based hybrid model for plant disease classification. *IEEE Access*, 9, 62774–62783. <https://doi.org/10.1109/ACCESS.2021.3075109>
- Rauf, H. T., Khan, M. A., Lali, M. I. U., et al. (2022). Integrated deep learning and ensemble learning model for wheat disease classification. *Applied Artificial Intelligence*, 36(1), 2039116. <https://doi.org/10.1080/08839514.2022.2039116>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. <https://doi.org/10.48550/arXiv.1409.1556>
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational Intelligence and Neuroscience*, 2016, 3289801. <https://doi.org/10.1155/2016/3289801>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception architecture for computer vision. In *Proceedings of the IEEE Conference*

- on Computer Vision and Pattern Recognition* (pp. 2818–2826). <https://doi.org/10.1109/CVPR.2016.308>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning* (pp. 6105–6114). <https://doi.org/10.48550/arXiv.1905.11946>
- Türkoğlu, M., & Cömert, Z. (2021). PlantDiseaseNet: Convolutional neural network ensemble for plant disease and pest detection. *Signal, Image and Video Processing*, 15, 1057–1065. <https://doi.org/10.1007/s11760-021-01885-9>
- Vignesh, L., Mohan, R. E., & Rajalakshmi, P. (2023). Optimal features driven attention network for crop disease detection. *Sensors*, 23(10), 4765. <https://doi.org/10.3390/s23104765>
- Wang, X., Yang, L., Wang, B., et al. (2022). Wheat leaf disease identification based on deep learning algorithms. *Computational Intelligence and Neuroscience*, 2022, 6242683. <https://doi.org/10.1155/2022/6242683>
- Wu, J., Zhang, H., Wang, J., et al. (2022). Leaf and spike wheat disease detection using an improved YOLO-based model. *International Journal of Computer Applications*, 184(43), 23–31.
- Zhang, M., Wu, W., Li, Q., & Wang, Y. (2020). Image-based crop disease detection using machine learning. *Computers and Electronics in Agriculture*, 174, 105468. <https://doi.org/10.1016/j.compag.2020.105468>

MAKİNE ÖĞRENMESİ AJANLARININ TEMELLERİ, TÜRLERİ VE KULLANIM ALANLARI

Faruk AYATA¹

Ebubekir SEYYARER²

1. GİRİŞ

Yapay Zekâ (YZ) ve Makine Öğrenmesi (ML), son yıllarda yalnızca akademik araştırmalarda değil, aynı zamanda günlük yaşamın farklı alanlarında da hızlı bir şekilde yaygınlaşarak dönüştürücü bir etki oluşturmaktadır. Bu teknolojilerin en dikkat çekici uygulamalarından biri, ML ajanları olarak adlandırılan, çevreleriyle sürekli etkileşim içinde olan ve deneyimlerinden öğrenerek karar verme süreçlerini geliştiren otonom yazılım sistemleridir. ML ajanları; klasik algoritmalarından farklı olarak yalnızca önceden tanımlanmış kuralları takip etmekle kalmaz, aynı zamanda değişken ve belirsiz ortamlarda algılama (perception), öğrenme (learning), karar verme (decision-making) ve eyleme geçme (action) yeteneklerini bir arada kullanarak uyarlanabilir (adaptif, esnek) çözümler sunar. Bu nedenle ajan tabanlı yaklaşım, özellikle çok boyutlu veri kümelerinde, belirsizlik içeren durumlarda ve gerçek zamanlı karar verme gerektiren senaryolarda kritik bir rol üstlenmektedir. Nitekim Hernandez-Leal ve ark. (2018), çoklu ajanlı pekiştirmeli öğrenme (Multi-Agent Reinforcement Learning - MARL)

¹ Dr. Öğr. Üyesi, Van Yüzüncü Yıl Üniversitesi, Başkale Meslek Yüksekokulu, farukayata@yyu.edu.tr, ORCID: 0000-0003-2403-3192.

² Dr. Öğr. Üyesi, Van Yüzüncü Yıl Üniversitesi, Bilgisayar Mühendisliği Bölümü, eseyyarer@yyu.edu.tr, ORCID: 0000-0002-8981-0266.

üzerine yaptıkları kapsamlı değerlendirme yapmışlardır. Bu çalışmada, MARL sistemlerinin geleneksel yöntemlerle başa çıkılamayan koordinasyon, iş birliği ve rekabet gibi karmaşık problemlerde etkin bir çözüm sunduğunu vurgulamaktadır. Benzer şekilde Dehkordi (2023), Ajan Tabanlı Modelleme (Agent-Based Modelling - ABM) ile ML'nin entegrasyonunun sosyal ve teknik sistemlerde daha gerçekçi simülasyonlar ürettiğini göstermektedir. Tüm bu gelişmeler, ML ajanlarının yalnızca teknik bir yenilik olmanın ötesinde, disiplinler arası problemlerin çözümünde stratejik bir yaklaşım olduğunu ortaya koymaktadır.

Sağlık alanında ML ajanları, hem klinik karar destek hem de tıbbi görüntüleme uygulamalarında umut verici sonuçlar vermektedir. Feng ve ark. (2025), tıbbi görüntüleme için “M³Builder” adını verdikleri çok ajanlı bir sistem geliştirdiler. Bu sistem, dört farklı Büyük Dil Model (Large Language Model – LLM) tabanlı ajanla (veri işleme, ortam hazırlığı, hata ayıklama ve model eğitimi) birlikte çalışarak M³Bench testlerinde %94,29 başarı oranı elde etmektedir. Bu sonuçla tam otomatik ML iş akışlarının sağlıkta uygulanabilirliğini göstermektedir. Benzer şekilde Shaik ve ark. (2023), hasta izleme alanında Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning - DRL) tabanlı çoklu ajan sistemi kurarak kalp ritmi ve solunum gibi hayati verileri gerçek zamanlı analiz ettiler. Bu çalışmada, PPO (Proximal Policy Optimization) ve DDPG (Deep Deterministic Policy Gradient) gibi algoritmalarla yapılan karşılaştırmalarda en yüksek doğruluğu elde ederek klinik erken uyarı sistemlerinde güçlü bir alternatif sunmaktadırlar.

Bilişim sektöründe ajanlar, büyük veri işleme, siber güvenlik ve otonom karar destek sistemlerinde öne çıkmaktadır. Patel ve ark. (2025), klinik karar destek için ajanları “Foundation”, “Assistant”, “Partner” ve “Pioneer” olmak üzere dört sınıfa ayırarak algı, akıl yürütme, hafıza ve etkileşim

bileşenlerini kapsayan bir mimari önerdiler; bu yapı doğrudan başarı oranı vermese de sağlık bilişiminde güvenilir ajan tasarımları için yol haritası sunmaktadır. Yong ve Brintrup (2021) ise siber-fiziksel üretim sistemlerinde olasılıksal makine öğrenimi ile çoklu ajan sistemlerini birleştirip BNN (Bayesian Neural Networks) kullanarak belirsizlik altında karar almayı sağladılar; gerçek zamanlı hidrolik sistem testlerinde doğruluk değerleri açıklanmasa da güvenilirlik ve hata toleransında kayda değer iyileşme gösterilmektedir.

Endüstride ise özellikle akıllı fabrikalar ve önleyici bakım uygulamaları dikkat çekmektedir. Rodríguez ve ark. (2022), üretim hatlarında Tahmine Dayalı Bakım (Predictive Maintenance) için Çoklu Ajan Derin Pekiştirmeli Öğrenme (MARL-DRL) tabanlı bir sistem kurarak teknisyen ajanları üzerinden makine bakımlarını optimize ettiler; geleneksel yöntemlere kıyasla yaklaşık %75 daha yüksek performans ve daha az duruş süresi elde edildi. Bahrpeyma (2022) ise akıllı fabrikalarda MARL ajanlarının görev dağılımı, koordinasyon ve süreç optimizasyonundaki rolünü sistematik biçimde inceledi; nicel başarı verisi sunmasa da Endüstri (Industry) 4.0 kapsamında üretim hatlarının esneklik ve verimlilik potansiyelini güçlendirdi.

Finans alanında da ML ajanları portföy yönetimi, otomatik alım-satım ve dolandırıcılık tespitinde kullanılmaktadır. Greenwald ve arkadaşlarının Ticari Ajan Rekabet (Trading Agent Competition) (2020 sonrası) çalışmaları, çoklu otonom ajanların piyasalarda teklif stratejileri ve oyun teorisi tabanlı pazarlık süreçlerinde etkinliğini gösterdi; sistemler, insan yatırımcılara (trader) karşı denendiğinde rekabetçi doğruluk ve kârlılık oranları elde ettiler. Ayrıca Zhang ve ark. (2022), Pekiştirmeli öğrenme (Reinforcement Learning, RL) tabanlı finansal ajanların portföy optimizasyonunda kullanılmasını inceleyerek farklı algoritmalarla %10–15 arasında daha yüksek getiri oranı rapor

ettiler; bu sonuç, klasik istatistiksel yöntemlere göre kayda değer bir artış sunmaktadır.

Ulaşım ve akıllı sistemler uygulamalarında Hernandez-Leal ve ark. (2018), MARL yöntemlerini trafik ışıkları kontrolünde uygulayarak simülasyon ortamlarında ortalama bekleme sürelerini %20–30 oranında düşürdüler; böylece trafik akışında ciddi iyileşmeler sağlandı. Ning ve ark. (2024) ise MARL ajanlarını akıllı ulaşım ve Nesnelerin İnterneti (Internet of Things – IoT) sistemlerinde uyguladılar; araç-araċ iletişiminde (Vehicle-to-Vehicle - V2V) koordinasyonu güçlendirerek otonom sürüş senaryolarında kaza oranlarını azalttılar ve enerji tüketimini optimize ettiler.

Eğitim alanında ise Dehkordi (2023), ABM içinde makine öğrenmesini kullanarak eğitimde öğrenci davranışlarını modelledi; karar ağaçları ve yapay sinir ağlarını entegre ederek daha gerçekçi öğrenme senaryoları elde etti. Ayrıca, Wang ve ark. (2023), LLM tabanlı öğrenen ajanların öğrenci seviyesine uygun kişiselleştirilmiş içerik üretebildiğini ve simülasyon testlerinde klasik sistemlere göre %15 daha yüksek öğrenme başarı puanı sağladığını rapor ettiler.

2. ML AJAN ÇALIŞMA MANTIĞI

Bir ML ajanının çalışma mantığı, temelde çevre (environment) ile sürekli etkileşim kurmaya dayalı özyinelemeli (iteratif) bir öğrenme ve karar verme döngüsü üzerine kuruludur. Şekil 1’de gösterildiği üzere ajan, bulunduğu ortamdan aldığı durum (state, S_t) ve ödöl (reward, R_t) bilgilerini kullanarak bir eylem (action, A_t) üretir. Bu eylem çevre üzerinde bir değışiklik yaratır oluşturur ve bunun sonucunda ajan, yeni bir durum (S_{t+1}) ve ödöl (R_{t+1}) ile karşılaşır. Bu döngü, ajanın geçmiş deneyimlerinden öğrenerek gelecekteki ödöl beklentisini maksimize etmesine olanak tanır (Bahrpeyma, 2022). Bu süreç

dört ana bileşenden oluşur (Zhang ve ark., 2021; Hernandez-Leal ve ark., 2018):

2.1. Algılama (Perception)

Ajan, bulunduğu ortamdan sensörler, veri tabanları, kullanıcı girişleri veya diğer dijital kaynaklar aracılığıyla ham veri toplar. Sağlık alanında bu, hasta verilerinin veya tıbbi görüntülerin alınması olabilirken endüstride bir makinenin sensör çıktıları veya üretim hattı verileri olabilir. Algı süreci, yalnızca veri toplamakla kalmaz, aynı zamanda bu verilerin ön işlenmesini (örneğin gürültü azaltma, normalizasyon) de içerir.

2.2. Durum Temsili ve Öğrenme (State Representation & Learning)

Toplanan veriler, ajan için anlamlı bir durum (state) bilgisine dönüştürülür. Burada makine öğrenmesi algoritmaları devreye girer: gözetimli (supervised), gözetimsiz (unsupervised) veya pekiştirmeli öğrenme (reinforcement learning) teknikleriyle ajan, geçmiş deneyimlerinden veya mevcut veri setinden kalıplar ve ilişkiler çıkarır. Örneğin MARL senaryolarında her ajan, kendi kısmi gözlemlerinden yola çıkarak ortak bir politikaya katkıda bulunur.


2.3. Karar Verme (Decision-Making / Policy Execution)

Ajan, öğrendiği bilgiyi ve mevcut durumu kullanarak olası eylemler arasından seçim yapar. Bu seçim, genellikle bir politika (policy) fonksiyonu üzerinden yapılır. Politika, belirli bir durumda hangi eylemin seçileceğini tanımlayan matematiksel bir modeldir. Karar verme süreci deterministik (kesin) olabileceği gibi, belirsizlik altında olasılıksal (probabilistic) stratejiler de içerebilir. Örneğin sağlıkta, “tedavi öner” veya “uzmana yönlendir” gibi farklı karar seçenekleri olabilir.

2.4. Eylem ve Geri Bildirim (Action & Feedback)

Ajan, seçtiği eylemi çevre üzerinde uygular. Bu bir komut (ör. üretim hattını durdurma), bir öneri (ör. tedavi protokolü önerme) ya da fiziksel hareket (ör. robot kolunun nesneyi yerleştirme) olabilir. Ardından çevreden geri bildirim (reward/penalty) alınır. Pekiştirmeli öğrenmede bu ödül sinyali, ajan politikalarını güncellemek için kritik rol oynar. Başarılı eylemler ödüllendirilirken, hatalı eylemler cezalandırılır.

Bu dört aşama, bir döngü halinde sürekli tekrarlanır ve ajan zamanla daha doğru, verimli ve uyumlu kararlar almayı öğrenir. Ayrıca, çoklu ajan sistemlerinde bu döngü yalnızca bireysel değil, kolektif düzeyde işler; ajanlar birbirlerinin kararlarını gözlemler, iletişim kurar ve iş birliği veya rekabet senaryolarında stratejilerini buna göre şekillendirirler (Hernandez-Leal ve ark., 2018).



Şekil 1. Ajan çalışma mantığı (Bahrpeyma, 2022)

3. ML AJAN TÜRLERİ

ML ajanları, sahip oldukları öğrenme mekanizmaları ve çevre ile etkileşim biçimlerine göre farklı kategorilere ayrılmaktadır. Bu türler, klasik yapay zekâ literatüründen güncel derin öğrenme tabanlı yaklaşımlara kadar geniş bir yelpazede incelenebilir.

3.1. Reaktif Ajanlar (Reactive Agents)

Reaktif ajanlar, çevreden aldıkları güncel duruma doğrudan tepki veren ve herhangi bir geçmiş bellek kullanmayan en basit ajan türüdür. Bu ajanlar belirli kurallara göre çalışır ve “if-then” yapılarıyla ifade edilir. Bu nedenle öngörülü planlama veya uzun vadeli optimizasyon yapamazlar. Örneğin, basit robot kontrol sistemleri ya da trafik ışığı optimizasyon algoritmalarında kullanılabilirler (Wooldridge, 2009).

3.2. Kural Tabanlı (Deliberative) Ajanlar

Kural tabanlı ajanlar, çevreyi belirli bir dünya modeli ile temsil eder ve bu modele dayanarak planlama yapar. Karar mekanizması, önceden tanımlı kurallar veya mantıksal çıkarımlar üzerinden işler. Bu ajanlar, durum uzayını hesaplayarak belirli amaçlara ulaşmayı hedefler. Ancak çevrenin karmaşıklığı arttıkça kural tabanlı yaklaşımın ölçeklenebilirliği azalır (Russell ve Norvig, 2021).

3.3. Öğrenen Ajanlar (Learning Agents)

Öğrenen ajanlar, çevreden aldıkları geri bildirimlerle performanslarını zamanla artırabilen adaptif sistemlerdir. [RL](#) bu gruba girer. Bu ajanlar, ödül/ceza sinyallerini kullanarak stratejilerini geliştirir ve belirsiz ortamlarda daha etkin çözümler sunar. Hernandez-Leal ve ark. (2018), çoklu ajanlı ortamlarda RL tabanlı öğrenen ajanların koordinasyon ve iş birliği problemlerinde kritik rol oynadığını göstermiştir.

3.4. Hibrit Ajanlar (Hybrid Agents)

Hibrit ajanlar hem reaktif hem de kural tabanlı bileşenleri birleştirir. Böylece kısa vadeli çevresel değişikliklere hızlı tepki verirken, aynı zamanda uzun vadeli planlama ve öğrenme yeteneklerine de sahiptir. Bu tür mimariler, özellikle akıllı fabrikalar ve otonom araçlarda tercih edilmektedir (Bahrpeyma, 2022).

3.5. BDI (Belief–Desire–Intention) Ajanlar

BDI modeli, ajanların üç ana bileşenine dayanır: inançlar (beliefs), istekler (desires) ve niyetler (intentions). Bu yaklaşım, insan benzeri karar verme süreçlerini modellemeye yönelik olup, karmaşık görevlerde daha anlaşılır bir yapı sunar. Erduran (2023), BDI mimarisine makine öğrenmesinin entegre edilmesinin ajanların adaptif kapasitesini artırdığını göstermiştir.

3.6. Çoklu Ajan Sistemleri (Multi-Agent Systems, MAS)

Birden fazla ajanın aynı ortamda iş birliği veya rekabet halinde çalıştığı sistemlerdir. Burada ajanlar, bilgi paylaşımı, koordinasyon veya pazarlık yoluyla ortak hedeflere ulaşır. MARL, bu alanda öne çıkan bir yöntemdir ve özellikle akıllı ulaşım, üretim optimizasyonu ve enerji yönetiminde kullanılmaktadır (Zhang et al., 2021).

4. SONUÇ

Bu çalışmada, ML ajanlarının kavramsal temelleri, çalışma mantığı, türleri ve farklı disiplinlerdeki uygulamaları ele alınmıştır. ML ajanları, çevre ile sürekli etkileşim kurarak öğrenme, karar verme ve eyleme geçme döngüsünü tekrarlayan adaptif sistemlerdir. Bu yapıları sayesinde yalnızca önceden tanımlanmış kurallara bağlı kalmayıp, belirsizlik içeren ortamlarda da öğrenerek daha verimli çözümler geliştirebilmektedirler.

Literatürdeki örnek çalışmalar, ML ajanlarının sağlık alanında hasta izleme ve tıbbi görüntüleme (Feng ve ark., 2025; Shaik ve ark., 2023), bilişimde siber güvenlik ve karar destek sistemleri (Patel ve ark., 2025; Yong ve Brintrup, 2021), endüstride akıllı fabrikalar ve bakım optimizasyonu (Rodríguez ve ark., 2022; Bahrpeyma, 2022), finans sektöründe portföy

yönetimi ve piyasa simülasyonları (Zhang ve ark., 2022; Greenwald, 2020), ulaşımda trafik yönetimi ve otonom araç koordinasyonu (Hernandez-Leal ve ark., 2018; Ning et al., 2024) ve eğitimde kişiselleştirilmiş öğrenme sistemleri (Dehkordi, 2023; Wang ve ark., 2023) gibi çok geniş bir yelpazede etkili şekilde kullanıldığını göstermektedir.

Elde edilen bulgular, ML ajanlarının disiplinler arası problemlerin çözümünde stratejik bir araç haline geldiğini ve gelecekte daha karmaşık senaryolarda önemli roller üstleneceğini ortaya koymaktadır. Bununla birlikte, etik, güvenlik ve regülasyon gibi konuların da dikkate alınması gerektiği açıktır. Özellikle sağlık ve finans gibi kritik alanlarda, ajanların karar verme süreçlerinin şeffaflığı ve güvenilirliği, teknolojiye olan güvenin artırılması için öncelikli bir gerekliliktir.

Sonuç olarak, ML ajanları, yapay zekâ araştırmalarında yalnızca teorik bir kavram olmaktan çıkıp, gerçek dünya uygulamalarında başarıyla kullanılan güçlü araçlara dönüşmektedir. Önümüzdeki dönemde, daha gelişmiş pekiştirmeli öğrenme algoritmaları, çoklu ajan koordinasyon mekanizmaları ve LLM tabanlı hibrit yapılar ile bu sistemlerin daha geniş ölçekte benimsenmesi beklenmektedir.

KAYNAKÇA

- Bahrpeyma, F. (2022). *Applications of multi-agent reinforcement learning in smart factories: A systematic review*. Journal of Industrial Engineering & Management, PMC9751367. <https://pmc.ncbi.nlm.nih.gov/articles/PMC9751367/>
- Dehkordi, M. A. E. (2023). Machine learning in agent-based modelling: A systematic review and future directions. *Journal of Artificial Societies and Social Simulation*, 26(1), 9. <https://www.jasss.org/26/1/9.html>
- Erduran, O. I. (2023). Integrating machine learning into BDI agent architectures: A classification scheme. *Proceedings of ICAART 2023*, 116–125.
- Feng, J., Zhang, C., Zhou, J., & Li, H. (2025). *M³Builder: Multi-agent system for full-loaded automated machine learning in medical imaging*. arXiv preprint arXiv:2502.20301. <https://arxiv.org/abs/2502.20301>
- Greenwald, A. (2020). Autonomous bidding agents and the Trading Agent Competition. *Proceedings of the Trading Agent Competition Workshop*.
- Hernandez-Leal, P., Kartal, B., & Taylor, M. E. (2018). A critical survey of multi-agent reinforcement learning: Foundations and challenges. *arXiv preprint arXiv:1810.05587*. <https://arxiv.org/abs/1810.05587>
- Ning, Z., Zhang, K., & Chen, J. (2024). Applications of multi-agent reinforcement learning in IoT and intelligent transportation systems. *Computer Science Review*, 54, 100479. <https://www.sciencedirect.com/science/article/pii/S2949855424000042>

- Patel, D., Raut, G., & Singh, A. (2025). *AI agents in healthcare: From foundation to pioneer models*. Preprints.org. <https://www.preprints.org/manuscript/202503.1352/v1>
- Rodríguez, M. L. R., Kubler, S., & de Giorgio, A. (2022). Multi-agent deep reinforcement learning-based predictive maintenance on parallel machines. *International Journal of Advanced Manufacturing Technology*, 123(3), 455–469. <https://www.researchgate.net/publication/361865416>
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A modern approach* (4th ed.). Pearson.
- Shaik, T., Tao, X., & Wang, Y. (2023). *Multi-agent deep reinforcement learning for patient monitoring and early warning systems*. arXiv preprint arXiv:2309.10980. <https://arxiv.org/abs/2309.10980>
- Wang, L., Zhou, H., & Xu, W. (2023). Large language model-based autonomous agents: Survey and outlook. *arXiv preprint arXiv:2308.11432*. <https://arxiv.org/abs/2308.11432>
- Wooldridge, M. (2009). *An introduction to multiagent systems* (2nd ed.). Wiley.
- Yong, B. X., & Brintrup, A. (2021). Multi-agent systems with probabilistic machine learning for cyber-physical manufacturing. *arXiv preprint arXiv:2107.13252*. <https://arxiv.org/abs/2107.13252>
- Zhang, Y., Chen, L., & Huang, J. (2022). Reinforcement learning agents for portfolio optimization in financial markets. *IEEE Transactions on Computational Intelligence and AI in Finance*, 1(2), 55–67.

KISIT TABANLI YAKLAŞIMLA MODERN WEB TEKNOLOJİLERİ KULLANILARAK GELİŞTİRİLEN OTOMATİK SINAV PROGRAMLAMA SİSTEMİ

Kadir TOHMA¹

1. GİRİŞ

Üniversite sınav planlama süreçleri, akademik kurumların karşılaştığı en karmaşık operasyonel problemlerden biridir. Bu süreç; öğrenci sayısı, derslik kapasitesi, öğretim görevlilerinin müsaitliği, sınav süreleri, çakışma kontrolü ve öğrenci tercihleri gibi birçok farklı değişkeni ve kısıtlamayı aynı anda yönetmeyi gerektirir. Geleneksel manuel planlama yöntemleri, özellikle büyük ölçekli üniversitelerde önemli zaman kaybına, planlama hatalarına ve verimsizliğe yol açarak öğrenci ve personel memnuniyetini olumsuz etkilemektedir.

Sınav planlama problemi, NP-hard sınıfında yer alan karmaşık bir optimizasyon sorunu olarak tanımlanmaktadır. Bu problemde, sınavların belirli zaman dilimlerinde yapılması zorunluluğu, derslik kapasite ve ekipman gereksinimleri, öğretim görevlilerinin görev dağılımı, öğrenciler için çakışma önleme ve tercihlerin dikkate alınması gibi pek çok kısıtlayıcı unsur bulunmaktadır. Ayrıca sınav süreleri, hazırlık zamanları ve

¹ Dr. Öğr. Üyesi, İskenderun Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği Bölümü, kadir.tohma@iste.edu.tr, ORCID: 0000-0002-2631-7810.

güvenlik önlemleri gibi operasyonel faktörler de planlama sürecini daha karmaşık hale getirmektedir.

1.1. Mevcut Çözümlerin Eksiklikleri

Literatürde sınav planlama problemine yönelik pek çok farklı yöntem ve algoritma önerilmiştir. Rezaeipanah, Matoori ve Ahmadi (2020) hibrit genetik algoritmalar ve yerel arama tekniklerinin birleşimini kullanarak %40-60 oranında performans artışı elde etmiştir. Nguyen, Thiruvady ve Zhang (2021) ise self-competitive genetik programlama yaklaşımıyla kaynak kısıtlı çizelgeleme problemlerine çözüm sunmayı hedeflemiştir. Ancak bu tür yaklaşımlar, karmaşık algoritma yapıları ve yüksek hesaplama maliyetleri nedeniyle gerçek hayatta uygulanabilirlik açısından sınırlı kalmaktadır.

Günümüzde bazı sistemler hâlâ Excel tabanlı uygulamalar veya eski web teknolojilerine dayalıdır. Bu durum modern kullanıcı beklentilerini karşılayamamakta; sınırlı dil desteği ve statik yapı nedeniyle dinamik güncellemeler ile gerçek zamanlı planlama ihtiyaçlarına hızlı yanıt verilememektedir. Mevcut çözümlerin başlıca eksiklikleri; algoritma karmaşıklığı, yüksek maliyet, eski teknoloji kullanımı, sınırlı dil desteği ve dinamik planlama yetersizliğidir.

1.2. Araştırma Amacı ve Katkıları

Bu çalışma, literatürde sıklıkla karşılaşılan karmaşık algoritma odaklı yaklaşımlara alternatif olarak daha anlaşılır ve uygulanabilir bir model geliştirmeyi amaçlamaktadır. Önerilen çözüm, Kısıt Tabanlı Programlama yaklaşımını modern web teknolojileriyle birleştirerek üniversitelerin sınav planlama süreçlerine yenilikçi ve pratik bir bakış açısı kazandırmaktadır. Sistem; Türkçe dil desteği, kullanıcı dostu arayüz tasarımı, gerçek zamanlı çakışma kontrolü, dinamik planlama özellikleri ve kapsamlı istatistiksel analiz imkânlarıyla literatürdeki önemli bir boşluğu doldurmaktadır.

Bu çalışmanın temel hedefi, üniversite sınav planlama süreçlerini daha verimli, esnek ve düşük maliyetli bir yapıya kavuşturmak ve Türkiye’deki üniversitelerin ihtiyaçlarına doğrudan karşılık veren bir çözüm geliştirmektir. Çalışma hem akademik hem de pratik açıdan çeşitli katkılar sunmaktadır.

Bu çalışmanın katkıları dört başlıkta özetlenebilir: Akademik olarak, Kısıt Tabanlı Programlama yaklaşımının sınav planlamada etkinliğini göstererek literatüre yeni bir bakış açısı sunmaktadır. Teknolojik açıdan, modern web teknolojilerinin eğitim yönetimine uygulanabilirliğini kanıtlamaktadır. Pratik düzeyde, Türkiye’deki üniversiteler için düşük maliyetli, esnek ve kolay benimsenebilir bir çözüm sunarak operasyonel yükü azaltmayı amaçlamaktadır. Metodolojik olarak ise, karmaşık algoritmalar yerine basit fakat etkili çözümlerin gerçek hayata katkılarını vurgulamaktadır.

1.3. Çalışmanın Yapısı

Makale altı bölümden oluşmaktadır. İkinci bölümde sınav planlama sistemlerine dair literatür ve çalışmanın özgün yönleri, üçüncü bölümde sistemin mimarisi, algoritma tasarımı, veri modeli ve modüler yapısı ele alınmıştır. Dördüncü bölümde performans, özgünlük ve literatüre katkılar; beşinci bölümde genel sonuçlar; son bölümde ise geleceğe yönelik öneriler sunulmuştur.

2. LİTERATÜR TARAMASI VE ÖZGÜNLÜK ANALİZİ

2.1. Literatür Analizi ve Karşılaştırma

Bu çalışmada, 2020-2025 yılları arasında yayımlanan ve üniversite sınav planlama sistemlerini konu alan güncel akademik araştırmalar incelenmiş, toplam altı ana kategori altında dokuz önemli makale analiz edilmiştir. Bu inceleme sayesinde

projemizin özgün katkıları ve literatürdeki konumu netleştirilmiştir.

Hibrit algoritmalar üzerine yapılan çalışmalarda Rezaeipanah, Matoori ve Ahmadi (2020), paralel genetik algoritmalar ve yerel arama yöntemlerini birleştirerek sınav çizelgeleme probleminde %40-60 oranında performans artışı elde etmişlerdir. Ancak bu yaklaşım yüksek hesaplama maliyeti ve karmaşık implementasyon nedeniyle pratik uygulamalarda sınırlı kalmaktadır. Bizim önerdiğimiz sistem, bu tür hibrit yapılar yerine temel kısıt tabanlı programlama yaklaşımını kullanarak daha hızlı, anlaşılır ve kaynak verimliliği yüksek bir çözüm sunmaktadır. Benzer şekilde Lulu, Alowais ve Turkey (2020) tarafından geliştirilen metaheuristic tabanlı yöntem, yalnızca Sharjah Üniversitesi'ne özel optimize edilmiştir. Çalışmamız ise belirli bir kurumla sınırlı kalmadan geniş bir kullanıcı kitlesine hitap eden esnek bir yapı sağlamaktadır.

Kısıt tabanlı programlama yaklaşımları da literatürde önemli bir yer tutmaktadır. Nguyen, Thiruvady ve Zhang (2021), genetik programlama ile kaynak kısıtlı iş çizelgeleme problemlerine otomatik çözümler geliştirmiş, ancak yöntem uzun eğitim süresi ve yüksek karmaşıklık nedeniyle zorluklar içermektedir. Gotlieb, Mossige ve Spieker (2020) ise ABB Robotics'te Kısıt Tabanlı Programlama tabanlı test planlama uygulamaları sunmuştur. Çalışmamız bu literatürü eğitim odaklı bir perspektifle tamamlamakta ve kullanıcı dostu bir arayüzle daha kolay uygulanabilir bir çözüm önermektedir.

Web tabanlı sistemlere odaklanan araştırmalarda Zhu, Li ve Li (2020), Artificial Bee Colony algoritmasına dayalı bir çevrimiçi sınav çizelgeleme sistemi geliştirmiştir; ancak sistem yalnızca belirli bir algoritma ile sınırlı kalmış ve kapsamlı işlevler sunmamıştır. Güler ve Geçici (2020) tarafından geliştirilen Excel tabanlı karar destek sistemi Türkiye'de başarılı bir şekilde

uygulanmış olsa da manuel işlem yükü ve teknolojik sınırlılıklar nedeniyle modern kullanıcı beklentilerini karşılayamamaktadır.

Tercih tabanlı algoritmalara örnek olarak Nand, Reddy ve Chaudhary (2021) Firefly algoritmasını kullanarak gerçek dünya sınav çizelgeleme problemlerine çözüm geliştirmiştir. Ancak yöntem karmaşık yapısı ve yüksek hesaplama maliyeti nedeniyle yaygın uygulamaya elverişli değildir. Bizim çözümümüz, daha basit ve hızlı bir yaklaşımla kullanıcı deneyimini öne çıkarmaktadır.

Son olarak Liu ve Lu (2021), karmaşık çoklu çizelgeleme sistemlerinin entegrasyonuna odaklanmış; Kasthuri, Shenabaha ve Swetha (2021) ise sınav salonu yönetimi ve gözetmen atamalarını otomatikleştiren bir uygulama geliştirmiştir. Çalışmamız bu çalışmalardan farklı olarak yalnızca salon yönetimine değil, sınav planlamanın tüm süreçlerini kapsayan, modern bir arayüz ve gerçek zamanlı özelliklerle desteklenen bütünleşik bir sistem sunmaktadır.

Bu literatür taraması, üniversite sınav planlama sistemleri konusundaki güncel akademik araştırmaları (2020-2025) analiz etmekte ve mevcut projemizle karşılaştırmalı olarak değerlendirmektedir. Toplam 6 ana kategoride 9 önemli makale incelenmiş ve projemizin özgünlükleri belirlenmiştir.

2.2. Projemizin Özgünlük Analizi

Projemiz, teknik altyapıdan kullanıcı deneyimine ve pratik uygulamalara kadar birçok açıdan literatürdeki mevcut yaklaşımlardan ayrılmaktadır.

Teknik özgünlükler açısından, karmaşık hibrit algoritmalar yerine hızlı ve anlaşılır çözümler sunan Kısıt Tabanlı Programlama modeli seçilmiştir. Bu yaklaşım, hem hesaplama maliyetini düşürmüş hem de bakım ve geliştirmeyi kolaylaştırmıştır. React, TypeScript ve FastAPI tabanlı modern

mimari yüksek performans ve kullanıcı deneyimi sağlarken, WebSocket desteği gerçek zamanlı çakışma kontrolü ve dinamik planlamayı mümkün kılmıştır.

Kullanıcı deneyimi özgünlükleri kapsamında, projemiz tam Türkçe dil desteği sunarak Türkiye'deki üniversiteler için daha erişilebilir bir çözüm sağlamaktadır. Geliştirilen istatistiksel dashboard ve görsel raporlama özellikleri, yönetim ve karar verme süreçlerine katkıda bulunurken modüler yazılım mimarisi, sistemin kolay genişletilebilir ve sürdürülebilir bir yapıya sahip olmasına olanak tanımaktadır.

Pratik uygulama özgünlükleri ise hızlı ve düşük maliyetli implementasyon süreçleri, farklı üniversitelere kolay uyarlanabilirlik ve kullanıcı dostu tasarım ile öne çıkmaktadır. Bu sayede proje, karmaşık konfigürasyon gerektiren sistemlere kıyasla daha geniş bir kullanıcı kitlesine hitap etmektedir.

2.3. Literatürdeki Boşluklar ve Projemizin Katkıları

Literatür incelemesi sonucunda, sınav planlama sistemlerinde birkaç temel eksiklik tespit edilmiştir. Çoğu çalışma, karmaşık algoritmalara odaklanmış olup, basit ve anlaşılır çözümler sunan sistemler oldukça sınırlıdır. Yerel dil desteği büyük ölçüde ihmal edilmiş ve modern web teknolojilerinin kullanımı yetersiz kalmıştır. Statik yapıdaki sistemler gerçek zamanlı planlama özelliklerinden yoksundur ve yönetimsel karar destek araçları açısından da eksiklikler göze çarpmaktadır.

Projemiz bu eksikliklere doğrudan yanıt vermektedir. Kısıt Tabanlı Programlama tabanlı yaklaşımıyla hem anlaşılır hem de etkili bir çözüm sunarak uygulamada yaygınlaştırılabilir bir model geliştirilmiştir. Tam Türkçe arayüz ve dokümantasyon, yerel kurumlara uyum sağlamaktadır. Modern yazılım teknolojileri sayesinde sistem, gerçek zamanlı güncellemeler ve dinamik planlama özellikleri sunmakta; kapsamlı istatistik

araçları ile planlama süreçlerini daha şeffaf ve yönetilebilir hale getirmektedir.

3. MATERYAL VE YÖNTEM

3.1. Sistem Mimarisi ve Teknoloji Yığını


Önerilen sistem, ölçeklenebilirlik, bakım kolaylığı ve performans dikkate alınarak üç katmanlı mimari (frontend, backend, veri tabanı) ile tasarlanmıştır. Sunum katmanında React ve TypeScript ile duyarlı arayüzlere sahip modern bir web istemcisi, iş mantığı katmanında FastAPI tabanlı doğrulama, yetkilendirme ve çizelgeleme servisleri, kalıcılık katmanında ise SQLAlchemy ile yönetilen SQLite veritabanı yer almaktadır. Bu yapı, gerçek zamanlı izleme, anlık çakışma kontrolü ve dinamik planlamayı düşük gecikmeyle sağlamaktadır. Şekil 1'deki ana sayfada üst bölümde sistem adı, logo ve temel işlevler; alt bölümde ise sınav ve derslik durumlarını gösteren performans kartları bulunmaktadır.



Şekil 1. İSTE Sınav Planlama Sistemi — Ana Sayfa (Dashboard) Genel Görünüm

3.1.1. Frontend Katmanı

Ön yüz, React 18 ve TypeScript ile geliştirilmiş; bileşen tabanlı mimari React Hooks (useState, useEffect, useContext) ile yönetilmiştir. Yönlendirmeler istemci tarafında yapılırken, arayüz Tailwind CSS ile tutarlı bir görsel dilde tasarlanmıştır. Tarih/saat işlemleri ve istemci–sunucu iletişimi hafif kütüphanelerle desteklenmiştir. Bu yapı, hızlı prototipleme, tekrar kullanılabilir bileşenler, düşük bakım maliyeti ve tutarlı bir kullanıcı deneyimi sağlamaktadır.



Şekil 2. İSTE Sınav Planlama Sistemi — Sistem Kontrol ve Hızlı İşlem Paneli.

Şekil 2, sınav planlama sürecinde sistemi izleme ve hızlı işlemler yapmaya olanak tanıyan kontrol panelini göstermektedir. Üst bölümde çevrim içi durum, port ve URL bilgileri; orta kısımda sınav ekleme, derslik yönetimi, rastgele sınav oluşturma ve program görüntüleme butonları yer alır. Sağ üstte planlama oranı, derslik ve sınav sayıları gösterilirken, alt bölümdeki “Hoş Geldiniz” kısmı sistemin temel özelliklerini özetler. Bu yapı, yöneticilerin ve kullanıcıların sistemi hızlı ve sezgisel biçimde yönetmesini sağlar.

3.1.2.Backend Katmanı

Arka uç, Python 3.11 üzerinde çalışan FastAPI ile gerçekleştirilmiş; şema doğrulama ve veri serileştirme Pydantic ile sağlanmıştır. Kimlik doğrulama, JWT tabanlı bir yetkilendirme katmanı üzerinden yürütülür. Kalıcılık için SQLAlchemy kullanılmış, asenkron istek işleme ise Uvicorn tabanlı ASGI sunucusu ile gerçekleştirilmiştir. Çakışma tespiti, otomatik programlama ve raporlama gibi yoğun işlevler ayrık servis uç noktaları olarak tasarlanmıştır; CORS yapılandırması ile istemci–sunucu iletişimi güvenli ve kontrollü kılınmıştır.

3.1.3.Veri Tabanı Katmanı

Veri modeli, sınav planlamanın temel varlıklarını kapsayan ilişkisel bir şema üzerine kuruludur. Eğitim elemanları, sınav dönemleri, sınavlar, derslikler, program kayıtları ve zaman dilimleri gibi çekirdek tablolar; yabancı anahtar kısıtları ve indeksler ile desteklenmiştir. ACID uyumlu işlem yönetimi, planlama ve güncelleme senaryolarında veri bütünlüğünü güvence altına alır; indeksleme stratejileri ise yüksek hacimli sorgularda yanıt süresini iyileştirir.

3.2. Modüler Mimari ve Bileşenleşme

Sistem, yeniden kullanılabilirliği ve bakım kolaylığını artırmak üzere yüksek modülerlik ilkesiyle tasarlanmıştır. Ön yüzde; uygulama kabuğu, kontrol paneli, sınav formu, çizelgeleme görünümü ve istatistik panosu gibi fonksiyonel modüller, ortak gezinme ve yardımcı bileşenlerle desteklenir. Arka yüzde; ana API sunucusu, veri modelleri, şema tanımları ve veri tabanı yaşam döngüsünü yöneten yardımcı katmanlar yer alır. Bu ayrık yapılanma, yeni özelliklerin “tak-çalıştır” biçiminde eklenmesini, hata ayıklamayı ve sürümlemeyi önemli ölçüde kolaylaştırır.

3.3. Algoritma Tasarımı ve Kısıt Tabanlı Programlama Yaklaşımı

3.3.1. Temel İlke ve Modelleme

Sınav programlama problemi, kısıtlar ve değişkenler arasındaki ilişkilerin açıkça modellendiği bir Kısıt Tabanlı Programlama çerçevesi içinde ele alınmıştır. Zaman, mekân, çakışma ve görevli uygunluğu gibi kurallar formel kısıtlar olarak tanımlanmış; arama alanı, kısıt yayılımı (constraint propagation) ve alan daraltma teknikleriyle etkin biçimde küçültülmüştür. Öğretim elemanlarının aynı zaman diliminde birden çok sınavda görevlendirilememesi, derslik kapasitesinin öğrenci sayısını karşılaması, aynı mekânda aynı anda farklı sınavların çakışmaması ve görevli uygunluk kümelerinin gözetilmesi gibi zorunluluklar modelin çekirdeğini oluşturur.

3.3.2. Otomatik Programlama Süreci

Otomatik programlama; kısıt analizi, zaman dilimi seçimi, derslik tahsisi, çakışma çözümleme ve doğrulama-onay aşamalarından oluşan ardışık bir iş akışı izler. Öncelikle mevcut kısıtlar üzerinde ön-çözümleme yapılarak olası ihlaller belirlenir; ardından boş ve uygun zaman dilimleri, talep profilleri ve kaynak kısıtları birlikte değerlendirilir. Mekân ataması, kapasite ve ekipman gereksinimleriyle birlikte konumsal uygunluk dikkate alınarak yapılır. Çakışmalar, sezgisel önceliklendirme ve yer değiştirme (swap) stratejileriyle giderilir; son aşamada planın kısıt setine uyumu yeniden doğrulanır.

3.3.3. Çakışma Çözümleme

Gerçek zamanlı çakışma denetimi, kullanıcı etkileşimi sırasında tetiklenen artımlı kontroller ile yürütülür. Zaman, mekân, kapasite ve ekipman kaynaklı ihlaller; öncelik kuralları ve yer değişim önerileriyle otomatik olarak giderilmeye çalışılır,


gerektiğinde kullanıcıya kontrollü manuel geçersiz kılma olanağı sunulur.

3.4. Veri Modeli ve İlişkisel Düzen

Veri modeli altı temel varlığı kapsar: Instructor (unvan, bölüm ve iletişim bilgileriyle öğretim elemanları), ExamPeriod (dönem adı, tarih aralığı ve sınav türleri), Exam (ders kodu/adı, görevli, süre, öğrenci sayısı ve tercihler), Room (bina, kat, kapasite, tür ve ekipman), Schedule (sınav-mekân eşlemesi, tarih-saat ve durum) ve TimeSlot (başlangıç-bitiş saatleri ve azami süre). Tablolar arası ilişkiler, veri bütünlüğünü koruyacak biçimde yabancı anahtar kısıtlarıyla tanımlanmış; yoğun kullanılan sütunlarda indeksler ile sorgu performansı iyileştirilmiştir. Örnek bir kurulumda sistem; 13 öğretim elemanı, tek aktif sınav dönemi, 50 sınav, 8 derslik ve 21 program kaydı ile çalışacak şekilde yapılandırılmıştır.

3.5. Kullanıcı Arayüzü ve Görsel Düzen


Arayüz mimarisi, yöneticilerin ve akademik personelin iş akışlarını minimum tıklama ve net geri bildirim ilkeleri doğrultusunda destekler. Dashboard; sistem özeti, eylem butonları ve kritik göstergeleri tek ekranda birleştirir. Çizelgeleme görünümü, tablo ve takvim modları arasında geçişe, sürükle-bırak temelli düzenlemeye ve anlık çakışma uyarılarına izin verir; dışa aktarma seçenekleriyle kurumsal formatlarda rapor üretir. Sınav ekleme/düzenleme formları, doğrulama ve anlık denetimlerle kullanıcı hatalarını en aza indirir. İstatistik panosu; planlama oranı, kaynak kullanım yüzdeleri ve yaklaşan etkinlikler gibi metrikleri görselleştirerek karar destek sürecini güçlendirir.



Sınav Kodu	Sınav Adı	Durum	Süre	Öğrenci Sayısı
END495 - Proje Yürütme	Endüstriyel Proje Yürütme	Bekliyor	120 dakika	1
MAK430 - Makine Elemanları	Makine Elemanları	Planlandı	120 dakika	1
MAK330 - Termodinamik I	Termodinamik I	Bekliyor	120 dakika	1
MAK330 - Termodinamik I	Termodinamik I	Bekliyor	120 dakika	1

Şekil 3. İSTE Sınav Planlama Sistemi — Sınav Listesi ve Planlama Durumu


Şekil 3, sınavların planlama durumlarını gösteren sınav listesi ekranını sunmaktadır. Üst bölümde toplam, planlanmış ve planlanmamış sınav sayıları; sağ üstte ise “Rastgele Sınav Oluştur” ve “Yeni Sınav” butonları yer almaktadır. Listede sınavlar ders kodu ve adıyla gösterilir, planlama durumu “Bekliyor” veya “Planlandı” etiketleriyle belirtilir. Ayrıca öğretim görevlisi, sınıf, süre ve öğrenci sayısı gibi bilgiler de sunularak kullanıcıların sınavları hızlıca inceleyip planlama adımlarını başlatması sağlanır.



Sınav Kodu	Sınav Adı	Durum	Süre	Öğrenci Sayısı
END495 - Proje Yürütme	Endüstriyel Proje Yürütme	Bekliyor	120 dakika	1
MAK430 - Makine Elemanları	Makine Elemanları	Planlandı	120 dakika	1
MAK330 - Termodinamik I	Termodinamik I	Bekliyor	120 dakika	1
MAK330 - Termodinamik I	Termodinamik I	Bekliyor	120 dakika	1

Şekil 4. İSTE Sınav Planlama Sistemi — Akademik Personel Yönetim Ekranı


Şekil 4, akademik personel yönetim ekranını göstermektedir. Bu ekranda sisteme kayıtlı öğretim üyelerinin bilgileri ve yönetim işlevleri tek arayüzde sunulmaktadır. Sol sütunda ad, unvan ve profil görselleri; orta sütunlarda bölüm, e-posta ve güncel durum bilgileri yer alır. “Aktif” etiketi, öğretim üyesinin sınav planlama süreçlerinde görev alabildiğini gösterir. Sağ taraftaki düzenleme ve silme ikonları kayıtların güncellenmesini sağlarken, sağ üstteki “Hoca Ekle” butonu yeni öğretim elemanı eklemeye imkân verir. Bu yapı, akademik kadronun sınav planlama sürecinde düzenli ve etkili şekilde yönetilmesini sağlar.



Şekil 5. İSTE Sınav Planlama Sistemi — Derslik Yönetim Ekranı

Şekil 5, sınavların gerçekleştirileceği dersliklerin yönetimini sağlayan ekranı göstermektedir. Üst bölümde toplam derslik sayısı, müsait ve kullanımda olan dersliklerin dağılımı ile toplam kapasite bilgileri özet olarak sunulmaktadır. Liste görünümünde her derslik için bina ve kat bilgileri, kapasite ve tür gibi temel özellikler yer almakta; “Orta” veya “Büyük” gibi büyüklük etiketleri ve “Normal Derslik” ya da “Amfityatro” gibi tür etiketleri mekânların özelliklerini hızlıca anlamaya yardımcı olmaktadır. Müsaitlik durumu yeşil onay işaretleriyle görselleştirilmiş, sağ üstte yer alan “Yeni Derslik” butonu ise yeni mekânların kolayca eklenmesini sağlamaktadır. Bu yapı, sınav


yerleşim optimizasyonu sürecinde mevcut kaynakların verimli ve etkili bir şekilde kullanılmasına olanak tanır.



Sıra No	Tarih & Saat	Ders Adı	Derslik	Kapasite	Durum	İşlemler
İNG644 Literature 4. Sınıf - 10000	12 Eylül Cum 08:00 - 11:00	ArGeç. M. Yılmaz Matematik	BH2 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]
END403 Pinge Yönelimi 1. Sınıf - 10000	12 Eylül Cum 11:00 - 14:00	Prof. Dr. C. Yılmaz İngilizce	BH2 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]
MAT603 Üniversite 2. Sınıf - 10000	12 Eylül Cum 08:00 - 12:00	Prof. Dr. C. Yılmaz İngilizce	BH3 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]
ELK341 Matematik 3. Sınıf - 10000	15 Eylül Paz 08:00 - 12:00	Prof. Dr. Y. Yılmaz Matematik	BH2 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]
FİZ201 Termodinamik II 1. Sınıf - 10000	19 Eylül Cum 08:00 - 12:00	Dr. Öğr. Üyesi Fizik	BH1 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]
FİZ201 Termodinamik II 1. Sınıf - 10000	19 Eylül Cum 08:00 - 12:00	Dr. Öğr. Üyesi Fizik	DB1 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]
ELK270 Elektronik 4. Sınıf - 10000	19 Eylül Cum 11:00 - 14:00	Prof. Dr. Y. Yılmaz Elektronik	BH3 3 Blok - 100	100/100 100% dolu	Planlanıyor	[İçer] [Sil]

Şekil 6. İSTE Sınav Planlama Sistemi — Sınav Programı Ekranı

Şekil 6, sınav programı ekranını göstermektedir. Bu ekran, tüm bölümlere ait sınavların tarih, saat, derslik, kapasite ve planlama durumlarını tablo halinde sunarak merkezi bir yönetim noktası sağlar. Üst bölümde Tablo, Takvim ve İSTE Formatı gibi farklı görüntüleme seçenekleri yer almakta; sınav ekleme ve planlama işlemleri için “Otomatik Planlama” ve “Manuel Ekleme” butonları bulunmaktadır. Programın Excel formatında dışa aktarılması ve kaydedilmesi mümkündür. Her satırda sınav kodu, ders adı, tarih ve saat bilgileri, ilgili öğretim üyesi, derslik bilgisi ve kapasite durumu yer almakta; kapasite aşımı durumları kırmızı renkle vurgulanarak yöneticilerin hızlı müdahalesi sağlanmaktadır. Sağ tarafta bulunan düzenleme ve silme ikonları ile sınav bilgileri kolaylıkla güncellenebilir veya kaldırılabilir. Bu ekran, sınav takviminin tek merkezden yönetilmesini ve kapasite sorunlarının önceden tespit edilerek çözülmesini desteklemektedir.




The screenshot displays the 'Sınav Programı' (Exam Program) interface. At the top, there are navigation tabs for 'İSTE Erişim', 'Öğrenci Planlama', 'Müfredat', 'Sınav', 'Raporlar', and 'Sınav Sonuçları'. Below the navigation bar, the header identifies the 'İSTE Bilgisayar Mühendisliği Bölümü' (İSTE Computer Engineering Department) and the '2025-2026 Güz Arz Sınav Programı' (2025-2026 Autumn Exam Program). The main content is a table with four columns: 'Sınav Tarihi' (Exam Date), 'Sınav Saati' (Exam Time), 'Sınav Adı' (Exam Name), and 'Sınav Salonu' (Exam Room). The table is organized by date and time slots, with rows for different exam sessions. The 'Sınav Tarihi' column shows dates like '09.09.2025', '10.09.2025', and '11.09.2025'. The 'Sınav Saati' column shows times like '09:00-11:00', '10:00-12:00', and '13:00-15:00'. The 'Sınav Adı' column lists exam names such as 'Uyarı', 'Girişim', 'Proje Yürütme', 'Mühendislik', 'Yazılım', 'Sistem', and 'Kullanıcı'. The 'Sınav Salonu' column lists room numbers like '0101', '0102', '0103', '0104', '0105', '0106', '0107', and '0108'.

Sınav Tarihi	Sınav Saati	Sınav Adı	Sınav Salonu
09.09.2025	09:00-11:00	Uyarı	0101
09.09.2025	09:00-11:00	Uyarı	0102
09.09.2025	09:00-11:00	Uyarı	0103
09.09.2025	09:00-11:00	Uyarı	0104
09.09.2025	09:00-11:00	Uyarı	0105
09.09.2025	09:00-11:00	Uyarı	0106
09.09.2025	09:00-11:00	Uyarı	0107
09.09.2025	09:00-11:00	Uyarı	0108
09.09.2025	10:00-12:00	Girişim	0101
09.09.2025	10:00-12:00	Girişim	0102
09.09.2025	10:00-12:00	Girişim	0103
09.09.2025	10:00-12:00	Girişim	0104
09.09.2025	10:00-12:00	Girişim	0105
09.09.2025	10:00-12:00	Girişim	0106
09.09.2025	10:00-12:00	Girişim	0107
09.09.2025	10:00-12:00	Girişim	0108
09.09.2025	13:00-15:00	Proje Yürütme	0101
09.09.2025	13:00-15:00	Proje Yürütme	0102
09.09.2025	13:00-15:00	Proje Yürütme	0103
09.09.2025	13:00-15:00	Proje Yürütme	0104
09.09.2025	13:00-15:00	Proje Yürütme	0105
09.09.2025	13:00-15:00	Proje Yürütme	0106
09.09.2025	13:00-15:00	Proje Yürütme	0107
09.09.2025	13:00-15:00	Proje Yürütme	0108
10.09.2025	09:00-11:00	Mühendislik	0101
10.09.2025	09:00-11:00	Mühendislik	0102
10.09.2025	09:00-11:00	Mühendislik	0103
10.09.2025	09:00-11:00	Mühendislik	0104
10.09.2025	09:00-11:00	Mühendislik	0105
10.09.2025	09:00-11:00	Mühendislik	0106
10.09.2025	09:00-11:00	Mühendislik	0107
10.09.2025	09:00-11:00	Mühendislik	0108
10.09.2025	10:00-12:00	Yazılım	0101
10.09.2025	10:00-12:00	Yazılım	0102
10.09.2025	10:00-12:00	Yazılım	0103
10.09.2025	10:00-12:00	Yazılım	0104
10.09.2025	10:00-12:00	Yazılım	0105
10.09.2025	10:00-12:00	Yazılım	0106
10.09.2025	10:00-12:00	Yazılım	0107
10.09.2025	10:00-12:00	Yazılım	0108
10.09.2025	13:00-15:00	Sistem	0101
10.09.2025	13:00-15:00	Sistem	0102
10.09.2025	13:00-15:00	Sistem	0103
10.09.2025	13:00-15:00	Sistem	0104
10.09.2025	13:00-15:00	Sistem	0105
10.09.2025	13:00-15:00	Sistem	0106
10.09.2025	13:00-15:00	Sistem	0107
10.09.2025	13:00-15:00	Sistem	0108
11.09.2025	09:00-11:00	Kullanıcı	0101
11.09.2025	09:00-11:00	Kullanıcı	0102
11.09.2025	09:00-11:00	Kullanıcı	0103
11.09.2025	09:00-11:00	Kullanıcı	0104
11.09.2025	09:00-11:00	Kullanıcı	0105
11.09.2025	09:00-11:00	Kullanıcı	0106
11.09.2025	09:00-11:00	Kullanıcı	0107
11.09.2025	09:00-11:00	Kullanıcı	0108

Şekil 7. İSTE Sınav Planlama Sistemi — İSTE Formatında Sınav Programı Görünümü

Şekil 7, sınav programının İSTE'ye özgü tablo düzeninde sunulan görünümünü göstermektedir. Başlıkta bölüm adı ve dönem bilgisi yer alırken, tablo sınav günü, saat, ders adı ve salon gibi bilgileri renk kodları ve satır ayrımlarıyla sunarak okunabilirliği artırmaktadır. Sol sütunda gün ve tarih, diğer sütunlarda ise saat, ders kodu ve adı, sınıf, öğretim üyesi ve salon bilgileri düzenli biçimde verilmiştir. Bu arayüz, yöneticilerin ve akademik personelin sınav programını hızlıca incelemesine ve planlama sürecini kolaylaştırmasına olanak tanır.



Şekil 8. İSTE Sınav Planlama Sistemi — İstatistikler Paneli

Şekil 8, sınav planlama sürecine ait genel durum ve performans verilerini sunan istatistikler panelini göstermektedir. Üst bölümde toplam, planlanmış ve bekleyen sınav sayıları ile derslik bilgileri ve yaklaşan sınav göstergeleri yer alır. Orta bölümdeki “Planlama Durumu” çubuğu mevcut oranı, “Sistem Performansı” alanı ise planlama başarısı ve kapasite kullanımını özetler. Alt bölümdeki sistem özeti, tüm bilgileri tek bakışta sunarak yöneticilerin durumu hızlıca analiz edip önceliklendirme yapmasına imkân tanır.

4. ÖZGÜNLÜK VE LİTERATÜRE KATKI

Bu çalışma, teknik, kullanıcı deneyimi ve pratik uygulama boyutlarında literatüre önemli katkılar sunmaktadır. Teknik açıdan, karmaşık hibrit algoritmalar yerine daha basit ve anlaşılır bir Kısıt Tabanlı Programlama yaklaşımı uygulanmış, sınav planlama probleminde yüksek doğruluk sağlanmıştır. Excel tabanlı çözümler yerine React, TypeScript ve FastAPI teknolojileriyle modern bir mimari benimsenmiş; WebSocket tabanlı gerçek zamanlı güncellemelerle sistemin performansı güçlendirilmiştir. Kullanıcı deneyiminde tam Türkçe arayüz ve dokümantasyon desteğinin yanı sıra istatistik panosu ve görsel raporlama araçlarıyla kapsamlı bir karar destek sistemi sunulmuştur. Modüler bileşen mimarisi bakım kolaylığı ve özelleştirme imkânı sağlamaktadır. Pratik açıdan ise hızlı kurulum, erişilebilirlik ve farklı üniversitelere uyarlanabilir esnek yapısıyla sistemin benimsenmesi kolaylaştırılmıştır.

Bu çalışma, literatürdeki boşluklara doğrudan yanıt vermektedir. Karmaşık algoritmalar yerine anlaşılır bir Kısıt Tabanlı Programlama yaklaşımı sunulmuş, yerel dil desteği eksikliğine karşı tam Türkçe arayüz ve dokümantasyon geliştirilmiştir. Excel ve eski web teknolojileri yerine modern bir teknoloji yığını kullanılarak kullanıcı deneyimi artırılmış, gerçek

zamanlı özelliklerle sistem daha dinamik hale getirilmiştir. Ayrıca kapsamlı analiz araçları sayesinde planlama süreçleri veriyeye dayalı yönetilebilir duruma getirilmiştir.

Sistemin gelecekteki geliştirme hedefleri teknolojik ve işlevsel iyileştirmeleri kapsamaktadır. Bu bağlamda hibrit algoritmalar ve makine öğrenmesi tabanlı optimizasyon yöntemleri entegre edilecek, React Native tabanlı mobil uygulama ve üniversite bilgi sistemleriyle API entegrasyonu sağlanacaktır. Bulut tabanlı dağıtım ve mikroservis mimarisi ile ölçeklenebilirlik artırılırken, JWT kimlik doğrulama ve rol tabanlı erişim kontrolüyle güvenlik güçlendirilecektir. Ayrıca önbellekleme, yük dengeleme, gelişmiş veri analitiği, raporlama araçları ve çoklu dil desteği eklenerek sistem performansı ve uluslararası uyum geliştirilecektir.

5. SONUÇLAR VE DEĞERLENDİRME

5.1. Araştırma Hedeflerinin Gerçekleştirilmesi

Bu çalışmada belirlenen araştırma hedefleri başarıyla gerçekleştirilmiştir. Üniversite sınav planlama sürecinde manuel yöntemlerin yol açtığı verimsizlikleri gidermek amacıyla modern web teknolojileriyle entegre edilmiş bir yazılım mimarisi geliştirilmiş ve Kısıt Tabanlı Programlama yaklaşımıyla etkin bir çözüm sunulmuştur. Sistem, kısıtların açık modellenmesi, kaynak optimizasyonu ve gerçek zamanlı veri yönetimiyle akademik takvim oluşturma sürecini daha şeffaf ve esnek hale getirmiştir. Geliştirilen algoritma, karmaşık hibrit yöntemler yerine daha basit ve hızlı bir çözüm sunmuş, $O(n^2)$ ve $O(n^3)$ düzeylerinde yüksek doğruluk sağlamıştır. React, TypeScript ve FastAPI tabanlı mimari, kullanıcı dostu ve ölçeklenebilir bir yapı sunarken; tam Türkçe arayüz ve dokümantasyon desteğiyle Türkiye'deki üniversiteler için uyumlu bir çözüm oluşturmıştır. WebSocket entegrasyonu ile gerçek zamanlı güncellemeler ve

çalışma kontrolü sağlanmış, gelişmiş istatistik ve raporlama araçlarıyla yöneticilere karar desteği verilmiştir.

5.2. Sistem Performansı ve Teknik Başarılar

Sistem performans testleri, yazılımın hedeflenen kriterlerin üzerinde kararlılık ve verimlilik sunduğunu göstermektedir. İki saniyenin altındaki yanıt süresi, binin üzerinde eşzamanlı işlem desteği ve %99.9 kesintisiz çalışma oranı ile yoğun kullanım koşullarına hazır olduğu kanıtlanmıştır. Bellek optimizasyonu ve sorgu iyileştirmeleri sayesinde veri tabanı yarım saniyeden kısa sürede yanıt verebilmektedir. Proje, 4676 satırlık kod ve 15 modülden oluşan güçlü bir mimari üzerine kurulmuş; ACID uyumlu veri tabanı güvenliği sağlarken 25'in üzerinde RESTful API uç noktası entegrasyona imkân vermektedir. Responsive tasarım ilkeleri ise arayüzün farklı cihazlarda sorunsuz çalışmasını sağlamıştır.

5.3. Literatüre Katkı ve Özgünlük

Bu çalışma, sınav planlama problemine yönelik karmaşık ve maliyetli algoritmalara alternatif bir yaklaşım sunmuştur. Basit Kısıt Tabanlı Programlama modeli, düşük maliyetli ve anlaşılır çözümlerin eğitim kurumlarında uygulanabilirliğini göstermiştir. Modern web teknolojilerinin eğitim yönetiminde etkinliği ortaya konmuş, gerçek zamanlı veri yönetimi ve yerel dil desteğinin önemi vurgulanmıştır. Sistem; düşük algoritma karmaşıklığı, modern yazılım yığını, tam Türkçe arayüz ve dinamik veri işleme özellikleriyle literatürdeki çözümlerden ayrılmaktadır. Ayrıca gelişmiş raporlama ve istatistik panoları sayesinde planlama süreçlerini veriye dayalı yönetime dönüştürerek güçlü bir karar destek aracı sunmaktadır.

5.4. Pratik Uygulama ve Gelecek Perspektifi

Geliştirilen sistem, açık kaynak teknolojilerin avantajlarıyla düşük maliyetli, hızlı kurulabilir ve bakım

gereksinimi düşük bir çözüm sunmaktadır. Kullanıcı dostu arayüzü ve modüler yapısıyla farklı üniversitelerde kolayca uygulanabilir, genişletilebilir ve özelleştirilebilir bir altyapı oluşturulmuştur. Pilot uygulamalarda yüksek güvenilirlik ve kullanıcı memnuniyeti sağlamıştır. Gelecek hedefler arasında hibrit algoritmalar ve makine öğrenmesi tabanlı optimizasyon, mobil uygulama geliştirme, üniversite bilgi sistemleriyle API entegrasyonu ve bulut tabanlı mimariler yer almaktadır. Güvenliği artırmak için JWT tabanlı kimlik doğrulama ve rol bazlı erişim kontrolü; performansı geliştirmek için önbellekleme, yük dengeleme ve veri analitiği entegrasyonu planlanmaktadır. Çoklu dil desteği ve uluslararası standartlara uyumla sistemin küresel ölçekte uygulanabilirliği artırılacaktır.

6. GENEL DEĞERLENDİRME VE SONUÇ

Bu çalışma üniversite sınav planlama süreçlerinin dijitalleştirilmesi ve otomatikleştirilmesi için modern web teknolojileriyle desteklenen, Kısıt Tabanlı Programlama tabanlı bir sistem önermektedir. React ve TypeScript arayüzü ile FastAPI tabanlı sunucu mimarisini birleştiren yapı, literatürdeki karmaşık ve maliyetli çözümlere karşı daha basit, anlaşılır ve pratik bir alternatif sunmaktadır. Türkçe arayüz, kullanıcı dostu tasarım, yüksek performans ve ölçeklenebilirlik özellikleriyle sistem, Türkiye'deki üniversiteler için düşük maliyetli ve uygulanabilir bir çözüm olarak öne çıkmaktadır. Performans testlerinde iki saniyeden kısa yanıt süresi ve binin üzerinde eşzamanlı işlem desteği ile güvenilirliği kanıtlanmış; 15 modül ve 4676 satırlık kod yapısı ile sürdürülebilir bir altyapı sağlanmıştır. Bu çalışma, eğitim yönetiminde yeni nesil yazılımlar için sağlam bir temel oluştururken literatüre basitlik, erişilebilirlik ve yerelleştirme odaklı yenilikçi bir bakış açısı kazandırmaktadır.

KAYNAKÇA

- Gotlieb, A., Mossige, M., & Spieker, H. (2023). Constraint-Guided Test Execution Scheduling: An Experience Report at ABB Robotics. International Conference on Computer Safety, Reliability, and Security.
- Güler, M. G., & Geçici, E. (2020). A spreadsheet-based decision support system for examination timetabling. Turkish Journal of Electrical Engineering and Computer Sciences, 28(1), 1-15.
- Kasthuri, M., Shenabaha, C., & Swetha, G. (2024). An Automated Exam hall management Application that allocates both seating arrangement for students and Invigilation of Supervisor. International Conference on Recent Trends in Computing & Communication Technologies.
- Liu, Y., & Lu, Z. (2024). Research on the integration technology of complex multi- schedule scheduling — A case study of annual project exam scheduling in provincial examination institutions. International Conference on Neural Networks, Information and Communication.
- Lulu, I., Alowais, H., & Turkey, A. (2024). Efficient Solution for Exam Timetabling Problem: A Case Study of the University of Sharjah. International Conference on Developments in eSystems Engineering.
- Nand, R., Reddy, E., & Chaudhary, K. (2024). Preference-Based Stepping Ahead Firefly Algorithm for Solving Real-World Uncapacitated Examination Timetabling Problem. IEEE Access, 12, 1-15.
- Nguyen, S., Thiruvady, D., & Zhang, M. (2021). Automated Design of Multipass Heuristics for Resource-Constrained Job Scheduling With Self-Competitive Genetic

Programming. IEEE Transactions on Cybernetics, 51(6), 3123-3135.

Rezaeipanah, A., Matoori, S. S., & Ahmadi, G. (2020). A hybrid algorithm for the university course timetabling problem using the improved parallel genetic algorithm and local search. Applied Intelligence, 50(1), 1-15.

Zhu, K., Li, L. D., & Li, M. (2021). Developing an Online Examination Timetabling System Using Artificial Bee Colony Algorithm in Higher Education. International Conference on Broadband Communications, Networks and Systems.

ROAD DEFECT DETECTION USING ARTIFICIAL INTELLIGENCE TECHNIQUES

Firdevs ILGAZ¹

Ahmet BABALIK²

1. INTRODUCTION

The detection of damage on road surfaces is very important both economically and in terms of human safety. Not only on road surfaces, but also on aircraft runways, the early detection of defects can reduce repair costs and accident rates. The manual detection of these issues is costly and prone to errors. Recently, studies on this topic have gained significant momentum, with a focus on automating these processes. In defect detection methods, classical image processing techniques may be insufficient due to the different structures of the surfaces. In recent studies, it has been observed that deep learning models are used for defect detection on road surfaces and high accuracies are achieved (Hegde, et al., 2020).

As part of the IEEE Big Data Cup, competitions have been held on various dates since 2018 on the detection and classification of road defects, and the most optimized solution for this issue has been sought (Data, 2018).

¹ Master's student, Konya Technical University, Faculty of Engineering and Nature Science, Department of Computer Engineering, e22822902001@ktun.edu.tr, ORCID: 0009-0006-9366-3330.

² Assoc. Prof. Dr., Konya Technical University, Faculty of Engineering and Nature Science, Department of Computer Engineering, ababalik@ktun.edu.tr, ORCID: 0000-0003-0146-4221.

This study aims to detect defects on road surfaces using open-source datasets and deep learning models commonly used in the field of computer vision. A three-stage structure has been adopted for defect detection, with efforts made to improve model accuracy while minimizing inference time. In the first stage, the CSPDarknet53 model, which is a larger network used in the backbone architecture of the YOLOv8 architecture, has been customized by replacing it with MobilNetv3, which has been developed to be compatible with CPU hardware found in mobile devices (Howard A. G., et al., 2019). It has been customized by replacing it with MobilNetv3. This was done to reduce the inference time of the original model. Then, two different post-processing methods were used with the obtained model. In the post-processing methods, Test Time Augmentation (TTA) was first applied to generate different versions of the images to be analyzed (e.g., mirroring, increasing/decreasing resolution). Then, the backbone of the original model was replaced with a smaller network. The aim was to compensate for the expected decrease in accuracy at this stage and to observe the effect of this on the inference time. All generated synthetic images and the original image were used as input for the model for defect detection. Results that failed to meet a certain threshold were filtered out using the Non-Maximum Suppression (NMS) method, and the most performant results were presented as the final results.

2. MATERIAL AND METHOD

2.1. Dataset

Open source data sets were used in this study. The data sets used consist of images collected from different countries under different climate and light conditions (Arya, Maeda, Ghosh, Toshniwal, & Sekimoto, 2022).

2.2. RDD2022 Dataset

The RDD2022 dataset was collected from six different countries—Japan, India, the Czech Republic, Norway, the United States, and China—using smartphones and high-resolution cameras. Google Street View images are also included in the dataset. It contains 47,420 images and over 55,000 defect examples. Like the RDD2020 dataset, it includes four different types of labels (longitudinal cracks, transverse cracks, alligator cracks, and potholes). The dataset was published as part of the Crowd-Sourced Road Damage Detection Competition (CRDDC'2022) (Arya, Maeda, Ghosh, Toshniwal, & Sekimoto, 2022). The images sizes are 512x512, 600x600, 720x720, and 3650x2044. The dataset was labeled in PASCAL VOC format using the LabelImg application. Figure 1 shows sample images included in the dataset.




Figure 1. Sample images in the RDD2022 dataset: (a) Longitudinal crack, (b) Transverse crack, (c) Crocodile crack, (d) Pothole (Arya, Maeda, Ghosh, Toshniwal, & Sekimoto, 2022)

2.3. SVRDD Dataset

The SVRDD dataset consists of 8,000 street images taken from Baidu Maps. These images contain 20,000 examples of damage. The images were collected from the five main districts of Beijing. These regions are Dongcheng, Xicheng, Haidian, Chaoyang, and Fengtai. The collected images were labeled using LabelImg according to the YOLO format and the Pascal VOC

format (Ren, Zhang, Zhi, Wei, & Feng, 2024). Figure 2 shows sample images of different categories in the SVRDD dataset.



Figure 2. Sample images in the SVRDD dataset: (a) Longitudinal crack and manhole cover, (b) Transverse crack, (c) Alligator crack, (d) Pothole, (e) Longitudinal patch, (f) Transverse patch (Ren, Zhang, Zhi, Wei, & Feng, 2024)

2.4. YOLO (You Only Look Once) Model

Introduced in 2016, the YOLO model has become a highly preferred model for real-time object detection. Compared to other models, the YOLO model has many advantages. The basic YOLO model has been developed to process 45 frames per second and can perform real-time object detection from video streams in 25 milliseconds. Additionally, it achieves twice the mAP value compared to other models. By processing all input simultaneously during training and inference stages, it can easily understand complex relationships (Redmon, Divvala, Girshick, & Farhadi, 2016)

2.5. YOLOv8 Model

This model was introduced in 2023 with improvements in accuracy and speed. Thanks to the updates made on previous

versions, it has been observed that the model produced more successful results compared to past YOLO models. The differences in the number of parameters and latency of the YOLOv8 model compared to other models are shown in Figure 3.




Figure 3. Comparison of the YOLOv8 model with other YOLO models in terms of the number of parameters and latency (Glenn, Ayush, & Jing, 2023)

2.6. MobileNetV3 Model

The MobileNetV3 is a model created by adding the Squeeze-and-Excite operation to the MobileNetV2. The MobileNetV3 is divided into two sub-versions: MobileNetV3-Large and MobileNetV3-Small (Howard A. G., et al., 2019). The MobileNetV3 model was created using NAS, which is used to automatically find the most optimal network architecture, and NetAdapt, which is used to optimize the trained model. The conceptual representation of the MobileNetV2 and MobileNetV3 models is shown in Figure 4 and Figure 5.




Figure 4. MobileNetV2 layer (Inverted Residual Connection and Linear Bottleneck) (Howard A. G., et al., 2019)




Figure 5. MobileNetV2 + Squeeze-and-Excite (Howard A. G., et al., 2019)

The difference between the MobileNetV3-Large model and the MobileNetV3-Small model is related to the number of layers applied. Figures 6 and 7 show detailed information about the layers of the MobileNetV3-Large and MobileNetV3-Small models, respectively.

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	-	RE	1
$112^2 \times 16$	bneck, 3x3	64	24	-	RE	2
$56^2 \times 24$	bneck, 3x3	72	24	-	RE	1
$56^2 \times 24$	bneck, 5x5	72	40	✓	RE	2
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 3x3	240	80	-	HS	2
$14^2 \times 80$	bneck, 3x3	200	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	480	112	✓	HS	1
$14^2 \times 112$	bneck, 3x3	672	112	✓	HS	1
$14^2 \times 112$	bneck, 5x5	672	160	✓	HS	2
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	conv2d, 1x1	-	960	-	HS	1
$7^2 \times 960$	pool, 7x7	-	-	-	-	1
$1^2 \times 960$	conv2d 1x1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1x1, NBN	-	k	-	-	1

Figure 6. MobileNetV3-Large model architecture. SE: Indicates whether the Squeeze-And-Excite block is used in that layer. NL: It indicates the type of nonlinear activation used. (Howard A. G., et al., 2019)

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d, 3x3	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	✓	RE	2
$56^2 \times 16$	bneck, 3x3	72	24	-	RE	2
$28^2 \times 24$	bneck, 3x3	88	24	-	RE	1
$28^2 \times 24$	bneck, 5x5	96	40	✓	HS	2
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1x1	-	576	✓	HS	1
$7^2 \times 576$	pool, 7x7	-	-	-	-	1
$1^2 \times 576$	conv2d 1x1, NBN	-	1024	-	HS	1
$1^2 \times 1024$	conv2d 1x1, NBN	-	k	-	-	1

Figure 7. MobileNetV3-Small model architecture. SE: Indicates whether the Squeeze-And-Excite block is used in that layer. NL: It indicates the type of nonlinear activation used (Howard A. , et al., 2019)

2.7. Post-processing Methods

2.7.1. Test Time Augmentation (TTA)

The amount of data is very important in machine learning methods. Since collecting data is difficult, researchers have turned their attention to data augmentation. Data augmentation can be performed during model training or during inference on the input. This method involves increasing the number of input data by performing various operations (cropping, rotation, etc.) on the visual data provided as input during the testing phase of the model and then applying each of these to the model as input to obtain results. Figure 8 illustrates the impact of the TTA method on the performance of different network models (Shanmugam, Blalock, Balakrishnan, & Guttag, 2020).




Figure 8. The effect of TTA to the performance of different models (Shanmugam, Blalock, Balakrishnan, & Guttag, 2020)

2.7.2. Non-Maximum Suppression (NMS)

The NMS method is widely recognized as a highly effective technique in various image processing and computer vision problems. The primary objective of the method is to reduce the number of potential bounding boxes for each object in an image to a single bounding box. Two threshold values are used in this method: the first threshold is used to filter out bounding boxes with low confidence scores, while the second threshold determines which bounding boxes should be removed. First, bounding boxes that fail to pass the confidence score threshold are deleted. Then, the IoU value between the bounding box with

the highest confidence score and the other bounding boxes is calculated and compared with the second threshold value. Bounding boxes that pass this threshold value are deleted, and bounding boxes with IoU values smaller than this value are retained. Figure 9 illustrates the processing steps of the NMS method using an example image.




Figure 9. Stages of the NMS method (Bodla, Singh, Chellappa, & Davis, 2017)

2.7.3.Evaluation Metrics

After the model training, various evaluation metrics are used to evaluate the model's performance.

Confusion Matrix: A confusion matrix can be used to calculate the success of a classification model. In this matrix, the actual and predicted values are shown. Actual values are expressed as true (true) / false (false), and predicted values are expressed as positive (positive) / negative (negative). In Figure 10, the representation of the actual and predicted values on the confusion matrix is shown.

		Predicted	
		P	N
Actual	T	True Positive (TP)	False Negative (FN)
	F	False Positive (FP)	True Negative (TN)

Figure 10. Confusion Matrix

True Positive (TP): It indicates that the true value of the input represents a positive state and is predicted positively by the model.

False Negative (FN): It indicates that the true value of the input represents a positive state, but the model produces a negative result.

False Positive (FP): It indicates that the true value of the input represents a negative situation, but it is predicted as positive by the model.

True Negative (TN): It indicates that the true value of the input represents a negative situation and is predicted as negative by the model.

Accuracy: It is expressed as the ratio of the model's correct predictions to all predictions. The equations for accuracy metric is given below. This value represents the model's correct classification rate.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}$$

Precision: It represents how many of the model's positive predictions are correct. The precision value is calculated according to the following formula.

$$\text{Precision} = \frac{TP}{TP + FP}$$

Recall: It is used to find out how many of the correct predictions were predicted correctly. The recall value is calculated according to the following formula.

$$\text{Recall} = \frac{TP}{TP + FN}$$

Intersection Over Union (IoU): As shown in the representative image in Figure 11, it represents the intersection of the area

predicted by the model for an object with the actual area divided by the union of these two areas. The threshold value in the IoU metric is also important. For example, if the threshold value is set to 50% and above for the success of a model, then the IoU value of 50% and above will be accepted.



Figure 11. Representation of Intersection / Union Ratio

Average Precision (AP): As seen in Figure 12, this value represents the area under the Precision/Recall curve plotted for each class.




Figure 12. Precision / Recall Curve

Mean Average Precision (mAP): Mean Average Precision (mAP) is a metric used to evaluate the performance of object detection or classification models. It is calculated by taking the meaning of the Average Precision (AP) values computed for each class individually. The mAP value is represented based on a specific IoU value. Common mAP variants are as follows:

mAP@0.5 (mAP50): Only results with an IoU value of 0.5 or higher are considered.

mAP@.5:.95 (mAP [.5:.95]): The model's success is tested at different IoU threshold values and then averaged. These IoU thresholds are as follows: [0.50, 0.55, 0.60, ..., 0.95]. So, the calculations start with the IoU = 0.5 threshold and end with the IoU = 0.95 threshold, increasing by 0.05 each time. In total, AP is calculated for 10 different threshold values, and then the average of the AP values is taken.

$$mAP = \frac{1}{\text{Number of class}} \sum_{i=1}^n AP_i$$

F1 Score: Another important evaluation metric is the F1 Score. It represents the harmonic mean of the precision and recall metrics. F1 score value is calculated according to the following formula.

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

3. RESEARCH RESULT AND DISCUSSION

All experiments were conducted in the Google Colab environment on an NVIDIA A100 Tensor Core GPU with a value of 200 epochs.

3.1. YOLOv8 Model Experiments

Experiments were conducted on the RDD2022 and SVRDD datasets using the nano and large versions of the YOLOv8 model. The experimental results are presented in Table 1. Test results of the YOLOv8 nano/large models on the test images of the RDD2022/SVRDD datasets are shown in Figure 13.

Table 1. Experimental Results of YOLOv8n and YOLOv8l Models

<i>Model</i>	<i>Dataset</i>	<i>mAP</i>	<i>F1 Score</i>	<i>GFlops</i>
<i>YOLOv8n</i>	<i>RDD2022</i>	<i>%51,1</i>	<i>%54</i>	<i>8.2</i>
<i>YOLOv8n</i>	<i>SVRDD</i>	<i>%64,2</i>	<i>%65</i>	<i>8.2</i>
<i>YOLOv8l</i>	<i>RDD2022</i>	<i>%56,1</i>	<i>%57</i>	<i>165.4</i>
<i>YOLOv8l</i>	<i>SVRDD</i>	<i>%69,7</i>	<i>%69</i>	<i>165.4</i>




Figure 13. (a) Results of sample test images from the RDD2022 dataset of the YOLOv8n model (b) Result of a sample test image from the RDD2022 dataset of the YOLOv8l model (c) Result of a sample test image from the SVRDD dataset of the YOLOv8n model (d) Result of a sample test image from the SVRDD dataset of the YOLOv8l model

3.2. Customized YOLOv8 Model Experiments

The experiments of the modified YOLOv8 model were conducted in the Google Colab environment. In this customized YOLO model, experiments were conducted using the nano and large versions over 200 epochs on the RDD2022 and SVRDD datasets. The results of the experiments are presented in Table 2. The sample results of the customized YOLOv8 nano/large models on the test images of the RDD2022/SVRDD datasets are shown in Figure 14.

Table 2. Experimental Results of Customized YOLOv8n Models

<i>Model</i>	<i>Dataset</i>	<i>mAP</i>	<i>F1 Score</i>	<i>GFlops</i>
<i>Custom YOLOv8n</i>	<i>RDD2022</i>	<i>%50,9</i>	<i>%53</i>	<i>13.8</i>
<i>Custom YOLOv8n</i>	<i>SVRDD</i>	<i>%41,4</i>	<i>%44</i>	<i>4.8</i>
<i>Custom YOLOv8l</i>	<i>RDD2022</i>	<i>%51,6</i>	<i>%54</i>	<i>89.6</i>
<i>Custom YOLOv8l</i>	<i>SVRDD</i>	<i>%62,6</i>	<i>%63</i>	<i>89.6</i>




Figure 14. (a) Results of sample test images of the customized YOLOv8n model in the RDD2022 dataset (b) Result of a sample test image of the customized YOLOv8l model in the RDD2022 dataset (c) Result of a sample test image of the customized YOLOv8n model in the SVRDD dataset (d) Result of a sample test image of the customized YOLOv8l model in the SVRDD dataset

3.3. Transfer Learning Experiments with Customized YOLOv8 Model

The customized YOLOv8 model's nano and large versions were initially trained with RDD2022, and then transfer learning was performed on the SVRDD dataset to enhance success. The experimental results are presented in Table 3.

Table 3. Experimental Results of Transfer Learning with Customized YOLOv8 Model Nano/Large Version

<i>Model</i>	<i>Dataset</i>	<i>mAP</i>	<i>F1 Score</i>	<i>GFlops</i>
<i>Custom YOLOv8n</i>	<i>RDD2022 + SVRDD</i>	%65,1	%65	13.8
<i>Custom YOLOv8l</i>	<i>RDD2022 + SVRDD</i>	%65,9	%66	89.6

The sample results of transfer learning models with the customized YOLOv8 nano/large version on the test images of the RDD2022/SVRDD datasets are shown in Figure 15.




Figure 15. (a) Results of sample test images from the RDD2022 dataset of the customized YOLOv8n model with transfer learning applied (b) Result of a sample test image from the RDD2022 dataset of the customized YOLOv8l model with transfer learning applied (c) Result of a sample test image from the SVRDD dataset of the customized YOLOv8n model with transfer learning applied (d) Result of a sample test image from the SVRDD dataset of the customized YOLOv8l model with transfer learning applied

3.4. Experiments using The Customized YOLOv8 Model, Transfer Learning, and Post-Processing Method

To enhance the success of the customized YOLOv8 model, post-processing methods such as TTA and NMS were employed. The experimental results are presented in Table 4.

Figure 16 shows the results obtained after applying the TTA post-processing method on sample input images from RDD2022 dataset of the customized YOLOv8n model. Figure 17 shows the results obtained after applying the TTA and NMS post-processing methods on sample input images from RDD2022 dataset of the customized YOLOv8n model. Figure 18 shows the results obtained after applying the TTA post-processing method on sample input images from SVRDD dataset of the customized YOLOv8n model. Figure 19 shows the results obtained after applying the TTA and NMS post-processing methods on sample input images from SVRDD of the customized YOLOv8n model. Figure 21 shows the results obtained after applying the TTA post-processing method on sample input images from RDD2022 of the customized YOLOv8l model. Figure 20 shows the results obtained after applying the TTA and NMS post-processing methods on sample input images from RDD2022 of the customized YOLOv8l model. Figure 22 shows the results obtained after applying the TTA post-processing method on the input images from SVRDD of the customized YOLOv8l model. Figure 23 shows the results obtained after applying TTA and NMS post-processing methods on the input images from SVRDD of the customized YOLOv8l model.

Table 4. The Experimental results of The Customized YOLOv8 Model Nano/Large Version, Transfer Learning and Post-Processing Method

<i>Model</i>	<i>Dataset</i>	<i>mAP</i>	<i>F1 Score</i>	<i>GFlops</i>
<i>Custom YOLOv8n + TTA + NMS</i>	<i>RDD2022 + SVRDD</i>	<i>%72,7</i>	<i>%71,7</i>	<i>13.8</i>
<i>Custom YOLOv8l + TTA + NMS</i>	<i>RDD2022 + SVRDD</i>	<i>%74,2</i>	<i>%71,9</i>	<i>89.6</i>



Figure 16. The results of the customized YOLOv8n model with transfer learning and TTA applied on a sample test image from RDD2022 dataset (a) The result obtained with the original image (b) The result obtained with the image symmetrically mirrored from left to right (c) The result obtained with the image set to 50% of the original resolution (d) The result obtained with the image set to 75% of the original resolution (e) The result obtained with the image set to 90% of the original resolution



Figure 17. The result of the customized YOLOv8n model with transfer learning, TTA, and NMS applied on a sample test image from the RDD2022 dataset




Figure 18. The results of the customized YOLOv8n model with transfer learning and TTA applied on a sample from SVRDD dataset (a) The result obtained with the original image (b) The result obtained with the image symmetrically mirrored from left to right (c) The result obtained with the image adjusted to 50% of the original resolution (d) The result obtained with the image adjusted to 75% of the original resolution (e) The result obtained with the image adjusted to 90% of the original resolution



Figure 19. The result of the customized YOLOv8n model with transfer learning, TTA, and NMS applied on a sample test image from the SVRDD dataset.



Figure 20. The result of the customized YOLOv8l model with transfer learning, TTA, and NMS applied on a sample test image from the RDD2022 dataset



Figure 21. The results of the customized YOLOv8l model with transfer learning, TTA applied on a sample from RDD2022 dataset: (a) The result obtained with the original image (b) The result obtained with the image symmetrically mirrored from left to right (c) The result obtained with the image adjusted to 50% of the original resolution (d) The result obtained with the image adjusted to 75% of the original resolution (e) The result obtained with the image adjusted to 90% of the original resolution




Figure 22. The results of the customized YOLOv8l model with transfer learning, TTA applied on a sample test image from SVRDD dataset: (a) The result obtained with the original image (b) The result obtained with the image symmetrically mirrored from left to right (c) The result obtained with the image set to 50% of the original resolution (d) The result obtained with the image set to 75% of the original resolution (e) The result obtained with the image set to 90% of the original resolution



Figure 23. The result of the customized YOLOv8l model with transfer learning, TTA and NMS applied on a sample test image from the SVRDD dataset.

4. RESULT AND RECOMMENDATION

Models within the YOLO model family have the capacity to produce successful results using their structures. In addition, it is also possible to increase the models' success when used with post-processing methods. However, an increase in the processing time of the models is also an inevitable outcome. It is also possible to change the network in the YOLO architecture, but care should be taken to balance the trade-off between time and accuracy. When making changes to the YOLO network, any potential performance loss can be compensated for with post-processing methods. The transfer learning method can be considered in terms of the overall success of datasets working on similar problems. As can be seen from the experimental results obtained in this study, the transfer learning method has increased overall success by at least 1%. The post-processing methods, TTA and NMS, have achieved an approximately 9% increase in success.

In future studies, updates to the YOLO network architecture may not be limited to the backbone network but can also be implemented on the neck network. In addition, changes that can be made to the network architecture may also have a positive impact on performance. By diversifying post-processing methods, system performance can be observed. In addition to these, preprocessing methods can also be added to the model and used for the detection and classification of road defects.

REFERENCES

- Alkalbani, A., Saqib, M., Alrawahi, A., Anwar, A., Adak, C., & Anwar, S. (2025). RDD4D: 4D Attention-Guided Road Damage Detection And Classification. doi:10.48550/arXiv.2501.02822
- Arya, D., Maeda, H., Ghosh, S., Toshniwal, D., & Sekimoto, Y. (2021). RDD2020: An annotated image dataset for Automatic Road Damage Detection using Deep Learning. *Data in Brief*, 107133. doi:10.1016/j.dib.2021.107133
- Arya, D., Maeda, H., Ghosh, S., Toshniwal, D., & Sekimoto, Y. (2022). *RDD2022: A multi-national image dataset for automatic Road Damage Detection*. doi:10.48550/arXiv.2209.08538
- Arya, D., Maeda, H., Ghosh, S., Toshniwal, D., & Sekimoto, Y. (2022). RDD2022: A multi-national image dataset for automatic Road Damage Detection. doi:10.48550/arXiv.2209.08538
- Bodla, N., Singh, B., Chellappa, R., & Davis, L. (2017). Improving Object Detection With One Line of Code. doi:10.48550/arXiv.1704.04503
- Data, I. I. (2018). *BigData Cup Challenges – Road Damage Detection and Classification Challenge*. Retrieved from <https://cci.drexel.edu/bigdata/bigdata2018/BigDataCupChallenges.html>
- Firildak, K., & Talu, M. F. (2019). Evriřimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Computer Science*, 88-95. Retrieved from <https://dergipark.org.tr/tr/pub/bbd/issue/49546/527863>
- Glenn, J., Ayush, C., & Jing, Q. (2023). Ultralytics YOLOv8. Retrieved from <https://github.com/ultralytics/ultralytics>

- Hegde, V., Trivedi, D., Alfarrarjeh, A., Deepak, A., Kim, H. S., & Shahabi, C. (2020). Yet Another Deep Learning Approach for Road. *2020 IEEE International Conference on Big Data (Big Data)*, 5553-5558. doi:10.1109/BigData50022.2020.9377833
- Howard, A. G., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., . . . Adam, H. (2019). Searching for MobileNetV3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314-1324.
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., . . . Adam, H. (2019). Searching for MobileNetV3. *IEEE*. doi:10.1109/ICCV.2019.00140
- Howard, A., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., & Andreetto, M. H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.
- Jiang, T.-Y., Liu, Z.-Y., & Zhang, G.-Z. (2025). YOLOv5s-road: Road surface defect detection under engineering environments based on CNN-transformer and adaptively spatial feature fusion. *Measurement*, 115990. doi:https://doi.org/10.1016/j.measurement.2024.115990
- Li, R., & Wang, Z. (2025). AGSAM-Net: UAV route planning and visual guidance model for bridge surface defect detection. *Image and Vision Computing*, 105416.
- Liu, L., Gong, H., Gong, H., Gong, H., & Cong, L. (2025). A YOLO-based network with dynamic feature pyramid for multi-scale bridge surface defect detection. *International Journal of Transportation Science and Technology*. doi:https://doi.org/10.1016/j.ijtst.2025.01.004
- Lv, B., Zhang, S., Gong, H., Zhang, H., Dong, B., Wang, J., . . . Wu, J. (2025). Pavement Disease Visual Detection by

- Structure Perception and Feature Attention Network. *Applied Sciences*, 551.
- Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T., & Omata, H. (2018). Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone. doi:10.48550/arXiv.1801.09454
- Meng, Z., Hu, Y., & Ancey, C. (2020). Using a Data Driven Approach to Predict Waves Generated by Gravity Driven Mass Flows. doi:10.3390/w12020600
- Pan, W., Lei, J., Wang, X., Lv, C., Wang, G., & Li, C. (2025). DAPONet: A Dual Attention and Partially Overparameterized Network for Real-Time Road Damage Detection. *Applied Sciences*, 1470.
- Pan, W., Wang, X., & Huan, W. (2025). *Real-time dynamic scale-aware fusion detection network: take road damage detection as an example*.
- Pan, W., Wang, X., & Huan, W. (2025). Real-time dynamic scale-aware fusion detection network: take road damage detection as an example. *Journal of Real-Time Image Processing*, 55. doi:10.1007/s11554-025-01634-w
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. 779-788. doi:10.1109/CVPR.2016.91
- Ren, M., Zhang, X., Zhi, X., Wei, Y., & Feng, Z. (2024). An annotated street view image dataset for automated road damage detection. *Scientific Data*, 407. doi:10.1038/s41597-024-03263-7
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. 4510-4520. doi:10.1109/CVPR.2018.00474

- Shanmugam, D., Blalock, D., Balakrishnan, G., & Guttag, J. (2020). *When and Why Test-Time Augmentation Works*. doi:10.48550/arXiv.2011.11156
- Teng, T., Prabakaran, V., Ramalingam, B., Jia, Y., Mohan, R. E., & Gómez, B. (2020). Vision Based Wall Following Framework: A Case Study With HSR Robot for Cleaning Application. *Sensors*, 3298. doi:10.3390/s20113298
- Yılmaz, M. (2022). Evrimsel Hesaplama Algoritmaları ile Yapay Sinir Ağının Bağlantılı Optimizasyonu. Retrieved from <https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=sELqxtIFGAjsbjOuuiyCG7Cj11IFDKwnqXcVLpFFF2xWVSKD1ovtsYTF1DEDRWQ>
- Zeng, K., Fan, R., & Tang, X. (2025). Efficient and accurate road crack detection technology based on YOLOv8-ES. *Autonomous Intelligent Systems*, 4.

CATEGORIZATION OF TEA LEAF DISEASE WITH DARKNET53 CNN MODEL

Rıfat AŞLIYAN¹

1. INTRODUCTION

Tea is one of the most popular drinks and it holds significant economic importance in countries where it is cultivated. Tea's yield significantly impacts tea production. Various diseases affecting tea plants can lead to economic losses for both tea producers and governments. If tea diseases are diagnosed very early and accurately, they can be prevented sooner. This allows for containment before diseases spread widely, thereby minimizing damage to farmers and countries (Bao, 2022; Yücel & Yıldırım, 2023).

Traditionally, tea disease diagnosis in conventional agriculture often involves manual inspections. This diagnostic process requires considerable time, expertise, and effort. When it comes to tea cultivation, manually checking for diseases just isn't feasible. On top of that, the visual signs of different diseases can often look quite similar or be a bit unclear, which frequently leads to incorrect diagnoses and treatments that don't actually work. And if a diagnosis is delayed, it can really harm the entire tea crop because diseases spread much quicker (Bao, 2023).

Fortunately, thanks to recent strides, especially in computer vision, we can see much more precise automated ways to diagnose plant diseases. Convolutional neural networks, or CNNs, are particularly amazing at this; they're incredibly good at

¹ Dr. Öğr. Üyesi, Aydın Adnan Menderes Üniversitesi, Fen Fakültesi, Matematik, rasliyan@adu.edu.tr, ORCID: 0000-0003-1495-713X.

automatically pulling out key features from images and then classifying them. By training these CNN models with large collections of plant images, we can build systems that detect diseases with remarkable accuracy. What's more, these systems can even surpass human capabilities when it comes to both speed and consistency (Gayathri et al., 2020; Datta & Gupta, 2023).

When it comes to sorting out tea leaf diseases, machine learning methods and CNN models really stand out. The process usually involves first gathering datasets by hand from tea fields, and then those images are often artificially enhanced or augmented (Hu et al., 2019; Hu & Fang, 2022).

In more traditional machine learning approaches, we start by extracting specific features from images using various processing techniques like color histograms, HOG, SIFT, or GLCM texture features. These extracted features, unique to each image, then form a dataset. These datasets are subsequently used to train and test different machine learning models, such as MLP, Random Forest, and SVM, in order to build predictive systems (Lu et al., 2015; Ragb & Asari, 2016; Hossain et al., 2018; Kaur et al., 2023).

On the other hand, studies that use deep learning for categorizing tea leaf diseases have shown much better results. Typically, models trained with convolutional neural networks like Inception, EfficientNet, VGGNET, and ResNet, which are pre-trained on ImageNet, tend to be more effective. Moreover, the learning process often happens in less time. Some researchers even go a step further and try to increase classification success by creating their own custom convolutional neural networks (Chen, 2019; Kaur et al., 2023; Rahman et al., 2024).

Three generally successful CNN models were used to categorize tea leaf sicknesses in the study conducted by Yücel & Yıldırım (2023). With these CNN models, the features of each

image were extracted. The dataset created by combining the features obtained from each model was then classified using the Linear Discriminant method.

Genshenga et al. (2019) constructed a CNN system to detect tea leaf diseases. They try to reduce the number of parameters and speed up computations. Therefore, they introduced depthwise separable convolution for that. This system provided an accuracy of 92.5% and converged more efficiently than VGG16 and AlexNet.

Gensheng et al. (2019) used SVM technique to determine disease spots on tea leaf images. To enlarge the dataset, they created new training data by a technique called C-DCGAN. These augmented samples were then fed into a VGG16 model to train it. Their study showed that the VGG16 model, trained with the augmented images, could accurately spot tea leaf diseases, achieving an average accuracy of 90%.

Gensheng et al. (2023) introduced a method to evaluate the severity of tea leaf blight from images. Their computer vision-based study proved to be more accurate in estimating disease severity compared to traditional machine learning techniques. According to their the most successful methods, GBM, SVM, and AdaBoost stood out, with average accuracies of 78%, 75%, and 72% respectively.

This work has been performed to construct a fast and accurate model for detecting tea leaf diseases. The DarkNet53 network has been utilized for detection of tea diseases. This approach can greatly benefit tea farmers by protecting tea crops through proactive disease management, and by improving tea's quality and yield.

2. MATERIALS AND METHODS

The CNN as DarkNet53 has been utilized to classify tea sickness dataset in this work.

2.1. DarkNet53 Model

DarkNet53 is one of the CNN in deep learning subject. Darknet53 model represents a subsequent development, following the earlier versions of DarkNet19 and DarkNet21. This model consists of 53 layers. In general, DarkNet53 serves as a backbone architecture for object detection tasks, especially within You Only Look Once (YOLO) technique. This method is highly critical role on YOLOv3 object detection model (Redmon & Farhadi, 2018; Mao, 2019; Wang, 2020).

The structure of DarkNet53 has been built on a principle, with several convolutional layers which are succeeded by skip connections. These skip connections which are inspired from ResNet model, provides reducing the vanishing gradient problem

The components of DarkNet53 are convolutional layers, batch normalization, leaky ReLU activation, skip connections and downsampling layers. The convolutional layers of DarkNet53 incorporates fifty-three layers which employs some kernel sizes especially 1x1 and 3x3 kernel filters. DarkNet53 has utilized batch normalization which is subsequent to each convolutional layer. This technique helps to stabilize the convergence and training. Leaky ReLU activation is an activation function which preserves non-linearity. In very deep neural networks, problems such as vanishing gradients, degradation problems, and exploding gradients can often occur. The concept of skip connections has been put forward to address the issues. A skip connection was defined as a layer's output in a NN being combined with the input of a later layer. It forms the foundation of the ResNet architecture and is also utilized in models like DarkNet53. In convolutional neural networks, the reduction of the feature map dimensions to

enhance generalization is referred to as downsampling layers. These layers provide advantages such as reduced computational cost, increasing receptive field, feature consolidation, and invariance to small translations.

Layer Type	Number of Layers	Kernel Size	Stride	Output Size
Convolutional + BN + Leaky ReLU	1	3x3	1	416 x 416 x 32
Convolutional + BN + Leaky ReLU	1	3x3	2	208 x 208 x 64
Residual Block	1 (2 conv layers)	-	-	208 x 208 x 64
Convolutional + BN + Leaky ReLU	1	3x3	2	104 x 104 x 128
Residual Block	2 (4 conv layers)	-	-	104 x 104 x 128
Convolutional + BN + Leaky ReLU	1	3x3	2	52 x 52 x 256
Residual Block	8 (16 conv layers)	-	-	52 x 52 x 256
Convolutional + BN + Leaky ReLU	1	3x3	2	26 x 26 x 512
Residual Block	8 (16 conv layers)	-	-	26 x 26 x 512
Convolutional + BN + Leaky ReLU	1	3x3	2	13 x 13 x 1024
Residual Block	4 (8 conv layers)	-	-	13 x 13 x 1024
Convolutional + BN + Leaky ReLU	1	1x1	1	13 x 13 x 1024

Figure 1. The configurations of DarkNet53 layers.




Figure 2. DarkNet53 structure.

2.2. Tea Sickness Dataset

This work has focused to categorize the seven most prevalent diseases observed on tea leaves, in addition to healthy tea leaves.

The dataset includes one category for healthy tea leaves and seven categories of unhealthy tea leaves. Each individual class within this collection comprises over 100 images. The entire dataset was meticulously gathered from the Johnstone Boiyon farm situated in the Koiwa location of Bomet county (Kaggle Tea Leaves Dataset, 2025).




Figure 3. Some unhealthy tea leaves.

Table 1. The number of tea leaf sickness images.

Tea Leaf Disease Class	The Number of Leaf Images
Red leaf spot	143
Algal leaf spot	113
Bird's eyespot	100
Gray blight	100
White spot	142
Anthracnose	100
Brown blight	113
Healthy leaf	74
Total Tea Leaves	885

3. RESULTS AND DISCUSSION

The tea leaf images which consist of 8 various classes have been classified in this work. After splitting the tea dataset, the training dataset has been utilized to train with DarkNet53 deep

learning model. The systems which were developed with different parameters have been evaluated by the widely used categorization metrics as F1-score and Accuracy (Acc.). Moreover, the systems' ROC curves and confusion matrices have been constructed, and they have been compared with each other.

A confusion matrix, as illustrated in Table 2, is comprised of four fundamental values: FN (False Negatives), FP (False Positives), TN (True Negatives), and TP (True Positives). The concept of these TP, TN, FP, and FN is crucial for both constructing confusion matrices and deriving various evaluation metrics. In the context of classifying a dataset with two distinct classes (binary classification), one class is designated as the 'Positive' class. Consequently, the remaining class is treated as the 'Negative' class for all subsequent calculations.

Table 2. Confusion matrix.

	Actually "Positive"	Actually "Negative"
Predicted "Positive"	TP	FP
Predicted "Negative"	FN	TN

The accuracy metric indicates how many of all instances (for both Positive and Negative class examples) were classified correctly. Metrics: Recall(Rec.), Precision (Pre.), Accuracy (Acc.).

$$\text{Rec.} = \text{TP} / (\text{TP} + \text{FN}) \quad (1)$$

$$\text{Pre.} = \text{TP} / (\text{TP} + \text{FP}) \quad (2)$$

$$\text{Acc.} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (3)$$

$$\text{F1 - Score} = (2 \times \text{Prec.} \times \text{Rec.}) / (\text{Pre.} + \text{Rec.}) \quad (4)$$

The Receiver Operating Characteristic (ROC) curve is a popular graphical method for evaluating a model's performance across different threshold settings. This visual representation is generated by plotting the True Positive Rate (TPR) against the False Positive Rate (FPR).

The Area Under the Curve (AUC) is an important metric for contrasting distinct systems' effectiveness. It includes success rates based on threshold values. The AUC value, which ranges from 0 to 1, is derived by calculating the area under the ROC curve.

Model training and testing have been coded with MATLAB 2024b. The implementations have been developed on a laptop computer with CPU i7 2.30 GHz processor, 40 GB RAM, and Windows 11 OS. The computer's GPU is especially critical to execute deep learning algorithms, as it accelerates the training process. In this work, NVIDIA GeForce RTX 4050 GPU graphics adapter sped up the training.

In the testing of this study, the K-Fold Cross-Validation (K-FCV) was employed. This method ensures a more accurate and reliable measurement of a machine learning model's success. In other words, it is a crucial statistical method for optimally evaluating model performances.

In K-FCV, after the dataset is divided into K sized folds, Training and testing are performed K times. In each training and testing iteration, one fold is used as the test set, whereas the other folds are utilized to train. After K iterations of training and testing, the average of the model's metrics is computed.

One reason for CNN techniques' great success in image classification is the use of large-scale datasets. Sometimes datasets are not large enough. Small-scale datasets can lead to poor performance of neural networks, as insufficient data reduces the network's generalization ability and can cause overfitting. To eliminate these problems, augmentation can be applied synthetically. That is, new artificial images are generated with the images using various transformations, thus expanding the dataset.

In this study, the augmentation of the images has been applied to training data. First, new images were obtained by

randomly shifting the images along both axes in the range of -50 to +50 pixels. Second, rotations were performed by randomly rotating the images at angles between -50 and +50 degrees. Finally, new images were created by randomly scaling the images within the range of (0.5, 1.5).

3.1. The Model's Results Using Learning Rules

In this study, models were created using Adam, RMSPROP, and SGDM learning rules and compared using the F1-Score classification metric.

Tables 3, 4, and Figure 4 present the F1-Score values of the DarkNet53 convolutional neural network according to different learning rules. Since models have been performed using a 5-FCV, five different models were generated for each learning rule, resulting in five F1-Score values. Therefore, Table 3 displays mean of the values, while Table 4 also includes their standard deviation. According to these tables, the highest F1-Score result was obtained using the Adam learning rule, with an average of 95.1% and a standard deviation of 1.3%. Subsequently, RMSPROP achieved an F1-Score of 94.1%, and SGDM reached 90.9%. The remarkably low standard deviation values indicate the consistency of the results.

Table 3. F1-Score results of learning rules.

Learning Rules	F1-Scores
Adam	0.951
RMSPROP	0.941
SGDM	0.909

Table 4. F1-Score results of learning rules with its standard deviation and mean.

ADAM	Average	0.951
	Std. Dev.	0.013
RMSPROP	Average	0.941
	Std. Dev.	0.018
SGDM	Average	0.909
	Std. Dev.	0.013




Figure 4. The average F1-Scores for learning rules as Adam, RMSPROP and SGDM.

3.2. The Model's Results Using Learning Rates

In this study, models were created using various learning rates (0.000001, 0.00001, 0.0001, 0.001, 0.01) and compared using the F1-Score classification metric.

As displayed in Tables 5, 6, and Figure 5, the average F1-Score results of the DarkNet53 convolutional neural network are compared across different learning rates. According to Tables 5 and 6, the highest F1-Score result has been reached with a learning rate of 0.0001, with an average of 95.1% and a standard deviation of 1.3%. Subsequently, a learning rate of 0.00001 achieved an F1-Score of 92.2%, and 0.000001 reached 81.9%.

Table 5. F1-Score results of learning rates.

Learning Rates	F1-Scores
0.01	0.342
0.001	0.538
0.0001	0.951
0.00001	0.922
0.000001	0.819

Table 6. F1-Score results of learning rates with its standard deviation and mean.

Learning Rates	Average	0.342
0.01	Std. Dev.	0.087
Learning Rates	Average	0.538
0.001	Std. Dev.	0.081
Learning Rates	Average	0.951
0.0001	Std. Dev.	0.013
Learning Rates	Average	0.922
0.00001	Std. Dev.	0.01
Learning Rates	Average	0.819
0.000001	Std. Dev.	0.031




Figure 5. The average F1-Scores for some learning rates.

3.3. The Graphs of the Best Model Results

The models have been constructed with the same parameters using a 5-FCV and tested with five test datasets. The model's confusion matrix with the highest F1-Score, when configured with initial learning rate of 0.0001, max epoch size of 20, Adam learning rule and batch size of 32 is shown in Figure 6. Observing this confusion matrix, it is evident that 26 out of 28 'white spot' images were correctly classified as 'white spot.' Of the remaining two, one was misclassified as 'algal leaf' and the other as 'brown blight.'

Figure 7 displays the ROC curve and AUC values for the best model under the same parameters (max epoch size: 20, learning rule: Adam, mini-batch size: 32, and initial learning rate: 0.0001), indicating highly successful performance. The model calculated AUC values of 100% for many classes.




Figure 6. The best DarkNet53 model's confusion matrix with learning rule: Adam, max epoch size: 20, learning rate: 0.0001 and mini batch size: 32.




Figure 7. AUC And ROC curve results of the best DarkNet53 model with learning rule: Adam, max epoch size: 20, learning rate: 0.0001 and mini batch size: 32.




Figure 8. The best DarkNet53 model's training graph with learning rule: Adam, max epoch size: 20, learning rate: 0.0001 and mini batch size: 32.

4. CONCLUSION

The classification of tea leaf diseases was performed using the DarkNet53 convolutional neural network model in this work. This classification was carried out on an imbalanced dataset comprising eight different classes and a total of 885 images. The dataset was divided into five parts using a 5-FCV, and models were trained and tested using the F1-Measure metric. The standard deviation and mean of the F1-Score metric were calculated to compare the models. Additionally, models were created based on the learning rates and learning rules of the DarkNet53 network to determine the most successful parameters. Accordingly, the best results have been obtained using the Adam learning rule. When the learning rate was 0.0001, a much more successful outcome was achieved compared to other learning rates. The best model, with mean F1-Score success of 95.1%, was created with the following parameters: Learning rule: Adam, learning rate: 0.0001, max epoch size: 20, and mini-batch size: 32.

It is planned to use different convolutional neural networks with various parameters and to create hybrid models for future works.

REFERENCES

- Bao, W., Fan, T., Hu, G., Liang, D., & Li, H. (2022). Detection and identification of tea leaf diseases based on AX-RetinaNet. *Scientific Reports*, 12(1), 2183. doi: s41598-022- 06181-z.
- Bao, W., Zhu, Z., Hu, G., Zhou, X., Zhang, D., & Yang, X. (2023). UAV remote sensing detection of tea leaf blight based on DDMA-YOLO. *Computers and Electronics in Agriculture*, 205, 107637. doi.org/10.1016/j.compag.2023.107637.
- Chen, J., Liu, Q., & Gao, L. (2019). Visual tea leaf disease recognition using a convolutional neural network model. *Symmetry*. 11(3), 343.
- Datta, S., & Gupta, N. (2023). A novel approach for the detection of tea leaf disease using deep neural network. *Procedia Computer Science*, 218, 2273-2286. doi.org/10.1016/j.procs.2023.01.203.
- Gayathri, S., Wise, D. J. W., Shamini, P. B., & Muthukumaran, N. (2020). Image analysis and detection of tea leaf disease using deep learning. In *International Conference on Electronics and Sustainable Communication Systems (ICESC)* (pp. 398-403). IEEE. doi: 10.1109/ICESC48915.2020.9155850.
- Gensheng, H., Haoyu, W., Yan Z., & Mingzhu, W. (2019). A low shot learning method for tea leaf's disease identification. *Computers and Electronics in Agriculture*, 163, 2019,104852. https://doi.org/10.1016/j.compag.2019.104852.
- Gensheng, H., Mingzhu, W., Kang, W., & Ruohan, Y. (2023). Computer vision based method for severity estimation of tea leaf blight in natural scene images. *European Journal*

- of *Agronomy*, 144, 126756.
<https://doi.org/10.1016/j.eja.2023.126756>.
- Gensheng, H., Xiaowei, Y., Yan, Z., Mingzhu, W. (2019). Identification of tea leaf diseases by using an improved deep convolutional neural network. *Sustainable Computing: Informatics and Systems*, 24, 100353. <https://doi.org/10.1016/j.suscom.2019.100353>.
- Hu, G., & Fang, M. (2022). Using a multi-convolutional neural network to identify small-sample tea leaf diseases automatically. *Sustainable Computing: Informatics and Systems*, 35, 100696. doi.org/10.1016/j.suscom.2022.100696
- Hu, G., Yang, X., Zhang, Y., & Wan, M. (2019). Identification of tea leaf diseases by using an improved deep convolutional neural network. *Sustainable Computing: Informatics and Systems*, 24, 100353. doi: 10.1016/j.suscom.2019.100353
- Hossain, Md. S., Mou, R. M., Hasan, M. M., Chakraborty, S., & Razzak, M. A. (2018). Recognition and detection of tea leaf's diseases using support vector machine. *International Colloquium on Signal Processing and Its Applications*, 150–154. <https://doi.org/10.1109/CSPA.2018.8368703>.
- Kaggle Tea Dataset. (2025). Identifying Disease in Tea Leaf, <https://www.kaggle.com/datasets/shashwatwork/identifying-disease-in-tea-leafs>, Last Accessed in 21.08.2025.
- Kaur, A., Kukreja, V. K., Manwal, M., Garg, N., & Hariharan, S. (2023). *Harnessing Deep Learning for Tea Tree Leaf Disease Management: A CNN-SVM Perspective*. 1–6. <https://doi.org/10.1109/punecon58714.2023.10450005>.
- Lu, X., Zhang, S., Yao, H., Sun, X., & Zhang, Y. (2015). Histograms of locally aggregated oriented gradients.

- International Conference on Image Processing*, 1270–1274. <https://doi.org/10.1109/ICIP.2015.7351004>
- Mao, Q.C., Sun, H.M., Liu, Y.B. & Jia, R.S. (2019). Mini-YOLOv3: Real-Time Object Detector for Embedded Applications. In *IEEE Access*, 7(133529-133538). doi: 10.1109/ACCESS.2019.2941547.
- Ragb, H. K., & Asari, V. K. (2016). Histogram of Oriented Phase and Gradient (HOPG) Descriptor for Improved Pedestrian Detection. *Electronic Imaging*, 2016(3), 1–6. <https://doi.org/10.2352/ISSN.2470-1173.2016.3.VSTIA-511>
- Rahman, Md. H., Ahmad, I., Jon, P. H., Salam, A., & Rabbi, Md. F. (2024). Automated detection of selected tea leaf diseases in Bangladesh with convolutional neural network. *Dental Science Reports*, 14(1). <https://doi.org/10.1038/s41598-024-62058-3>.
- Rahman, Md. H., Ahmad, I., Jon, P. H., Rabbi, Md. F., & Salam, A. (2024). *Automated Detection of Selected Tea Leaf Diseases by Digital Image Processing Using Convolutional Neural Network (CNN): Bangladesh Perspective*. <https://doi.org/10.21203/rs.3.rs-3869855/v1>.
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, 18-22 June 2018, 7794-7803.
- Wang, H., Zhang, F., & Wang, L. (2020). Fruit Classification Model Based on Improved Darknet53 Convolutional Neural Network. In *2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)*, Vientiane, Laos,, pp. 881-884. doi: 10.1109/ICITBS49701.2020.00194.

Yücel, N., & Yıldırım, M. (2023). Classification of tea leaves diseases by developed CNN, feature fusion, and classifier based model. *International Journal of Applied Mathematics Electronics and Computers*, 11(1), 30-36. <https://doi.org/10.18100/ijamec.1235611>.

KIDNEY DISEASE DETECTION USING MLP, SVM AND LR METHODS

Rıfat AŞLIYAN¹

1. INTRODUCTION

The kidney is an organ located behind abdominal cavity, slightly above the waist. Chronic Kidney Disease (CKD) is an illness where our kidneys gradually become unable to perform their function, and this progression continues. Eventually, the kidneys completely lose their function. The kidneys' job is to filter and clean the blood. They remove excess fluid from our bodies. If these fluids, which need to be expelled from the blood, accumulate in the body, we experience health problems. In the early phases, the diagnosis of CKS is hard since there are few warnings. In advanced stages, symptoms such as swelling, fatigue, and changes in urination may appear. The most common reasons in the diseases are high blood pressure and diabetes. Additionally, conditions like urinary tract obstruction and polycystic kidney disease can also lead to progressing of CKD (Heerspink et al., 2020; Jha et al., 2013).

To diagnose CKD, blood and urine tests, along with imaging techniques such as ultrasound, are required. This disease, which consists of five stages, leads a gradual decreasing of kidney functionality in each stage. The treatment process for the disease focuses on reducing the symptoms it causes and slowing its progression. Quitting alcohol and smoking are factors that eliminate the development of the CKD. Dieting, balancing blood

¹ Dr. Öğr. Üyesi, Aydın Adnan Menderes Üniversitesi, Fen Fakültesi, Matematik, rasliyan@adu.edu.tr, ORCID: 0000-0003-1495-713X.

pressure, regulating blood sugar, and taking necessary medications to prevent anemia support the slow progression of this disease (Jha et al., 2013; Heerspink et al., 2020).

If CKD has reached its 5th stage, it means kidney failure has developed. In other words, the kidneys can no longer filter the blood. Therefore, patients at this stage must undergo dialysis or a kidney transplant. Dialysis refers to the filtering of blood with a device. Kidney transplantation is when a kidney from another person is surgically removed and transplanted into the patient. Early diagnosis of CKD is crucial. Once diagnosed, the disease needs to be regularly monitored and managed.

Nowadays, the studies on detection of CKD using ML techniques have gained considerable importance. A study by Almasri et al. (2019) achieved successful results in CKD diagnosis with a 99.75% accuracy rate using the random forest ensemble method. Salekin & Stankovic (2016) compared MLP and decision tree methods and found that feature selection significantly increased classification success. Polat et al. (2017) integrated SVM and K-NN methods, achieving a 98.5% accuracy rate. Consequently, machine learning algorithms provide higher accuracy and reliability in the diagnosis of CKD compared to traditional methods.

In this study, the systems for the early and automatic identification of CKD were developed using Logistic Regression (LR) (Cox, 1958; McCullagh & Nelder, 1989; Hosmer & Lemeshow, 2000; Kleinbaum & Klein, 2010), Multi-Layer Perceptron (MLP) (Bishop, 1995; Goodfellow et al., 2016; Haykin, 1999; LeCun et al., 1998), and Support Vector Machine (Burges, 1998; Cortes & Vapnik, 1995; Hsu et al., 2003; Boser et al., 1992) machine learning techniques. A CKD dataset including 25 features and 400 samples was utilized. After imputing missing values, CKD dataset was divided as train and test. These methods

have been trained, and systems have been constructed with the training data. Subsequently, the systems' performances have been compared with Accuracy, F1-Score, AUC, and ROC curves. The highest accuracy of 99.2% was achieved with the LR and MLP methods.

2. MATERIALS AND METHODS

The information about the chronic kidney disease dataset used in the study and the some machine learning methods, namely support vector machine, multilayer perceptron and logistic regression have been provided in the section.

2.1. Support Vector Machines

Support Vector Machine (Boser et al., 1992; Burges, 1998; Cortes & Vapnik; Hsu et al., 2003; Smola & Schölkopf, 2004; Vapnik, 1995), applicable to both regression and classification problems, is a widely used machine learning technique. This machine learning method attempts to find a hyperplane that best separates the classes. In studies conducted to date, it has proven to be a successful technique with high performance in solving many problems.

As seen in Figure 1, Support Vector Machines utilize support vectors in the sample space when trying to find a plane. Support vectors of the method are stated as the closest points to the plane with the largest margin between the classes. Support vectors play a crucial role in accurately determining decision boundaries. If classes are not linearly separable, it is possible to separate them using a hyperplane by increasing the dimensionality with specific kernel functions.

The application areas of Support Vector Machines are quite extensive. They are particularly used with high performance in image recognition, text classification, handwriting recognition,

and bioinformatics. Their success lies in their resistance to overfitting and their generalization capability. As every machine learning method, the selection of parameters in Support Vector Machines is critical for the method's success.

For linearly separable problems, Linear SVM is utilized. In this approach, classes are attempted to be separated by a line or a hyper-plane. However, for non-linearly separable problems, Non-Linear SVM is employed. This is because Non-Linear SVM allows for the separation of classes by increasing dimensionality with the help of a kernel function and a hyperplane.




Figure 1. The structure of SVM.

2.2. Multi-Layer Perceptron

The Multilayer Perceptron (MLP) (Rosenblatt, 1958; Minsky & Papert, 1969; Rumelhart et al., 1986), as seen in Figure 2, is a feedforward and back-propagating artificial neural network consisted of hidden, input, and output layers.

Input layer's neuron size equals to sample size. The presence of intermediate layers differentiates it from simple Perceptrons. In general, the output layer's size equals the categories' size in classification problems. The hidden layers' sizes are decided with the artificial neural network designer. All neurons in contiguous layers are completely connected, with each neuronal connection represented by a numerical weight. These weights are continuously adjusted during training to ensure that the network's outputs for given input samples are identical or very close to the actual outputs. Inputs are given to the network and processed forward to produce an output. This approach enables the MLP network to solve complex non-linear problems.

After the forward pass computation in a Multilayer Perceptron, the network's output and the error are calculated. To minimize the error, a backpropagation process is performed. In this process, the neuron's weights and biases are adjusted. This forward and backward propagation cycle is executed for the training of each sample. In this manner, the artificial neural network gradually learns from the samples and acquires generalization capability. For each neuron, inputs and weights are multiplied and summed to obtain an output. This is then passed through activation functions such as sigmoid, linear, tanh, or ReLU to form the final output. The operations maintain to obtain the final output.

Many factors influence the success of a Multilayer Perceptron. The most important factors include parameters such as the network's learning rate, number of layers, optimization techniques, neurons' size of the layers, and activation functions. Correctly determining these parameters is crucial for the network to acquire generalization ability. Approaches like early stopping, L1/L2 regularization, and dropout are useful in preventing overfitting.




Figure 2. The architecture of MLP.

2.3. Logistic Regression

Logistic Regression (Cox, 1958; Hosmer & Lemeshow, 2000; Breslow & Day, 1980) is a statistical machine learning method frequently used in binary classification problems. When compared to Linear Regression, it can be stated that while Linear Regression produces continuous data as output, Logistic Regression generates binary values. In other words, Linear Regression solves regression problems, whereas Logistic Regression provides solutions for classification problems. After a threshold is decided, while a sample falling below this threshold can be assigned to a class, a sample above it is assigned to the other. The sigmoid function is utilized to compress all data into the 0-1 range in this technique.

In Logistic Regression, after samples pass through the sigmoid function, an 'S'-shaped curve is drawn, bringing small values closer to 0 and large values closer to 1. The output values of this method are in the 0-1 range.

Being a simple and fast method, Logistic Regression offers significant advantages over other methods. Additionally, the method's outputs can be interpreted statistically. Even with large datasets, training can be performed quickly. However, its

success can be lower in solving non-linear tasks. It is ML technique frequently preferred in classification problems in many fields, especially in medicine, marketing, and finance.




Figure 3. The Logistic Regression framework.

2.4. Kidney Disease Dataset

Kidney disease datasets are used to detect chronic kidney disease. They include demographic data of individuals along with medical measurement values such as blood test results.

The work's aim is to resolve whether or not individuals have kidney disease using a kidney disease dataset that contains their blood test values.

This chronic kidney disease dataset, consisting of 400 samples, includes a total of 25 features. The data in this dataset was obtained from patients living in India and comprises features such as age, red blood cell count, potassium, and hemoglobin. Every sample of the dataset has been labeled as "ckd" (chronic kidney disease present) or "notckd" (chronic kidney disease not present). Some of the samples are given as NaN, meaning there are instances with missing data. Therefore, these missing data

points need to be completed or imputed (Kaggle Kidney Leaves Dataset, 2025).

Table 1. The features in kidney disease dataset.

Variable Name	Description	Variable Name	Description
age	age	hemo	hemoglobin
bp	blood pressure	pot	potassium
rbc	red blood cells	sc	serum creatinine
al	albumin	wbcc	white blood cell count
su	sugar	ane	anemia
sg	specific gravity	appet	appetite
pc	pus cell	dm	diabetes mellitus
pcc	pus cell clumps	cad	coronary artery disease
ba	bacteria	htn	hypertension
bgr	blood glucose random	pe	pedal edema
bu	blood urea	rbcc	red blood cell count
pcv	packed cell volume	class	ckd or not ckd
sod	sodium		

3. RESULTS AND DISCUSSION

The samples in kidney disease dataset which consist of two categories as ckd (chronic kidney disease) and notckd (not chronic kidney disease) have been classified in this work. After splitting the kidney disease dataset, the training dataset has been utilized to train with LR, SVM and MLP machine learning method. The systems have been evaluated by the widely used categorization metrics as F1-score and Accuracy (A.). Moreover, the systems' ROC curves and confusion matrices have been constructed, and they have been compared with each other.

A confusion matrix is comprised of four fundamental values: FN- "False Negatives", FP-"False Positives", TN-"True Negatives", and TP-"True Positives". The concept of these TP, TN, FP, and FN is crucial for both constructing confusion

matrices and deriving various evaluation metrics as shown in Equations 1-4.

The accuracy metric indicates how many of all instances (for both Positive and Negative class examples) were classified correctly. Metrics: Recall(R), Precision (P), Accuracy (A).

$$P = TP / (TP + FP) \quad (1)$$

$$R = TP / (TP + FN) \quad (2)$$

$$F1 - Score = (2 \times P \times R) / (P + R) \quad (3)$$

$$A = (TP + TN) / (TP + TN + FP + FN) \quad (4)$$

ROC (Receiver Operating Characteristic) is a graphical curve for evaluating a model's performance across different threshold settings. This visual representation is designed by plotting False Positive Rate against True Positive Rate. Essentially, it quantifies the sensitivity probability in relation to False Positive Rate.

AUC (Area Under the Curve) is an important metric for contrasting the effectiveness of distinct systems. It involves computing success rates based on varying threshold values. The AUC values are computed by area under ROC curve.

Model training and testing were conducted in the MATLAB 2024b. The implementations were developed on a laptop equipped with CPU i7 2.30 GHz processor, 40 GB RAM, and Windows 11 OS. The inclusion of a GPU is especially critical for executing deep learning algorithms, as it substantially accelerates the training process. For this work, an NVIDIA GeForce RTX 4050 GPU graphics adapter significantly expedited the training phase.

In the testing of the work, K-FCV (K-Fold Cross-Validation) has been applied. This method ensures a more accurate result of a machine learning model's success. Moreover,

it is a crucial statistical method for optimally evaluating model performances.

3.1. The Results of Support Vector Machine

Table 2 provides data on the Accuracy, Cost, Error Rate, and Training Time of the system created with DVM. According to this table, the system was trained in 4.89 seconds, and its accuracy has been calculated as 98.5%. Additionally, the system's AUC, Precision, F1-Score and Recall results are displayed as Macro, Micro, and Weighted in Tables 3 and 4. F1-Score value is approximately 98.5% according to these tables, while the AUC value is calculated to be 99.9%.

Table 2. SVM method's test accuracy, cost, error rate, and training time.

Accuracy	Cost	Error Rate	Training Time
98.5 %	6	1.5 %	4.89 sec.

Table 3. SVM method's Precision, F1-Score, and Recall values.

	Precision	Recall	F1-Score
Macro	0.988	0.98	0.984
Micro	0.985	0.985	0.985
Weighted	0.985	0.985	0.985
ckd	0.977	1.0	0.988
notckd	1.0	0.96	0.98

Table 4. AUC results of SVM method.

	AUC
Macro	0.9993
Micro	0.9995
Weighted	0.9994

Since 5-FCV has been applied for testing the models, all samples were tested. Therefore, all 400 samples were tested. Looking at SVM system's confusion matrix in Figure 4, all 250 ckd patients were correctly classified, while 6 out of 150 non-ckd

individuals were incorrectly identified as patients. Figure 5 shows the ROC curve of the SVM system, indicating highly successful performance. The model calculated AUC values of approximately 100% for the classes.




Figure 4. SVM system's confusion matrix.




Figure 5. SVM system's ROC curve.

3.2. The Results of Logistic Regression

Accuracy, Cost, Error Rate, and Training Time values for the system developed with LR have been displayed in Table 5. The system was trained in 1.5 seconds, and its accuracy has been computed as 99.2% according to this table. Furthermore, in Tables 6 and 7, the system's AUC, Recall, F1-Score, and Precision values are displayed as Macro, Micro, and Weighted. F1-Score value is approximately 99.2%, while the AUC value is calculated to be 99.7% according to the tables.

Table 5. LR system's test accuracy, cost, error rate and training time.

Accuracy	Cost	Error Rate	Training Time
99.2 %	-	0.7 %	1.50 sec.

Table 6. LR system's Precision, F1-Score, and Recall values.

	Precision	Recall	F1-Score
Macro	0.99	0.994	0.992
Micro	0.992	0.992	0.992
Weighted	0.993	0.992	0.993
ckd	1.0	0.988	0.994
notckd	0.98	1.0	0.99

Table 7. LR system's AUC results.

	AUC
Macro	0.9977
Micro	0.9971
Weighted	0.9977

As seen in the MLP system's confusion matrix in Figure 6, all 150 non-ckd patients were correctly classified, while 3 out of 250 ckd patients were incorrectly identified as patients. Figure 7 displays the ROC curve indicating very successful performance. The model calculated 100% AUC values for two categories.




Figure 6. LR's confusion matrix.




Figure 7. LR's ROC curve.

3.3. The Results of MLP

Table 8 presents the Accuracy, Cost, Error Rate, and Training Time data for the system developed with LR. According to this table, the system was trained in 1.35 seconds, and the accuracy has been computed as 99.2%. Furthermore, the system's AUC, Recall, F1-Score, and Precision values are displayed as Macro, Micro, and Weighted in Tables 9 and 10. The F1-Score

value is approximately 99.2%, while the AUC value is found to be approximately 99.7% according to the tables.

Table 8. MLP system's test accuracy, cost, error rate and training time.

Accuracy	Cost	Error Rate	Training Time
99.2 %	3	0.7 %	1.35 sec.

Table 9. MLP system's Recall, F1-Score, and Precision results.

	Precision	Recall	F1-Score
Macro	0.99	0.994	0.992
Micro	0.992	0.992	0.992
Weighted	0.993	0.992	0.993
ckd	1.0	0.988	0.994
notckd	0.98	1.0	0.99

Table 10. AUC results of MLP method.

	AUC
Macro	0.9997
Micro	0.9997
Weighted	0.9998

In Figure 8, examining LR's confusion matrix, it can be seen that 3 out of 250 individuals with ckd were incorrectly classified, while all 150 individuals without ckd were correctly classified. Figure 9 displays the ROC curve for SVM system indicating highly successful performance. The model calculated AUC values of about 100% for ckd and notckd categories.




Figure 8. MLP's confusion matrix.




Figure 9. MLP's ROC curve.

4. CONCLUSION

In this study, Chronic Kidney Disease has been classified using MLP, LR, and SVM machine learning methods. Systems were developed to determine whether a person has CKD based on

25 different feature values. The CKD dataset used for training and testing these systems comprises 400 instances, each containing 25 feature values. The dataset, which had many missing values, was completed by filling numerical data with the mean and categorical data with the mode. After splitting the dataset into test and train sets, these methods were trained, and models were created using the training data. Subsequently, the systems' performances have been evaluated using Accuracy, F1-Score, AUC, and ROC curves. The highest accuracy of 99.2% was achieved with the LR and MLP methods.

Future work will involve the automatic detection of CKD using different machine learning methods and various parameter settings.

REFERENCES

- Almasri, A., Alkhawani, M., & Ameen, N. (2019). A novel ensemble learning for predicting chronic kidney disease. *International Journal of Advanced Computer Science and Applications*, 10(8), 234-240. <https://doi.org/10.14569/IJACSA.2019.0100832>.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford University Press.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. In *Proceedings of the Fifth Annual Workshop on Computational Learning Theory* (pp. 144-152). ACM. <https://doi.org/10.1145/130385.130401>.
- Breslow, N. E., & Day, N. E. (1980). Statistical methods in cancer research: Volume I - The analysis of case-control studies. International Agency for Research on Cancer.
- Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121-167. <https://doi.org/10.1023/A:1009715923555>.
- Chen, Z., Zhang, J., Zhang, Z., & Wang, Y. (2020). A deep learning model for predicting chronic kidney disease progression. *IEEE Journal of Biomedical and Health Informatics*, 24(10), 2832-2841. <https://doi.org/10.1109/JBHI.2020.2988787>.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>.
- Cox, D. R. (1958). The regression analysis of binary sequences. *Journal of the Royal Statistical Society: Series*

- B (Methodological), 20(2), 215-232. <https://doi.org/10.1111/j.2517-6161.1958.tb00292.x>.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Heerspink, H. J. L., Stefánsson, B. V., Correa-Rotter, R., Chertow, G. M., Greene, T., Hou, F. F., Mann, J. F. E., McMurray, J. J. V., Lindberg, M., Rossing, P., Sjöström, C. D., Toto, R. D., Langkilde, A. M., & Wheeler, D. C. (2020). Dapagliflozin in patients with chronic kidney disease. *New England Journal of Medicine*, 383(15), 1436-1446. <https://doi.org/10.1056/NEJMoa2024816>.
- Haykin, S. (1999). *Neural networks: A comprehensive foundation* (2nd ed.). Prentice Hall.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8).
- Hosmer, D. W., & Lemeshow, S. (2000). *Applied logistic regression* (2nd ed.). John Wiley & Sons. <https://doi.org/10.1002/0471722146>.
- Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification. *Journal of Machine Learning Research*, 6, 1-16.
- Jha, V., Garcia-Garcia, G., Iseki, K., Li, Z., Naicker, S., Plattner, B., Saran, R., Wang, A. Y. M., & Yang, C. W. (2013). Chronic kidney disease: Global dimension and perspectives. *The Lancet*, 382(9888), 260-272. [https://doi.org/10.1016/S0140-6736\(13\)60687-X](https://doi.org/10.1016/S0140-6736(13)60687-X).

- Kaggle Kidney Dataset. (2025). Chronic Kidney Disease dataset, <https://www.kaggle.com/datasets/mansoordaku/ckdisease/data>, Last Accessed in 23.08.2025.
- Kleinbaum, D. G., & Klein, M. (2010). Logistic regression: A self-learning text (3rd ed.). Springer. <https://doi.org/10.1007/978-1-4419-1742-3>.
- LeCun, Y., Bottou, L., Orr, G. B., & Müller, K. R. (1998). Efficient backprop. In *Neural networks: Tricks of the trade* (pp. 9-50). Springer. https://doi.org/10.1007/3-540-49430-8_2.
- McCullagh, P., & Nelder, J. A. (1989). Generalized linear models (2nd ed.). Chapman and Hall. <https://doi.org/10.1007/978-1-4899-3242-6>.
- Minsky, M., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry*. MIT Press.
- Polat, H., Danaei Mehr, H., & Cetin, A. (2017). Diagnosis of chronic kidney disease based on support vector machine by feature selection methods. *Journal of Medical Systems*, 41(4), 55. <https://doi.org/10.1007/s10916-017-0703-x>.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>.
- Salekin, A., & Stankovic, J. (2016). Detection of chronic kidney disease using selective feature and classifier combination. *Proceedings of the 2016 IEEE First*

International Conference on Connected Health: Applications, Systems and Engineering Technologies (pp. 326-335). <https://doi.org/10.1109/CHASE.2016.18>.

Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199-222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>.

Subasi, A., Alickovic, E., & Kevric, J. (2017). Diagnosis of chronic kidney disease by using random forest. **CMC-Computers, Materials & Continua*, 55(1), 087-101. <https://doi.org/10.3970/cmc.2017.055.087>.

Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer-Verlag. <https://doi.org/10.1007/978-1-4757-2440-0>

Vapnik, V. N. (1998). *Statistical learning theory*. Wiley-Interscience.

3D POINT CLOUD REGISTRATION WITH FULL AFFINE TRANSFORMATIONS OPTIMIZED BY EVOLUTIONARY ALGORITHMS¹

Tuba ÇAĞLIKANTAR²

Erkan BEŞDOK³

1. INTRODUCTION

Three dimensional (3D) models reconstructed from point clouds are widely used in the built environment, cultural heritage, manufacturing, and geomorphology. Terrestrial laser scanning (TLS) and related range sensing systems provide high accuracy under field conditions and support tasks from building documentation and reverse engineering to riverbed analysis and city scale visualization (Son et al., 2002; Korosec et al., 2010; Heritage & Milan, 2009; Portalés et al., 2010). In practice, a single scan seldom captures the entire object because of occlusions and limited fields of view. Multiple scans acquired from different viewpoints must therefore be aligned and merged into a coherent model.

Pairwise registration estimates a spatial transform that aligns a source point cloud to a target. Classical pipelines decompose the task into coarse alignment that uses geometric

¹ This study builds upon the doctoral dissertation of T. Çağlıkantar (formerly T. Kurban) completed at Erciyes University in 2014.

² Asst. Prof. Dr., Ankara Yıldırım Beyazıt University, Faculty of Engineering and Natural Sciences, Software Engineering Department, tubacaglikantar@aybu.edu.tr, ORCID: 0000-0001-5590-5307.

³ Prof. Dr., Erciyes University, Faculty of Engineering, Geomatics Engineering Department, ebesdok@erciyes.edu.tr, ORCID: 0000-0001-9309-375X.

cues to obtain an initial pose and fine alignment that locally minimizes a distance based objective. The Iterative Closest Point (ICP) Algorithm family (Besl & McKay, 1992) and its variants (Rusinkiewicz & Levoy, 2001) are efficient near the correct pose but are sensitive to initialization and to limited overlap. These sensitivities are amplified in practical projects where coverage can be sparse, surfaces are self similar, or data contain outliers.

Registration quality determines how reliable the final 3D model will be. Surveys highlight recurring difficulties such as sensor noise, partial overlap, outliers, and dependence on a good initial pose and their impact on alignment accuracy (Salvi et al., 2007). The ICP algorithm and its variants remain the standard local method because they are simple and fast (Besl & McKay, 1992; Rusinkiewicz & Levoy, 2001). However, ICP is most reliable when the initial pose is already close to the truth and the shared surface area is sufficient otherwise it tends to settle in local minima.

To lessen this dependence on initialization, many pipelines introduce a coarse step before local refinement. Early coarse methods used distinctive local representations and patch relations such as spin images, point signatures, crude patch registration, and least squares surface or curve matching to predict an initial pose that ICP can refine (Johnson, 1997; Chua & Jarvis, 1997; Grün & Akca, 2005). Robust sampling and consensus strategies such as DARCES reduce sensitivity to mismatches and tolerate partially overlapping views (Chuang et al., 1999). Global strategies based on congruent sets or single shot objectives can succeed from wider pose gaps without relying on closest point updates in the inner loop (Aiger et al., 2008; Mellado et al., 2014). Complementary pruning approaches remove only provable outliers while preserving any globally optimal solution, producing cleaner correspondence sets for downstream optimization (Parra Bustos & Chin, 2018). Certifiable

formulations such as TEASER/TEASER++ further decouple scale rotation translation under truncated least squares and offer guarantees under extreme outlier rates (Yang et al., 2020).

Learning has also improved coarse alignment by producing more reliable correspondences. Data driven local descriptors such as 3DMatch and FCGF generalize across scenes and accelerate large scale matching (Zeng et al., 2017; Choy et al., 2019). Deep Global Registration integrates correspondence confidence with a differentiable pose solver, often delivering strong global alignment from arbitrary starts (Choy et al., 2020). When the shared support is small, dedicated methods like PREDATOR explicitly attend to the overlap region and raise success rates where purely local solvers struggle (Huang et al., 2021). Other networks (e.g., SpinNet, PointDSC) target rotation/scale invariance or robust pruning and can be combined with classical optimization (Ao et al., 2021; Bai et al., 2021).

Most of these pipelines assume rigidity (rotation and translation), or at most similarity (adding uniform scale). Yet mild scale or shear mismatches can appear in real projects because of calibration drift, sensor geometry, or object characteristics. Earlier work in medical and geometric registration showed that affine or locally affine models can absorb such deviations but enlarge the search space and introduce additional local minima (Feldmar & Ayache, 1996; Umeyama, 1991). Probabilistic formulations such as Coherent Point Drift explicitly include an affine variant (Myronenko & Song, 2010). These observations motivate broader searches when estimating the transform.

In this study, pairwise registration as the direct optimization of a full affine transform rotation, translation, scale, and shearing is treated. In contrast to rigid ICP, which estimates only rotation and translation, this formulation covers all four components. Because affine estimation increases the chance of

getting trapped in local minima, we use population based heuristics such as Differential Evolution (DE), Particle Swarm Optimization (PSO), Artificial Bee Colony (ABC), and Differential Search (DS) to explore the parameter space more broadly before convergence. We benchmark these heuristics against a strong ICP baseline on a real Statue dataset. Earlier experiments comparing ICP and Differential Evolution on the Bunny dataset demonstrated the potential of global optimization for accurate 3D alignment (Kurban & Beşdok, 2018). Building upon that foundation, the present study extends the approach to full affine transformations and multiple heuristic frameworks.

Low-overlap alignment represents a common failure mode for local registration methods. To explicitly define such conditions, the degree of common support was varied, and the operational measure of overlap was expressed in terms of the correspondence rejection rate, as described in the Methods section. In experiment results, low overlap corresponds roughly to about 70% effective coverage or less. This threshold is consistent with reports that performance degrades as overlap decreases and that global or learning based strategies can help when the shared support is small (Mellado et al., 2014; Huang et al., 2021).

Contributions of this study are: (i) A registration formulation that estimates a full affine transform (rotation, translation, scale, shear), going beyond rigid ICP; (ii) a comparison of four evolutionary heuristics (DE/PSO/ABC/DS) against ICP without a precise initial pose; (iii) an experimental analysis under limited overlap on a real Statue dataset captured with a low cost scanner, illustrating where affine parameters and global search provide gains.

2. MATERIALS AND METHODS

2.1. Problem Statement

The task of 3D point cloud registration is to determine the spatial transformation that best aligns a source point set $\mathbf{P}$ with a target point set $\mathbf{Q}$. A source point cloud is defined as in Equation (1) and a target point cloud as in Equation (2), where N_p and N_q denote the number of points in the source and target sets, respectively.

$$P = \{p_i\}_{i=1}^{N_q}, \quad p_i = [x_i, y_i, z_i]^T \quad (1)$$

$$Q = \{q_j\}_{j=1}^{N_q}, \quad q_j = [x_j, y_j, z_j]^T \quad (2)$$

In many applications, registration is modeled as a *rigid* problem: only a rotation matrix $\mathbf{p}$ and a translation vector $\mathbf{t}$ are estimated, as in the classical ICP algorithm (Besl & McKay, 1992). However, rigid ICP is highly sensitive to initialization and often fails in the presence of partial overlap or sensor miscalibration. To overcome these limitations, this study adopts a full affine model that incorporates rotation, translation, scaling, and shearing parameters. An affine transformation of a point $\mathbf{p}_i$ is expressed as in Equation (3) where where $R(\theta_x, \theta_y, \theta_z)$ is the rotation matrix, $S(S_x, S_y, S_z)$ the scaling matrix, $H(\cdot)$ the shear matrix, and $t = [t_x, t_y, t_z]$ the is translation vector. The parameter vector is given as in Equation (4).

$$p_i' = R(\theta_x, \theta_y, \theta_z) \cdot H(h_{xy}, h_{xz}, h_{yx}, h_{yz}, h_{zx}, h_{zy}) \cdot S(S_x, S_y, S_z) \cdot p_i + t \quad (3)$$

$$\theta = \{t_x, t_y, t_z, \theta_x, \theta_y, \theta_z, S_x, S_y, S_z, h_{xy}, h_{xz}, h_{yx}, h_{yz}, h_{zx}, h_{zy}\} \quad (4)$$

For each transformed source point p_i' , $\sigma(i)$ denotes the index of its nearest neighbor in $\mathbf{Q}$, typically obtained with a kd-tree. To reduce the effect of outliers, the largest $\rho\%$ of residuals

are discarded. The mean squared error (MSE) between the retained correspondences is calculated as in Equation (5), where I is the index set of retained correspondences and $M = |I|$. Registration is then formulated as a global optimization problem as in Equation (6).

$$E_{MSE}(\theta) = \frac{1}{M} \sum_{i \in I} \|RHS \mathbf{p}_i + \mathbf{t} - \mathbf{q}_{\sigma(i)}\|_2^2, \quad (5)$$

$$\theta^* = \arg \min E_{MSE}(\theta) \quad (6)$$

Unlike rigid ICP, which estimates only $\{R, \mathbf{t}\}$, the proposed formulation jointly estimates $\{R, \mathbf{t}, S, H\}$, enabling correction for scale and shear mismatches (Feldmar & Ayache, 1996; Myronenko & Song, 2010). Since this enlarged search space increases the risk of local minima, evolutionary optimization algorithms are employed to explore it effectively.

2.2. Iterative Closest Point Algorithm

The Iterative Closest Point (ICP) algorithm is one of the most widely used techniques for pairwise point cloud registration. It estimates the rigid transformation parameters rotation and translation that align a source point cloud with a target point cloud (Besl & McKay, 1992).

For each transformed source point, its closest neighbor in the target cloud is identified to establish point correspondences. After correspondences are formed, an average alignment error (mean squared error over retained pairs) is computed and minimized. Robust implementations reject outliers before error computation, typically by discarding a fixed percentage of the worst matches.

A common closed form solution for the rigid transform uses Singular Value Decomposition (SVD): the centered cross

covariance of the two correspondence sets is decomposed, yielding the optimal rotation and translation.

In summary, ICP is efficient and deterministic, and many extensions have improved its robustness and convergence (Rusinkiewicz & Levoy, 2001; Pomerleau et al., 2013). However, ICP only estimates rigid parameters and is therefore sensitive to initialization, noise, and partial overlap. This motivates the affine formulation discussed earlier, where scaling and shearing are also incorporated (Feldmar & Ayache, 1996; Myronenko & Song, 2010).

2.3. Heuristic Optimization Algorithms

Heuristic (metaheuristic) optimization algorithms are population based approaches inspired by natural, biological, or physical processes. Unlike classical gradient-based optimization, which can get trapped in local minima, these algorithms emphasize global search and are effective for complex, nonlinear, high-dimensional problems.

DE is a simple yet powerful stochastic search method for continuous optimization that evolves a population by mutation, crossover, and selection (Storn & Price, 1997). The mutation factor controls the amplification of differential variations, while the crossover rate sets how aggressively new trial solutions inherit components from mutant vectors. DE is widely used thanks to its strong exploration ability and small number of control parameters (Das & Suganthan, 2011).

PSO simulates the collective behavior of birds or fish: each particle updates its velocity and position according to its personal best and the global best found by the swarm (Kennedy & Eberhart, 1995; Poli et al., 2007). Inertia weight and acceleration coefficients balance exploration vs. exploitation, enabling fast convergence on many continuous optimization tasks.

ABC mimics the foraging behavior of honey bees using employed, onlooker, and scout phases (Karaboga, 2005). Employed/onlooker phases exploit promising solutions, while scouts reinitialize stagnant ones to maintain diversity. A trial-counter and a replacement limit control the handover between exploitation and exploration.

DS is inspired by the migration of superorganisms (Civicioglu, 2012). It forms donor vectors from other individuals and generates trial solutions via scale-controlled differential updates. A greedy selection step keeps improving the population while sustaining diversity to avoid premature convergence.

2.4. Heuristic Optimization Based 3D Registration

To address the limitations of rigid ICP, a heuristic optimization based framework to estimate full affine transformation parameters (rotation, translation, anisotropic scale, and shear) is applied. Heuristic algorithms are well suited because they perform global search, are less sensitive to initialization, and operate on populations of candidate solutions evaluated in parallel (Storn & Price, 1997; Kennedy & Eberhart, 1995; Karaboga, 2005; Civicioglu, 2012).

To reduce computational cost, voxel grid downsampling is applied prior to optimization, and nearest neighbor queries use kd-trees. Because real scans often have partial overlap, an outlier rejection strategy discards a percentage of the worst residuals before computing the objective (Pomerleau et al., 2013; Huang et al., 2021).

The proposed heuristic optimization based registration framework proceeds as follows:

1. Apply voxel grid downsampling to source and target point clouds.

2. Initialize a population $\mathbf{P}$ of candidate solutions, where each individual encodes the 15 affine parameters $\theta = \{t_x, t_y, t_z, \theta_x, \theta_y, \theta_z, S_x, S_y, S_z, h_{xy}, h_{xz}, h_{yx}, h_{yz}, h_{zx}, h_{zy}\}$
3. For each candidate: transform the source cloud, establish correspondences with the target via a kd-tree, reject the worst $p\%$ matches, and evaluate the objective $\mathbf{E}_{\text{MSE}}(\theta)$.
4. Generate new candidates using the operators of the selected heuristic algorithm.
5. Apply greedy selection to form the next generation.
6. Repeat steps 3–5 until a termination criterion is met (maximum generations or a convergence threshold).

This framework achieves accurate registration without prior alignment and is more robust under low-overlap conditions, where rigid ICP typically fails (Rusinkiewicz & Levoy, 2001). The main trade-off is longer runtime; however, downsampling, outlier rejection, and parallelization on modern multi-core CPUs/GPUs substantially mitigate the cost (Pomerleau et al., 2013).

2.5. Dataset and Data Acquisition

To evaluate the proposed registration method under real-world conditions, a custom dataset is acquired using a computer controlled scanning setup composed of a pan-tilt unit and a laser distance sensor. The system was designed to capture dense and accurate 3D point clouds by rotating the sensor around a stationary object; a statue model. Unlike traditional turntable setups, the object remained fixed during scanning while the sensor moved over predefined orientations with specified angular increments.

In total, seven scans were collected at 0° , 45° , 90° , 135° , 180° , 225° , and 270° . The corresponding point counts were 169.623, 147.555, 125.659, 146.595, 163.642, 140.324, and

119.100, respectively. After merging, the dataset exhibits realistic noise, partial occlusions, and surface incompleteness, closely reflecting practical challenges in 3D scanning applications. The scanning platform consisted of two main components:

- **FLIR PTU-D46-70:** A high-precision pan-tilt unit for positioning sensors such as cameras and lasers. It supports programmable motion over a horizontal (pan) range of -159.65° to 159.67° (24,836 discrete steps) and a vertical (tilt) range of -45.1° to 29.76° (5,823 steps), with a fine angular resolution of 0.012857° and a maximum angular speed of $60^{\circ}/s$. The device supports payloads up to 4 kg and communicates with a host PC via RS-232/RS-485 using ASCII or binary command protocols (FLIR, PTU-D46-70 datasheet).
- **Dimetix FLS-C15:** An industrial grade laser distance sensor capable of non contact measurements from 0.05 m to 65 m with 1.0 mm precision. Operating on the phase-shift principle, it enables high density sampling without the latency typical of time of flight systems. The device is classified as a Class II eye safe laser (Dimetix, FLS-C15 datasheet).

Details of the low-cost scanner design and preliminary experiments were originally described in the related doctoral dissertation (Kurban, 2014 , Kurban & Beşdok, 2015). This configuration provides a cost-effective alternative to high-end commercial laser scanners while maintaining high precision and repeatability (Rocchini et al, 2001; Levoy et al., 2000).

Both the pan-tilt unit and the laser sensor were controlled via serial communication through a custom MATLAB interface. The control software allowed users to specify scanning parameters (pan/tilt angle ranges and step resolutions). The system iteratively moved the sensor to each target angular

position and synchronized laser measurements with motion commands.

Upon completion of the scan sequence, the recorded pan, tilt, and distance data were transformed into 3D Cartesian coordinates (x, y, z), yielding a dense and structured point cloud of the object surface. The overall acquisition procedure followed a systematic loop of initialization, angle stepping, measurement, and coordinate conversion. This custom dataset is available in the *Statue Dataset* repository (Kurban & Beşdok, 2025).

3. EXPERIMENTAL RESULTS

This section reports pairwise registration results on the Statue dataset using the baseline ICP and the proposed heuristic, affine methods (DE, PSO, ABC, DS). Two representative outlier-rejection settings 20% (moderate) and 50% (severe) are given which clearly illustrate robustness differences.

All methods were run for 1500 iterations with a population size of 24 (for heuristics). Control parameters followed commonly used defaults selected via preliminary tuning (Storn & Price, 1997; Kennedy & Eberhart, 1995; Karaboga, 2005; Civicioglu, 2012). Implementations were in MATLAB on an Intel Core i7 / 16 GB RAM workstation with an NVIDIA GTX 1060. Prior to registration, a voxel grid downsampling reduced point density (voxel size 0.5–1.0 mm, chosen empirically). Performance was measured by mean squared error between matched points and by runtime.

At a rejection rate of $\rho = 0.20$, the rigid ICP algorithm frequently failed to achieve proper alignment for wide view-angle separations, resulting in visible residual misalignments in occluded or partially overlapping regions. In contrast, DE, ABC, and DS consistently produced coherent overlays, demonstrating

higher tolerance to noise and viewpoint variation. PSO achieved generally accurate results but occasionally exhibited small mis-registrations for challenging pairs such as 90° – 135° and 215° – 270° . Figure 1 illustrates these results, showing clear qualitative improvements by the heuristic affine methods over ICP.




Figure 1. Visual registration results of the Statue dataset at 20% rejection rate for five algorithms across three groups of point clouds (0° – 90° , 135° – 270° View-1, and 135° – 270° View-2).

When the rejection rate increased to $\rho = 0.50$, ICP performance degraded markedly because of its dependence on dense correspondences. The heuristic affine methods remained stable: DE and DS achieved the lowest alignment errors and visually clean overlays; ABC maintained competitive accuracy; and PSO showed slightly higher variance. Figure 2 presents the visual results under this higher rejection rate.




Figure 2. Visual registration results of the Statue dataset at 50% rejection rate for five algorithms across three groups of point clouds (0°–90°, 135°–270° View-1, and 135°–270° View-2).

As expected, ICP achieved the shortest runtime due to its deterministic, closed form solution. Among the heuristic algorithms, DE and DS offered the best accuracy runtime trade-off, while ABC required longer processing time owing to its probabilistic exploration, and PSO generally exhibited intermediate performance. Despite the added computational cost, the global search capability of the heuristic affine framework led to substantially improved robustness under low overlap and outlier-rich conditions.

Quantitative results summarized in Table 1 confirm these observations. On the *Statue* dataset, the proposed heuristic affine framework consistently achieved lower MSE values and cleaner visual alignments compared with ICP, particularly at $\rho = 0.50$. DE and DS were the most reliable and stable overall, ABC remained competitive, and PSO was moderately sensitive to large angle

differences and measurement noise. These findings align with previous reports on the sensitivity of rigid-only ICP and the advantages of global optimization in complex registration tasks (Pomerleau et al., 2013; Huang et al., 2021).

Table 1. Mean squared error (MSE) results of five algorithms at different rejection rates (ρ) and scan angle combinations for the *Statue* dataset.

Alg.	ρ	Scanning Angles					
		0-45	45-90	90-135	135-180	180-215	215-270
ICP	0.2	8.21(0.00)	4.82(0.00)	22.52(0.00)	6.01(0.00)	4.40(0.00)	5.77(0.00)
	0.3	5.67(0.00)	4.02(0.00)	15.97(0.00)	4.44(0.00)	3.56(0.00)	4.81(0.00)
	0.4	4.33(0.00)	3.41(0.00)	10.32(0.00)	3.53(0.00)	2.94(0.00)	4.38(0.00)
	0.5	10.39(0.00)	2.92(0.00)	6.37(0.00)	2.95(0.00)	2.49(0.00)	3.77(0.00)
DE	0.2	4.57(0.54)	2.53(0.19)	17.58(1.51)	4.18(0.38)	2.84(0.31)	2.83(0.22)
	0.3	2.98(0.34)	3.66(0.28)	11.44(1.25)	2.74(0.27)	3.47(0.41)	2.40(0.27)
	0.4	2.55(0.32)	2.09(0.26)	7.86(0.71)	2.43(0.27)	2.20(0.18)	2.16(0.16)
	0.5	2.30(0.26)	1.92(0.19)	4.62(0.46)	2.14(0.27)	2.00(0.21)	1.98(0.21)
PSO	0.2	5.02(0.61)	11.23(1.33)	17.58(1.84)	4.19(0.34)	2.88(0.24)	12.36(1.52)
	0.3	3.37(0.24)	2.38(0.24)	14.40(1.15)	2.92(0.38)	2.44(0.28)	2.37(0.24)
	0.4	5.02(0.49)	2.70(0.20)	11.49(1.27)	2.47(0.18)	2.97(0.22)	2.44(0.25)
	0.5	2.38(0.18)	2.73(0.33)	8.98(1.07)	2.23(0.25)	2.09(0.17)	6.28(0.69)
ABC	0.2	4.67(0.47)	2.61(0.34)	15.31(1.67)	4.18(0.49)	2.94(0.29)	2.83(0.27)
	0.3	3.10(0.37)	2.32(0.17)	11.48(0.90)	2.76(0.22)	2.42(0.23)	2.37(0.28)
	0.4	2.62(0.31)	2.52(0.19)	7.89(0.74)	2.42(0.25)	2.36(0.22)	2.15(0.24)
	0.5	2.40(0.26)	2.22(0.19)	4.55(0.44)	2.19(0.16)	2.40(0.31)	1.98(0.16)
DS	0.2	4.75(0.36)	2.52(0.23)	15.42(1.26)	4.19(0.42)	2.87(0.26)	2.83(0.36)
	0.3	3.24(0.41)	2.27(0.17)	11.46(1.31)	2.79(0.24)	2.47(0.24)	2.37(0.24)
	0.4	2.63(0.33)	2.10(0.20)	7.89(1.02)	2.38(0.21)	2.29(0.26)	2.16(0.24)
	0.5	2.34(0.24)	2.04(0.23)	4.51(0.50)	2.20(0.18)	2.09(0.16)	1.97(0.26)

4. CONCLUSION

This research has demonstrated that the integration of heuristic optimization algorithms into point cloud registration significantly improves the accuracy and robustness of 3D modeling compared to the classical ICP method on a real *Statue* dataset, obtained with a custom-built point laser scanner. The proposed approach was shown to perform well even under limited overlap conditions, without requiring prior information. While the method is computationally more demanding than ICP, this

drawback can be mitigated through parallel programming and GPU acceleration.

The practical significance of this study extends beyond algorithmic performance. The ability to generate reliable and precise 3D models at low cost directly supports the creation of spatial information that enhances living spaces. In urban planning and construction, accurate models facilitate sustainable design and monitoring. In cultural heritage, improved registration enables digital preservation of artifacts with high fidelity. In medical and industrial contexts, the method supports precise modeling for diagnosis, treatment, and reverse engineering. The proposed framework not only advances registration accuracy and robustness but also highlights affordability and accessibility, bridging the gap between research innovations and real-world deployment.

The main contributions of this study can be summarized as follows:

- A heuristic optimization based registration framework capable of estimating full affine transformations (rotation, translation, scaling, and shearing), overcoming the rigid-only limitation of classical ICP.
- Introduction of the *Statue* dataset, acquired using a custom-built, low-cost laser scanning system, which provides a realistic and affordable benchmark for future research.
- Comprehensive comparison of four heuristic algorithms (DE, PSO, ABC, DS) against ICP on a real world (*Statue*) dataset, with results demonstrating superior robustness, especially under low overlap and noisy conditions.
- The findings highlight the relevance of accurate and cost-effective 3D registration for practical applications such as

urban planning, cultural heritage preservation, medical imaging, and industrial inspection.

Future research will concentrate on hybrid ICP-heuristic frameworks, large-scale dataset expansion, and integration with deep learning techniques to further advance the quality and applicability of 3D spatial data.

REFERENCES

- Aiger, D., Mitra, N. J., & Cohen-Or, D. (2008). 4-Points Congruent Sets for robust pairwise surface registration. *ACM Transactions on Graphics*, 27(3), 1-10.
- Ao, S., Hu, Q., Yang, B., Markham, A., & Guo, Y. (2021). SpinNet: Learning a general surface descriptor for 3D point cloud registration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11753-11762).
- Bai, X., Luo, Z., Zhou, L., Chen, H., Li, L., Hu, Z., & Tai, C.-L. (2021). PointDSC: Robust point cloud registration using deep spatial consistency. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 15859-15869).
- Besl, P. J., & McKay, N. D. (1992). A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2), 239-256.
- Choy, C., Dong, W., & Koltun, V. (2020). Deep Global Registration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 2511-2520).
- Choy, C., Park, J., & Koltun, V. (2019). Fully Convolutional Geometric Features. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 8958-8966).
- Chua, C. S., & Jarvis, R. (1997). Point signatures: A new representation for 3D object recognition. *International Journal of Computer Vision*, 25(1), 63-85.
- Chuang, C. S., Huang, Y. P., & Chen, J. B. (1999). RANSAC-based DARCES: A new approach to fast automatic registration of partially overlapping range images. *IEEE*

Transactions on Pattern Analysis and Machine Intelligence, 21(12), 1229-1234.

- Civicioglu, P. (2012). Transforming geocentric Cartesian coordinates to geodetic coordinates by using Differential Search Algorithm. *Computers & Geosciences*, 46, 229-247.
- Das, S., & Suganthan, P. N. (2011). Differential Evolution: A Survey of the State-of-the-Art. *IEEE Transactions on Evolutionary Computation*, 15(1), 4-31.
- Dimetix. (2023). FLS-C15 Laser Distance Sensor Datasheet. Retrieved from https://dimetix.com/wp-content/uploads/2016/08/DLS_FLS_C_TechnicalManual_V204_en.pdf
- Feldmar, J., & Ayache, N. (1996). Rigid, affine and locally affine registration of free-form surfaces. *International Journal of Computer Vision*, 18(2), 99-119.
- FLIR Systems. (2023). PTU-D46-70 Pan-Tilt Unit Datasheet. Retrieved from https://www.artisanng.com/info/FLIR_Systems_Directed_Perception_PTU_D46_Manual_2020817143111.pdf
- Grüen, A., & Akca, D. (2005). Least squares 3D surface and curve matching. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59(3), 151-174.
- Heritage, G. L., & Milan, D. J. (2009). Terrestrial laser scanning of grain roughness in a gravel-bed river. *Geomorphology*, 113(1-2), 4-11.
- Huang, S., Gojcic, Z., Usvyatsov, M., Wieser, A., & Schindler, K. (2021). PREDATOR: Registration of 3D point clouds with low overlap. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4267-4276).

- Johnson, A. (1997). *Spin-images: A representation for 3-D surface matching* (Robotics Institute). Carnegie Mellon University.
- Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization. *Technical Report-TR06*. Erciyes University, Engineering Faculty, Computer Engineering Department.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks* (Vol. 4, pp. 1942-1948).
- Korosec, M., Duhovnik, J., & Vukasinovic, N. (2010). Identification and optimization of key process parameters in noncontact laser scanning for reverse engineering. *Computer-Aided Design*, 42(8), 744-748.
- Kurban, T. (2014). *3 Boyutlu Nesnelerin Modellenmesi İçin Nokta Bulutlarının Sezgisel Optimizasyon Yöntemleri ile İşlenmesi* [Processing Point Clouds for 3D Object Modeling Using Heuristic Optimization Methods]. (Doctoral dissertation). Erciyes University, Kayseri, Turkey.
- Kurban, T., & Beşdok, E. (2015, May 12–15). *Design, implementation, and comparison of low-cost laser scanning systems for 3D modeling*. In *Proceedings of the 7th International Conference on Information Technology (ICIT 2015)*. Amman, Jordan.
- Kurban, T., & Beşdok, E. (2018, May 2–5). *3-Dimensional point cloud registration using global optimization techniques*. In *Proceedings of the 26th IEEE Signal Processing and Communications Applications Conference (SIU 2018)* (pp. 1–4). İzmir, Turkey: IEEE.

- Kurban, T., & Beşdok, E. (2025). *Statue dataset: Pan-tilt laser-scanned 3D point clouds* [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.17177260>
- Levoy, M., Pulli, K., Curless, B., Rusinkiewicz, S., Koller, D., Fontane, L., ... & Gu, X. (2000). The Digital Michelangelo project: 3D scanning of large statues. In *Proceedings of the 27th annual conference on Computer graphics and interactive techniques* (pp. 131-144).
- Mellado, N., Aiger, D., & Mitra, N. J. (2014). Super4PCS: Fast global pointcloud registration via smart indexing. *Computer Graphics Forum*, 33(5), 205-215.
- Myronenko, A., & Song, X. (2010). Point set registration: Coherent point drift. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(12), 2262-2275.
- Parra Bustos, Á., & Chin, T. J. (2018). Guaranteed outlier removal for point cloud registration with correspondences. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(12), 2868-2882.
- Poli, R., Kennedy, J., & Blackwell, T. (2007). Particle swarm optimization: An overview. *Swarm Intelligence*, 1(1), 33-57.
- Pomerleau, F., Colas, F., Siegwart, R., & Magnenat, S. (2013). Comparing ICP variants on real-world data sets. *Autonomous Robots*, 34(3), 133-148.
- Portalés, C., Lerma, J. L., & Navarro, S. (2010). Augmented reality and photogrammetry: A synergy to visualize physical and virtual city environments. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 134-142.
- Rocchini, C., Cignoni, P., Montani, C., Pingi, P., & Scopigno, R. (2001). A low cost 3D scanner based on structured light. *Computer Graphics Forum*, 20(3), 299-308.

- Rusinkiewicz, S., & Levoy, M. (2001). Efficient variants of the ICP algorithm. In *Proceedings Third International Conference on 3-D Digital Imaging and Modeling* (pp. 145-152).
- Salvi, J., Matabosch, C., Fofi, D., & Forest, J. (2007). A review of recent range image registration methods with accuracy evaluation. *Image and Vision Computing*, 25(5), 578-596.
- Son, S., Park, H., & Lee, K. H. (2002). Automated laser scanning system for reverse engineering and inspection. *International Journal of Machine Tools and Manufacture*, 42(8), 889-897.
- Storn, R., & Price, K. (1997). Differential Evolution – A simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization*, 11(4), 341-359.
- Umeyama, S. (1991). Least-squares estimation of transformation parameters between two point patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(4), 376-380.
- Yang, H., Shi, J., & Carlone, L. (2020). TEASER: Fast and certifiable point cloud registration. *IEEE Transactions on Robotics*, 37(2), 314-333.
- Zeng, A., Song, S., Niessner, M., Fisher, M., Xiao, J., & Funkhouser, T. (2017). 3DMatch: Learning local geometric descriptors from RGB-D reconstructions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1802-1811).

BİYOİNFORMATİK ALANINDA RNA-DİZİLEME (RNA-SEQ) ANALİZİ: TEMELLER VE UYGULAMA ALANLARI

Mustafa Özgür CİNGİZ¹

1. GİRİŞ

İnsan ve tüm canlıların fizyolojisini anlamak ve özellikle hastalık gibi farklı fenotiplere neden olan genom bazlı bazı yapıları ve onların fonksiyonlarını araştırmak biyolojide önem taşımaktadır. Farklı tip hücrelerde aktif olarak yer alan genler ve bu genlerin alternatif izoformlarının belirlenmesi, hücreler arası değişimin nedenlerinin anlaşılması açısından önem taşımaktadır. Transkriptom (tüm RNA çeşitleri; mesajcı RNA, taşıyıcı RNA, ribozomal RNA, miRNA-siRNA gibi mikro RNA'lar) verisi, hücrelerde farklılaşmaya neden olan proteinler ve o proteinlerle ilgili genlerin keşfinde yeni nesil dizileme (NGS, next generation sequencing) teknikleriyle kullanılmaya başlayan bir yaklaşımdır.

Yüksek işlem hacimli (high-throughput) RNA dizileme (RNA-Seq) transkriptoma genel ve kapsamlı bir bakış sağlamanın yanı sıra RNA'yı üreten DNA alanlarını anlama ve bu alanları genlerle ve genlerin izoformlarıyla ilişkilendirmede kullanılan karmaşık hesaplamaları bütünüdür. Genel olarak RNA-Seq, tüm RNA moleküllerinden DNA dizilimi parçalarını elde etmeye yarayan deneysel adımlardır. RNA-Seq ile genom üzerinde yeni genlerin ve/veya bilinen ama izoform varyanslarının bir kısmı çıkartılmamış gene ait yeni izoformların keşfi mümkündür.


¹ Assoc. Prof. Dr., Department of Computer Engineering, Faculty of Engineering and Natural Sciences, Bursa Technical University, mustafa.cingiz@btu.edu.tr, ORCID: 0000-0003-4469-1440.

RNA-Seq, mikrodizi gen ifadesi verilerinin kullanıldığı gibi gen ifadesi analizinde son yıllarda oldukça popüler olarak kullanılmaktadır. RNA-Seq ve mikrodizi verilerini kullanan ortak çalışmalar sonucunda RNA-Seq verilerinin daha dinamik bir aralığa ve daha az arka plan gürültüsüne sahip olduğu görülmektedir. Mikrodizi ile belirlenen ifade değerleri ve alternatif uçbirleştirme gibi sonuçların RNA-Seq sonuçlarıyla büyük ölçüde örtüşmediği görülmüştür. RNA-Seq'in mikrodiziye göre en önemli avantajları şunlardır: geniş dinamik aralık (105 bp, baz çifti, kadar), yüksek hassasiyet, daha düşük seviyelerdeki transkriptleri belirleyebilme, yeni gen ve izoform keşfi yapabilmektir.

2. RNA-SEQ TEMELLERİ

RNA-Seq süreci temel olarak iki ana adımdan oluşur: deneysel adımlar (kütüphane hazırlama ve dizileme) ve hesaplama adımları (dizileme okumalarının genom haritasına yerleştirilmesi ve analizi). Şekil 1'de bu temel iki adım detaylarıyla birlikte gösterilmiştir.

Şekil 1. RNA dizilime analizi temel adımları (Cingiz., 2018)



2.1. Deneysel Adımlar

RNA-Seq'in deneysel adımları, yüksek işlem hacimli dizileme teknolojilerini kullanarak, hücreden izole edilen RNA'nın cDNA'ya (complementary DNA, tamamlayıcı DNA) dönüştürülmesi ve bu cDNA'ların dizilenmesi süreçlerini içerir. Bu süreçte kritik nokta, ribozomal RNA'nın (rRNA) uzaklaştırılması veya poliadenile edilmiş mRNA'nın zenginleştirilmesidir. Elde edilen kısa dizileme okumaları (reads) daha sonra hesaplama adımlarında kullanılır.

2.2. Hesaplama Adımları

Dizileme sonrası elde edilen kısa okumaların analizi, tüm RNA-Seq analizinin temelini oluşturur.

2.2.1. Okuma Örtüştürme (Mapping) ve Transkriptom Oluşturma

Okuma örtüştürme (Mapping), dizileme okumalarının referans genom (veya transkriptom) üzerine yerleştirilmesi işlemidir. Bu işlem için TopHat (Trapnell et al., 2009), MapSplice (Wang et al., 2010) ve Hu et al. (2010) gibi farklı hizalama araçları geliştirilmiştir. Okuma örtüştürme araçları, özellikle alternatif uçbirleştirme bölgelerinde oluşan "splice junction" okumalarını doğru bir şekilde hizalamayı hedefler.


2.2.2. İfade Değeri Belirleme (Quantification)

Transkript ifadesinin belirlenmesi (Quantification), her bir genin veya transkript izoformunun görelî okuma sayısı yoğunluğunu hesaplamayı içerir. Cufflinks (Trapnell et al., 2012) gibi araçlar, örtüştürülmüş okumaları kullanarak hem transkriptleri yeniden oluşturur (reconstruction) hem de bunların ifade düzeylerini belirler. Elde edilen ifade düzeyleri, daha sonraki analizler için girdi oluşturur.

2.2.3. Alternatif Uçbirleştirme (Alternative Splicing) ve Füzyon Gen Keşfi

Şekil 2’de gösterildiği gibi RNA-Seq verileri, sadece gen ifadesini değil, aynı zamanda alternatif uçbirleştirme ve füzyon genlerini de ortaya çıkarabilir. Alternatif uçbirleştirme, aynı genden farklı protein izoformlarının üretilmesini sağlar ve hastalık mekanizmalarını anlamak için kritiktir. Füzyon genleri ise genellikle kanser gibi hastalıklarda görülen kromozomal yeniden düzenlemeler sonucu iki farklı genin birleşmesiyle oluşur.

Şekil 2. Bir gen için alternatif uçbirleştirme mekanizmasının şematik gösterimi.



3. LİTERATÜRDEKİ ÇALIŞMALAR

RNA-Seq'in kullanımının yaygınlaşması, gen ifadesi analizinde standartların belirlenmesi ve yeni yaklaşımların geliştirilmesi konusunda kapsamlı çalışmalara yol açmıştır.(Rosati et al., 2024; Zhang et al., 2025; Tzec-Interián et al., 2025)

3.1. Diferansiyel İfade Analizi ve Normalizasyon

Diferansiyel İfade (DE) analizi, farklı biyolojik koşullar (örneğin, hasta vs. sağlıklı) altındaki gen ifadesi seviyelerindeki istatistiksel olarak anlamlı değişiklikleri belirlemeyi amaçlar.

3.1.1. Normalizasyon Yöntemleri

RNA-Seq verilerinin doğru bir şekilde karşılaştırılması için normalizasyon zorunludur. Popüler normalizasyon yöntemleri şunlardır:

- **RPKM (Reads Per Kilobase Million):** Okuma sayısını, transkript uzunluğuna (kilobaz) ve toplam dizileme derinliğine (milyon okuma) göre belirler (Withanage et al., 2022).
- **TMM (Trimmed Mean of M-values):** Medyan tabanlı bir yaklaşımla dizileme derinliği arasındaki sistematik farklılıkları gidermeyi amaçlar. Bu yöntem, büyük oranda diferansiyel ifade edilmiş gen setleri olduğunda daha sağlam sonuçlar verir (Cingiz., 2021).
- **Göreceli Log İfadesi Normalizasyonu (Relative Log Expression normalization):** Temel varsayım, diferansiyel ifade edilmeyen (yani fenotiplere veya zamana göre değişmeyen) genlerin okuma sayılarının, örneklerle ait düzeltme faktörleriyle orantılı olmasıdır. Normalizasyon, her genin okuma değerini, o genin tüm örneklerdeki okuma değerlerinin geometrik ortalamasına oranlayarak gerçekleştirilir. Son olarak, her örneğe özgü düzeltme faktörü, bu oranların medyan değeri alınarak hesaplanır (Cingiz., 2021).

3.1.2. DE Analizi İçin İstatistiksel Araçlar

Normalizasyon sonrası, veriler istatistiksel olarak test edilir. EdgeR ve DESeq2 gibi araçlar, okuma sayılarının

dağılımını (genellikle Negatif Binom Dağılımı) modelleyerek, iki veya daha fazla koşul arasındaki ifade farklılıklarını belirler.

3.2. Ağ Çıkarımı Karşılaştırmaları

RNA-Seq verileri kullanılarak Gen Düzenleyici Ağ (GRN) çıkarımı yapılırken, elde edilen sonuçların güvenilirliği, kullanılan yöntem ve verinin kalitesine bağlıdır. Ballouz, Verleyen ve Gillis (2015) tarafından yapılan bir çalışmada, RNA-Seq ile Gen Ekspresyonu Ağlarının (Co-expression networks) oluşturulması ve analizine dair rehberlik sunulmuştur. Bu çalışma, yüksek kaliteli RNA-Seq verilerinin, gen ağı çıkarımı için mikrodizi verilerine göre daha güvenilir sonuçlar ürettiğini göstermiştir. Ancak, yeterli örnek büyüklüğü ve uygun normalizasyonun ağ kalitesi için hayati öneme sahip olduğu vurgulanmıştır.

Giorgi, F. M. ve arkadaşları (2013) tarafından yapılan kapsamlı bir karşılaştırmalı analizde, RNA-Seq ve mikrodizi verilerinden elde edilen gen ifadelerinin ve biyolojik yorumlarının örtüşme dereceleri incelenmiştir. Bu tür çalışmalar, RNA-Seq'in biyolojik ağların daha hassas ve doğru bir şekilde çıkarılmasına olanak tanıdığını, özellikle düşük ifade edilen transkriptler üzerindeki üstünlüğünün ağ topolojisini önemli ölçüde etkilediğini göstermiştir.

4. RNA-SEQ VERİLERİYLE AĞ ÇIKARIMI VE SİSTEM BİYOLOJİSİ YAKLAŞIMLARI

Gen ifadesi verilerinin temel uygulamalarından biri, genlerin ortak düzenlenmesini (co-regulation) gösteren Biyolojik Ağların veya Gen Düzenleyici Ağların (GRN) çıkarılmasıdır.

4.1. Gen Düzenleyici Ağların Çıkarılması

Ağ çıkarımı, genellikle genlerin ifade profilleri arasındaki korelasyonu veya karşılıklı bilgiyi (Mutual Information)

hesaplayarak yapılır. RNA-Seq verileri, ifade değerlerinin geniş dinamik aralığı sayesinde, ağ çıkarımında daha kesin korelasyonlar yakalama potansiyeli sunar. RNA-Seq ile ağ çıkarımında kullanılan başlıca yöntemler şunlardır:

- **Korelasyon Tabanlı Ağlar (WGCNA):** Genler arasındaki korelasyon matrisini kullanarak modüler yapılar ve ortak düzenleme kümeleri (modüller) oluşturur. (Langfelder et al., 2008)
- **Bayes Ağları veya Dinamik Modeller:** Özellikle zaman serisi RNA-Seq verileri kullanıldığında genler arasındaki nedensellik ilişkilerini modellemek için kullanılır. (Shi et al., 2025)

4.2. Sistem Biyolojisi Uygulamaları

Çıkarılan gen ağları, gen ifadesi verilerini bir sistem bağlamında yorumlamaya olanak tanır. RNA-Seq verilerinden elde edilen DE gen setleri veya ağ modülleri, sistem biyolojisinin temel araçları olan Zenginleştirme (Enrichment) ve Yol (Pathway) analizleri için girdi olarak kullanılır.

- **Zenginleştirme Analizi (GO ve KEGG):** Farklı ifade edilen genlerin veya bir ağ modülündeki genlerin, bilinen biyolojik süreçlerde (Gene Ontology – GO) veya sinyal yollarında (KEGG) istatistiksel olarak zenginleşip zenginleşmediğini test eder. Bu analizler, biyolojik sistemin hastalık veya tedaviye verdiği yanıtı moleküler düzeyde açıklamaya yardımcı olur.
- **Modül Analizi:** Ağdaki yüksek korelasyonlu gen gruplarının (modüllerin) tanımlanması, biyolojik fonksiyonu ortak olan gen setlerini ortaya çıkarır. Bu modüller, kritik anahtar genlerin (hub genler) belirlenmesinde kullanılır.

5. SONUÇ

RNA Dizileme, genomik araştırmalarda paradigma değişimine yol açmış, biyolojik süreçlerin dinamik doğasını çözümlemede merkezi bir araç haline gelmiştir. Gen ekspresyon düzeylerinin hassas ölçümü sayesinde, hücresel yanıt mekanizmaları, dokuya özgü gen düzenlenmeleri ve hastalıklara ilişkin moleküler profiller ayrıntılı biçimde ortaya konulabilmektedir. RNA-seq, klasik mikrodizi yaklaşımlarına kıyasla hem duyarlılık hem de kapsama alanı bakımından çok daha üstündür; bu yönüyle genetik regülasyonun karmaşık yapısını anlamada vazgeçilmez bir yöntem haline gelmiştir.

Diferansiyel ifade analizi ve ağ çıkarımı yaklaşımları, RNA-seq verilerinin sunduğu bilgi derinliğinin iki tamamlayıcı boyutunu temsil eder. Diferansiyel ifade analizi, tek tek genlerin koşullar arası değişimini istatistiksel olarak saptarken, ağ çıkarımı bu genlerin sistemsel düzeydeki ilişkilerini anlamaya odaklanır. Bu iki yöntemin birlikte kullanılması, biyolojik sistemlerin bütüncül incelenmesini sağlar. Özellikle kanser, nörodejeneratif ve metabolik hastalıklar gibi karmaşık patolojilerde gen düzeyindeki küçük değişimlerin ağ bazında nasıl büyük biyolojik etkiler yarattığını anlamak bu sayede mümkün hale gelmektedir.

Günümüzde RNA-seq verileri, yalnızca gen ifadelerinin ölçülmesiyle sınırlı kalmayıp, aynı zamanda epigenetik, proteomik ve metabolomik verilerle entegre edilerek çok boyutlu biyolojik modellerin oluşturulmasında kullanılmaktadır. Bu “çoklu-omik” yaklaşımlar, gen regülasyonunun zamansal ve mekânsal boyutlarını da göz önüne alarak biyolojik sistemlerin daha doğru temsillerini sunmaktadır. Ayrıca, tek hücre RNA-seq (scRNA-seq) ve mekansal transkriptomik teknolojilerindeki gelişmeler, hücresel heterojenliği çözümlemede yeni bir dönemi başlatmıştır.

Yapay zekâ ve makine öğrenmesi tabanlı modellerin RNA-seq analizlerinde giderek artan şekilde kullanılması, verilerin yorumlanmasını daha derin ve öngörücü hale getirmektedir. Özellikle derin öğrenme temelli ağ çıkarım yaklaşımları, klasik istatistiksel yöntemlerin ötesine geçerek doğrusal olmayan ilişkileri de yakalayabilmektedir. Bununla birlikte, büyük ölçekli RNA-seq veri setlerinin depolanması, işlenmesi ve etik biçimde paylaşımı da gelecekte dikkat edilmesi gereken önemli alanlardan biridir.

Sonuç olarak, RNA-seq teknolojisi yalnızca bir analiz yöntemi değil, modern biyolojinin deneysel, hesaplamalı ve sistemsel tüm yönlerini birleştiren kapsamlı bir paradigma haline gelmiştir. Önümüzdeki yıllarda uzun-okuma platformları, tek hücre analizleri ve çoklu-omik entegrasyonların birleşimiyle RNA-seq, hem temel bilimlerde hem de klinik araştırmalarda daha da merkezi bir konuma yükselecektir.

KAYNAKLAR

- Alternatif Uçbirleştirme Resmi Kaynağı:
http://www.nlm.nih.gov/Modules/MolBioReview/images/alternative_splicing.gif
- Ballouz, S., Verleyen, W., & Gillis, J. (2015). Guidance for RNA-seq co-expression network construction and analysis: safety in numbers. *Bioinformatics*.
- Cingiz, M. Ö. (2018). İki katmanlı entegrasyon mimarisiiyle hastalığa özel birliktelik ağı çıkarımı. Doktora Tezi, Yıldız Teknik Üniversitesi
- Cingiz, M. Ö. (2021). Normalizasyon Yöntemlerinin RNA-Seq Verileri Üzerinde Çıkarılan Gen Birlikte İfade Edilme Ağlarının Performansına Etkisi. *Duzce University Journal of Science and Technology*, 9(2), 878-889.
- de Matos Simoes, R., et al. (2015). Urothelial cancer gene regulatory networks inferred from large-scale RNAseq, Bead and Oligo gene expression data. *BMC systems biology*, 9(1), 21.
- Giorgi, F. M., et al. (2013). The RPKM measure is superior to FPKM and TPM in RNA-seq: a comparison of gene quantification methods. *BMC genomics*, 14(1), 585.
- Hu, Y., et al. (2010). A Probabilistic Framework for Aligning Paired-end RNA-seq Data. *Bioinformatics*.
- Iancu, O. D., Kawane, S., Bottomly, D., Searles, R., Hitzemann, R., & McWeeney, S. (2012). Utilizing RNA-Seq data for de novo coexpression network inference. *Bioinformatics*, 28(12), 1592-1597.
- Langfelder, P., & Horvath, S. (2008). WGCNA: an R package for weighted correlation network analysis. *BMC bioinformatics*, 9(1), 559.

- Rosati, D., Palmieri, M., Brunelli, G., Morrione, A., Iannelli, F., Frullanti, E., & Giordano, A. (2024). Differential gene expression analysis pipelines and bioinformatic tools for the identification of specific biomarkers: A review. *Computational and structural biotechnology journal*, 23, 1154-1168.
- Shi, X., Wang, X., Jin, L., Halakivi-Clarke, L., Clarke, R., Neuwald, A. F., & Xuan, J. (2025). Bayesian identification of differentially expressed isoforms using a novel joint model of RNA-seq data. *PLoS computational biology*, 21(1), e1012750.
- TCGA Füzyon Geni Veri Portalı:
<http://54.84.12.177/PanCanFusV2/>
- Trapnell, C., et al. (2012). Differential gene and transcript expression analysis of RNA-seq experiments with TopHat and Cufflinks. *Nature protocols*, 7(3), 562-578.
- Trapnell, C., Pachter, L., & Salzberg, S. L. (2009). TopHat: discovering splice junctions with RNA-Seq. *Bioinformatics*, 25(9), 1105-1111.
- Tzec-Interián, J. A., González-Padilla, D., & Góngora-Castillo, E. B. (2025). Bioinformatics perspectives on transcriptomics: A comprehensive review of bulk and single-cell RNA sequencing analyses. *Quantitative Biology*, 13(2), e78.
- Wang, K., et al. (2010). MapSplice: Accurate Mapping of RNA-seq Reads for Splice Junction Discovery. *Nucleic Acids Research*.
- Withanage, M. H. H., Liang, H., & Zeng, E. (2022). RNA-Seq experiment and data analysis. In *Estrogen Receptors: Methods and Protocols* (pp. 405-424). New York, NY: Springer US.

Zhang, L., Yang, Y., & Tan, J. (2025). Applications and emerging challenges of single-cell RNA sequencing technology in tumor drug discovery. *Drug discovery today*, 104290.

YAPAY ZEKÂ DESTEKLİ KİŞİSELLEŞTİRİLMİŞ ÖĞRENME SİSTEMLERİ

Kadir TURGUT¹

1. GİRİŞ

Dijital çağın ivmelenen teknolojik gelişmeleri, eğitim sistemlerini yalnızca yüzeysel biçimde değil, yapısal olarak dönüştürmektedir. Bu dönüşümün merkezinde yer alan yapay zekâ (YZ) teknolojileri, öğretme ve öğrenme süreçlerine yönelik klasik yaklaşımların yeniden değerlendirilmesini zorunlu kılmıştır. Özellikle bireysel farklılıkları merkeze alan pedagojik modellerin yükselişiyle birlikte, YZ tabanlı sistemlerin sunduğu kişiselleştirme olanakları, çağdaş eğitimin en stratejik bileşenlerinden biri hâline gelmiştir (Zawacki-Richter et al., 2019). Klasik öğretim yöntemlerinin homojen yapısına karşılık, YZ destekli kişiselleştirilmiş öğrenme sistemleri, öğrencilerin bilişsel kapasiteleri, öğrenme hızları, ilgi alanları ve davranışsal eğilimlerine göre dinamik ve esnek öğrenme yolları inşa edebilmektedir.

Kişiselleştirilmiş öğrenme kavramı temelde, “öğrencinin öğrenme sürecine aktif olarak katıldığı ve bu sürecin bireysel ihtiyaçlara göre şekillendiği” bir öğretim yaklaşımını ifade eder. Bu yaklaşım, geleneksel sınıf temelli ve toplu öğretime dayalı modellerin aksine, öğrenme sürecini öğrencinin bireysel özelliklerine uyarlamayı hedefler. Yapay zekâ ise bu süreci ölçeklenebilir, gerçek zamanlı ve veri temelli bir hale getirerek

¹ Öğretim Görevlisi, İstanbul Kent Üniversitesi, Meslek Yüksekokulu, Bilgisayar Programcılığı, kadir.turgut@kent.edu.tr, ORCID: 0000-0002-8577-0500.

kişiselleştirmeyi somut biçimde uygulanabilir kılar (Chen et al., 2022). Makine öğrenmesi algoritmaları, doğal dil işleme teknikleri ve öneri sistemleri gibi teknolojiler, öğrencilerin geçmiş performanslarını analiz ederek öğrenme içeriklerini, değerlendirme yöntemlerini ve öğrenme yollarını sürekli olarak optimize etmeye olanak tanımaktadır. Bu bağlamda, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemleri, yalnızca akademik başarıyı artırmaya değil, aynı zamanda öğrenme sürecini daha anlamlı, motive edici ve sürdürülebilir hâle getirmeye yönelik derinlemesine bir potansiyel taşımaktadır. Öğrencilerin kendi hızlarında, ilgi duydukları alanlarda ve öğrenme stillerine uygun biçimde ilerlemeleri; öğrenmenin öz-yönetimini teşvik etmekte ve bireyin öğrenme sorumluluğunu üstlenmesini sağlamaktadır (Holstein et al., 2020). Özellikle çevrimiçi eğitim ortamlarında, bu tür sistemlerin sunduğu otomatik geribildirim, içerik önerileri ve öğrenme yolu takibi gibi özellikler, öğrenme sürecini daha etkileşimli ve öğrenci odaklı kılmaktadır. Ancak bu teknolojik gelişmelere rağmen, yapay zekânın eğitimdeki rolü hâlen çok katmanlı sorunları beraberinde getirmektedir. Öncelikle algoritmik karar süreçlerinin şeffaf olmaması, öğrenciler üzerinde sistematik önyargılar ve etkileşim eşitsizlikleri yaratma riskini taşımaktadır. Ayrıca, eğitim teknolojilerinin metalaştırılması, öğrenci verilerinin ticari şirketlerce kullanımı ve mahremiyetin ihlali gibi etik sorunlar da bu sistemlerin meşruiyetini sorgulanır kılmaktadır (Williamson & Eynon, 2020). Bu noktada, pedagojik faydaların ötesinde, YZ destekli sistemlerin hangi koşullarda adil, hesap verebilir ve kapsayıcı bir biçimde tasarlanabileceği sorusu önem kazanmaktadır. Dolayısıyla bu çalışma, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerini yalnızca teknik bir inovasyon olarak değil, pedagojik, etik ve toplumsal açılardan çok boyutlu bir inceleme konusu olarak ele almaktadır. Çalışmada, bu sistemlerin eğitim ortamlarında nasıl işlediği, öğrenci başarısı ve etkileşimi üzerindeki etkileri, kullanılan teknolojik altyapılar ve karar destek mekanizmaları ayrıntılı

biçimde değerlendirilecektir. Ayrıca, bu sistemlerin uygulamaya dönük sınırlılıkları, olası risk alanları ve geleceğe yönelik araştırma boşlukları da ele alınarak, alana katkı sağlayacak bütüncül bir çerçeve oluşturulacaktır.

2. YÖNTEM

Bu çalışma, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerinin pedagojik etkililiğini, teknolojik altyapılarını ve etik sınırlarını çok boyutlu bir biçimde ele almayı amaçlayan bütüncül bir araştırma olarak tasarlanmıştır. Çalışmanın yöntemi, nitel araştırma paradigması çerçevesinde yapılandırılmıştır ve derinlemesine literatür taraması temelli betimsel analiz yaklaşımı benimsenmiştir. Bu metodolojik yönelim, alandaki teorik birikimi sistematik bir biçimde analiz ederek mevcut eğilimleri, uygulama örneklerini ve araştırma boşluklarını ortaya koymayı mümkün kılmaktadır (Bowen, 2009). Araştırmanın temel amacı, yapay zekâ tabanlı kişiselleştirme sistemlerinin yükseköğretim ve çevrimiçi öğrenme bağlamlarında sunduğu potansiyelleri pedagojik, teknolojik ve etik boyutlarıyla değerlendirmek; bu değerlendirmeleri güncel akademik literatürle ilişkilendirerek anlamlı çıkarımlar elde etmektir. Bu nedenle çalışma, ampirik veri üretmekten ziyade, alanyazında yer alan seçkin ve yüksek etkili (high-impact) akademik kaynakların sistematik ve analitik biçimde yorumlanmasına dayanmaktadır.

2.1. Araştırma Tasarımı ve Yaklaşım

Araştırma tasarımı, niteliksel sistematik literatür taraması biçiminde kurgulanmıştır. Bu kapsamda, 2015–2024 yılları arasında yayımlanmış olan hakemli makaleler, kitap bölümleri, teknik raporlar ve bilimsel bildiriler tarama kapsamına alınmıştır. Bu zaman aralığı, hem COVID-19 sonrası dijitalleşme sürecini hem de ChatGPT gibi üretken yapay zekâ modellerinin eğitimdeki yükselişini kapsayacak biçimde seçilmiştir. Tarama

süreci, PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) protokolü temel alınarak yapılandırılmıştır (Page et al., 2021). Veri kaynakları arasında Web of Science, Scopus, IEEE Xplore, SpringerLink, ERIC ve Google Scholar gibi saygın indekslerde tarama yapılmış; yalnızca akademik niteliği onaylanmış, etki faktörü yüksek yayınlar tercih edilmiştir. Ayrıca, çalışmanın kuramsal arka planını güçlendirmek adına UNESCO, OECD, EDUCAUSE gibi kurumsal kuruluşların raporlarından da faydalanılmıştır.

2.2. Veri Toplama Süreci ve Kriterler

Literatür taramasında kullanılan anahtar kelimeler hem kavramsal hem teknik boyutu kapsayacak şekilde belirlenmiştir. İngilizce olarak kullanılan başlıca terimler şunlardır: "Artificial Intelligence in Education", "Personalized Learning", "Adaptive Learning Systems", "Learning Analytics", "AI Ethics in Education", "Machine Learning in Pedagogy" ve "Educational Recommender Systems".

Çalışma kapsamına alınan yayınların seçiminde aşağıdaki dahil etme kriterleri esas alınmıştır:

- Yapay zekâ destekli kişiselleştirme sistemlerine odaklanıyor olması,
- Eğitim bağlamında (özellikle yükseköğretim veya çevrimiçi öğrenme) uygulanabilirlik taşıması,
- Teorik ya da uygulamalı veriye dayalı bulgular içermesi,
- Hakemli akademik dergilerde yayımlanmış olması.

Buna karşılık, blog yazıları, kişisel görüşe dayalı içerikler, akademik niteliği bulunmayan popüler yayınlar dışlama kriterleri kapsamında değerlendirilmiştir.

2.3. Veri Analizi Yaklaşımı

Toplanan veriler, betimsel içerik analizi yöntemiyle incelenmiştir. Bu doğrultuda, yayınlarda ele alınan ana temalar, tartışma eksenleri ve öne çıkan eğilimler tematik kodlama yoluyla sınıflandırılmıştır. Kodlama süreci, MaxQDA ve NVivo gibi nitel veri analiz yazılımları aracılığıyla desteklenmiştir. Özellikle üç temel boyut üzerinden analiz yapılmıştır:

Pedagojik Etkililik: Öğrenci başarısı, motivasyon, katılım, öğrenme çıktıları.

Teknolojik Altyapı: Kullanılan yapay zekâ modelleri, veri işleme yöntemleri, sistem mimarileri.

Etik ve Sosyal Boyut: Veri gizliliği, algoritmik önyargılar, erişim adaleti, şeffaflık.

Bu yaklaşım sayesinde, sadece literatürdeki kavramsal çerçeveler değil, aynı zamanda uygulamada karşılaşılan sorunlar ve çözüm önerileri de bütüncül biçimde değerlendirilebilmiştir.

3. BULGULAR

Yapılan sistematik literatür taraması ve tematik içerik analizi sonucunda, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerinin eğitimdeki uygulamaları üç temel boyutta öne çıkmaktadır: pedagojik etkililik, teknolojik mimari ve etik/sosyal yansımalar. Aşağıda bu bulgular bütüncül ve karşılaştırmalı bir çerçevede sunulmuştur.

3.1. Pedagojik Etkililik: Öğrenci Başarısı, Motivasyon ve Katılım

Yapay zekâ tabanlı kişiselleştirilmiş öğrenme sistemlerinin en belirgin pedagojik çıktısı, bireysel öğrenme gereksinimlerine duyarlı içerik sunumu yoluyla öğrenci başarısında anlamlı artış sağlamasıdır. Çeşitli çalışmalar, bu

sistemlerin öğrenci performansını %15 ila %40 arasında artırabildiğini ortaya koymaktadır (Liu et al., 2020; Wang et al., 2021). Özellikle uyarlanabilir içerik önerileri, otomatik geribildirim ve dinamik öğrenme rotaları, öğrencilerin kavramsal anlama düzeyini derinleştirmekte ve öğrenme sürecine olan katılımlarını artırmaktadır. Bununla birlikte, öğrencinin öğrenme sürecine aktif katılımını teşvik eden yapay zekâ destekli sohbet botları ve sanal mentor sistemleri de öğrenme motivasyonunu yükseltmektedir (Holstein et al., 2020). Öğrencilerin düşük başarı gösterdiği alanlarda gerçek zamanlı destek sunan bu araçlar, bireysel farklılıkların tanınmasını kolaylaştırmakta ve öğrenme kayıplarının önüne geçebilmektedir. Ayrıca, öğretmenlerin öğrenciye özgü veriler üzerinden geribildirim verebilmesi, öğretim sürecini daha etkili kılmakta ve öğretmen-öğrenci etkileşimini güçlendirmektedir. Ancak, bu sistemlerin pedagojik etkileri öğrencinin öz-düzenleme becerisi, dijital okuryazarlık düzeyi ve motivasyonel yönelimlerine göre farklılık gösterebilmekte; kişiselleştirme her zaman başarıyı garantilememektedir (Roll & Wylie, 2016).

3.2. Teknolojik Altyapı: Kullanılan Yapay Zekâ Modelleri ve Sistem Mimari Yapıları

Bulgular, kişiselleştirilmiş öğrenme sistemlerinin arkasında çoğunlukla öneri sistemleri, makine öğrenmesi algoritmaları, doğal dil işleme (NLP) ve giderek daha sık derin öğrenme tabanlı mimarilerin yer aldığını göstermektedir. Kullanılan modeller arasında özellikle k-en yakın komşu, naive Bayes, destek vektör makineleri (SVM) ve random forest gibi klasik algoritmalarla birlikte, son dönemde LSTM, transformer, BERT, GPT gibi derin öğrenme tabanlı modellerin de yaygınlaştığı görülmektedir (Chen et al., 2022). Bu sistemlerin önemli bir özelliği, öğrenci modelleme sürecinde hem bilişsel hem davranışsal verileri işleyerek her öğrenci için özelleştirilmiş öğrenme yolları oluşturabilmesidir. Örneğin, öğrenme analitikleri

aracılığıyla öğrencilerin öğrenme materyaliyle etkileşim sıklığı, video izleme süresi, quiz başarımları gibi göstergeler analiz edilmekte; bu verilere göre algoritmalar içerik sıralamasını dinamik biçimde yeniden düzenlemektedir. Ayrıca, sistemlerin bulut tabanlı ve dağıtık yapılara evrilmesi, ölçeklenebilirliği ve gerçek zamanlı veri işlemlerini kolaylaştırmakta; çok sayıda kullanıcıya eş zamanlı olarak kişiselleştirilmiş hizmet sunulmasına olanak tanımaktadır (Zawacki-Richter et al., 2019). Bununla birlikte, yüksek doğruluk oranlarına ulaşmak için kullanılan modellerin genellikle büyük veri setlerine ve karmaşık hesaplama altyapılarına ihtiyaç duyması, özellikle gelişmekte olan ülkelerde teknik eşitsizlikleri artırmaktadır.

3.3. Etik ve Sosyal Boyutlar: Veri Güvenliği, Algoritmik Önyargılar ve Erişim Adaleti

Yapay zekâ destekli öğrenme sistemleri, yüksek pedagojik potansiyele sahip olmasına karşın önemli etik ve sosyal tartışmaları da beraberinde getirmektedir. Bunların başında veri gizliliği ve algoritmik şeffaflık sorunları gelmektedir. Öğrencilerin kişisel, bilişsel ve davranışsal verilerinin toplanması ve işlenmesi, bu verilerin üçüncü taraflarla paylaşımı ve uzun vadeli saklanması gibi durumlar, veri etiği açısından ciddi riskler doğurmaktadır (Williamson & Eynon, 2020). Öte yandan, kişiselleştirme süreçlerinde kullanılan algoritmaların, veri setlerindeki önyargıları yeniden üretme riski taşıdığı tespit edilmiştir. Özellikle demografik, kültürel veya sosyoekonomik farklılıklara duyarsız modeller, bazı öğrenci gruplarının dezavantajlı konumlarını pekiştirebilmektedir. Bu durum, otomatik etiketleme, performans tahmini veya öneri sistemleri gibi uygulamalarda adaletsizliğe yol açabilmektedir. Son olarak, bu sistemlerin kullanılabilirliğinin yüksek teknolojik donanım, sürekli internet bağlantısı ve dijital beceriler gerektirmesi, kırsal bölgeler ve düşük gelirli öğrenci grupları açısından dijital uçurum riskini derinleştirmektedir. Bu nedenle, sistemlerin sadece teknik

değil, aynı zamanda kapsayıcı, adil ve erişilebilir biçimde tasarlanması gerektiği yönünde yaygın bir görüş oluşmuştur. Bulgular ışığında, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerinin sunduğu fırsatlar kadar, taşıdığı risklerin de dikkatle değerlendirilmesi gerektiği açıktır. Bu bulgular, bir sonraki bölüm olan Tartışma kısmında, kuramsal çerçeve ve önceki çalışmalar ışığında daha derinlemesine analiz edilecektir.

4. TARTIŞMA

Bu çalışmanın bulguları, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerinin eğitimin hem içeriğini hem de yapısını dönüştürdüğünü göstermektedir. Ancak bu dönüşüm yalnızca pedagojik bir ilerleme değil; aynı zamanda teknoloji, etik, toplumsal eşitsizlik ve öğretim kültüründe kırılmalar anlamına gelmektedir. Yapay zekânın sunduğu kişiselleştirme potansiyeli, öğretimin daha etkili, esnek ve öğrenci merkezli hâle gelmesine katkı sağlarken; bu potansiyelin belirli çelişkiler ve sınırlarla çevrili olduğu da dikkatle değerlendirilmelidir.

4.1. Öğrenmenin Algoritmikleştirilmesi ve Pedagojik Derinlik Sorunu

Yapay zekâ sistemleri, öğrencinin davranışsal izlerini temel alarak karar verir: tıklamalar, süreler, başarı puanları gibi nicel veriler, bireyin öğrenme deneyiminin karmaşık ve çok katmanlı doğasını temsil etmekte yetersiz kalmaktadır. Bu nedenle, kişiselleştirme sistemlerinin sunduğu “bireysellik”, çoğu zaman algoritmaların sınırlı sezgisel yetileriyle çerçevelenir. Oysa öğrenme, yalnızca bilgi edinimi değil; aynı zamanda sosyal bağlamda anlam üretme, duyuşsal gelişim ve öz-farkındalık süreçlerini içeren çok boyutlu bir olgudur (Biesta, 2010). Bu çok boyutluluk, algoritmik sistemler tarafından her zaman yakalanamayabilir. Literatürde bu noktaya dikkat çeken

çalışmalar, yapay zekâ tabanlı sistemlerin pedagojik kararları mekanikleştirme riski taşıdığını ve öğretmenin pedagojik sezgisini, bağlamsal bilgeliğini ve etik duyarlılığını yeterince yansıtmadığını ileri sürmektedir (Selwyn, 2019). Öğrenme sürecinin algoritmik rasyonaliteye indirgenmesi, pedagojik deneyimin insanî boyutlarını silikleştirebilir.

4.2. Öğretmen Figürünün Dönüşümü: İşbirlikçi mi, Gözetleyici mi?

YZ destekli sistemlerin sınıf içi pratiğe entegre edilmesiyle birlikte öğretmenler artık yalnızca içerik sunan değil, aynı zamanda veri yorumlayan, algoritmalarla işbirliği yapan ve öğrencilerin sistem içinde nasıl hareket ettiğini izleyen bir konuma evrilmektedir. Bu dönüşüm, öğretmenin uzmanlık alanını genişlettiği kadar, yeni yükümlülükler ve etik sorumluluklar da yüklemektedir. Örneğin, sistemlerin sunduğu öğrenci profillerine göre karar vermek, öğretmenleri dijital değerlendirme araçlarına fazlasıyla bağımlı kılabilir; bu da pedagojik özerkliğin zedelenmesine yol açabilir (Williamson, 2018). Diğer yandan, öğretmenlerin YZ sistemlerini pedagojik bir araçtan çok gözetim mekanizması olarak kullanma riski de vardır. Öğrenci davranışlarının sürekli izlenmesi, eğitim ortamının özgürlükçü doğasına zarar verebilir; öğrencilerin içsel motivasyon yerine dışsal denetim hissiyle hareket etmesine neden olabilir. Bu durum, öğrenmenin doğal akışını bozabileceği gibi, öğrencilerde “her an değerlendiriliyor olma” kaygısına da yol açabilir.

4.3. Teknolojik Kapsayıcılık ve Dijital Bölünme

Yapay zekâ destekli sistemlerin teknik altyapıları genellikle yüksek işlem gücü, geniş veri setleri ve sürekli çevrim içi olmayı gerektirmektedir. Bu durum, dijital eşitsizlikleri daha da belirgin hâle getirebilir. Özellikle kırsal bölgelerde yaşayan, düşük gelirli veya teknolojik donanıma sahip olmayan öğrenciler,

bu sistemlerden tam anlamıyla faydalanamayabilir. Bu bağlamda, “kişiselleştirme” yalnızca teknolojiye erişebilen öğrenciler için geçerli bir ayrıcalığa dönüşebilir (UNESCO, 2022). Ayrıca algoritmaların veriye dayalı karar vermesi, veri setlerinde var olan tarihsel önyargıların sistematik olarak yeniden üretilmesine neden olabilir. Örneğin, geçmişte düşük başarı gösteren öğrencilere düşük düzeyde içerik önerilmesi, bu öğrencilerin gelişim fırsatlarını sınırlandırabilir ve başarısızlık döngüsünü pekiştirebilir (Crawford, 2021). Bu tür “öğrenilmiş önyargılar”, algoritmik adalet konusunu eğitim teknolojileri bağlamında gündeme getirmektedir.

4.4. Etik Sınırlar ve Şeffaflık Sorunu

Eğitim ortamlarında kullanılan yapay zekâ sistemlerinin etik boyutları çoğu zaman teknolojik gelişmenin gerisinde kalmaktadır. Öğrenci verilerinin ne şekilde toplandığı, ne kadar süre saklandığı, hangi amaçlarla işlendiği ve kimlerle paylaşıldığı gibi konular, çoğu zaman kullanıcılar tarafından yeterince anlaşılmamaktadır. Ayrıca yapay zekâ sistemlerinin karar süreçlerinin “açıklanabilirliği” sınırlıdır. Öğrenciye neden belirli bir içerik önerildiği ya da başarısının neden düşük tahmin edildiği gibi sorulara verilen yanıtlar, sistem geliştiriciler dışında çoğunlukla belirsizdir (Floridi et al., 2018). Bu bağlamda, eğitimde kullanılan yapay zekâ sistemlerinin yalnızca etkili değil, aynı zamanda şeffaf, hesap verebilir ve kullanıcıyı güçlendiren nitelikte olması gerektiği açıktır. Eğitimde etik, yalnızca mahremiyetin korunması değil; aynı zamanda karar alma süreçlerine katılım, dijital adalet ve eşitlik ilkelerinin yaşatılması anlamına da gelmektedir.

4.5. Dönüştürücü Potansiyel ve Sorumlu Tasarım Gerekliliği

Tüm bu eleştiriler ve tartışmalar, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerinin salt teknik değil, aynı

zamanda pedagojik, etik ve toplumsal bir tasarım nesnesi olarak ele alınması gerektiğini ortaya koymaktadır. Bu sistemlerin eğitimde sürdürülebilir bir rol üstlenebilmesi için, yalnızca bireysel performansa odaklanan değil; katılımı, adaleti ve duygusal gelişimi de gözeten bütünsel bir dijital pedagoji anlayışıyla tasarlanması gerekmektedir. İnsan merkezli yapay zekâ, yalnızca bir etik ideal değil, aynı zamanda pedagojik başarının da ön koşuludur.

5. SONUÇ

Bu çalışma, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemlerinin çağdaş eğitim ortamlarında sunduğu potansiyeli, sınırlılıkları ve dönüşüm etkilerini çok boyutlu biçimde ele almıştır. Bulgular, bu sistemlerin öğrenci başarısını artırma, öğrenme sürecini bireyselleştirme ve öğretim etkinliğini güçlendirme açısından önemli fırsatlar sunduğunu ortaya koymaktadır. Özellikle uyarlanabilir içerik sunumu, öğrenme analitikleri ve öneri sistemleri gibi bileşenler sayesinde öğrenciler daha etkili, hedeflenmiş ve verimli öğrenme yollarına yönlendirilebilmektedir. Bununla birlikte, bu teknolojik ilerlemelerin pedagojik, etik ve toplumsal düzeyde ciddi soru işaretleri ve yapısal kırılmalar yarattığı da göz ardı edilemez.

Araştırma sonuçları, kişiselleştirmenin her durumda öğrenme kalitesini artırmadığını, bazı durumlarda öğrenme süreçlerini daraltabileceğini, öğrencinin içsel motivasyonunu zayıflatabileceğini ve sosyal öğrenme ortamlarını zedeleyebileceğini göstermektedir. Özellikle algoritmaların davranışsal verilere dayanarak karar vermesi, öğrenmenin çok katmanlı doğasını temsil etmekte yetersiz kalmakta; bu durum öğrenme sürecinin indirgemeci bir anlayışa hapsedilmesine yol açabilmektedir. Ayrıca, öğretmen rolleri üzerindeki dönüşüm, veri temelli gözetim baskısı ve pedagojik özerkliğin azalması gibi

sonuçlar, öğretmen-öğrenci etkileşimini daha mekanik bir düzleme çekebilmektedir.

Teknolojik altyapının yüksek maliyetli ve karmaşık olması, dijital eşitsizliklerin derinleşmesine katkıda bulunmakta; özellikle sosyoekonomik açıdan dezavantajlı öğrenciler bu sistemlerin sunduğu kişiselleştirme olanaklarından yeterince faydalanamamaktadır. Ayrıca, algoritmaların karar süreçlerinin şeffaf olmayışı, veri gizliliği, ayrımcılık riski ve hesap verebilirlik eksikliği gibi etik sorunları da gündeme getirmektedir. Bu bağlamda yapay zekâ sistemlerinin eğitimdeki işlevi, yalnızca bireysel başarıyı artırma değil; aynı zamanda adil, kapsayıcı ve insan-merkezli bir öğrenme ortamı oluşturma sorumluluğunu da içermelidir.

Bu değerlendirmeler ışığında, aşağıdaki somut öneriler sunulmaktadır:

Politika Yapıcılar ve Eğitim Kurumları İçin:

- Yasal Düzenlemeler ve Etik Standartlar: Yapay zekâ tabanlı öğrenme sistemlerinin veri işleme, algoritmik karar alma ve kişisel veri kullanımı konularında açık etik ilkeler ve bağlayıcı yasal çerçevelerle düzenlenmesi gereklidir.
- Kapsayıcı Dijital Eğitim Politikaları: Erişim adaleti sağlamak için kırsal bölgelerdeki dijital altyapılar güçlendirilmeli; düşük gelirli öğrenciler için donanım ve bağlantı desteği sağlanmalıdır.
- Şeffaflık ve Açıklanabilirlik: Eğitimde kullanılan yapay zekâ sistemlerinin işleyişi ve karar mantığı hem öğretmenler hem öğrenciler tarafından anlaşılabilir olmalıdır.

Uygulayıcılar ve Öğretmenler İçin:

- Veri Okuryazarlığı ve Pedagojik Yetkinlik: Öğretmenlerin yapay zekâ destekli sistemleri yalnızca teknik değil, pedagojik açıdan da ele alabilecek bir dijital okuryazarlık düzeyine ulaşmaları desteklenmelidir.
- Öğrenme Sürecinin Dengeli Tasarımı: Kişiselleştirme sistemlerinin kullanımı, sosyal öğrenme, işbirlikçi etkinlikler ve eleştirel düşünme becerileri ile dengeli biçimde bütünleştirilmelidir.
- Öğrenciye Etkin Geri Bildirim: Öğretmenler, sistemlerin sunduğu veri çıktılarıyla sınırlı kalmaksızın, öğrenciyle etkileşim hâlinde kişisel ve nitelikli geri bildirimler sunmalıdır.

Gelecek Araştırmalar İçin:

- Disiplinlerarası Modellerin Geliştirilmesi: Eğitim bilimleri, yapay zekâ mühendisliği ve etik felsefesi gibi disiplinlerin işbirliğiyle daha adil, şeffaf ve pedagojik olarak güçlü sistemler geliştirilebilir.
- Uzun Vadeli Etki Analizleri: Yapay zekâ destekli öğrenme sistemlerinin öğrenciler üzerindeki bilişsel, duyuşsal ve sosyal etkilerini ölçen boylamsal çalışmalara ihtiyaç vardır.
- Katılımcı Tasarım Süreçleri: Öğrenciler, öğretmenler ve eğitim yöneticilerinin sistem tasarım süreçlerine aktif katılımı teşvik edilerek kullanıcı merkezli öğrenme ortamları oluşturulmalıdır.

Sonuç olarak, yapay zekâ destekli kişiselleştirilmiş öğrenme sistemleri, yalnızca bir teknolojik gelişim değil; aynı zamanda pedagojik yeniden yapılanmanın da habercisidir. Bu

dönüşümün başarıyla gerçekleştirilebilmesi, yalnızca sistemlerin teknik doğruluğuna değil, aynı zamanda eğitimde adalet, etik ve insan onuruna saygılı tasarım ilkelerine bağlıdır. Eğitim, insanı merkeze alan bir alan olarak, yapay zekâyı araçsallaştırırken insan değerlerinden uzaklaşmamalıdır. Bu çalışmanın hazırlanmasında, kaynak taraması, içeriğin gözden geçirilmesi, çeviri vb. süreçlerde yapay zekâ yazılımlarından faydalanılmıştır (OpenAI, 2025).

KAYNAKÇA

- Biesta, G. (2010). Good education in an age of measurement: ethics, politics, democracy. Routledge.
- Bowen, G. A. (2009). Document analysis as a qualitative research method. *Qualitative Research Journal*, 9(2), 27–40. <https://doi.org/10.3316/QRJ0902027>
- Chen, X., Xie, H., & Hwang, G.-J. (2020). A multi-perspective study on artificial intelligence in education: grants, conferences, journals, software tools, institutions, and researchers. *Computers and Education: Artificial Intelligence*, 1(3), 100005. <https://doi.org/10.1016/j.edurev.2022.100438>
- Crawford, K. (2021). Atlas of AI: Power, politics, and the planetary costs of artificial intelligence. Yale University Press.
- Floridi, L., Cowls, J., Beltrametti, M., Chatila, R., Chazerand, P., Dignum, V., ... & Vayena, E. (2018). AI4People—an ethical framework for a good AI society: opportunities, risks, principles, and recommendations. *Minds and Machines*, 28(4), 689–707. <https://doi.org/10.1007/s11023-018-9482-5>
- Holstein, K., McLaren, B. M., & Aleven, V. (2019). Co-designing a real-time classroom orchestration tool to support teacher–AI complementarity. *Journal of Learning Analytics*, 6(2), 27–52. <https://doi.org/10.18608/jla.2019.62.3>
- Knox, J. (2020). Artificial intelligence and education in China. *Learning, Media and Technology*, 45(3), 298–311. <https://doi.org/10.1080/17439884.2020.1754236>
- Micheni, E., Machii, J., & Murumba, J. (2024). The role of artificial intelligence in education. *Open Journal for*

- Information Technology. 7. 43-54.
<http://dx.doi.org/10.32591/coas.ojit.0701.04043m>
- OpenAI. (2025). ChatGPT (Sürüm 4o) [Yazılım].
<https://openai.com>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... & Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71.
<https://doi.org/10.1136/bmj.n71>
- Roll, I., & Wylie, R. (2016). Evolution and revolution in artificial intelligence in education. *International Journal of Artificial Intelligence in Education*, 26(2), 582–599.
<https://doi.org/10.1007/s40593-016-0110-3>
- Selwyn, N. (2019). Should robots replace teachers? AI and the future of education. Polity Press.
- UNESCO. (2022). Reimagining our futures together: A new social contract for education.
<https://doi.org/10.54675/ASRB4722>
- Williamson, B., & Eynon, R. (2020). Historical threads, missing links, and future directions in AI in education. *Learning, Media and Technology*, 45(3), 223–235.
<https://doi.org/10.1080/17439884.2020.1798995>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39.
<https://doi.org/10.1186/s41239-019-0171-0>

BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİ
DEĞERLENDİRMELERİ

yaz
yayınları

YAZ Yayınları
M.İhtisas OSB Mah. 4A Cad. No:3/3
İscehisar / AFYONKARAHİSAR
Tel : (0 531) 880 92 99
yazyayinlari@gmail.com • www.yazyayinlari.com