



- **Web Uygulamalarında Enjeksiyon Saldırılarının Tespiti**
- **İlkokul 3. Sınıf Öğrencilerine Yönelik Artırılmış Gerçeklik Teknolojisi İle İngilizce Eğitimi İçin Mobil Oyun Uygulaması**
- **Derin Öğrenme Yöntemleri Kullanılarak Böbrek Hastalıklarının Tespiti ve Çoklu Sınıflandırma**
- **Hesaplamalı İlaç Keşfi ve Makine Öğrenme Algoritmaları**
- **Koroner Arter Hastalığı Sınıflandırılmasında Destek Vektör Makinelerinin Gri Kurt Optimizasyonuna Dayalı Özellik Seçim Yöntemi ile Geliştirilmesi**
- **Silis Dumanı İkameli Çimentoların Priz Sürelerinin ANFIS ile Tahmini**
- **3D Modelling and Simulation Based on Kinematic Analysis for Hip-therapy**

# İÇİNDEKİLER

## Sayfa

### Araştırma Makaleleri

- Web Uygulamalarında Enjeksiyon Saldırılarının Tespiti..... 1
- İlkokul 3. Sınıf Öğrencilerine Yönelik Artırılmış Gerçeklik Teknolojisi İle İngilizce Eğitimi İçin Mobil Oyun Uygulaması..... 12
- Derin Öğrenme Yöntemleri Kullanılarak Böbrek Hastalıklarının Tespiti ve Çoklu Sınıflandırma..... 19
- Hesaplamalı İlaç Keşfi ve Makine Öğrenme Algoritmaları..... 29
- Koroner Arter Hastalığı Sınıflandırılmasında Destek Vektör Makinelerinin Gri Kurt Optimizasyonuna Dayalı Özellik Seçim Yöntemi ile Geliştirilmesi ..... 37
- Silis Dumanı İkamelı Çimentoların Priz Sürelerinin ANFIS ile Tahmini..... 45
- 3D Modelling and Simulation Based on Kinematic Analysis for Hippotherapy..... 53

**(Araştırma Makalesi)****Web Uygulamalarında Enjeksiyon Saldırılarının Tespiti****Mehmet Serhan Erçin<sup>\*1</sup>, Esra Nergis Yolaçan<sup>2</sup>**

<sup>1</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040, Eskişehir, ORCID No : <https://orcid.org/0000-0002-0921-3913>

<sup>2</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040, Eskişehir, ORCID No : <https://orcid.org/0000-0002-0008-1037>

**Anahtar Kelimeler:**

Enjeksiyon,  
Makine Öğrenmesi,  
SQLi,  
XSS,  
CMDi,  
CVE

**Özet:** Enjeksiyon üst başlığında toplayabileceğimiz saldırılar, yıkıcı etkilerinden ve kolay uygulanabilirliklerinden dolayı saldırganlar tarafından daha çok tercih edilmekte, rastlanma sıklıkları her geçen gün artmaktadır. Günümüzde, web uygulamaları ve bağlantılı çerçeve yapıları, sıklıkla kullandığımız ve hayatımıza pek çok noktada dokunan, büyük hizmetlerdir. Bu yüzden siber saldırganların ilgisini sürekli canlı tutmakta ve yeni yöntemler keşfetmeye motive etmektedir. Sızma tespiti ve önlenmesi üzerine literatürde pek çok çalışma bulunmaktadır. Genel başlıklarda değerlendirilen bu çözümlerin, değişen ve gelişen uygulamalardan dolayı, alt başlıklarda ve ayrıntılı değerlendirilmesi ve buna uygun yeni çözümlerin bulunması gerekmektedir. Enjeksiyon tipi saldırılarda, girdilerin içerisindeki hedef sistem rezerv kelimeleri hariç tutulursa, kullanılan diğer harf ve rakamsal kombinasyonların sayısı sınırsızdır. Bu nedenle imza tabanlı sistemler yerine makine öğrenmesi yöntemlerinin genelleştirme performansı enjeksiyonların tespitinde önemli avantajlar sağlayacaktır. Bu çalışmada özellikle web enjeksiyon saldırılarına ilişkin saldırının doğru tespit edilmesinin yanı sıra, zamansal performans ve çıktılarının sınıflandırılması da esas alınmaktadır. Rassal Orman ve Karar Ağacı sınıflandırıcılarında %94,54 ve %94,61 isabet oranları elde edilmiş, 15 ve 12 sn. öğrenme süreleri performansı ölçülmüştür.

**(Research Article)****Detection of Injection Attacks in Web Applications****Keywords:**

Injection,  
Machine Learning,  
SQLi,  
XSS,  
CMDi,  
CVE

**Abstract:** The attacks that we can bring together on Injection subject whose frequency of occurrence is increasing day by day are more preferable for attackers due to their destructive effects and easy applicability. Today, web applications and linked framework structures are great services that we use frequently and that touch our lives at many points. Therefore, it keeps the interest of cyber attackers alive and motivates them to discover new methods. Due to the changing and developing services and applications via emerging technologies that general topics often needs reconsidering as sub topics and new solutions should be found accordingly. Generalization is an intense need in injection type attacks unlike some other intrusion methods. Hereby, the generalization ability of machine learning methods despite signature-based systems will provide significant advantages in the detection of injections. Therefore, machine learning methods which have much more ability of making generalization rather than signature-based systems will provide significant advantages in the detection of injections. This study is focused on input-driven web attacks, differentiating benign and malicious traffic, time performance on processes and accurate classification of outputs. With Random Forest and Decision Tree classifiers, 94.54% and 94.61% hit rates were obtained, and 15 and 12 sec. learning time performance was measured.

## 1. Giriş

Web sayfalarının çalışmasını sağlayan kodlamalar, uygun girdi ile istenilen sonucu verirken, diğer yandan siber saldırganlara aynı kodlamalara farklı girdiler vererek kendi amaçlarına uygun çıktılar almayı sağlayabilmektedirler. Bu amaçla yapılan farklı girdilerin tamamına enjeksiyon denilmektedir. Enjeksiyonlar için girdi olarak “yük” (payload) kavramının tercih edilmesinin sebebi, bağlantı için gerekli olan iletişim bilgileri (sunucu ve varsa istemci tarafı kimlik bilgileri) girildikten sonra “istek” (request) belirten kısma vurgu yapmaktır. Enjeksiyonları sınıflandırırken pek çok öne çıkan özellik seçilebilir; hedef aldığı yapı, yorumlayıcı, veri tabanı yönetim sistemi, işletim sistemi, girdinin yapısı bunlardan bazılarıdır. ABD merkezli Mitre kuruluşunun Ortak Saldırı Deseni Numaralandırma ve Sınıflandırma (Common Attack Pattern Enumeration and Classification – CAPEC) [1] listesine göre Kod Enjeksiyonu, Kod Ekleme, Komut Enjeksiyonu, Girdi Verisi Manipülasyonu, Parametre Enjeksiyonu, Altyapı Manipülasyonu genel başlıklarında enjeksiyon saldırılarının pek çok alt türü bulunmaktadır. Buna göre Siteler Arası Betik (XSS), LDAP, XML, Yapılandırılmış Sorgu Dili (SQL), NoSQL, Email (SMTP/IMAP başlığı), Biçim Dizesi (Format String), Yansıtma (Reflection), Argüman, Kısayol Değiştirme (Path Traversal), Siteler Arası Kaynak Hırsızlığı (CSRF), Olay Kaydı, Sunucu Tarafı Kapsama (SSI), WebView, İşletim Sistemi Komut Satırı türü enjeksiyonlar da alt başlıklar olarak listelenmiştir. Bunlardan XSS, SQL, XML enjeksiyonlarının da kullanılan alt yöntemlere göre pek çok başlığı listelenmiştir [2–8]. Enjeksiyon saldırısı ile saldırı yapılan uygulamanın çalışması belirli komutları yürütmek yönünde manipüle edilmiş olur. Neticesinde ise veriler çalınabilir, bozulabilir, değiştirilebilir ya da verilen hizmet tamamen durabilir.

Önlenmesi basit, ancak değiştirilip tekrar denenmesi de basit olduğundan dolayı on yıllardır yeni teknikler geliştirilmesine rağmen girdi problemi tam olarak çözülememektedir. Çözüm yaklaşımları açısından doğrulama (validation), zararsızlaştırma (sanitization), düzenleme (regulation) gibi yazılımsal tekniklerin geliştirilmesine rağmen çözümsüzlük devam etmektedir. Bu çözümsüzlük, web uygulamalarının da yaygınlaşmasıyla birlikte “Uygunsuz (improper) Girdiler” [9] olarak literatürdeki yerini korumaktadır.

Uygunsuz girdiler problemini doğru tanımlayabilmek için Ray ve Ligatti, 2012’de yazdıkları makalede [10] SQL enjeksiyonu ile ilgili bazı örnekleri vermişlerdir. Saldırganların mantığını izah edebilmek için devam eden örnekler oluşturulmuştur.

```
SELECT hesap FROM müşteriler WHERE şifre='99';
```

Üstteki SQL cümlesinin WHERE koşulundaki “şifre” sütunu dışarıdan parametre almaktadır. Eğer dışarıdan gelen parametre düzgün bir kontrolden geçirilemezse saldırgan 99 ifadesi yerine ' or 1=1 -- ifadesini girdi olarak

gönderebilir ve neticede saldırgan aşağıdaki gibi bir SQL cümlesi elde etmiş olur.

```
SELECT hesap FROM müşteriler WHERE şifre=' or 1=1 --;
```

Saldırgan buradan bütün müşterilerin hesap bilgilerine ulaşmış olur. İmza tabanlı güvenlik sistemlerinde bunu saldırı olarak işaretleyip imza veritabanına bu saldırıyı kaydederseniz saldırgan bu kez 1=1 yerine 2=2 veya daha farklı sayısız “totoloji” oluşturan ifade uydurabilir. Bu durumda saldırganların deneyebileceği bütün kombinasyonları istatistiksel öğrenme modellerinden birisi ile yakalamak avantaj sağlayabilecektir.

Tablo 1’de bazı yük girdisi örnekleri, bu problemi daha ayrıntılı tanımlamak ve birlikte ele alınabileceğini göstermek için verilmiştir. Çalışmada kullanılan saldırı vektörü kavramı, ilgili web adresinin isminden sonra gelen kısma işaret eder. Bu yüzden “https://guvensiz-site.com.tr” olarak maskelenmiştir.

**Tablo 1 :** Zararlı yük girdisi örnekleri ve türleri

Payload	Türü
https://guvensiz-site.com.tr/ara?metin=ben-geldim	Normal
guvensiz-site.com.tr/ara?metin=<script> /*+saldirgan+bu+alanda+*/</script>	Reflected XSS
https://guvensiz-site.com.tr/ara?metin="+OR+1=1--	Totoloji SQLiA
site.com.tr/ara?metin=' UNION SELECT kullanıcı,sifre FROM kullanıcılar--	Union SQLiA
https://guvensiz-site.com.tr/evanterDurum.php?urunID=381&stokID=29	Normal E-Ticaret
https://guvensiz-site.com.tr/evanterDurum.php?dir=%3Bcat%20/etc/passwd	Command Injection
/?search=<xss+id%3dx+onfocus%3dalert(document.cookie)+tabindex%3d1>#x	Dom-Based XSS
http://domaincontroller.local/?action=dir&search=admin*)(password=_@{}/()! "\$% -^[]:;,%0aZARARLI%0aiçerik%0a%2e%0aMAIL+FROM:+<mailAdresim>%0aRCPT+TO:+<mailAdresim>%0aZARARLIçerik%0aFrom:+<mailAdresim>%0aTo:+<mailAdresim>%0aSubject:+deneme%0apostasi%0a%2e%0a	SMTP injection (Tamamı tek satır)
http://guvensiz-site.com.tr/evanter/resim.php?file=../../../../etc/passwd	Path Traversal

Mantıksal seviyede zararlı kod ile zararsız kodun birbirinden farkı yoktur, bu durum, zararlı kodun, makine öğrenmesi harici geleneksel tespit sistemleriyle tespitini zorlaştırmaktadır. Yorumlayıcıya (interpreter) göre, girdi alanına gelen her şey uygundur ve hatalı veya hatasız bir şekilde işlenebilir [11]. Sızma Tespit/Engelleme Sistemi (IDS/IPS) veya birlikte çalışmak üzere Web Uygulama Güvenlik Duvarı (WAF) adı verilen özelleşmiş yazılımlar, diğer pek çok bileşeni ile, enjeksiyonlara karşı güvenliği de sağlamaktadır. Sızma Tespit veya Güvenlik Duvarı yazılımları genel eğilim olarak her bir saldırıya ait yük girdilerini imza veritabanında tutar [12] ve bu saldırılara karşın tanımlanmış kurallar üzerinden tam eşleşme sağlandığında tespit ve engelleme işlemini gerçekleştirir [13]. Saldırganlar ise saldırı girdisinde saldırının özünü etkilemeyecek küçük bir değişiklik ile bu imzaları atlatılmaktadır. Saldırı tespit sistemlerinde

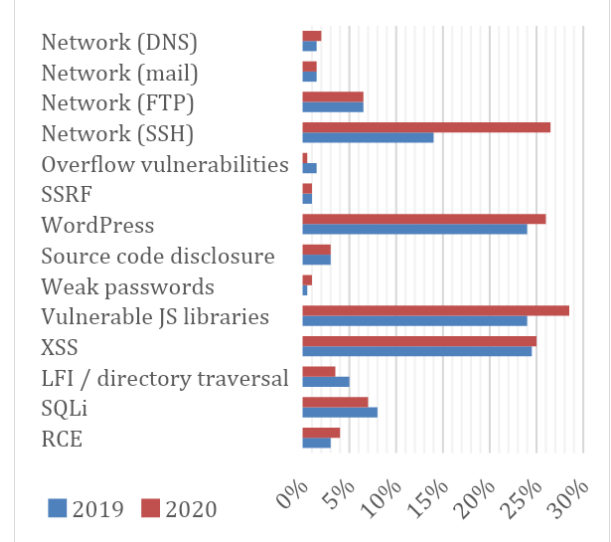
makine öğrenmesi/derin öğrenme yaklaşımlarının kullanımı 1990 yılında bilgisayar virüslerini tespit etme ile başlarken [14] 1998'den itibaren çok çeşitli saldırı türleri için birçok modelin çalışıldığı görülmektedir [15]. Yapay öğrenme uygulamalarında, saldırı yükleri doğru bir biçimde girdi olarak verilir ve doğru modelleme yapılırsa, test aşamasında saldırı olup olmadığını ve hatta saldırının türünü dahi tespit edecek şekilde çalışabilir.

**Tablo 2 : CWE numarası ile bağlantılı CVE adedi**

No	CWE Tanımı	Zafiyet A.
79	Failure to Preserve Web Page Structure ('Cross-site Scripting')	17106
119	Failure to Constrain Operations within the Bounds of a Memory Buffer	11994
20	Improper Input Validation	8875
200	Information Exposure	7520
89	Improper Sanitization of Special Elements used in an SQL Command ('SQL Injection')	6849
787	Out-of-bounds Write	4283
22	Improper Limitation of a Pathname to a Restricted Directory ('Path Traversal')	4013
125	Out-of-bounds Read	3625
94	Failure to Control Generation of Code ('Code Injection')	2736
287	Improper Authentication	2508
416	Use After Free	2322
269	Improper Privilege Management	2124
78	Improper Sanitization of Special Elements used in an OS Command ('OS Command Injection')	1729
476	NULL Pointer Dereference	1552
190	Integer Overflow or Wraparound	1514
400	Uncontrolled Resource Consumption ('Resource Exhaustion')	1017
120	Buffer Copy without Checking Size of Input ('Classic Buffer Overflow')	982
284	Access Control (Authorization) Issues	980
434	Unrestricted Upload of File with Dangerous Type	947
362	Race Condition	895
732	Incorrect Permission Assignment for Critical Resource	795
59	Improper Link Resolution Before File Access ('Link Following')	734
77	Improper Sanitization of Special Elements used in a Command ('Command Injection')	728
74	Failure to Sanitize Data into a Different Plane ('Injection')	713
798	Use of Hard-coded Credentials	680

ABD merkezli Mitre organizasyonunun Siber Güvenlik ARGE merkezi tarafından belirlenen Ortak Zayıflık Numaralandırması (Common Weakness Enumeration – CWE) listesinde [2] pek çok başlıkta kendine yer bulan enjeksiyon tipi saldırılar, Ortak Güvenlik Açıkları ve Zafiyetler (Common Vulnerabilities and Exposures – CVE) listesinde sıklıkla bakımından da en üstte yer almaktadır. Bu durumu göstermek amacıyla Mitre Organizasyonu CWE çalışma grubunun En Üst-25 listesi Tablo 2'de verilmiştir. Tablonun ilk sütunu CWE numarasını, son sütunu ise barındırdığı CVE adedini gösterir. CWE-79, CWE-20, CWE-89, CWE-94, CWE-78, CWE-77, CWE-74 zayıflıkları ise OWASP vakfının "En üst 10 Web Uygulama Güvenlik Riski 2021"

listesinin 3. sırasındaki A03-Injection [3] başlığı içerisinde toplanmıştır. CAPEC listesinde "ID 152: Inject Unexpected Items" kategorisinde 9 ana başlıkla ele alınmıştır. Web Uygulama Güvenlik Konsorsiyumu (The Web Application Security Consortium – WASC) Tehdit Sınıflandırması 2.0 raporunda da listenin yarıya yakını enjeksiyonlardan oluşmaktadır. Etki bakımından da pek çok veri sızıntısında başrolü oynayan bu saldırılar, her geçen gün siber saldırganların ilgisini daha çok çekmekte ve saldırılar üstel olarak artmaktadır. Şekil 1'de bir güvenlik firmasının ilgili CWE'lerin kritiklik derecesi en yüksek zafiyetlerine göre yapmış olduğu 2019 ve 2020 yıllarına dair karşılaştırmalı bir analiz bulunmaktadır.



Şekil 1. Acunetix 2021 Web Uygulamaları Güvenlik Rap. [16]

Tablo 2'de bağlantılı CVE görülme adedine göre sıralı CWE adları ve numaraları görülebilmektedir. Buna göre CWE-79 numaralı XSS zayıflığının temsil ettiği zafiyet sayısı, CWE-89 numaralı SQL injection zayıflığının temsil ettiği zafiyet sayısının neredeyse 3 katıdır. Tabloda 25 adet CWE listelenmiştir.

Literatürde web uygulamalarına yapılan saldırıların tespiti için birçok çalışma yapıldığı görülmektedir. SQL ve XSS'i bir arada değerlendirerek tespit etmeyi hedefleyen CODDLE [17] isimli çalışmada Abaimov ve Bianchi, girdilerdeki sembollerini tip/değer çiftlerine dönüştürmüşler ve derin öğrenme metoduna girerek %95 oranında isabet elde etmişlerdir. Benzer bir çalışmayı SQLiGoT [36] isimli çalışmada Kar ve diğerleri de yalnızca SQL enjeksiyonları için yapmış ve elde ettikleri Token'ları SVM'e girdi olarak vermişlerdir.

Kavitha ve diğerleri [18] K-Ortalama Kümeleme Algoritmasını kullanan denetimsiz makine öğrenimi tekniğini benimsemişlerdir. Önerilen sistemin akışına bakılacak olursa: Son kullanıcının web uygulamasında sorgulaması ve sorgu değerlerinin çıkarılıp iki katmanlı güvenlik sağlayan Sql Injection Detector'a gönderilmesi olarak özetlenebilir. Güvenliğin ilk katmanında, düşük seviyeli saldırılar için bağlamdan bağımsız dilbilgisi (Cfg) kullanılarak kalıplar oluşturulur. Üst düzey saldırılar için ikinci güvenlik katmanı kullanılarak eğitilir.

**Tablo 3 :** Literatürdeki yayınların ön işleme, yöntem ve amaçları

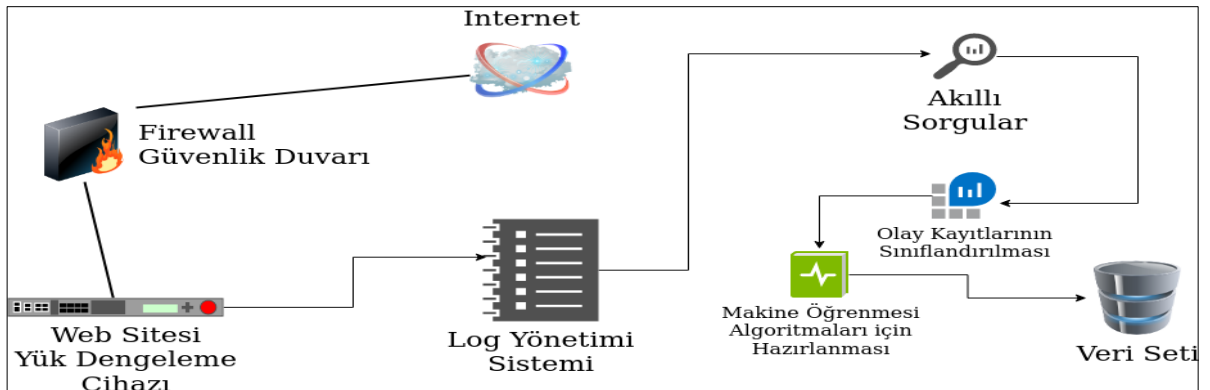
Yayın Adı	Veri Seti	Ön İşleme	Yöntem	Amaç
CODDLE [17] Kavitha v.d. [18]	Github (xss, sql payl.) Özel: Web Server	Tip / Değer Çiftleri Dilbilgisi Kalıpları (Cfg)	Derin Öğrenme Denetimsiz KNN ve Statik Analiz	SQLi ve XSS Tespiti SQLi Tespiti
Hoang v.d.[19] Yao Pan v.d. [20] ZEROWALL [21]	HTTP Params D. 1000 Safe, 500 Attack 1,4 Milyar Web İsteği	Web Günlüğü RSMT Tokenize (Encode/Decode)	DT, SVM Yarı Denetimli ML Denetimsiz RNN	Web Saldırıları Web Saldırıları Sıfırcı Gün Saldırıları
Gniewkowski, Mateusz v.d. [22] Alma, Das [23]	CSIC2010, CIDS2018, UMP ECML-KDD, VULNBANK	Doğal Dil İşl. RoBERTa Auto Encoder	Logistic Regression Özel LSTM	HTTP isteği Anomali Tespiti Web Saldırıları
TbD-NNbR [24] Betarte v.d. [25]	1204 Norm. 451 Zararlı DARPA '99, CSIC2010, PKDD2007	Tokenize Dil İşleme	Sinir Ağı Tek-Sınıf Sınıfl. ve N-Gram	SQLi Modsecurity Geliştirme
RPAD [26]	NIST:2783 Attack,512 N	Dil İşleme	Kural Tabanlı Desen Tanıma	Web Saldırıları
Ibarra-Fiallos, Santiago [27] Gogoi v.d. [28]	36000 Norm. 25000 Zararlı XSSStrike, XSSer	RegEx, Dil İşleme Tokenizasyon, TF- IDF,Sampl.	Statik Filtreleme Çeşitli ML algoritmaları	Girdi Doğrul., XML, JSON vb XSS
Nagarjun vd[29] Mereani,Howe [30] Vishnu,Jevitha [31] Hasan v.d. [32] Mishra [33]	XSSStrike,XSSer XSSed XSSed 616 SQL st. Xristica, libinjection	Vektörize JS Terimleri JS Terimleri SQL Terimleri RegEx, G-test Skoru, Entropi	Ensemble Learning SVM, KNN, RF NB,SVM,J48DT 23 ML Classif. NB, Gradient Boosting	XSS XSS XSS SQLi SQLi
Ross [34] TCSVM [35] Sheykhkanloo [36]	Özel: Web App Host SMOTE ile 12500 Nrm. 12500 Zar.	Korelasyon için Tokenize Hash fonk. ile Özellik çık. 32 tane elle seçilmiş Özellik	Decision Tree, Two-Class SVM Yapay Sinir Ağı (%70,%15,%10)	SQLi SQLi SQLi
SQLiGoT [37]	Çok Çeşitli İnternet Ky.	Sorgu Tokenizasyon	LibSVM (tek, 2 ve 3 Kanallı)	SQLi
OFDPI [38]	SDN üzerinden	TF-IDF	Logistic Regression	Host/Net. based IDS

Yao Pan v.d. makalelerinde [20], otonom yapıdaki saldırı tespit sistemleri konseptine önemli katkılar sağlamaktadır. Web uygulamalarının çalışma zamanı davranışını otonom olarak izleyen ve karakterize eden Robust Software Modeling Tool'a (RSMT) dayalı web saldırısı tespiti için denetimsiz/yarı denetimli bir yaklaşımın fizibilitesi üzerinde çalışılmıştır. Önerilen yaklaşıma göre çıkan sonuçlarda, SQL enjeksiyonu, siteler arası komut dosyası çalıştırma ve seri kaldırma dahil olmak üzere saldırıları, minimum etki alanı bilgisi ve çok az etiketlenmiş eğitim verisi ile verimli ve doğru bir şekilde tespit edilebildiği gösterilmektedir.

Ruming Tang ve diğerleri, Zerowall ismini verdikleri çalışmalarında, 1,4 milyar Web isteği üzerinde uyguladıkları yöntemle, mevcut WAF'lar tarafından

kaçırılan gerçek sıfırcı gün saldırılarını başarılı bir şekilde saptadıklarını ve 0,98'in üzerinde yüksek F1 puanları elde ettiklerini gösteriyorlar [21].

Gniewkowski, Mateusz ve diğerleri, HTTP isteklerini doğal dil işleme tekniklerinden RoBERTa ile vektörize ederek Logistic Regression ile denetimsiz öğrenmeye tabi tutmuşlardır [22]. Veri seti olarak CSIC2010, CSE-CIC-IDS2018 ve kendi hazırladıkları girdileri kullanmışlardır. F1 skorları ortalama veri setleri için %95 civarındadır. Tikam Alma ve Lal Das, 2020'de yine HTTP isteklerini girdi olarak kullanarak Auto-Encoder'la girdilerdeki kelimelerin ağırlıklarını öğrenen ve bunu LSTM hücrelerinden oluşturdukları bir modele girdi olarak veren bir çözüm [23] geliştirerek %99,79 başarımla elde etmişlerdir. Teresa George ve diğerleri, geliştirdikleri



Şekil 2. Veri seti elde etme mimarisi

TbD-NNbR [24] çerçeve (Framework) vekil (Proxy) sunucusunda gelen istekleri Token'lara çevirip test ettikten sonra zararlı ise bloklama, zararsız ise yeniden inşa ederek veritabanı uygulamasına yönlendirmektedirler. Her ne kadar bu yayında sadece SQL injection ile çalışılmışsa da yaklaşım bütün enjeksiyonlara uyarlanabilecek niteliktedir. 1204 normal, 451 zararlı veri ile çalışılmış, tespit oranı %99.75 olarak gerçekleşmiştir. Gustavo Betarte ve diğerleri, Modsecurity WAF'nin (Web Application Firewall) performansını arttırmak amacıyla yaptıkları çalışmada [25] makine öğrenmesi olarak Tek-Sınıf Sınıflandırma ve N-Gram metodunu ayrı ayrı uygulamışlar ve Modsecurity'nin performansını %20 civarında arttırmışlardır.

Makine öğrenmesi dışında bütün HTTP isteklerinden zararlıları tespit ve engelleme niyetiyle RPAD'i [26] yayınlayan Venkatramulu, kural tabanlı desen tanıma yaklaşımında %92,8 başarımla elde etmiştir. Kendisinden önce yapılan IPAAS çalışmasının %80 isabet oranıyla da performans kıyaslaması yapmıştır. Ibarra-Fiallos, Santiago ve diğerleri, web sayfalarına girdi yapılan alanlara bir ön filtre tasarlamayı düşünmüşlerdir. Bu bağlamda filtre her bir alan için, harf, rakam, nokta, soru işareti ve ünlem işareti gibi işaretleri kontrol ederken JSON ve XML dosyalarını da doğrulatmaktadır [27]. %98,4 isabet, 50 ms civarı bir performans yakalanmıştır. XSS tipi saldırıları tanımak amacıyla Gogoi ve diğerleri [28], Nagarjun ve Ahamad [29], Mereani ve Howe [30], Vishnu ve Jevitha [31]; SQL enjeksiyonlarını tanımak amacıyla Hasan ve diğerleri [32], Sonali Mishra [33], Kevin Ross [34], Uwagbole ve Buchanan [35] ve Sheykhkanloo [36] makine öğrenmesi sınıflandırıcıları ve derin öğrenme sinir ağlarını kullanmışlardır.

Cheng, Qiumei ve diğerleri, OFDPI ismini verdikleri çalışmalarında [38] network seviyesinde çalışan girdi makine öğrenmesi temelli girdi tanımlama sistemi geliştirmişlerdir. Buna göre paketler network seviyesinde aynalama (mirror) yöntemi ile OFDPI modelinin çalıştığı sisteme gelir. Burada şifresiz paketlerdeki girdiler okunarak TF-IDF'e önceliklendirilir ve dilsel özellikleri çıkartılır. Bu çıktılar da Logistic Regression ikili sınıflandırıcısına girdi olarak verilir. Şifreli paketlerin ise zararlı ve zararsız olanlarına göre özellikleri çıkartılarak Karar Ağacına girdi olarak verilir. İşlemci, ram, throughput, işlem zamanı gibi performansların da verildiği çalışmada %98 ve %99 başarımla elde edilmiştir.

İncelenen yayınlar Tablo 3'te amaçlarına ve ikincil ölçüt olarak kullandıkları yöntemin özgünlüğüne göre sıralı olacak şekilde verilmiştir. Buna göre yalnızca SQL veya yalnızca XSS inceleyen yayınlar bulunduğu gibi bütün web saldırılarını önlemeyi amaçlayan, sıfırinci gün saldırılarını hedef edinen, WAF performansı arttırmak isteyen yayınların bulunduğu görülmüştür. Bu çalışmada amaçlanan, girdi kalıplarının bir bütün olarak değerlendirilip hepsinin tespitinin çoklu sınıflandırma çıktısıyla verilmesi daha önce yapılmamıştır.

Çeşitli kâr amacı gütmeyen kuruluşlar, vakıflar ve güvenlik şirketlerinin raporlarında tasnif edilmiş saldırı

tipleri ve etiketlenmiş girdi parçalarından (payload) hareketle makine öğrenmesi sınıflandırıcı veya derin öğrenme modeli oluşturulmuştur, tespit etme ve sınıflandırma etme performansına ek olarak ne kadar vakit harcadığı da ölçülerek not edilmiştir. Literatürde bazı çalışmaların yalnızca Saldırı/Saldırı değil olarak sınıflandırma yaptığı, birçoğunun yalnızca bir ana başlık üzerinde girdileri modellemeye çalıştığı (SQL, XSS veya Komut Enjeksiyonu gibi), pek çoğunda harcanan zamana ilişkin performans metriklerinin hepsinin ölçülmediği görülmüştür. Bu çalışmada, literatürdeki eksikliklerin giderilmesi amacıyla belirlenen konularda iyileştirmeler yapılarak katkı sunulmaktadır. Buna göre;

- Enjeksiyon saldırısı tiplerinden bilinen ve uygulaması mümkün olanların modellemeye girdi olarak verilerek geniş bir veri seti kullanılması,
  - Eğitim ve test aşamaları için zamana ilişkin performansın ölçülmesi,
  - Girdi olan yük parçasının hangi saldırı tipine ait olduğuna dair tahminde bulunulması,
- katkıları sağlanmaktadır.

Makalenin bundan sonraki bölümlerde devam eden yapısı şu şekildedir: Bölüm 2'de çalışmanın gerçekleştirilmesi için gerekli materyal ve kullanılan metod açıklanmıştır. Buna göre veri setleri, ön işlem ve özellik çıkartma teknikleri, hazır makine öğrenmesi sınıflandırıcıları ve kurgulanan veya kullanılan yapay sinir ağı modelleri, kullanılan platform ve yazılım kütüphaneleri ve analiz araçları ayrıntıları verilmiştir. Bölüm 3'te elde edilen bulgular ve bulgulara ilişkin değerlendirmeler açıklanmaktadır. Bölüm 4'te ise çalışmanın öne çıkan yönleri, zayıflıkları ve gelecek çalışmalara ilişkin tartışmalar ve sonuçta ulaşılan yorumlara yer verilmiştir.

## 2. MATERYAL VE METOT

Bu çalışma kapsamında kullanılan/oluşturulan veri seti, gerçekleştirilen ön işlemler, uygulanan algoritmalar ve değerlendirme metrikleri bu bölümde detaylandırılmıştır.

### 2.1. Veri Setleri

Enjeksiyon başlığıyla zararlı girdiler etiketlenmiş olması gerektiğinden dolayı hazır olarak internet kaynaklarından elde edilen veri setleri, yerel bir alan adına yapılan girdilerle karşılaştırılmış ve etiketleme fonksiyonu hazırlanarak etiketleme yapılmıştır. Bu amaçla, bir alan adına (Domain) ve alt alan adlarına gelen HTTP istekleri kullanılmıştır. Veri seti güvenlik gerekçeleriyle alan adı ve alan adına işaret eden alt isimler maskelenmiş ve anonimleştirilmiştir. Buna göre 2307 zararlı, 2149 normal istek kullanılmıştır. Zararlı istekler 16 sınıfa bölünmüştür. Bunlar Piggy Backed, Blind SQL, XSS Keyword, Stored Procedure, Alternate Encoding, Union, Totoloji, SQL Error, SQLi, Enjeksiyon, SSTI, Open Redirect, XXE, Path Traversal, CMDi, CRLFİ isimlerine karşılık gelecek şekilde numaralandırılmıştır. Aynı zamanda, OWASP tarafından sağlanmış GitHub'da bulunan swisskyrepo, PayloadsAllTheThings girdileri [7] ve GitHub'da bulunan XSS ve SQL injection veri setleri [39] karşılaştırma ve etiketleme için kullanılmıştır.





Pandas, Numpy, Requests gibi kütüphaneler dizilerin tutulması, matematiksel işlemlerin yapılması ve HTTP isteklerinin alınması veya gönderilmesi için kullanılmıştır.

Python'da Django ve Flask framework'leri (Web gösterimi ve canlı olarak saldırıları test edebilmek amacıyla geliştirilmiş API için), platform bağımsız masaüstü uygulaması için de Kivy framework'ü kullanılmıştır.

## 2.5. Analiz Yöntemi

Çalışma kapsamında ele alınan yüklerden saldırı olarak etiketlenenler "pozitif", saldırı olmayan yükler ise "negatif" olarak isimlendirilmektedir. Yük tipinin doğru tespit edilmesine "T(True)", yanlış tespit edilmesine ise "F(False)" olarak belirtilmektedir. Trafik tipi ve tespit sonuçları ile ilgili ifadeler Tablo 4'te sunulmaktadır. Bu çalışmada gerçekleştirilen testlerin değerlendirilmesi için Tablo 5'te sunulan performans metrikleri kullanılmaktadır.

**Tablo 4 :** Trafik tipinin sınıflandırılması mantıksal gösterimi

Trafik Tipi	Pozitif Tahmin		Negatif Tahmin	
Saldırı (Pozitif)	Saldırılı olarak tahmin (TP)	saldırı	Saldırılı olarak tahmin (FN)	normal
Normal (Negatif)	Normali olarak tahmin (FP)	saldırı	Normali olarak tahmin (TN)	normal

**Tablo 5 :** Performans metrikleri

Metrik	Hesaplama
Doğruluk (Accuracy)	$\frac{TP + TN}{TP + TN + FN + FP}$
Hassasiyet (Precision)	$\frac{TP}{TP + FP}$
Özgüllük (Recall)	$\frac{TP}{TP + FN}$
F1-Skoru (F1-Score)	$2 \frac{Hassasiyet + Özgüllük}{Hassasiyet * Özgüllük}$

Çalışmada kullanılan veriler saldırı tiplerine göre de etiketli olduğundan, çoklu sınıflandırma performansı da değerlendirilmektedir. Doğruluk değeri, modelin çok etiketli veri setindeki bütün girdilere dair isabetli tahmin etme oranını verir. Hassasiyet değeri, ilgili sınıfa dair isabetli değerlerin modelin o sınıfa ait olduğunu tahmin ettiği tüm örneklerine oranını verirken, özgüllük değeri modelin o sınıftaki tüm örnekler arasında doğru şekilde sınıflandırdığı örneklerin oranıdır. F1-Skoru ise aslında modelin bir sınıfa dair girdileri diğerlerinden ne oranda başarı ile ayırt edebildiğini gösteren hassasiyet ve özgüllük değerlerinin harmonik ortalamasını verir.

## 3. BULGULAR VE DEĞERLENDİRMELER


Karar Ağacı ve Rassal Orman sınıflandırıcılarının ileri düzey performans gösterdikleri görülmüştür. Sonrasında lineer sınıflandırıcılar ve hemen hemen denk olarak topluluk öğrenmesi sınıflandırıcılarının iyi performans gösterdikleri not edilmiştir. Tamamında hiper parametre optimizasyonları yapılmış, özellikle tahmine dayalı

sınıflandırıcılarda doğru tespit oranının %50'lere düştüğü, işlem süresinin de 10 dakikanın üzerine çıktığı gözlemlenmiştir.

Yapay Sinir Ağları'nda parametreler dikkatle ayarlanmalı ve kaç devir boyunca eğitim sürecinin işletileceği doğru belirlenmelidir. Ayrıca veri seti yeterli miktarda olmadığı için yapay sinir ağlarında isabet oranları yakalansa da eğitim süreçlerinin uzunluğu göz önüne alınmalıdır.

	precision	recall	f1-score	support
CMDi	0.00	0.00	0.00	1
Enjeksiyon	0.81	0.75	0.78	79
Normal	0.94	1.00	0.97	302
PathTraversal	0.93	0.93	0.93	30
SQLi	0.60	0.35	0.44	17
XXE	1.00	0.50	0.67	2
XssKeyword	0.96	0.94	0.95	199
piggyBacked	1.00	1.00	1.00	26
storedProcedure	0.93	1.00	0.96	13
accuracy			0.93	669
macro avg	0.80	0.72	0.75	669
weighted avg	0.92	0.93	0.93	669


Şekil 4. LSTM Sinir Ağı çalışma performansı



Şekil 5. Rassal Orman (Random Forest) Sınıflandırıcı modeli karışım matrisi

**Tablo 6 :** Çalıştırılan modeller ve performansları

Sınıflandırıcı	Doğruluk	Öğrenme Süresi (sn)
Decision Tree	0.946	12.45
Random Forest	0.945	15.047
K-Nearest Neig.	0.905	7.88
Linear SVC	0.933	24.97
Ridge Class.	0.888	17.167
Passive	0.890	34.77
Aggressive		
Gradient	0.874	486.02
Boosting		
Extra Trees	0.863	49.75
LSTM	0.930	~1800
MLP	0.865	300



Şekil 6. Kelimelerin veri setinde rastlanma sıklıkları ve yakınlıkları



Şekil 7. Kelimelerin veri setinde rastlanma sıklıkları ve yakınlıkları (Şekil 6 – Orta bölüm)

Uygulanan ön işlem adımlarının ve etiketlendirme faaliyetlerinin isabetli olduğu bazı sınıflandırıcıların eğitim süreçlerinin kısalığından çıkartılabilir. Tablo 6'dan çalıştırılan modellerin performansları izlenebilir. Şekil 4'te LSTM sinir ağının performansı karışım matrisinde gösterilmiştir. Şekil 5'de Rassal Orman Sınıflandırıcısı'nın y ekseninde verinin ne olduğu, x ekseninde tahminler olmak üzere performansı gösterilmiştir. Veri setinin dengeli olmasının sonuçları etkilediği değerlendirilmektedir.


Şekil 6'da veri setinde görülen kavramların birbirlerine yakınlıkları görülebilmektedir. Örneğin, XSS keyword'lerinin birbirine yakın düşmesi beklenir. Modelin sınıflara dair kavramları bu şekilde birbirine yakınsatması sınıfları birbirinden ne kadar başarılı ayırdığını gösterirken gelecekte karşılaşılabileceği ve daha önce hiç tanımadığı girdileri doğru sınıflandıracağına dair

fikir vermektedir. Şekil 7, Şekil 6'nın ortasındaki üst üste gelmiş kelimelerin daha detaylı görülebilmesi için eklenmiştir.

Bu çalışma kapsamında geliştirilen uygulama Şekil 8'de görülmektedir. Uygulama ekranında, istenilen test verisi girilebilmekte, web tarayıcı üzerinden gelen istekler sınıflandırılabilmekte ve modeller çeşitli parametrelerle eğitilebilmektedir.

#### 4. TARTIŞMA VE SONUÇ

Bu çalışmada, web saldırılarına ilişkin bütün saldırı tiplerinin sınıflandırmasının doğru bir şekilde yapılmasının yanı sıra zamansal performansın ölçülmesi esas alınmıştır. Bu amaçla, dış dünya verilerinden elde edilmiş özgün bir veri seti kullanılmıştır. Veri setinin üzerinde çoklu sınıflandırma etiket çalışması yapılmıştır.



Şekil 8. Masaüstü Uygulaması, örnek bir saldırı yükü sonucu.

Elde edilen bu etiketli veri seti üzerinde özgün bir ön işlem fazı gerçekleştirilmiştir. Ön işlem fazından sonra makine öğrenmesi sınıflandırıcıları ve yapay sinir ağları kullanılarak çoklu sınıf sınıflandırma işlemi gerçekleştirilmiştir. Çalışmanın pratikte kullanılabilmesi için platform bağımsız bir uygulama geliştirilmiştir

Rassal Orman ve Karar Ağacı sınıflandırıcılarında %94,54 ve %94,61 isabet oranları elde edilmiş, 15 ve 12 sn. öğrenme süreleri performansı ölçülmüştür. LSTM ağının Normal (Saldırı olmayan) veriyi diğer etiketli verilerden ayırma performansına bakılırsa %97'lik F1 Skoru görülebilir. Sistemin normal tipteki veriyi saldırı tipindeki veriden neredeyse hatasız ayırabildiği elde edilen sonuçlardan görülebilmektedir.

Yapısı gereği enjeksiyon tipindeki saldırılar bir girdi verisinin içerisinde birden fazla bulunabilmektedir. Söz gelimi bir yük girdisi, XSS saldırısı içerisinde SQL enjeksiyonu ve hatta aynı anda CMD enjeksiyonunu da birlikte içerebilir. XSS'in "Script" etiketi içerisinde POST parametreleri arasında "Select" ifadesi gönderilebilirken, Windows işletim sistemine dair komutları da görme ihtimalimiz vardır. Gerçek dünyada karşılaşılabilecek bu tip örnekler çalışmanın bir diğer zorlayıcı tarafıdır, çünkü sınıflandırma performansını olumsuz etkilemektedir.

Geliştirilen uygulamanın Web Application Firewall - WAF veya Security Information and Event Management - SIEM gibi sistemler için doğrulama ünitesi gibi çalışabileceği değerlendirilmektedir. Girdi temelli saldırıların günümüz dünyasında halen en üst düzey güvenlik tehditlerinden olduğu, veri sızıntılarının engellenemediği değerlendirilirse güvenlik bileşenlerinin çeşitliliğinin artırılması ve yapay zeka ve makine öğrenmesiyle desteklenmesinin kritik olduğu görülebilir.

İlerleyen çalışmalarda normal tipteki veriye karşılık saldırı bloğundaki bütün sınıflandırmaların birleştirilerek ikili sınıflandırma sonuçlarına bakılabileceği değerlendirilmiştir.

## Etik Hususlar

### Etik kurallara uyum

Bu araştırmanın planlanmasından uygulanmasına, verilerin toplanmasından verinin analizine kadar olan tüm süreçte "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" kapsamında uyulması belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir. Çalışmanın yazım sürecinde bilimsel etik ve alıntı kurallarına uyulmuş, toplanan veriler üzerinde herhangi bir tahrifat yapılmamış ve bu çalışma herhangi başka bir akademik yayın ortamına değerlendirme için gönderilmemiştir.

## Finansman

Yazarlar kamu, ticari veya kâr amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe alınmadığını beyan ederler.

## Çıkar çatışması

Çalışma ile ilgili herhangi bir kişi veya kurumla çıkar çatışmasının bulunmadığını yazarlar olarak onaylıyoruz.

**KAYNAKÇA**

- [1] Mitre, CAPEC. 2023. CAPEC VIEW: Domains of Attack. [capec.mitre.org/data/definitions/3000.html](https://capec.mitre.org/data/definitions/3000.html) (Erişim Tarihi: 04.12.2023)
- [2] Mitre, CWE. 2021. CWE Top 25 Most Dangerous Software Weaknesses [cwe.mitre.org/top25/archive/2021/2021\\_cwe\\_top25.html](https://cwe.mitre.org/top25/archive/2021/2021_cwe_top25.html) (Erişim Tarihi: 04.12.2023)
- [3] OWASP. 2021. OWASP Top Ten. [owasp.org/www-project-top-ten/#](https://owasp.org/www-project-top-ten/#) (Erişim Tarihi: 04.12.2023)
- [4] OWASP. 2021. A03:2021 – Injection [owasp.org/Top10/A03\\_2021-Injection/](https://owasp.org/Top10/A03_2021-Injection/) (Erişim Tarihi: 04.12.2023)
- [5] OWASP. 2021. Injection Flaws [owasp.org/www-community/Injection\\_Flaws](https://owasp.org/www-community/Injection_Flaws) (Erişim Tarihi: 04.12.2023)
- [6] Milzarek, R. 2020. Injection Attacks Types and How to Best Protect Your Web Apps [crashtest-security.com/what-are-the-different-types-of-injection-attacks/](https://crashtest-security.com/what-are-the-different-types-of-injection-attacks/) (Erişim Tarihi: 04.12.2023)
- [7] GitHub. 2023. Payloads All The Things [github.com/swisskyrepo/PayloadsAllTheThings](https://github.com/swisskyrepo/PayloadsAllTheThings) (Erişim Tarihi: 04.12.2023)
- [8] OWASP. 2023. Attacks. [owasp.org/www-community/attacks/](https://owasp.org/www-community/attacks/) (Erişim Tarihi: 04.12.2023)
- [9] The Web Application Security Consortium. 2010. Tehdit Sınıflandırması 2.0, WASC-20: Improper Input Handling. [projects.webappsec.org/w/page/13246933/Improper%20Input%20Handling](https://projects.webappsec.org/w/page/13246933/Improper%20Input%20Handling) (Erişim Tarihi: 04.12.2023)
- [10] Ray, D., Ligatti, J. 2012. Defining code-injection attacks. *Acm Sigplan Notices*, 47(1), 179-190.
- [11] Asif, M., Chirchi, E. M. 2021. Implementation of ML Algorithm's for Cyber Security.
- [12] Valenza, A., Demetrio, L., Costa, G., Lagorio, G. 2020. WAF-A-MoLE: An adversarial tool for assessing ML-based WAFs. *SoftwareX*, 11, 100367.
- [13] Inamdar, D. M., Gupta, S. 2020. A Survey on Web Application Security. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, (6), 223-228.
- [14] Fox, K., Henning, R., Reed, J., Simonian R. 1990. A neural network approach towards intrusion detection. *Proceeding of 13th National Computer Security Conference*, Baltimore, MD, pp. 125–134, 1990.
- [15] Abaimov, S., Bianchi, G. 2021. A survey on the application of deep learning for code injection detection. *Array*, 11, 100077.
- [16] Acunetix. 2021. Web Uygulama Zafiyet Raporu. <https://www.acunetix.com/white-papers/acunetix-web-application-vulnerability-report-2021/> (Erişim Tarihi: 04.12.2023)
- [17] Abaimov, S., Bianchi, G. 2019. CODDLE: Code-injection detection with deep learning. *IEEE Access*, 7, 128617-128627.
- [18] Kavitha, M. N., Vennila, V., Padmapriya, G., Kannan, A. R. 2021. Prevention of SQL injection attack using unsupervised machine learning approach. *vol, 12, 12*.
- [19] Hoang, X. D. 2021. Detecting common web attacks based on machine learning using web log. In *Advances in Engineering Research and Application: Proceedings of the International Conference on Engineering Research and Applications, ICERA 2020* (pp. 311-318). Springer International Publishing.
- [20] Pan, Y., Sun, F., Teng, Z., White, J., Schmidt, D. C., Staples, J., Krause, L. 2019. Detecting web attacks with end-to-end deep learning. *Journal of Internet Services and Applications*, 10(1), 1-22.
- [21] Tang, R., Yang, Z., Li, Z., Meng, W., Wang, H., Li, Q., Liu, Y. 2020, July. Zerowall: Detecting zero-day web attacks through encoder-decoder recurrent neural networks. In *IEEE INFOCOM 2020-IEEE Conference on Computer Communications* (pp. 2479-2488). IEEE.
- [22] Gniewkowski, M., Maciejewski, H., Surmacz, T. R., Walentynowicz, W. 2021. HTTP2vec: Embedding of HTTP requests for detection of anomalous traffic. *arXiv preprint arXiv:2108.01763*.
- [23] Alma, T., Das, M. L. 2020. Web Application Attack Detection using Deep Learning. *arXiv preprint arXiv:2011.03181*.
- [24] George, T. K., Jacob, K. P., James, R. K. 2018. Token based detection and neural network based reconstruction framework against code injection vulnerabilities. *Journal of Information Security and Applications*, 41, 75-91.
- [25] Betarte, G., Giménez, E., Martínez, R., Pardo, Á. 2018. Machine learning-assisted virtual patching of web applications. *arXiv preprint arXiv:1803.05529*.
- [26] Venkatramulu, S., Guru, R. 2017. RPAD: Rule based pattern discovery for input type validation vulnerabilities detection & prevention of HTTP requests. *International Journal of Applied Engineering Research*, 12(24), 14033-14039.
- [27] Ibarra-Fiallos, S., Higuera, J. B., Intriago-Pazmiño, M., Higuera, J. R. B., Montalvo, J. A. S., Cubo, J. 2021. Effective filter for common injection attacks in online web applications. *IEEE Access*, 9, 10378-10391.
- [28] Gogoi, B., Ahmed, T., Saikia, H. K. 2021. Detection of XSS attacks in web applications: A machine learning approach. *International Journal of*

Innovative Research in Computer Science & Technology (IJRCST) ISSN, 2347-5552.

- [29] Nagarjun, P. M. D., Shaik, S. A. 2020. Ensemble methods to detect XSS attacks. *International Journal of Advanced Computer Science and Applications*, 11(5).
- [30] Mereani, F. A., Howe, J. M. 2018, January. Detecting cross-site scripting attacks using machine learning. In *International conference on advanced machine learning technologies and applications* (pp. 200-210). Cham: Springer International Publishing.
- [31] Vishnu, B. A., Jevitha, K. P. 2014, October. Prediction of cross-site scripting attack using machine learning algorithms. In *Proceedings of the 2014 International Conference on Interdisciplinary Advances in Applied Computing* (pp. 1-5).
- [32] Hasan, M., Balbahaith, Z., Tarique, M. 2019, November. Detection of SQL injection attacks: a machine learning approach. In *2019 International Conference on Electrical and Computing Technologies and Applications (ICECTA)* (pp. 1-6). IEEE.
- [33] Mishra, S. 2019. SQL injection detection using machine learning.
- [34] Ross, K. 2018. SQL injection detection using machine learning techniques and multiple data sources.
- [35] Uwagbole, S. O., Buchanan, W. J., Fan, L. 2017, May. Applied machine learning predictive analytics to SQL injection attack detection and prevention. In *2017 IFIP/IEEE Symposium on Integrated Network and Service Management (IM)* (pp. 1087-1090). IEEE.
- [36] Sheykhkanloo, N. M. 2020. A learning-based neural network model for the detection and classification of SQL injection attacks. In *Deep Learning and Neural Networks: Concepts, Methodologies, Tools, and Applications* (pp. 450-475). IGI Global.
- [37] Kar, D., Panigrahi, S., Sundararajan, S. 2016. SQLiGoT: Detecting SQL injection attacks using graph of tokens and SVM. *Computers & Security*, 60, 206-225.
- [38] Cheng, Q., Wu, C., Zhou, H., Kong, D., Zhang, D., Xing, J., Ruan, W. 2021. Machine learning based malicious payload identification in software-defined networking. *Journal of Network and Computer Applications*, 192, 103186.
- [39] Taşdelen, İ. 2023. Payload Box – Attack Payloads [github.com/payloadbox/](https://github.com/payloadbox/) (Erişim Tarihi: 04.12.2023)

**(Araştırma Makalesi)****İlkokul 3. Sınıf Öğrencilerine Yönelik Artırılmış Gerçeklik Teknolojisi İle İngilizce Eğitimi İçin Mobil Oyun Uygulaması****Filiz UYSAL<sup>\*1</sup>, Durmuş ÖZDEMİR<sup>2</sup>**<sup>1</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No : <https://orcid.org/0009-0009-5414-2112><sup>2</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No : <https://orcid.org/0000-0002-9543-4076>**Anahtar Kelimeler:**  
Artırılmış gerçeklik,  
Eğitimde Artırılmış Gerçeklik,  
Mobil öğrenme**Özet:** Artırılmış gerçeklik, son yıllarda tıp, askeri, sağlık, mesleki eğitim, farklı kademelerdeki öğretim süreçleri, turizm, tıp ve görsel medya gibi alanlarda kullanılmaktadır. Eğitimde artırılmış gerçeklik uygulamaları öğrencilerin hayal gücünün ve yaratıcılıklarının gelişmesine destek olarak ve gerçek dünyayla olan etkileşimini artırarak etkili bir öğrenme şekli sunmaktadır. Bu çalışmada İlkokul 3. sınıf öğrencilerinin İngilizce derslerine yönelik Milli Eğitim Bakanlığı müfredatına uygun şekilde yardımcı materyal olarak kullanılacak bir materyal tasarlanması amaçlanmıştır. Bu çalışma kapsamında etkinlik tasarımında öğrencilerin eğlenerek öğrenebilecekleri, dikkat çekici öğrenme ortamı sunabilen artırılmış gerçeklik teknolojisi tabanlı, Unity 3D ve Vuforia SDK ile mobil uygulama gerçekleştirilmiştir.**(Research Article)****Mobile Game Application For English Education Using Augmented Reality Technology For 3rd Grade Primary School Student****Keywords:**  
Augmented Reality,  
Augmented Reality in Education,  
Mobile Learning**Abstract:** In recent years, augmented reality has been used in fields such as medicine, military, health, vocational education, teaching processes at different levels, tourism, medicine and visual media. Augmented reality applications in education offer an effective way of learning by supporting the development of students' imagination and creativity and increasing their interaction with the real world. In this study, it is aimed to design a material that can be used as an auxiliary material for the English lessons of primary school 3rd grade students in accordance with the curriculum of the Ministry of National Education. Within the scope of this study, a mobile application was created with Unity 3D and Vuforia SDK, based on augmented reality technology, which can provide a remarkable learning environment where students can learn while having fun.**1. GİRİŞ**

Günümüzde teknoloji çok hızlı değişim göstermektedir. Teknolojinin ilerlemesi insanların ilgilerini, beklentilerini, motivasyonlarını etkilediği gibi öğrenme ihtiyaçlarını da değiştirmektedir. Son yıllarda öğrenme ortamlarında geleneksel yöntemlerin yetersiz kaldığı söylenebilir [1]. Öğrenme ortamındaki eksikliği gidermek için eğitimcilerin çeşitli materyalleri ve teknolojileri

derslerde kullandıkları görülmektedir. Taşınabilirlik, ilgi çekicilik, maliyet, içerik çeşitliliği, kolay ulaşılabilirlik gibi unsurlar göz önüne alındığında dijital materyaller eğitimde oldukça fayda sağlamaktadırlar. Öğretimde teknoloji kullanımının sonucunda önem kazanan bireyselleştirilmiş öğretim ile öğrenciler kendi öğrenme hızında ve beceri seviyesine göre ilerleyebilmekte, öğrenme içeriklerine istenilen yer ve zamanda erişebilmektedirler [2].

Öğrenci merkezli ve bireyselleştirilmiş öğretim için kullanılan çeşitli araç ve ortamlar bulunmaktadır. Bunlardan biri de artırılmış gerçeklik teknolojisi. Artırılmış gerçeklik (Augmented Reality(AR)) geliştirici tarafından belirlenen hedef resimler üzerine mobil cihazlarda bulunan dahili kamera ile ya da bilgisayara bağlı bir kamera ile bakıldığında yine geliştirici tarafından dizayn edilen üç boyutlu objenin hedef üzerinde belirip sanki gerçekten obje hedef resmin üzerindeymiş etkisini yaratan bir teknolojidir. Sanal ve gerçek nesnelerin birleştirilmesi öğrenenlerin karmaşık uzamsal ve soyut kavramları görselleştirmelerine, gerçek öğrenme ortamlarında mümkün olmayan deneyimler kazanmalarına imkân sunmaktadır [1].

Artırılmış gerçeklik teknolojisi temelde insan bilgisayar etkileşimini artırmak amacıyla ortaya çıkmış bir teknolojidir. Bu teknoloji, yaşadığımız dünyanın 3 boyutlu parametrelerini içermesinden dolayı eğitim alanında kendine yer edinmiştir.

Artırılmış gerçeklikte tamamen yarı sanal ortamlar bulunmaktadır ve cihaz ekranının (telefon/tablet/bilgisayar monitörü vb.) boyutu kadar fiziksel bir deneyim gerçekleştirebilmektedir. Bu deneyim uygulamanın kullanım alanına göre farklı işlevsellikler gösterebilmektedir. Örneğin bazı uygulamalarda, sadece telefonu objeye veya yüzeye tutarak bilgi edinmeye yönelik araçlar bulunurken, bazı uygulamalarda ise etkileşimli olarak bilgi alınabilmekte ve kullanıcının isteklerine yönelik cevaplar/çözümler üretilmektedir [3].

Moraless ve Garciaa yaptıkları çalışmada [4], ilkökull öğrencileri ile yapılan araştırmada, artırılmış gerçeklik kullanımının akademik başarıya etkileri ve yeni teknolojilere yönelik algılarını incelemişlerdir. Söz konusu çalışmada artırılmış gerçekliğin bir öğretim aracı olarak kullanılması akademik performans ve bilgi edinme sürecini olumlu yönde etkilediği sonucuna ulaşılmıştır. Ayrıca okulda yeni teknolojilerin kullanımıyla gerçekleştirilen öğretme ve öğrenme süreci, katılımcılar tarafından olumlu, teşvik edici ve kolaylaştırıcı olarak algılanmıştır [4].

Çetinkaya ve Akçay yapmış oldukları “Eğitim Ortamlarında Artırılmış Gerçeklik Uygulamaları” adlı çalışmada eğitim ortamlarında tüm kademelerde farklı gereksinimlere yönelik artırılmış gerçeklik uygulamalarının dünyada yaygın olarak kullanılmaya başlanıldığı ve ülkemizde artırılmış gerçeklik teknolojilerinin yaygınlaşmasında FATİH Projesinin önemli bir fırsat olduğunu öngörmektedir [5].

Bu çalışma sırasıyla şu şekilde sunulmuştur. İkinci bölüm olan yöntem bölümünde çalışmanın tasarımında kullanılan kuram ve tasarım ilkeleri ile tasarım aşamaları detaylı bir şekilde anlatılmıştır. Üçüncü bölümde ise yapılan uygulamanın arayüzleri ve içerik sunulmuştur. Tartışma ve sonuç bölümünde ise çalışmanın literatüre olan muhtemel katkıları ve öneriler tartışılmıştır.

## 2. YÖNTEM


### 2.1. Tasarım ilkeleri

Günümüzde özellikle Bilgi ve İletişim Teknolojilerinin (BİT) göstermiş olduğu hızlı gelişime paralel olarak bireyler tarafından bu teknolojilerin benimsenmesinin daha da kolaylaştığı ve bu teknolojilere ilişkin kullanım oranlarında da ciddi bir artışın gerçekleştiği dikkat çekmektedir [6].

Teknolojinin eğitim ortamlarına girmesi, farklı öğrenci özelliklerine uygun öğretim materyallerinin tasarlanmasını sağlayarak öğretim ortamlarını zenginleştirmenin yanında öğretim ortamlarına ulaşılabilirliği kolaylaştırıp verimli öğrenme ortamlarının oluşmasına olanak vermektedir. Öğretim teknolojisi kullanılarak hazırlanan öğrenme ortamları çeşitli kaynaklar ile öğrenme-öğretme ortamlarını daha çok duyuya hitap eden çevreler haline getirerek, öğrenci motivasyon ve başarısını da artırmaktadır. Bu bağlamda öğretim teknolojileri yöneldikleri duyarlar dikkate alınarak incelendiğinde; görsel ortamlar, işitsel ortamlar hem görsel hem de işitsel ortamlar olarak sınıflamak mümkün görünmektedir. Bu sınıflama doğrultusunda görsel ortamlar; kitaplar, yazı tahtaları, resimler, şemalar, grafikler, gerçek eşyalar veya bunların modellerini kapsamaktadır. İşitsel ortamlar ise radyo, plak, teyp ve ses bantları ile örneklendirilebilmektedir. Hem görsel hem de işitsel ortamları ise; film makinesi, hareketli filmler (animasyonlar), televizyon ve videoları içermektedir. Bu tür eğitim ortamları birden fazla duyuya hitap eden, dolayısı ile birden fazla veri türünü kapsayan ortamlar olarak öne çıkmakta ve çoklu ortam olarak isimlendirilmektedir [7].

Öğrenme yöntemlerinde (veya ortamlarında) gelişen teknolojinin kullanılmasıyla beraber birden fazla duyu organına hitap eden uyaranların etkileşimi çoklu öğrenme ortamı kavramının ortaya çıkmasını sağlamıştır. Çoklu ortam, literatürde farklı biçimlerde tanımlanmaktadır. En basit anlamıyla, çoklu ortam, birden fazla duyu organına hitap eden çevrelerdir. Bu bağlamda bir PowerPoint sunumu, televizyondaki bir film, bilgisayarda hazırlanmış sesli bir animasyon çoklu ortama örnek olarak verilmektedir [7]. Mayer tarafından yapılan çalışmada [8], belirtilmiş olan; öğrenenlerin çoklu öğrenme ortamlarında üç farklı bilişsel işlem gerçekleştirdiği dikkat çekmektedir. Bu işlemler sırası ile seçme, düzenleme ve bütünleştirme olarak adlandırılmaktadır. Materyal ile sunulan sözcük ve görsellerden, konu ile ilgili olanların duyu organları aracılığıyla seçiminin gerçekleştirilmesi ile kısa süreli (işleyen) belleğe alınması sürecine “*seçme*”, seçilen sözcük ya da görsellerin bilginin yapılandırılma sürecinde kullanılarak organize edilmesi sürecine “*düzenleme*”, seçilen materyallerin bireyde önceden var olan bilgileri ile ilişkilendirilmesi süreci ise, “*bütünleştirme*” aşamasını ifade etmektedir. Bu süreç bir bütün olarak değerlendirildiğinde, duyu organları aracılığıyla elde edilen bilginin uzun süreli bellekte depolanması ile Türetimci Çoklu Ortamla Öğrenme Kuramı ilişkilendirilmektedir.

Bireylerin bilgi işleme süreçlerini temsil eden çoklu ortamla öğrenmeye ilişkin yapı Şekil 1’de sunulmuştur.



Şekil 1. Çoklu ortamla Öğrenmenin Bilişsel Teorisi

## 2.2. Artırılmış gerçeklik tanımı ve özellikleri

Artırılmış Gerçeklik, 3D sanal nesnelere ile gerçek dünya varlıklarının birlikteliğine ve gerçek zamanlı etkileşimlere imkân sağlayan [9], bağlam temelli dijital bilgi ile gerçek dünya ortamlarını dinamik olarak harmanlayabilen yenilikçi bir teknolojidir [10].

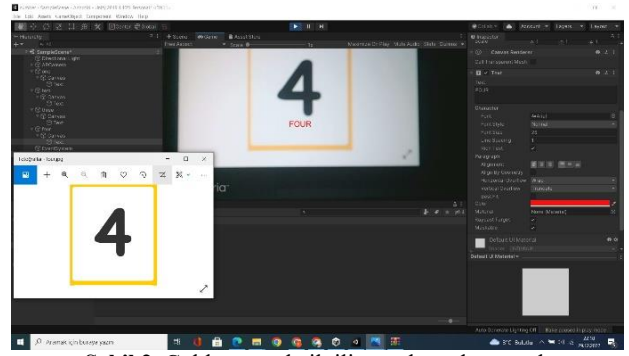
Artırılmış gerçeklik, dijital bilginin kullanım ortamıyla gerçek zamanlı olarak bütünleştirilmesidir. Tamamen yapay bir ortam yaratan sanal gerçekliğin aksine, artırılmış gerçeklik var olan ortamı kullanmaktadır. Sanal ve fiziksel dünyalar arasındaki boşluğu dolduran Augment, çevremizde yer alan nesnel dünyayı, görme, hayal etme ve öğrenme şeklini değiştirmektedir [11].

Artırılmış gerçekliğin faydaları, sadece görme duyusuna hitap etme özelliği ve kafaya monteli görüntüleme teknolojileri ile kullanılabilme yeteneği ile sınırlı tutulmamalıdır [9]. Artırılmış gerçeklik teknolojisinin etkileşim düzeyinin ve gerçeği temsil yeteneğinin oldukça iyi olması kullanıcıya 3D sanal nesnelere dokunma hissi ve varlık duygusu yaşatmakta ve bu sayede onun ilgi çekici ve özgün öğrenme deneyimleri yaşamasına olanak sağlamaktadır. Artırılmış gerçeklik sistemlerinde üç boyutlu modellerin yanı sıra metinler, görüntüler, videolar ve animasyonlar da kullanılabilir [11].

## 2.3. Tasarım, Geliştirme ve Uygulama

İlkokul 3. Sınıf öğrencileri için hazırlanan artırılmış gerçeklik uygulamasında menü ve ünite ile ilgili tasarımlar yapılırken, Mayerin teknoloji tabanlı öğretimsel çoklu ortam tasarımına yol gösterici ilkelerden olan, çoklu ortam, konumsal yakınlık, zamansal yakınlık, tutarlılık, gereksizlik, dikkat çekme, ses, biçim, parçalama bölme ilkelerinden faydalanılmıştır. [12]. Bu kısaca açıklamak gerekirse;

**Çoklu Ortam:** Resim ve yazının birlikte sunulduğu ortamlarda öğrenme, sadece yazıdan oluşan öğrenme ortamlarına göre daha iyi olur. Örnek olarak uygulamada kitaptan 4 rakamı gösterildiğinde İngilizce olarak yazılışı ekranda gösterilmektedir.



Şekil 2. Çoklu ortamla ilgili uygulamadan örnek

**Tutarlılık İlkesi:** Konu dışı materyaller tasarım dışında tutulursa öğrenme daha iyi olur. Konu ile alakası olmayan, birbirinden farklı materyallerin kullanılması öğrenenler üzerinde farklı anlamlara, kavram karmaşasına ve konunun dışına sapmaya neden olabilir.

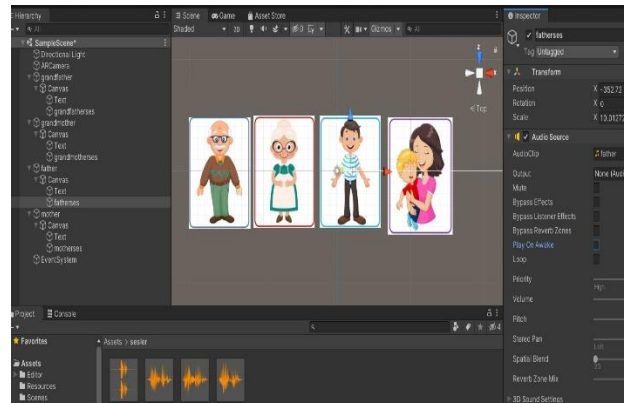
**Dikkat Çekme İlkesi:** Tasarım yaparken önemli görülen sözcük ve resimler vurgulandığında öğrenme daha iyi olur. Dikkat çekme altında öğrenene yeni bir şey öğretmemektedir. Sadece anlatılmak istenen konunun daha kalıcı olmasını sağlamaktadır.

**Gereksizlik İlkesi:** Öğrenme açısından resimlerin ve sözlü anlatımın birlikte kullanıldığı durumlar, resim, sözlü anlatım ve metnin birlikte kullanıldığı durumlara göre daha iyi sonuçlar vermektedir. Aynı anda birçok öğenin verilmesi bilişsel kanala yüklemeye yapacağından dolayı iyi bir öğrenme söz olmayacaktır.

**Konumsal Yakınlık İlkesi:** Birbiri ile ilişkili metinlerin ve resimlerin sayfa da yada ekran üzerinde birbirine yakın olması durumunda öğrenme daha iyi olur.

**Zamansal Yakınlık İlkesi:** Birbiri ile ilişkili metinlerin ve resimlerin aynı anda sunulduğu ortamlarda öğrenme daha iyi olur. Örneğin konu anlatıldıktan 5 dk. sonra o konu ile ilgili resim gösterilirse o konunun öğrenilme oranı daha az olur.

**Ses İlkesi:** Sözlü anlatımın insan sesi ile verilmesi durumunda öğrenme, makine sesi ile verilmesine göre daha iyi olur. Örnek olarak My Family Ünitesinde aile bireyleri tanıtılırken ses eklenerek aile bireyleri tanıtılmış, İngilizce yazılanların telaffuzuna yer verilmiştir.



Şekil 3. Ses ilkesi ile ilgili uygulamadan örnek



**Biçim:**Resim ve anlatımın birlikte sunulduğu ortamlarda öğrenme, resim ve yazının birlikte sunulduğu ortamlara göre daha iyi olur.

**Parçalama-Bölme İlkesi:**Konunun uygun biçimde bölümlere ayrıldığı durumlarda öğrenme, konunun bölümlere ayrılmadan verilmesine göre daha iyi olur.Yani öğrenmenin oranı artar [12].

### 2.3.1. Vuforia ayarları

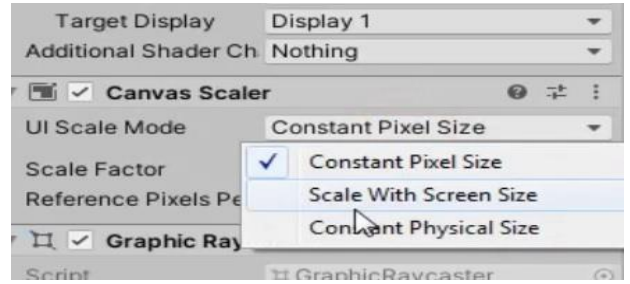
Vuforia kütüphanesi, artırılmış gerçeklik uygulamalarının geliştirildiği bir kütüphanesidir. Bilgisayar görünümünü kullanarak 3 boyutlu nesnelere algılamak için kullanır. Kütüphane birçok dil için geliştirilmiştir ve kolaylıkla unity projesine eklenebilir. Düzlemsel hedefler aygıt hedef veri tabanına resim biçiminde saklanır. Kütüphane sayesinde aygıtın bu resmi gördüğünde 3 boyutlu nesneyi göstermesi sağlanır. Hedef resim kamera açısından çıktığında 3 boyutlu nesne gösterilmekten çıkarılır [13].

Uygulama için öncelikle <https://developer.vuforia.com/> adresinden kullanıcı kaydının yapılması gerekmektedir. Kayıt olduktan sonra ücretsiz hesap planı seçilip devam edilir. Projeye başlamadan önce <https://developer.vuforia.com/downloads/sdk> adresinden “Download for Unity” eklentisi indirilmelidir. Bu eklenti Vuforia geliştirme kitinin Unity oyun motoruna entegre olmasını sağlamaktadır.

Vuforia5 SDK unity eklentisi Eklenti indirilip Unity 3D oyun motoruna dahil edildikten sonra Vuforia hesabı sayfasında yer alan “Develop” menüsünden “License Manager” ve “Target Manager” sekmelerine geçilmelidir. “License Manager” sekmesinde geliştirilmesi gereken uygulama için bir lisans anahtarı oluşturulmalıdır. Geliştirilecek uygulamanın Unity oyun motorunda çalışabilmesi için bir lisans koduna ihtiyaç vardır.

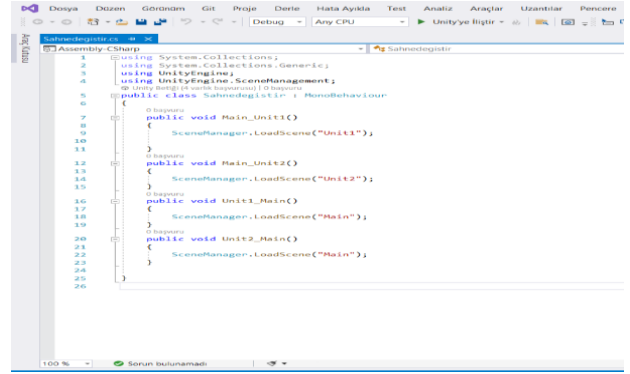
### 2.3.2. Sayfalar arasında butonlar ile geçiş

Butonlar ile sahneden sahneye yani menüler arasında geçiş yapabilmek için Hierarchy penceresinde sağ tıklayıp UI Button eklenir. Button Canvas ile beraber ekleniyor. Canvas cep telefonu yada tableti temsil etmektedir. Butonu istediğimiz gibi Canvasın üzerinde yerleştirebiliriz. Canvasda “UI Scale Mode”, “Scale With Screen Size” olarak düzenlenir. Böylece apk dosyasını farklı telefon ve tabletlerde çalıştırıldığında butonun yeri ekran büyüklüğüne göre ayarlanacaktır. Diğer butonları ekledikten sonra butonların konumlarını, boyutlarını, textlerini, butonların Inspector panelinden ayarlayabiliriz.



Şekil 4. UI Scale Mode

C# dosyası hazırlayarak geçiş kodlarını yazmak için sağ tuşu tıklayarak create c# scripti seçilir,. Oluşan C# Script dosyasına çift tıkladığında bilgisayarda yüklü olan Visual Studio açılarak Şekil 10’da yazan kodlar yazılıp çalıştırıldığında menüler arasındaki geçişler sağlanır.




Şekil 5. Menü geçişleri için örnek kodlar

### 2.3.3.UI Text ekleme (sahnede açıklama yazısı gösterme)

Bu kısımda öğrencinin kitabındaki sayıları telefonunun ya da tabletinin kamerası ile uygulamada okutulduğunda resimlerin İngilizce olarak yazılışının gösterilmesi amaçlanmıştır.

İlgili İmage targetı tıklayıp sağ tuş ile UI-Text seçilir. Sağ tarafta textimizin içeriğini değiştiren Şekil 14’teki ekran gelir.



Şekil 6. UI-Text


Kamera ile okutulan resimdeki bilginin İngilizce yazılışları Text kısmına yazılır. Yazı rengi, boyutu ayarlanır. Play tuşuna bastığımızda okuttuğumuz resimlerin İngilizce yazılışları ekranda gösterilir.

### 3. BULGULAR

#### 3.1.Uygulama Açılış Ekranı

Açılış ekranı, İngilizce eğitim uygulamasının açılması ile birlikte gelen ilk karşılama ekranıdır. Yani uygulamayı kullanan öğrencilerin gördüğü ilk ekrandır.

Yapılan çalışmada açılış ekranı Şekil 3'te gösterilmektedir.

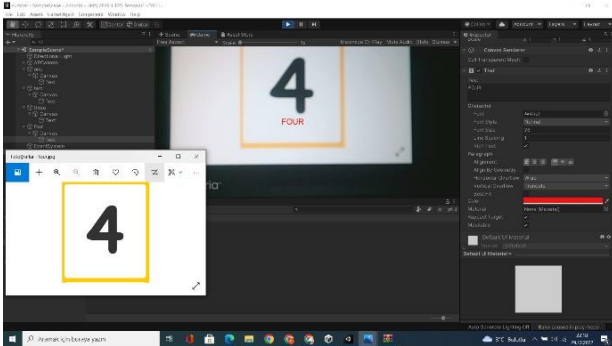


Şekil 7. Açılış ekranının Unity ile tasarımı

#### 3.2.Uygulamada Konu Anlatım Ekranı

Konu anlatım ekranının da farklı ünitelere ait videolar animasyonlar ve sesli anlatımlar bulunmaktadır.

İlkokul 3. Sınıf İngilizce dersi üniteleri ile ilgili konu anlatım sayfaları oluşturulurken MEB'in müfredatında olan Greeting-Selamlama, My family-Ailem, People I Love-Sevdiğim İnsanlar, Feelings-Duygular, Toys And Games-Oyuncaklar ve Oyunlar, My House-Evim, In My City-Şehirimde, Transportation-Ulaşım, Weather-Hava, Nature-Doğa konularında ayrı ayrı sayfalar oluşturulmuştur. Öğrencilerin İngilizce eğitimi konularının sunulmasında gerçekçi bir benzetim ortamı sunarak öğrenmeye destek olmuştur.



Şekil 8. Projeden örnek 4 sayısı kamera ile okutulduğunda İngilizce yazılışının ekranda gösterilmesi ve okunuşunun seslendirilmesi

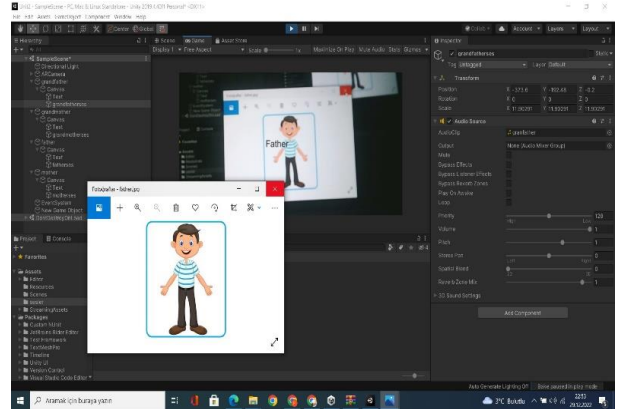


Şekil 9. Uygulamada My Family Ünitesi Konu Anlatımı

#### 3.3. Uygulamada Sesli Anlatım

Loris Malaguzzi'nin öncüsü olduğu Reggio Emilia metodunda çocuğun duyularına hitap etmek ve bütün duyularını geliştirmek önemlidir. Bu nedenle Reggio Emilia okullarında çeşitli malzemelerin varlığıyla çocukların farklı renk ve şekilleri fark etmeleri, bu nesnelere nasıl kullanacaklarını düşünmeleri ve nesnelere koku ve dokularını ayırt edebilmeleri amaçlanmış çoklu duyu ortamları dikkat çekmektedir [8]. Görmeye ve işitmeye odaklı materyal sunumlarını içeren "Çoklu Ortamla Öğrenme Kuramı" eğitimde birden fazla duyu kullanımının bilişsel açılımını yapmaktadır. Çok duyu ortamlarda öğrencilerin daha iyi öğrenmelerini sağlamak amacıyla metin, ses, animasyon, video, grafik, film, müzik, slayt gibi görme, işitme veya her iki duyuya birden hitap eden materyaller bulunmaktadır. Bu materyaller; bilgisayar ortamında sunulmasını içermektedir [14].

Eğitim uygulamasının yukarıda da belirtildiği gibi daha iyi öğrenme sağlanması açısından kelimelerin okunuşları, açıklamaları ile ilgili sesler uygulamaya eklenmiştir.



Şekil 10. Projeden örnek, Family Ünitesine ait resimler kamera ile gösterildiğinde İngilizce olarak okunuşu ve yazılışlarının ekranda gösterilmesi

Artırılmış gerçeklik teknolojisine dayalı öğretim durumları başarı, tutum, motivasyon ve dikkat çekme gibi değişkenler açısından öğrenme sürecini pozitif etkilemektedir[15]. Hsei ve Lee tarafından yapılan çalışmada [6], artırılmış gerçeklik uygulamalarının akademik başarıya katkısının yanı sıra İngilizce kelime öğreniminde deney grubunun kontrol grubuna göre daha istekli olduğunu tespit etmişler. Bunun yanısıra öğrenme sürecine aktif katılım imkanı sağladığı için öğrenci

motivasyonunu arttırdığı ve eğlenerek öğrenme ortamı sağladığını belirtmişlerdir. Ancak alanda öğrencilerin artırılmış gerçeklik uygulamalarına dair tutumlarını ortaya çıkarmaya yönelik çalışma sayısı sınırlıdır [16].

Pérez-López ve Contero tarafından artırılmış gerçeklik ortamı ile sindirim ve dolaşım sistemlerinin tanıtılması amacıyla bir yazılım geliştirilmiştir. AG teknolojisinin kullanımının öğrenme süreçlerini kısalttığı, motivasyonu arttırdığı, memnuniyet derecesini yükseldiği, konunun daha iyi anlaşıldığı sonuçlarına ulaşıldığı belirtilmiştir. Çalışmada video görüntüsü, nesne üzerine işaretlemeler, farklı örnek resim gösterme gibi zenginleştirici nesnelerin olmadığı görülmektedir. Bu yapıların sisteme eklenmesi ve yüklenilecek 3D nesnelerin dinamik hale getirilmesi uygulama ortamını genişleterek daha etkin bir AG uygulaması oluşturulmasını sağlayacaktır [17].

Öztürk ve Özdemir, 9. sınıf Coğrafya dersi için tasarlanmış oldukları sanal gerçeklik uygulamasının öğrencilerin akademik başarısını artırdığını ve ortamda bulunma hissi (presence) ile öğrenci etkileşimini sağladığını belirtmişlerdir [18].

Bu uygulama ile, öğrenciler pasif bilgi tüketmek yerine aktif katılım ile öğrenme sağlar. Ses, video, grafikler, animasyon ve simülasyon gibi farklı uygulamaları içeren etkileşimli öğretim ortamı sunan uygulamamız öğrencilere zaman ve mekan özgürlüğü de sunar.

#### 4. TARTIŞMA VE SONUÇ

Bu çalışmada, güncel öğretim teknolojileri arasında yer alan artırılmış gerçeklik yöntemi ile İlkokul 3. Sınıf öğrencilerinin İngilizce derslerine yönelik bir materyal tasarlanmıştır. Çalışmamızda motivasyon kaynağımız güncel literatürde dikkat çekme, motivasyon artırma, gerçekçilik gibi faydaları ve etkileri sunulan artırılmış gerçeklik yönteminin etkileri olmuştur. Eğitim alanında yapılan çalışmalara bakıldığında, artırılmış gerçeklik uygulamalarının genel olarak kullanıcılar üzerinde başarıyı, dikkati ve motivasyonu arttırdığı gözlemlenmiştir.

3. Sınıf İngilizce öğreniminin dışında diğer alanlardaki bilişsel öğrenmelerde de artırılmış gerçeklik uygulamalarının katkı sağlayacağı düşünülmektedir.

Artırılmış gerçeklik uygulamalarının eğitim alanında kullanılması hem öğrenciyi derse çekmek bakımından hem de üzerinde düşünülmesi ve hayal edilmesi zor olan sistemlerin veya objelerin ders esnasında üzerinde düşünülmesi kolay gerçekliği artırılmış üç boyutlu nesnelere haline getirilmesinde oldukça önemli rol oynayacaktır.

Artırılmış gerçeklik ile hazırlanmış 3. Sınıf İngilizce eğitim uygulamamızın kullanımı, geleneksel öğretim yöntemlerine göre çeşitli avantajlar sağlamaktadır. En önemli avantajları çeşitli duyuşsal algılarımızı uyarmasıdır. Dokunma, görme ve işitme çoklu

duyularımıza hitap eder. Öğrencilerin öğrenme sürecine aktif olarak katılmalarını sağlar.

Sonuç olarak; artırılmış gerçeklik uygulamalarının eğitsel alanda varlığını koruyacağı ve ileride yenilikçi teknolojilerle farklı yazılım ve ortamlarla eğitim dahil birçok alanda etki bırakacağı düşünülmektedir.

Artırılmış gerçeklik teknolojisiyle 3B nesnelere ve sesler tanımlanmış, böylece bilgisayar kameraları veya akıllı telefon kameraları kodlanan sayfayı gördüğünde seslendirilmiş ve üç boyutlu olan bir ara yüzle karşılaşmıştır. Bu seslendirme yöntemiyle öğrenciler dil öğreniminde etkili bir öğretimin yanı sıra kelime telaffuzunu da geliştirebilmektedirler. Bununla birlikte tekrar tekrar kullanmaya elverişli olduğu içinde ilerleyen eğitim süreçlerinde de rahatlıkla kullanılmaktadır[19].

Artırılmış gerçeklik, bilgi işleme ve görüntü teknolojilerindeki ilerlemeler paralelinde gelişmeye devam edecektir. Eğlenceden, insanlık yararına olan sayısız alanda varlığını sürdüreceği, bugün geldiği nokta ile kıyaslanırsa görülmektedir. Yeni çıkan her teknoloji gibi artırılmış gerçekliğin insan hayatını yönlendirmede etkisi olduğu şüphe götürmemekle birlikte, olumlu veya olumsuz etkileri ilerleyen zamanlarda görülecektir [20].

Artırılmış gerçeklik uygulamaları, kullanıcılarını cezbeden farklı bir alan kazandırdıkları için hızla büyümeye devam edecektir. Özellikle eğitim gibi insan hayatını etkileyen alanlarda kullanılan artırılmış gerçeklik uygulamaları kullanılması önem kazanacaktır.

Bu makalede artırılmış gerçeklik ile ilgili genel bilgiler verilmiş ve artırılmış gerçeklik uygulama geliştirme aşamaları açıklanmıştır. Artırılmış gerçeklik birçok farklı platformda ve farklı uygulama yazılımları ile geliştirilebilmektedir. Yazılımların mobil giyilebilir cihazlar, akıllı telefonlar veya masaüstü bilgisayarlar ile uyumlu olması gerekmektedir. Bu çalışmada Unity 3D oyun motoru ve Vuforia uygulama geliştirme ortamları kullanılmıştır. Uygulamanın nasıl geliştirildiği, hangi alanlarda ne tür sekmelerden yararlanıldığı anlatılmıştır. Vuforia SDK veri tabanı oluşturma ve hedef işaretçilerin Unity 3D oyun motoru ortamına aktarılıp artırılmış gerçeklik uygulamasının nasıl geliştirildiğine değinilmiştir. Sonuç olarak; artırılmış gerçeklik uygulamalarının eğitsel alanda varlığını koruyacağı ve ileride yenilikçi teknolojilerle farklı yazılım ve ortamlarla eğitim dahil birçok alanda etki bırakacağı düşünülmektedir. Eğitsel alanda yapılacak artırılmış gerçeklik uygulamalarının belirli standartlara göre tasarlanması, içerik ve görsel anlamda kullanıcıya hitap etmesi gerekmektedir.

#### **Etik Hususlar**

#### **Etik kurallara uyum**

Yazarlar olarak, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha

sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun çalıştığımızı deklare ederiz.

#### Finansman

Yazarlar olarak, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almadık.

#### Çıkar çatışması

Yazarlar olarak herhangi bir çıkar çatışması içinde bulunmadık.

#### KAYNAKÇA

- [1] Çetintav, G. 2023. Geometri Öğretiminde Artırılmış Gerçeklik Uygulamalarının Kullanımının Ortaokul Öğrencilerinin Öz Düzenleme Becerilerine Akademik Motivasyonlarına ve Başarılarına Etkisi.
- [2] Lai, J. W., Cheong, K. H. 2022. Adaption of Virtual and Augmented Reality for Mathematics Education: A Scoping Review, *IEEE Access*, 1 (10), 13693–13703. doi: 10.1109/ACCESS.2022.3145991.
- [3] Ulusoy Ç. S. 2022. Unity ve Vuforia Kullanarak Bir Artırılmış Gerçeklik Uygulaması. *Trakya Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*.
- [4] Morales, P. T., García, J. M. S. 2018. Project-based learning: A university experience, *Profesorado*, 22(2), 471–491. doi: 10.30827/PROFESORADO.V22I2.7733.
- [5] Çetinkaya, H.H., Akçay, M. B. 2013. Eğitim Ortamlarında Artırılmış Gerçeklik Uygulamaları, *Akademik Bilişim Kongresi*, <https://ab.org.tr/ab13/bildiri/114.pdf>
- [6] Odabaşı, F. 2019. Çoklu Ortamla Öğrenmede Konu Dışı İşlemleri Azaltma İlkelerinin Artırılmış Gerçeklik ve Sanal Gerçeklik Ortamlarında Bilişsel Yük ve Başarıya Etkisi, *Anadolu Üniversitesi, Eğitim Bilimleri Enstitüsü, Bilgisayar ve Öğretim Teknolojileri Eğitimi Anabilim Dalı*, <https://hdl.handle.net/11421/23640>
- [7] Akkoyunlu, B., Yılmaz Soylu, M. 2005. Türetimci Çoklu Ortam Öğrenme Kuramı Generative Theory Of Multimedia Learning. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 28, 9-18. <https://www.researchgate.net/publication/266370424>
- [8] Mayer, R.E.2001. *The Cambridge handbook of multimedia learning*. Cambridge University Press.
- [9] Azuma, R., Bailiot, Y., Behringer, R., Feiner, S., Julier, S., Macintyre, B. 2001. Recent Advances in Augmented Reality. *IEEE Computer Graphics and Applications*, November/December, 34-47.
- [10] Sommerauer, P., Müller, O. 2014. Augmented reality in informal learning environments: A field experiment in a mathematics exhibition, *Comput Educ*, 79, 59–68. doi: 10.1016/j.compedu.2014.07.013.
- [11] Yılmaz, R.M. 2016. Educational magic toys developed with augmented reality technology for early childhood education, *Comput Human Behav*, 54, 240–248. doi: 10.1016/j.chb.2015.07.040.
- [12] Erdoğan, K. 2023. MAYER'in Çoklu Ortam İlkeleri. <https://kazimerdogdu.wordpress.com/2014/03/21/mayer-in-coklu-ortam-ilkeleri/>
- [13] Baykara, M., Gürtürk, U., Atasoy, B., Perçin, I. 2017. Okul Öncesi Eğitimde Artırılmış Gerçeklik Tabanlı Mobil Öğrenme Sistemi Tasarımı, 2nd International Conference on Computer Science and Engineering, UBMK 2017, Institute of Electrical and Electronics Engineers Inc., 72–77. doi: 10.1109/UBMK.2017.8093560.
- [14] Kuzu, A., Çankaya, S., Mısırlı, Z.A. 2011. Tasarım Tabanlı Araştırma ve Öğrenme Ortamlarının Tasarımı ve Geliştirilmesinde Kullanımı Design-Based Research and Its Implementation in the Design and Development of Learning Environments *Anadolu Journal of Educational Sciences International*, 1(1),19-35.
- [15] Billingham, M., Kato, H., Poupyrev, I. 2001. The MagicBook - Moving seamlessly between reality and virtuality, *IEEE Comput Graph Appl*, 21(3), 6–8. doi: 10.1109/38.920621.
- [16] Çevik, G., Yılmaz, R.M., Göktaş, Y., Gülcü, A. 2017. Okul Öncesi Dönemde Artırılmış Gerçeklikle İngilizce Kelime Öğrenme, *Journal of Instructional Technologies and Teacher Education*, 6(2), 50-57. [347160 \(dergipark.org.tr\)](https://dergipark.org.tr/47160)
- [17] İçten, T., Bal, G. 2017. Artırılmış Gerçeklik Üzerine Son Gelişmelerin ve Uygulamaların İncelenmesi, *GU J Sci, Part C*, 5(2), 111-136.
- [18] Özdemir, D., Öztürk, F. 2022. The Investigation of Mobile Virtual Reality Application Instructional Content in Geography Education: Academic Achievement, Presence, and Student Interaction, *Int J Hum Comput Interact*, 38(16), 1487–1503. doi: 10.1080/10447318.2022.2045070.
- [19] Çakır, R., Solak, E., Tan, S.S. 2015. Artırılmış Gerçeklik Teknolojisi ile İngilizce Öğretiminin Öğrenci Performansına Etkisi, *Artırılmış Gerçeklik Teknolojisi İle İngilizce Kelime Öğretiminin Öğrenci Performansına Etkisi*, *Gazi Eğitim Bilimleri Dergisi*, 1 (1), 45-58.
- [20] Bingöl, B. 2018. Yeni Bir Yaşam Biçimi: Artırılmış Gerçeklik (Ag). *Etkileşim*. 1(1), 44-55. [710133 \(dergipark.org.tr\)](https://dergipark.org.tr/710133)

**(Araştırma Makalesi)****Derin Öğrenme Yöntemleri Kullanılarak Böbrek Hastalıklarının Tespiti ve Çoklu Sınıflandırma****Kenan GÜLLE\*<sup>1</sup>, Durmuş ÖZDEMİR<sup>2</sup>, Hasan TEMURTAŞ<sup>3</sup>**<sup>1</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No :<http://orcid.org/0000-0002-4650-1412><sup>2</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No :<http://orcid.org/0000-0002-9543-4076><sup>3</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No :<http://orcid.org/0000-0001-6738-3024>**Anahtar Kelimeler:**Derin Öğrenme,  
Böbrek Hastalığı,  
Biyomedikal,  
Poly-CNN,  
Çoklu Sınıflandırma,  
VGG

**Özet:** Derin öğrenme, sağlık alanında hastalık ve anomali tespiti gibi alanlarda son yıllarda başarılı sonuçlar elde etmiştir. Literatür incelendiğinde, böbrek hastalıklarının teşhisi, karmaşık, hata eğilimli ve zaman alıcı bir süreç olduğundan, bilgisayar destekli yazılımlara olan ihtiyaç kaçınılmazdır. Bu çalışmada, hastalara böbrek taşı, tümör ve kist teşhisi konmuş bilgisayarlı tomografi cihazı tarafından oluşturulan görüntüler kullanılmıştır. Veri setimizdeki görüntüler, erişime açık Kaggle platformundan elde edilmiştir. Veri seti, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve çalışmada önerdiğimiz geliştirilmiş Poly-CNN derin öğrenme modeli kullanılarak sınıflandırma performansı ölçülmüştür. Daha istikrarlı öğrenme sağlamak için CNN yapısına ekstra havuzlama katmanı ve bağlantı katmanı eklenmiştir. Eklenen bu katmanlar aşırı öğrenmeye sebebiyet vermemesi için, eğitim sırasında rastgele nöronlar devre dışı bırakılmıştır. Çalışmada kullanılan derin öğrenme modellerinde, kullanılan parametreler, katman yapıları, doğruluk ve kayıp grafikleri detaylı bir şekilde incelenmiştir. Çalışmada Poly-CNN'in %99,94'lük yüksek bir doğruluk oranıyla öne çıktığı görülmüştür. Bu sonuçlar, Poly-CNN modelinin, diğer kullanılan modellerde daha iyi bir performans sergileyerek, önerilen araştırma çerçevesinin etkinliğini belirgin bir şekilde ortaya koymaktadır.

**(Research Article)****Kidney Disease Detection and Multi-Classification Using Deep Learning Methods****Keywords:**Deep Learning,  
Kidney Disease,  
biomedical,  
Poly-CNN,  
Multiple Classification,  
VGG

**Abstract:** Deep learning has achieved successful results in recent years in areas such as disease and anomaly detection in the field of healthcare. When the literature is examined, the need for computer-aided software is inevitable since the diagnosis of kidney diseases is a complex, error-prone and time-consuming process. In this study, images created by a computerized tomography device were used in which patients were diagnosed with kidney stones, tumors and cysts. The images in our dataset were obtained from the open-access Kaggle platform. Classification performance was measured using the dataset, Classic CNN, ANN, ALEXNET, VGG16, VGG19 networks and the developed Poly-CNN deep learning model we proposed in the study. Extra pooling layer and connection layer were added to the CNN structure to provide more stable learning. To prevent these added layers from causing excessive learning, random neurons were disabled during training. In the deep learning models used in the study, the parameters used, layer structures, accuracy and loss graphs were examined in detail. The study showed that Poly-CNN stands out with a high accuracy rate of 99.94%. These results clearly demonstrate the effectiveness of the proposed research framework, with the Poly-CNN model outperforming other used models.

\*Sorumlu Yazar: kenangulle@hotmail.com

## 1. GİRİŞ

Günümüzde, sağlık sektöründe derin öğrenme yöntemlerinin kullanımı, çeşitli hastalıkların erken teşhisi, sınıflandırılmasında ve uzman hekimlere yönelik öneri sistemi olarak kullanımı önemli bir potansiyele sahiptir [1], [2], [3]. Böbrek tümörleri dünya çapında erkek ve kadınlarda en sık görülen 10. tümördür [4]. Bu araştırmada, böbrek hastalıklarının tespiti ve çoklu sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğinin ve veriminin belirlenmesi ve değerlendirilmesi amaçlanmaktadır. Derin öğrenme, geniş ve karmaşık veri setleri üzerinde otomatik öğrenme kapasitesi ile öne çıkan bir yapay zekâ dalıdır [5]. Hastalıklarının tespiti ve çoklu sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğini değerlendirmeyi amaçlayan ve mühendislik pratiğine aktarılmış birçok bilimsel çalışma yapılmıştır [6]. Bunlardan bazıları birçok araştırmacıya referans olarak sunulmuştur [6-10].

Tüzün ve Özdemir [7], MRI görüntüleriyle beyin tümörü hastalığının erken tespiti için mevcut derin öğrenme modellerinin karşılaştırmalı analizini sunmayı amaçlamaktadır. GoogleNet, Mobilenetv2, InceptionV3 ve Efficientnet-b0 modelleri Matlab platformunda kodlanarak beyin tümörü tespiti ve sınıflandırılması için kullanıldı. Glioma, Meningioma ve Hipofiz beyin tümörleri üzerinde sınıflandırma yapıldı. Kaggle platformunda halka açık olarak paylaşılan dört farklı sınıfta 7022 beyin MRI görüntüsü içeriyor. Analiz sonuçlarına göre, Efficientnet-b0 (%99,54), InceptionV3 (%99,47), Mobilenetv2 (%98,93) ve GoogleNet (%98,25) sırasıyla başarı elde etmiştir.

Özdemir ve Arslan [8], Covid-19 hastalığının erken teşhisini tespit etmek amacıyla derin öğrenme modellerinin karşılaştırmalı analizini sunmaktadır. VGG-19, VGG-16 ve Inception V3 modelleri Covid-19 tespiti için değerlendirilmiştir. Kamuya açık olan Kaggle veri tabanından eğitim için 280 göğüs röntgeni görüntüsü ve test için 140 göğüs röntgeni görüntüsü kullanılmıştır. Analiz sonuçlarına göre, Inception V3 (%92) en başarılı model olmuştur.

Krizhevsky vd. [9], çalışmalarında DigiMammo (UCHCDM) veritabanında toplanan 96 meme kanseri görüntüsü üzerinde gerçekleştirilmiştir. Görüntüler 69'u kanserli, 27'si sağlıklı bireylerden oluşmaktadır. Meme kanseri taraması için önerilen bir bilgisayar destekli tespit (CAD) yöntemi tanıtılmıştır. Mamografik görüntüler incelenerek şüpheli kanserli bölgeler belirlenmiştir. Ardından görüntüler eğitilmiş bir CNN ile beslenerek yanlış pozitifler eleme işlemi gerçekleştirilmiştir. Önerilen CAD yönteminin başarı oranının %92,8 olduğu gözlemlenmiştir.

Rehman vd. [10], çalışmalarında beyin tümörünün doğru teşhisi için halka açık figshare ortamında bulunan 233 hastadan toplanan 3064 MRI kesitinde oluşmaktadır. Önerilen çerçeve kapsamında, AlexNet, GoogLeNet ve VGGNet olmak üzere üç evrişimli sinir ağı mimarisi kullanılarak menenjiyom, hipofiz ve glioma gibi beyin

tümörlerini sınıflandırmak için çalışma yürütülmüştür. Her çalışma, beyin tümörü veri kümesi olan Figshare'deki MRI dilimleri kullanılarak ince ayar ve dondurma gibi transfer öğrenme tekniklerini kullanmaktadır. Sonuçların genelleştirilmesi, veri kümesi örneklerinin artırılması ve aşırı uyum şansını azaltmak için MRI dilimlerine veri artırma teknikleri uygulanmıştır. Önerilen çalışmalarda, VGG16 mimarisi ile yapılan sınıflandırma tespit açısından en yüksek doğruluğa (98.69) ulaştığı gözlemlenmiştir.

Bingöl ve vd.[11], Derin öğrenme ve yapay zekanın tıp alanındaki etkilerini değerlendirerek böbrek tümörü tespiti üzerindeki rolünü incelemiştir. Derin öğrenme modellerinin, özellikle radyolog yoğunluğu yüksek ortamlarda ve hızlı teşhis ihtiyacında, böbrek tümörü tespiti konusunda hızlı ve doğru sonuçlar sağlayabileceği vurgulanmaktadır. Çalışmada Kaggle platformundan elde ettikleri veri seti ile böbrek görüntülerini taş, kist ve tümör ve normal olarak sınıflandırma amacıyla, EfficientNetb0, Inceptionv3, GoogleNet, DenseNet201, ShuffleNet ve CNN tabanlı bir hibrit model önerisinde bulunmuştur. Veri setindeki görüntülerin %80'nini eğitim %20'sini test için ayırmıştır. Karşılaştırma yaptıkları modellerin hepsinde 5 epoch değeri, learning rate 1.0004 ve 16 batch size değeri kullanmıştır. Önerilen CNN tabanlı hibrit modelin %99,37 doğruluk değerine ulaşmıştır.

**Tablo 1.** Böbrek tümörü sınıflandırması ile ilgili çalışmalar.

Yıl	Dataset	Method	Sonuç	Kaynak
2021	KiTS19	InceptionV3, ROC	%97.4	[12]
2023	CT Kidney Dataset	Proposed CNN	%99.5	[13]
2022	KiTS19	DeepLabv3+ 2.5D	%99.7	[14]
2022	8400	2D-CNN	%97.0	[15]
2023	CT Kidney Dataset	Hybrid CNN Model	%99,3	[11]
2022	CT Kidney Dataset	Swin Transformer	%99,3	[16]
2024	CT Kidney Dataset	Proposed Model	%99,7	[17]


Literatürde de görüldüğü üzere farklı derin öğrenme mimarileri kullanılarak tıp alanında covid-19, beyin tümörü ve böbrek tümörü ve meme kanseri tespiti için, etkili araç olabileceği göstermektedir [18]. Derin öğrenme özellikle radyolog yoğunluğu yüksek ortamlarda ve hızlı teşhis ihtiyacında, doğru ve hızlı sonuçlar sağlama potansiyeline sahip olmaktadır [19]. Bu çalışmalardan elde edilen sonuçlar, derin öğrenme modellerinin tıbbi görüntüleme alanında çeşitli uygulamalarda etkili bir şekilde kullanılabilirliğini ve hastalıkların erken teşhisi konusunda önemli bir potansiyele sahip olduğunu ortaya koymaktadır. Tablo 1.'de böbrek tümörü sınıflandırması ile ilgili literatürde yapılan çalışmalar görülmektedir. Bu çalışmada da Kaggle platformundan elde edilen böbrek görüntüleri Classic CNN, ANN, ALEXNET, VGG16,

VGG19 ağları ve çalışmada önerdiğimiz geliştirilmiş Poly-CNN ağı gibi farklı derin öğrenme metodları kullanılarak analiz edilmesi amaçlanmıştır.

## 2. MATERYAL VE METOT

Bu çalışma, Classic Convolutional Neural Network (Classic CNN), Artificial Neural Network (ANN), AlexNet, VGG16 ve VGG19 gibi önceden belirlenmiş derin öğrenme modellerini içeren bir dizi modeli ve

geliştirilmiş Poly-CNN modelini kapsamaktadır. Bu modeller, böbrek hastalıklarının farklı alt tiplerini tanımak ve çoklu sınıflandırmada başarılı olmak amacıyla geniş bir görüntü veri seti üzerinde eğitilecek ve test edilecektir. Çalışmada geliştirilmiş uygulama ortamı Python programlama dilinin Jupyter Notebook açık kaynak kodlu programı tercih edilmiştir. Numpy, Matplotlib, Tensorflow, Keras gibi kütüphaneleri uygulamada kullanılmıştır. Çalışmanın akış modeli Şekil 1.'de gösterilmiştir.



Şekil 1. Çalışmanın genel yapısı


### 2.1. Veri Seti

Çalışmada böbrek hastalığının tespit edilmesi ve sınıflandırılması amacıyla kullanılan veri seti, Bangladeş'teki çeşitli hastanelerden PACS (Resim Arşivleme ve İletişim Sistemi) aracılığıyla toplanmış. Hastalara böbrek tümörü, kist, normal veya taş teşhisi konulmuş. Dicom görüntüleri kayıpsız JPG formatına dönüştürülmüş. Dönüştürme işleminden sonra, her bir görüntü doğruluğunu teyit etmek için bir radyolog ve bir tıbbi teknoloji tarafından tekrar kontrol edilmiştir [20]. Veri setinin sınıflara göre dağılımı ise 3709'u Cyst (kist), 5077'si Normal, 1377'si Stone (taş) ve 2283'ü Tumor (tümör) olmak üzere toplam 12446 Bilgisayarlı Tomografi (CT) görüntüsü içermektedir. Bu veri setinde kullanılan tüm görüntüler erişime açık Kaggle platformundan alınmıştır [20]. Veri setinden alınan örnek görüntüler Şekil 2'de gösterilmiştir. Çalışmada verilerin %70'ni eğitim, %15'ni test ve %15'ni doğrulama olarak ayrılmıştır.


### 2.2. Classic CNN, ANN, ALEXNET, VGG16, VGG19 ve Poly-CNN ile Öğrenilen Modellerin Mimarileri ve Uygulama Perspektifleri

Veri seti içindeki bilgiler kategorik hale getirilmiş ve modellerin daha etkili bir şekilde işleyebilmesi için uygun boyutlara getirilmiştir. Veri setini zenginleştirmek amacıyla veri artırma teknikleri uygulanmıştır [21]. Bu kapsamda özellik tabanlı normalizasyon işlemleri yanı sıra yatay ve dikey çevirmeler, 30 derecelik döndürme, ayrıca yatayda ve dikeyde %0,3 oranında genişletme gibi

çeşitli manipülasyonlar gerçekleştirilerek veri setindeki çeşitlilik artırılmıştır. Önerdiğimiz ağ yapısına göre oluşturulan modelin başlangıç değerleri ile modelin katmanları ve parametreleri belirlenmiştir. Farklı epoch değerleri ile oluşturulan model farklı iterasyonlarla eğitilmiş ve test verilerinin sınıflandırma sonuçları hesaplanmıştır. Çalışmada Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağı kullanılmıştır. Çalışmaya ait genel akış diyagramı Şekil 3'te verilmiştir.



Şekil 2. Böbrek hastalığı için kullanılan görüntüler [20]



Şekil 3. Çalışmaya ait akış diyagramı

### 2.2.1. Classic CNN

Çalışmada derin öğrenme modellerinden biri olan Classic CNN (Evrışimsel Sinir Ağları), görsel veri analizi ve tanıma alanında kullanılmaktadır [22]. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 batch size kullanılmıştır. Bu modelin girdisi 32x32x1 boyutundaki görüntülerdir. Classic CNN modelinde veri girişini Giriş Katmanı ile sağlayarak evrişim filtrelerini Evrişim Katmanları (Convolutional Layers) ile oluşturuldu. Evrişim sonuçlarında Relu Aktivasyon fonksiyonları uygulanarak evrişim sonuçlarının küçültüldüğü Havuzlama Katmanları (Pooling Layers) gösterildi. Havuzlama katmanlarının çıkışlarını düzeltirmek için Tam Bağlantılı Katman (Fully Connected Layer) kullanıldı. Sınıflandırmalar Çıkış Katmanı ile gösterildi. Her bir katmanın parametreleri (örneğin, filtre boyutları, adım büyüklükleri) ve aktivasyon fonksiyonları, böbrek veri setine göre oluşturuldu.

### 2.2.2. ANN

Yapay sinir ağları genellikle üç temel katmandan oluşan bir mimariye sahiptir: giriş katmanı, gizli katmanlar ve çıkış katmanıdır [23]. Bu modelin girdisi 150x150x3 boyutundaki görüntülerdir. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 batch size, aktivasyon fonksiyonu olarak relu ve softmax kullanılmıştır. Aktivasyon fonksiyonu nöronun çıkış değerini hesaplamaktadır.

### 2.2.2. AlexNet

Böbrek hastalığı veri seti üzerinde kullanılan AlexNet mimarisi, 5 evrişimli katman, 3 max-pooling katmanı, 3 normalizasyon katmanı, 2 tam bağlantılı katman ve 1 softmax katmanından oluşmaktadır. Evrişimli katmanlar, evrişimli filtreler ve doğrusal olmayan ReLU aktivasyon fonksiyonları ile tanımlanmaktadır. Maksimum havuzlama işlemi, havuzlama katmanları aracılığıyla gerçekleştirilmektedir [24]. Tam bağlantılı katmanların varlığı, giriş boyutunu sabit kılmaktadır. Modelin girdisi, 227x227x3 boyutundaki görüntülerden oluşmaktadır.

Çıkış katmanında kullanılan aktivasyon fonksiyonu Softmax'tır

### 2.2.3. VGG16

Çalışmanın bu aşamasında evrişimli sinir ağından (CNN) Görsel Geometri Grubu (VGG16) konseptindeki böbrek görüntüleri kullanıldı. VGG16 ağı çok küçük evrişimli filtrelerle oluşturulmuştur. Evrişimli katman ve üç tam bağlantılı katmandan oluşmakta olup ayrıca 16 katmanı destekleyen bir evrişim sinir ağı (CNN) modelidir [25]. Bu modelin girdisi (None,512) boyutundaki görüntülerdir.

### 2.2.4. VGG19


VGG19, özellikle görüntü sınıflandırma görevleri için tasarlanmış bir derin öğrenme modelidir [26]. VGG19, toplamda 19 katmandan oluşan derin bir sinir ağı mimarisine sahiptir. Bu 19 katman, evrişimli (convolutional) ve tam bağlantılı (fully connected) katmanları içermektedir Modelde genellikle ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmaktadır. ReLU, öğrenme sürecini hızlandırabilir ve eğitimi daha etkili hale getirebilmektedir Evrişimli katmanlar arasında maksimum havuzlama (max pooling) katmanları da bulunmaktadır. Havuzlama katmanları, özellik haritalarını ölçeklemek ve boyutunu azaltmak için kullanılmaktadır.

### 2.2.5. Önerilen Poly-CNN Modeli

Bu çalışma, Poly-CNN mimarisinin temelinde yatan yapısal özellikleri ve hiper parametreleri yeniden değerlendirerek, görüntü segmentasyonunda daha iyi performans sağlamayı hedeflemektedir. Elde edilen sonuçlar, geliştirilen modelin genel görüntü analizi uygulamalarında kullanılabilirliğini ve etkinliğini göstermeye yönelik önemli bir katkı sunmayı amaçlamaktadır. Convolutional Neural Network (CNN) tabanlı yenilikçi bir yaklaşım geliştirmeyi amaçlamaktadır. Geliştirdiğimiz Poly-CNN modeli, özellikle görüntü sınıflandırma görevleri için optimize edilmiş bir mimariye sahiptir. Başlangıçta, evrişim katmanları, giriş görüntülerinden düşük düzeyli özellikleri, kenarları ve köşeleri öğrenmeye odaklanacak şekilde ayarlandı. Ardından, max pooling katmanları, özellik haritalarını küçülterek önemli bilgileri vurgular, bu sayede daha yüksek seviyeli özelliklerin çıkarılmasına yardımcı olur. Tam bağlantılı katmanlar, evrişimli özellikleri daha karmaşık ve anlamlı özelliklere dönüştürmek için kullanılır. Dropout katmanları, rastgele nöronları devre dışı bırakarak ezberlemeyi azaltır ve eğitim yeteneğini artırır. Batch normalization katmanları ise eğitim sürecini hızlandırarak daha kararlı ve etkili bir model elde edilmesine katkı sağlar. Toplamda 88,516 parametre içeren bu model, ağırlıklarını öğrenerek verilere uygun bir şekilde adapte olur. Önceki yöntemlerin sınırlamalarını aşmak ve karmaşık görüntü yapısını daha etkili bir şekilde çözebilmek amacıyla tasarlanmıştır. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 Batch size



kullanılmıştır. Bu modelin girdisi 150x150x3 boyutundaki görüntülerdir.



Şekil 9. Poly-CNN Modelinin genel mimari yapısı

Önerdiğimiz derin öğrenme modelinin katmanlarını içeren katman yapısı ve parametre değerleri Tablo 2. de verilmiştir. Modelin ilk katmanı Rescaling katmanıdır, bu katman veri setindeki piksel değerlerini normalize etmek için kullanılır. Giriş olarak xTrain veri kümesinin şeklini kullanır. Ardından, üç adet Conv2D katmanı gelir (Conv1, Conv2, Conv3), her biri 3x3 boyutunda filtrelerle işlenmiş özellik haritalarını çıkarır. Her Conv2D katmanının ardından bir MaxPooling2D katmanı gelir (Pool1, Pool2, Pool3), bu katmanlar özellik haritalarındaki önemli bilgileri vurgular ve boyutlarını küçültür. Flatten katmanı, düzleştirme işlemi yaparak önceki katmanlardan elde edilen özellikleri tek boyutlu bir vektöre dönüştürür. Ardından iki adet Dense katmanı

gelir (Dense1, Dense2), bu katmanlar sinir ağının öğrenmesini sağlar. Her Dense katmanının ardından bir BatchNormalization katmanı (Norm1, Norm2) gelir, bu katmanlar ağı normalleştirerek eğitimi daha stabil hale getirir. Dropout katmanları (Dropout1, Dropout2) aşırı öğrenmeyi önlemek için kullanılır, eğitim sırasında belirli bir oranda rastgele nöronları devre dışı bırakır. Son katman Dense3, çıkış sınıf sayısına (Tumor, Taş, Kist, Normal) sahip bir softmax aktivasyon fonksiyonu içerir. Bu katman, modelin verilen girişlere dayanarak sınıflar arasında olasılıkları tahmin etmesini sağlar. Her bir katmanın içerdiği ağırlıklar (W) ve bias terimleri (b) Tablo.2’de belirtilmiştir.

Tablo 2. Poly-CNN Katman Yapısı ve Parametre Değerleri.

#	Katman Türü	Parametre Sayısı	Ağırlıklar (W)	Bias Terimleri (b)	Aktivasyon	Ek Bilgi
1	Rescaling (Rescale1)	0	-	-	-	Normalizasyon Faktörü: 1/255
2	Conv2D (Conv1)	160	(3, 3, 1, 16)	(16,)	ReLU	Filtre: 16, Çekirdek Boyutu: (3,3)
3	MaxPooling2D (Pool1)	0	-	-	-	Pooling Boyutu: (2, 2)
4	Conv2D (Conv2)	2320	(3, 3, 16, 16)	(16,)	ReLU	Filtre: 16, Çekirdek Boyutu: (3,3)
5	MaxPooling2D (Pool2)	0	-	-	-	Pooling Boyutu: (2, 2)
6	Conv2D (Conv3)	2320	(3, 3, 16, 16)	(16,)	ReLU	Filtre: 16, Çekirdek Boyutu: (3,3)
7	MaxPooling2D (Pool3)	0	-	-	-	Pooling Boyutu: (2, 2)
8	Flatten (Flatten1)	0	-	-	-	
9	Dense (Dense1)	4112	(1024, 16)	(16,)	ReLU	Birim Sayısı: 16
10	BatchNormalization (Norm1)	32	(16,)	(16,)	-	
11	Dropout (Dropout1)	0	-	-	-	Dropout Oranı: 0.5
12	Dense (Dense2)	272	(16, 16)	(16,)	ReLU	Birim Sayısı: 16
13	BatchNormalization (Norm2)	32	(16,)	(16,)	-	
14	Dropout (Dropout2)	0	-	-	-	Dropout Oranı: 0.5
15	Dense (Dense3)	4	(16, 4)	(4,)	Softmax	Softmax Aktivasyon Fonksiyonu, 4

### 3. BULGULAR VE DENEYSEL SONUÇLAR


Elde edilen sonuçlar, derin öğrenme modellerinin böbrek hastalıklarını başarılı bir şekilde tespit edebildiğini ve çeşitli alt tiplerini doğru bir şekilde sınıflandırabildiğini göstermektedir. Özellikle, geliştirilmiş Poly-CNN modeli, yüksek doğruluk oranları ve düşük hata payları ile

öne çıkmaktadır. Ayrıca kullanılan Classic CNN, ANN, ALEXNET, VGG16, VGG19 modelleri ve geliştirilmiş Poly-CNN modeli, böbrek hastalıklarının karmaşıklığını anlama ve spesifik alt tiplerini ayırt etme konusunda yüksek başarı elde etmiştir. Çalışma, derin öğrenme yöntemlerinin böbrek hastalıklarının tespiti ve çoklu sınıflandırma görevlerinde etkili bir şekilde kullanılabileceğini göstermektedir. Bu bulgular, klinik

uygulamalarda hastalık teşhis ve yönetim süreçlerini iyileştirmek için derin öğrenme teknolojilerinin potansiyelini vurgulamaktadır.

### 3.1. Kullanılan Modellerin Eğitim (Train), Doğrulama (Valid) ve Test Başarı Oranları

Çalışmanın bu aşamasında kullanılan Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağı Eğitim (Train), Doğrulama (Valid) ve Test Başarı Oranları (%) gösterilerek değerlendirilmiştir (Şekil 10). Uygulanan bu modellerde test için ayrılmış böbrek veri seti için yüksek doğruluk oranları sırasıyla %99,57 (Classic CNN), %99,78 (ANN), %89,44 (ALEXNET), %96,57 (VGG16), %99,78 (VGG19) ve %99,94 (Poly-CNN) gözlemlenmiştir. En yüksek doğruluğu %99,94 ile Poly-CNN sergilemiştir. Elde edilen bu sonuçlar doğrultusunda önerilen Poly-CNN araştırma çerçevesinin tekniği bilinen CNN modellerinden daha iyi performans göstermiştir.



Şekil 10. Tüm modellerin başarı oranları

Bu çalışma kapsamında, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ve Poly-CNN modelleri, böbrek hastalıklarının sınıflandırılması görevinde değerlendirilmiştir. Eğitim (Train), Doğrulama (Valid) ve Test aşamalarında elde edilen başarı oranları aşağıda verilen Tablo 3'de özetlenmiştir.

Tablo 3. Tüm modellerin başarı oranlarının karşılaştırması

MODEL	BAŞARI ORANLARI (%)		
	EĞİTİM (Train)	DOĞRULAMA A (Valid)	TEST
ANN	0,9997	0,9973	0,9978
ALEXNET	0,9211	0,8993	0,8944
VGG16	0,9807	0,9732	0,9657
VGG19	0,9988	0,9951	0,9978
<b>Poly-CNN</b>	<b>0,9997</b>	<b>0,9983</b>	<b>0,9994</b>
Classic CNN	0,9986	0,9957	0,9957

Çalışmada Sınıflandırıcının performansını ölçmek için accuracy, precision, recall ve F1-score değerlendirme metrikleri kullanıldı. Sınıflandırma doğruluğunu sayısal olarak göstermek için karışıklık matrisi kullanıldı. Bu matris, makine öğreniminde sıkça kullanılan bir tekniktir ve bir sınıflandırma sistemi tarafından gerçek ve tahmini


sınıfların elde edilmesiyle ilgili bilgi sağlar [27]. Karışıklık matrisi, iki boyuta sahiptir: gerçek ve tahmini sınıflar. Her satır, bir gerçek sınıf örneğini temsil ederken, her sütun bir tahmini sınıfın durumunu gösterir.

**Gerçek Pozitif (TP):** Sınıflandırıcının pozitif sınıfı pozitif olarak doğru bir şekilde tahmin ettiği tahmin sayısını ifade eder.

**Gerçek Negatif (TN):** Sınıflandırıcının negatif sınıfı negatif olarak doğru şekilde tahmin ettiği tahmin sayısını ifade eder.

**Yanlış Pozitif (FP):** Sınıflandırıcının negatif sınıfı hatalı bir şekilde pozitif olarak tahmin ettiği tahmin sayısını ifade eder.

**Yanlış Negatif (FN):** Sınıflandırıcının pozitif sınıfı hatalı olarak negatif olarak tahmin ettiği tahmin sayısını ifade eder.



Şekil 10. İkili sınıflandırma için karışıklık matrisi

**Accuracy:** Bir modelin doğru tahmin ettiği örneklerin toplam veri kümesine oranını temsil eder. Başka bir deyişle, doğru sınıflandırılan örneklerin, veri kümesindeki tüm örneklerin yüzdesidir. Bu metrik, modelin genel performansını ölçer ve ne kadarının doğru tahmin edildiğini gösterir.

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

**Precision:** Pozitif olarak tahmin edilen verilerin ne kadarının doğru tahmin edildiğini gösterir. Yani, yüksek bir precision, daha az yanlış pozitif anlamına gelir. Precision, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekte de pozitif olduğunu ölçer.

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

**Recall:** Sınıflandırıcının tamamlama yeteneğini ölçen bir metriktir. Yüksek recall, daha düşük yanlış negatifleri gösterirken, düşük recall daha yüksek yanlış negatifleri gösterir. Precision'daki iyileşme genellikle recall'daki azalmayla birlikte gelir. Recall, modelin gerçek pozitif örnekleri ne kadar iyi kapsayabildiğini belirtir ve bu, yanlış negatiflerin azalması anlamına gelir.

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

**F1-Score:** recall ve precision'in çarpımının, recall ve precision'in toplamına bölünmesiyle elde edilir. Bu metrik hem modelin tamamlama yeteneğini hem de doğruluk

oranını dengeli bir şekilde değerlendirir. Yani, F1-Score, yanlış negatiflerin azaltılmasıyla birlikte yanlış pozitiflerin de kontrol altında tutulup tutulmadığını gösteren bir ölçüdür.

$$\text{F1 Score} = \frac{\text{TP}}{\text{TP} + \frac{1}{2}(\text{FP} + \text{FN})}$$

**Tablo 4.** Test verisi için değerlendirme metrikleri

Classes	Evaluation Metrics	CNN Models					
		ANN	Classic CNN	VGG16	VGG19	AlexNet	Poly-CNN
Cyst	<i>precision</i>	1.0000	0.9982	0.9981	0.9982	0.9959	0.9964
	<i>recall</i>	0.9982	0.9910	0.9658	0.9946	0.8815	1.0000
	<i>f1-score</i>	0.9991	0.9946	0.9817	0.9964	0.9352	0.9982
Normal	<i>precision</i>	0.9974	0.9974	0.9303	1.0000	0.9484	1.0000
	<i>recall</i>	1.0000	1.0000	1.0000	1.0000	0.9895	1.0000
	<i>f1-score</i>	0.9987	0.9987	0.9639	1.0000	0.9685	1.0000
Stone	<i>precision</i>	0.9951	0.9760	0.9698	0.9856	0.5722	1.0000
	<i>recall</i>	0.9854	0.9854	0.9324	0.9952	1.0000	0.9903
	<i>f1-score</i>	0.9902	0.9807	0.9507	0.9904	0.7279	0.9951
Tumor	<i>precision</i>	0.9971	1.0000	1.0000	1.0000	1.0000	1.0000
	<i>recall</i>	1.0000	1.0000	0.9096	1.0000	0.6414	1.0000
	<i>f1-score</i>	0.9985	1.0000	0.9527	1.0000	0.7815	1.0000
<i>accuracy</i>		0.9979	0.9957	0.9657	0.9979	0.8945	<b>0.9989</b>

Farklı CNN modelleriyle yapılan böbrek rahatsızlığı sınıflandırma çalışmalarındaki değerlendirme metrikleri Tablo 4'te verilmiştir. Sonuçlar incelendiğinde genel olarak başarılı sonuçlar elde edilmiştir. Özellikle Cyst ve Tumor sınıflarında modeller yüksek doğruluk göstermiş, Poly-CNN modeli genel performans açısından diğer

modellere göre öne çıkmıştır. Ancak, Stone sınıfında recall değeri biraz düşük çıkmış, bu sınıfta daha fazla iyileştirme için çalışma yapılabilir. Sonuçlar, model seçiminin ve performansın sınıflara göre değişebileceğini göstererek, problem alanına özgü optimizasyonların önemini vurgular.

### 3.2. Kullanılan Modellerin Hata Çapraz Entropi Grafikleri

Böbrek veri setini kullanarak elde ettiğimiz çapraz entropi hata değerlerinin değişimini Şekil 11 üzerinde epoch değerlerine göre gösterdik. Grafikten anlaşılacağı üzere, Classic CNN'de 2. epoch'ta hata en yüksek seviyede, 15. epoch'ta hata en düşük seviyeye gerilemiştir. Aynı şekilde, ANN'de 2. epoch'ta hata en yüksek, 15. epoch'ta hata en düşük seviyededir. ALEXNET'te ise 8. epoch'ta hata en yüksek, 15. epoch'ta hata en düşük düzeydedir. VGG16 modelinde 2. epoch'ta hata en yüksek, 15. epoch'ta ise hata en düşük seviyededir. VGG19'da ise hata değerleri sabit kalmıştır. Poly-CNN modelinde ise 2. epoch'ta hata en yüksek, 15. epoch'ta ise hata en düşük seviyededir.

### 3.2. Kullanılan Modellerin Sınıflandırma Doğruluğu Grafikleri

Ağırlıklar sürekli güncellenmekte olup, en iyi öğrenmeler Şekil 12'de gösterilmiştir. Grafikte anlaşıldığı üzere en iyi öğrenmeler Classic CNN'de ANN'de, ALEXNET'de VGG16'da, VGG19'd ve Poly-CNN'de 15. epoch da görülmektedir.

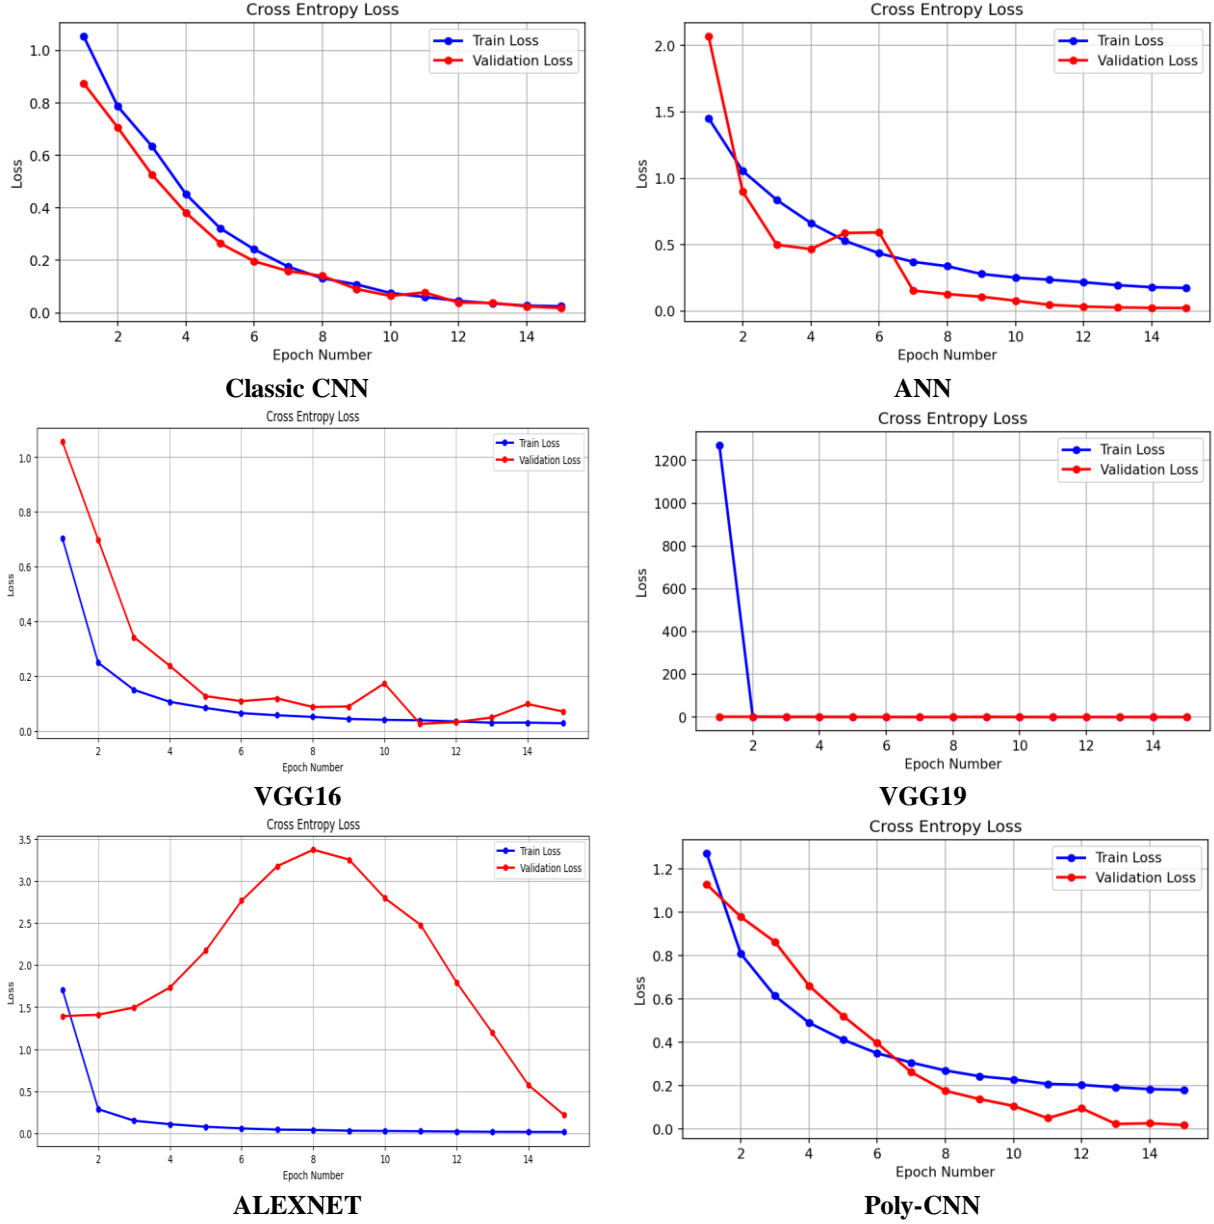
### 4. TARTIŞMA VE SONUÇ

Bilgisayarlı görüntü işleme ve derin öğrenme teknolojilerindeki hızlı ilerlemeler, tıbbi görüntüleme alanında çeşitli uygulamalar için yeni olanaklar sağlamaktadır [28]. Bu alandaki en önemli uygulamalardan biri, medikal görüntü sınıflandırmasıdır [29]. Medikal görüntü sınıflandırması, uzmanların hastalıkları teşhis etmelerine, tedavi stratejilerini belirlemelerine ve hastaların durumlarını izlemelerine yardımcı olabilecek bir araç olarak büyük bir potansiyele sahiptir.


Böbrek hastalıkları, sağlık sorunları arasında önemli bir yer tutmaktadır ve erken teşhis, etkili tedavi ve hastalık izlemesi için kritik öneme sahiptir. Bu nedenle, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağırları ve geliştirilmiş Poly-CNN ağı gibi popüler derin öğrenme mimarileri kullanılarak böbrek görüntülerinin sınıflandırılması yapılmıştır. Derin öğrenme tabanlı sınıflandırma yöntemlerini kullanarak böbrek görüntülerini başarıyla sınıflandırılmış ve bu yöntemlerin klinik uygulamalardaki potansiyeli değerlendirilmiştir. Böbrek hastalıklarının sınıflandırmasında Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağırları ve geliştirilmiş Poly-CNN ağı gibi farklı derin öğrenme metodlarını kullanılarak veri seti üzerinde performans

analizleri yapılmıştır. Uygulanan bu modellerde böbrek veri seti için yüksek doğruluk oranları gözlemlenmiştir. En yüksek doğruluğu %0,9994 ile Poly-CNN sergilemiştir. Elde edilen bu sonuçlar doğrultusunda önerilen araştırma çerçevesinin tekniği bilinen Classic

CNN'den daha iyi performans gösteren Poly-CNN ortaya konulmuştur. Poly-CNN diğer çalışmalara kıyasla doğrulukta gözle görülebilir bir artış olduğundan dolayı önerilen yöntemin etkinliğini açıkça ortaya koymaktadır.



Şekil 11. Modellerin Hata Çapraz Entropi Grafikleri



Şekil 12. Modellerin Çapraz entropi hata grafikleri

Sonuç olarak bu çalışma, bilgisayar destekli tıbbi teşhis alanında bir katkı sağlamayı amaçlayan önemli bir araştırma çalışmasıdır. Derin öğrenme yöntemlerinin medikal görüntü sınıflandırması üzerindeki etkisini anlamak, hastaların daha hızlı ve doğru bir şekilde teşhis edilmesine ve tedavi edilmesine katkı sağlayabilmektedir. Bu çalışma, tıbbi görüntüleme ve derin öğrenme alanlarındaki araştırmacılara, doktorlara ve sağlık profesyonellerine faydalı olacaktır. Gelecekteki çalışmalar, daha fazla derin öğrenme modeli ve daha geniş veri setleri kullanarak bu yöntemlerin daha da optimize edilmesi hedeflenmektedir.

### Etik Hususlar

#### Etik kurallara uyum

Yazarlar olarak, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun çalıştığımızı deklare ederiz.

### Finansman

Yazarlar olarak, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almadık.

### Çıkar çatışması

Yazarlar olarak herhangi bir çıkar çatışması içinde bulunmadık.

### KAYNAKÇA

- [1] Tahir, M., Naeem, A., Malik, H., Tanveer, J., Naqvi, R.A., Lee, S.W. 2023. DSCC\_Net: Multi-Classification Deep Learning Models for Diagnosing of Skin Cancer Using Dermoscopic Images, *Cancers (Basel)*, 15(7). doi: 10.3390/cancers15072179.
- [2] Srikantamurthy, M.M., Rallabandi, V.P.S., Dudekula, D.B., Natarajan, S., Park, J. 2023. Classification of benign and malignant subtypes of breast cancer histopathology imaging using hybrid CNN-LSTM based transfer learning, *BMC Med.*

- Imaging, 23(1), 19. doi: 10.1186/s12880-023-00964-0.
- [3] Cıfci, M. 2022. Derin Öğrenme Metodu Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Derg., 24(71), 487–500. doi: 10.21205/deufmd.2022247114.
- [4] Gharaibeh, M., Alzu'bi, D., Abdullah, M., Hmeidi, I., Al Nasar, M.R. Abualigah, L. Gandomi, A.H. 2022. Radiology Imaging Scans for Early Diagnosis of Kidney Tumors: A Review of Data Analytics-Based Machine Learning and Deep Learning Approaches. Big Data Cogn. Comput. 6, 29. <https://doi.org/10.3390/bdcc6010029>
- [5] Aalami, N. 2020. Derin öğrenme yöntemlerini kullanarak görüntülerin analizi, Eskişehir Türk Dünyası Uygul. ve Araştırma Merk. Bilişim Derg., 1(1), 17–20.
- [6] Liu, X., Song, L., Liu, S., Zhang, Y. 2021. A Review of Deep-Learning-Based Medical Image Segmentation Methods, Sustainability, 13(3). doi: 10.3390/su13031224.
- [7] Özdemir, D., Tüzün, B.N. 2023. Classification of Brain Tumors With Deep Learning Models, J. Sci. Reports-A, 054, 296–306. doi: 10.59313/jsr-a.1293119.
- [8] Özdemir, D., Arslan, N.N. 2022. Analysis of Deep Transfer Learning Methods for Early Diagnosis of the Covid-19 Disease with Chest X-ray Images, Düzce Üniversitesi Bilim ve Teknol. Derg., 10(2), 628–640. doi: 10.29130/dubited.976118.
- [9] Krizhevsky, A., Sutskever, I., Hinton, G.E. 2012. Imagenet classification with deep convolutional neural networks, Adv. Neural Inf. Process. Syst., 25.
- [10] Rehman, A., Naz, S., Razzak, M.I., Akram, F., Imran, M. 2020. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning, Circuits Syst. Signal Process., 39(2), 757–775. doi: 10.1007/s00034-019-01246-3.
- [11] Bingol, H., Yildirim, M., Yildirim, K., Alatas, B. 2023. Automatic classification of kidney CT images with relief based novel hybrid deep model., Peer J. Comput. Sci., 9, e1717. doi: 10.7717/peerj-cs.1717.
- [12] N. Heller et al., 2021. The state of the art in kidney and kidney tumor segmentation in contrast-enhanced CT imaging: Results of the KiTS19 challenge, Med. Image Anal., 67, 101821. doi: <https://doi.org/10.1016/j.media.2020.101821>.
- [13] Bhandari, M., Yogarajah, P., Kavitha, M.S., Condell, J. 2023. Exploring the Capabilities of a Lightweight CNN Model in Accurately Identifying Renal Abnormalities: Cysts, Stones, and Tumors, Using LIME and SHAP, Appl. Sci., 13(5). doi: 10.3390/app13053125.
- [14] da Cruz, L.B., et al., 2022. Kidney tumor segmentation from computed tomography images using DeepLabv3+ 2.5D model, Expert Syst. Appl., 192, 116270. <https://doi.org/10.1016/j.eswa.2021.116270>.
- [15] Alzu'bi D., et al., 2022. Kidney Tumor Detection and Classification Based on Deep Learning Approaches: A New Dataset in CT Scans, J. Healthc. Eng. 3861161. doi: 10.1155/2022/3861161.
- [16] Islam, M.N., Hasan, M., Hossain, M.K., Alam, M. G. R., Uddin, M. Z., Soylu, A. 2022. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography, Sci. Rep., 12(1), 11440. doi: 10.1038/s41598-022-15634-4.
- [17] Sasikaladevi, N., Revathi, A. 2024. Digital twin of renal system with CT-radiography for the early diagnosis of chronic kidney diseases, Biomed. Signal Process. Control, 88, 105632. <https://doi.org/10.1016/j.bspc.2023.105632>.
- [18] Raza A., et al., 2022. A Hybrid Deep Learning-Based Approach for Brain Tumor Classification, Electronics, 11(7). doi: 10.3390/electronics11071146.
- [19] Yu, A.C., Mohajer, B., Eng, J. 2022. External Validation of Deep Learning Algorithms for Radiologic Diagnosis: A Systematic Review, Radiol. Artif. Intell., 4(3), e210064. doi: 10.1148/ryai.210064.
- [20] CT Kidney Dataset: Normal-Cyst-Tumor and Stone. (2023, 06 Haziran) Erişim Adresi.” <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>.
- [21] Tan, M., Emeksiz, C. 2023. Yüz Tanıma Sistemleri İçin Geliştirilmiş Veri Artırma Temelli Adaptif Yüz Tanıma Modeli, Düzce Üniversitesi Bilim ve Teknol. Derg., 11(2), 588–606. doi: 10.29130/dubited.1024670.
- [22] Koushik, J. 2016. Understanding Convolutional Neural Networks. <http://arxiv.org/abs/1605.09081>.
- [23] Tosunoğlu, N.G., Benli, Y.K. 2012. Forecasting of Morgan Stanley Capital International Turkey Index with Artificial Neural Networks, Ege Acad. Rev., 12(4), 541–547.
- [24] Krizhevsky, A., Sutskever, I., Hinton, G.E. 2017. ImageNet Classification with Deep Convolutional Neural Networks, Commun. ACM, 60(6), 84–90. doi: 10.1145/3065386.
- [25] da Rocha, D.A., Ferreira, F. M. F., Peixoto, Z. M. A. 2022. Diabetic retinopathy classification using VGG16 neural network, Res. Biomed. Eng., 38(2), 761–772. doi: 10.1007/s42600-022-00200-8.
- [26] Karacı, A. 2022. VGGCOV19-NET: automatic detection of COVID-19 cases from X-ray images using modified VGG19 CNN architecture and YOLO algorithm, Neural Comput. Appl., 34(10), 8253–8274. doi: 10.1007/s00521-022-06918-x.
- [27] Balasubramaniam, S., Velmurugan, Y., Jaganathan, D., Dhanasekaran, S. 2023. A Modified LeNet CNN for Breast Cancer Diagnosis in Ultrasound Images, Diagnostics, 13(17). doi: 10.3390/diagnostics13172746.
- [28] Maqsood, S., Damaševičius, R., Maskeliūnas, R. 2022. Multi-Modal Brain Tumor Detection Using Deep Neural Network and Multiclass SVM, Medicina (B. Aires), 58(8). doi: 10.3390/medicina58081090.
- [29] Rajpurkar, P., Chen, E., Banerjee, O., Topol, E.J. 2022. AI in health and medicine, Nat. Med., 28(1), 31–38. doi: 10.1038/s41591-021-01614-0.

**(Araştırma Makalesi)****Derin Öğrenme Yöntemleri Kullanılarak Böbrek Hastalıklarının Tespiti ve Çoklu Sınıflandırma****Kenan GÜLLE\*<sup>1</sup>, Durmuş ÖZDEMİR<sup>2</sup>, Hasan TEMURTAŞ<sup>3</sup>**<sup>1</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No :<http://orcid.org/0000-0002-4650-1412><sup>2</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No :<http://orcid.org/0000-0002-9543-4076><sup>3</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No :<http://orcid.org/0000-0001-6738-3024>**Anahtar Kelimeler:**Derin Öğrenme,  
Böbrek Hastalığı,  
Biyomedikal,  
Poly-CNN,  
Çoklu Sınıflandırma,  
VGG

**Özet:** Derin öğrenme, sağlık alanında hastalık ve anomali tespiti gibi alanlarda son yıllarda başarılı sonuçlar elde etmiştir. Literatür incelendiğinde, böbrek hastalıklarının teşhisi, karmaşık, hata eğilimli ve zaman alıcı bir süreç olduğundan, bilgisayar destekli yazılımlara olan ihtiyaç kaçınılmazdır. Bu çalışmada, hastalara böbrek taşı, tümör ve kist teşhisi konmuş bilgisayarlı tomografi cihazı tarafından oluşturulan görüntüler kullanılmıştır. Veri setimizdeki görüntüler, erişime açık Kaggle platformundan elde edilmiştir. Veri seti, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve çalışmada önerdiğimiz geliştirilmiş Poly-CNN derin öğrenme modeli kullanılarak sınıflandırma performansı ölçülmüştür. Daha istikrarlı öğrenme sağlamak için CNN yapısına ekstra havuzlama katmanı ve bağlantı katmanı eklenmiştir. Eklenen bu katmanlar aşırı öğrenmeye sebebiyet vermemesi için, eğitim sırasında rastgele nöronlar devre dışı bırakılmıştır. Çalışmada kullanılan derin öğrenme modellerinde, kullanılan parametreler, katman yapıları, doğruluk ve kayıp grafikleri detaylı bir şekilde incelenmiştir. Çalışmada Poly-CNN'in %99,94'lük yüksek bir doğruluk oranıyla öne çıktığı görülmüştür. Bu sonuçlar, Poly-CNN modelinin, diğer kullanılan modellerde daha iyi bir performans sergileyerek, önerilen araştırma çerçevesinin etkinliğini belirgin bir şekilde ortaya koymaktadır.

**(Research Article)****Kidney Disease Detection and Multi-Classification Using Deep Learning Methods****Keywords:**Deep Learning,  
Kidney Disease,  
biomedical,  
Poly-CNN,  
Multiple Classification,  
VGG

**Abstract:** Deep learning has achieved successful results in recent years in areas such as disease and anomaly detection in the field of healthcare. When the literature is examined, the need for computer-aided software is inevitable since the diagnosis of kidney diseases is a complex, error-prone and time-consuming process. In this study, images created by a computerized tomography device were used in which patients were diagnosed with kidney stones, tumors and cysts. The images in our dataset were obtained from the open-access Kaggle platform. Classification performance was measured using the dataset, Classic CNN, ANN, ALEXNET, VGG16, VGG19 networks and the developed Poly-CNN deep learning model we proposed in the study. Extra pooling layer and connection layer were added to the CNN structure to provide more stable learning. To prevent these added layers from causing excessive learning, random neurons were disabled during training. In the deep learning models used in the study, the parameters used, layer structures, accuracy and loss graphs were examined in detail. The study showed that Poly-CNN stands out with a high accuracy rate of 99.94%. These results clearly demonstrate the effectiveness of the proposed research framework, with the Poly-CNN model outperforming other used models.

\*Sorumlu Yazar: kenangulle@hotmail.com

## 1. GİRİŞ

Günümüzde, sağlık sektöründe derin öğrenme yöntemlerinin kullanımı, çeşitli hastalıkların erken teşhisi, sınıflandırılmasında ve uzman hekimlere yönelik öneri sistemi olarak kullanımı önemli bir potansiyele sahiptir [1], [2], [3]. Böbrek tümörleri dünya çapında erkek ve kadınlarda en sık görülen 10. tümördür [4]. Bu araştırmada, böbrek hastalıklarının tespiti ve çoklu sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğinin ve veriminin belirlenmesi ve değerlendirilmesi amaçlanmaktadır. Derin öğrenme, geniş ve karmaşık veri setleri üzerinde otomatik öğrenme kapasitesi ile öne çıkan bir yapay zekâ dalıdır [5]. Hastalıklarının tespiti ve çoklu sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğini değerlendirmeyi amaçlayan ve mühendislik pratiğine aktarılmış birçok bilimsel çalışma yapılmıştır [6]. Bunlardan bazıları birçok araştırmacıya referans olarak sunulmuştur [6-10].

Tüzün ve Özdemir [7], MRI görüntüleriyle beyin tümörü hastalığının erken tespiti için mevcut derin öğrenme modellerinin karşılaştırmalı analizini sunmayı amaçlamaktadır. GoogleNet, Mobilenetv2, InceptionV3 ve Efficientnet-b0 modelleri Matlab platformunda kodlanarak beyin tümörü tespiti ve sınıflandırılması için kullanıldı. Glioma, Meningioma ve Hipofiz beyin tümörleri üzerinde sınıflandırma yapıldı. Kaggle platformunda halka açık olarak paylaşılan dört farklı sınıfta 7022 beyin MRI görüntüsü içeriyor. Analiz sonuçlarına göre, Efficientnet-b0 (%99,54), InceptionV3 (%99,47), Mobilenetv2 (%98,93) ve GoogleNet (%98,25) sırasıyla başarı elde etmiştir.

Özdemir ve Arslan [8], Covid-19 hastalığının erken teşhisini tespit etmek amacıyla derin öğrenme modellerinin karşılaştırmalı analizini sunmaktadır. VGG-19, VGG-16 ve Inception V3 modelleri Covid-19 tespiti için değerlendirilmiştir. Kamuya açık olan Kaggle veri tabanından eğitim için 280 göğüs röntgeni görüntüsü ve test için 140 göğüs röntgeni görüntüsü kullanılmıştır. Analiz sonuçlarına göre, Inception V3 (%92) en başarılı model olmuştur.

Krizhevsky vd. [9], çalışmalarında DigiMammo (UCHCDM) veritabanında toplanan 96 meme kanseri görüntüsü üzerinde gerçekleştirilmiştir. Görüntüler 69'u kanserli, 27'si sağlıklı bireylerden oluşmaktadır. Meme kanseri taraması için önerilen bir bilgisayar destekli tespit (CAD) yöntemi tanıtılmıştır. Mamografik görüntüler incelenerek şüpheli kanserli bölgeler belirlenmiştir. Ardından görüntüler eğitilmiş bir CNN ile beslenerek yanlış pozitifler eleme işlemi gerçekleştirilmiştir. Önerilen CAD yönteminin başarı oranının %92,8 olduğu gözlemlenmiştir.

Rehman vd. [10], çalışmalarında beyin tümörünün doğru teşhisi için halka açık figshare ortamında bulunan 233 hastadan toplanan 3064 MRI kesitinde oluşmaktadır. Önerilen çerçeve kapsamında, AlexNet, GoogLeNet ve VGGNet olmak üzere üç evrişimli sinir ağı mimarisi kullanılarak menenjiyom, hipofiz ve glioma gibi beyin

tümörlerini sınıflandırmak için çalışma yürütülmüştür. Her çalışma, beyin tümörü veri kümesi olan Figshare'deki MRI dilimleri kullanılarak ince ayar ve dondurma gibi transfer öğrenme tekniklerini kullanmaktadır. Sonuçların genelleştirilmesi, veri kümesi örneklerinin artırılması ve aşırı uyum şansını azaltmak için MRI dilimlerine veri artırma teknikleri uygulanmıştır. Önerilen çalışmalarda, VGG16 mimarisi ile yapılan sınıflandırma tespit açısından en yüksek doğruluğa (98.69) ulaştığı gözlemlenmiştir.

Bingöl ve vd.[11], Derin öğrenme ve yapay zekanın tıp alanındaki etkilerini değerlendirerek böbrek tümörü tespiti üzerindeki rolünü incelemiştir. Derin öğrenme modellerinin, özellikle radyolog yoğunluğu yüksek ortamlarda ve hızlı teşhis ihtiyacında, böbrek tümörü tespiti konusunda hızlı ve doğru sonuçlar sağlayabileceği vurgulanmaktadır. Çalışmada Kaggle platformundan elde ettikleri veri seti ile böbrek görüntülerini taş, kist ve tümör ve normal olarak sınıflandırma amacıyla, EfficientNetb0, Inceptionv3, GoogleNet, DenseNet201, ShuffleNet ve CNN tabanlı bir hibrit model önerisinde bulunmuştur. Veri setindeki görüntülerin %80'nini eğitim %20'sini test için ayırmıştır. Karşılaştırma yaptıkları modellerin hepsinde 5 epoch değeri, learning rate 1.0004 ve 16 batch size değeri kullanmıştır. Önerilen CNN tabanlı hibrit modelin %99,37 doğruluk değerine ulaşmıştır.

**Tablo 1.** Böbrek tümörü sınıflandırması ile ilgili çalışmalar.

Yıl	Dataset	Method	Sonuç	Kaynak
2021	KiTS19	InceptionV3, ROC	%97.4	[12]
2023	CT Kidney Dataset	Proposed CNN	%99.5	[13]
2022	KiTS19	DeepLabv3+ 2.5D	%99.7	[14]
2022	8400	2D-CNN	%97.0	[15]
2023	CT Kidney Dataset	Hybrid CNN Model	%99,3	[11]
2022	CT Kidney Dataset	Swin Transformer	%99,3	[16]
2024	CT Kidney Dataset	Proposed Model	%99,7	[17]

Literatürde de görüldüğü üzere farklı derin öğrenme mimarileri kullanılarak tıp alanında covid-19, beyin tümörü ve böbrek tümörü ve meme kanseri tespiti için, etkili araç olabileceği göstermektedir [18]. Derin öğrenme özellikle radyolog yoğunluğu yüksek ortamlarda ve hızlı teşhis ihtiyacında, doğru ve hızlı sonuçlar sağlama potansiyeline sahip olmaktadır [19]. Bu çalışmalardan elde edilen sonuçlar, derin öğrenme modellerinin tıbbi görüntüleme alanında çeşitli uygulamalarda etkili bir şekilde kullanılabilirliğini ve hastalıkların erken teşhisi konusunda önemli bir potansiyele sahip olduğunu ortaya koymaktadır. Tablo 1.'de böbrek tümörü sınıflandırması ile ilgili literatürde yapılan çalışmalar görülmektedir. Bu çalışmada da Kaggle platformundan elde edilen böbrek görüntüleri Classic CNN, ANN, ALEXNET, VGG16,




VGG19 ağları ve çalışmada önerdiğimiz geliştirilmiş Poly-CNN ağı gibi farklı derin öğrenme metotları kullanılarak analiz edilmesi amaçlanmıştır.

## 2. MATERYAL VE METOT

Bu çalışma, Classic Convolutional Neural Network (Classic CNN), Artificial Neural Network (ANN), AlexNet, VGG16 ve VGG19 gibi önceden belirlenmiş derin öğrenme modellerini içeren bir dizi modeli ve

geliştirilmiş Poly-CNN modelini kapsamaktadır. Bu modeller, böbrek hastalıklarının farklı alt tiplerini tanımak ve çoklu sınıflandırmada başarılı olmak amacıyla geniş bir görüntü veri seti üzerinde eğitilecek ve test edilecektir. Çalışmada geliştirilmiş uygulama ortamı Python programlama dilinin Jupyter Notebook açık kaynak kodlu programı tercih edilmiştir. Numpy, Matplotlib, Tensorflow, Keras gibi kütüphaneleri uygulamada kullanılmıştır. Çalışmanın akış modeli Şekil 1.'de gösterilmiştir.



Şekil 1. Çalışmanın genel yapısı

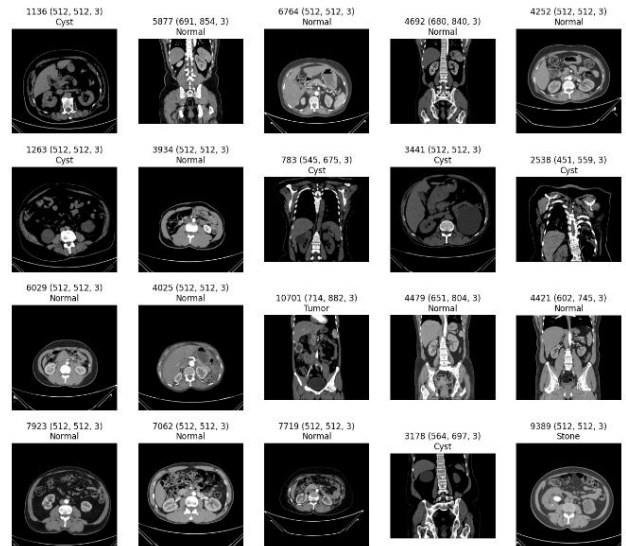
### 2.1. Veri Seti

Çalışmada böbrek hastalığının tespit edilmesi ve sınıflandırılması amacıyla kullanılan veri seti, Bangladeş'teki çeşitli hastanelerden PACS (Resim Arşivleme ve İletişim Sistemi) aracılığıyla toplanmış. Hastalara böbrek tümörü, kist, normal veya taş teşhisi konulmuş. Dicom görüntüleri kayıpsız JPG formatına dönüştürülmüş. Dönüştürme işleminden sonra, her bir görüntü doğruluğunu teyit etmek için bir radyolog ve bir tıbbi teknoloji tarafından tekrar kontrol edilmiştir [20]. Veri setinin sınıflara göre dağılımı ise 3709'u Cyst (kist), 5077'si Normal, 1377'si Stone (taş) ve 2283'ü Tumor (tümör) olmak üzere toplam 12446 Bilgisayarlı Tomografi (CT) görüntüsü içermektedir. Bu veri setinde kullanılan tüm görüntüler erişime açık Kaggle platformundan alınmıştır [20]. Veri setinden alınan örnek görüntüler Şekil 2'de gösterilmiştir. Çalışmada verilerin %70'ni eğitim, %15'ni test ve %15'ni doğrulama olarak ayrılmıştır.

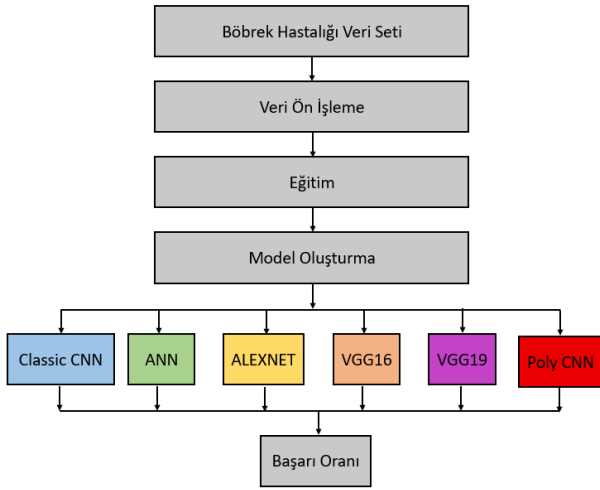
### 2.2. Classic CNN, ANN, ALEXNET, VGG16, VGG19 ve Poly-CNN ile Öğrenilen Modellerin Mimarileri ve Uygulama Perspektifleri

Veri seti içindeki bilgiler kategorik hale getirilmiş ve modellerin daha etkili bir şekilde işleyebilmesi için uygun boyutlara getirilmiştir. Veri setini zenginleştirmek amacıyla veri artırma teknikleri uygulanmıştır [21]. Bu kapsamda özellik tabanlı normalizasyon işlemleri yanı sıra yatay ve dikey çevirmeler, 30 derecelik döndürme, ayrıca yatayda ve dikeyde %0,3 oranında genişletme gibi

çeşitli manipülasyonlar gerçekleştirilerek veri setindeki çeşitlilik artırılmıştır. Önerdiğimiz ağ yapısına göre oluşturulan modelin başlangıç değerleri ile modelin katmanları ve parametreleri belirlenmiştir. Farklı epoch değerleri ile oluşturulan model farklı iterasyonlarla eğitilmiş ve test verilerinin sınıflandırma sonuçları hesaplanmıştır. Çalışmada Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağı kullanılmıştır. Çalışmaya ait genel akış diyagramı Şekil 3'te verilmiştir.



Şekil 2. Böbrek hastalığı için kullanılan görüntüler [20]



Şekil 3. Çalışmaya ait akış diyagramı

### 2.2.1. Classic CNN

Çalışmada derin öğrenme modellerinden biri olan Classic CNN (Evrışimsel Sinir Ağları), görsel veri analizi ve tanıma alanında kullanılmaktadır [22]. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 batch size kullanılmıştır. Bu modelin girdisi 32x32x1 boyutundaki görüntülerdir. Classic CNN modelinde veri girişini Giriş Katmanı ile sağlayarak evrişim filtrelerini Evrişim Katmanları (Convolutional Layers) ile oluşturuldu. Evrişim sonuçlarında Relu Aktivasyon fonksiyonları uygulanarak evrişim sonuçlarının küçültüldüğü Havuzlama Katmanları (Pooling Layers) gösterildi. Havuzlama katmanlarının çıkışlarını düzeltirmek için Tam Bağlantılı Katman (Fully Connected Layer) kullanıldı. Sınıflandırmalar Çıkış Katmanı ile gösterildi. Her bir katmanın parametreleri (örneğin, filtre boyutları, adım büyüklükleri) ve aktivasyon fonksiyonları, böbrek veri setine göre oluşturuldu.

### 2.2.2. ANN

Yapay sinir ağları genellikle üç temel katmandan oluşan bir mimariye sahiptir: giriş katmanı, gizli katmanlar ve çıkış katmanıdır [23]. Bu modelin girdisi 150x150x3 boyutundaki görüntülerdir. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 batch size, aktivasyon fonksiyonu olarak relu ve softmax kullanılmıştır. Aktivasyon fonksiyonu nöronun çıkış değerini hesaplamaktadır.

### 2.2.2. AlexNet

Böbrek hastalığı veri seti üzerinde kullanılan AlexNet mimarisi, 5 evrişimli katman, 3 max-pooling katmanı, 3 normalizasyon katmanı, 2 tam bağlantılı katman ve 1 softmax katmanından oluşmaktadır. Evrişimli katmanlar, evrişimli filtreler ve doğrusal olmayan ReLU aktivasyon fonksiyonları ile tanımlanmaktadır. Maksimum havuzlama işlemi, havuzlama katmanları aracılığıyla gerçekleştirilmektedir [24]. Tam bağlantılı katmanların varlığı, giriş boyutunu sabit kılmaktadır. Modelin girdisi, 227x227x3 boyutundaki görüntülerden oluşmaktadır.

Çıkış katmanında kullanılan aktivasyon fonksiyonu Softmax'tır

### 2.2.3. VGG16

Çalışmanın bu aşamasında evrişimli sinir ağından (CNN) Görsel Geometri Grubu (VGG16) konseptindeki böbrek görüntüleri kullanıldı. VGG16 ağı çok küçük evrişimli filtrelerle oluşturulmuştur. Evrişimli katman ve üç tam bağlantılı katmandan oluşmakta olup ayrıca 16 katmanı destekleyen bir evrişim sinir ağı (CNN) modelidir [25]. Bu modelin girdisi (None,512) boyutundaki görüntülerdir.


### 2.2.4. VGG19

VGG19, özellikle görüntü sınıflandırma görevleri için tasarlanmış bir derin öğrenme modelidir [26]. VGG19, toplamda 19 katmandan oluşan derin bir sinir ağı mimarisine sahiptir. Bu 19 katman, evrişimli (convolutional) ve tam bağlantılı (fully connected) katmanları içermektedir Modelde genellikle ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmaktadır. ReLU, öğrenme sürecini hızlandırabilir ve eğitimi daha etkili hale getirebilmektedir Evrişimli katmanlar arasında maksimum havuzlama (max pooling) katmanları da bulunmaktadır. Havuzlama katmanları, özellik haritalarını ölçeklemek ve boyutunu azaltmak için kullanılmaktadır.

### 2.2.5. Önerilen Poly-CNN Modeli

Bu çalışma, Poly-CNN mimarisinin temelinde yatan yapısal özellikleri ve hiper parametreleri yeniden değerlendirerek, görüntü segmentasyonunda daha iyi performans sağlamayı hedeflemektedir. Elde edilen sonuçlar, geliştirilen modelin genel görüntü analizi uygulamalarında kullanılabilirliğini ve etkinliğini göstermeye yönelik önemli bir katkı sunmayı amaçlamaktadır. Convolutional Neural Network (CNN) tabanlı yenilikçi bir yaklaşım geliştirmeyi amaçlamaktadır. Geliştirdiğimiz Poly-CNN modeli, özellikle görüntü sınıflandırma görevleri için optimize edilmiş bir mimariye sahiptir. Başlangıçta, evrişim katmanları, giriş görüntülerinden düşük düzeyli özellikleri, kenarları ve köşeleri öğrenmeye odaklanacak şekilde ayarlandı. Ardından, max pooling katmanları, özellik haritalarını küçülterek önemli bilgileri vurgular, bu sayede daha yüksek seviyeli özelliklerin çıkarılmasına yardımcı olur. Tam bağlantılı katmanlar, evrişimli özellikleri daha karmaşık ve anlamlı özelliklere dönüştürmek için kullanılır. Dropout katmanları, rastgele nöronları devre dışı bırakarak ezberlemeyi azaltır ve eğitim yeteneğini artırır. Batch normalization katmanları ise eğitim sürecini hızlandırarak daha kararlı ve etkili bir model elde edilmesine katkı sağlar. Toplamda 88,516 parametre içeren bu model, ağırlıklarını öğrenerek verilere uygun bir şekilde adapte olur. Önceki yöntemlerin sınırlamalarını aşmak ve karmaşık görüntü yapısını daha etkili bir şekilde çözebilmek amacıyla tasarlanmıştır. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 Batch size

kullanılmıştır. Bu modelin girdisi 150x150x3 boyutundaki görüntülerdir.



Şekil 9. Poly-CNN Modelinin genel mimari yapısı

Önerdiğimiz derin öğrenme modelinin katmanlarını içeren katman yapısı ve parametre değerleri Tablo 2. de verilmiştir. Modelin ilk katmanı Rescaling katmanıdır, bu katman veri setindeki piksel değerlerini normalize etmek için kullanılır. Giriş olarak xTrain veri kümesinin şeklini kullanır. Ardından, üç adet Conv2D katmanı gelir (Conv1, Conv2, Conv3), her biri 3x3 boyutunda filtrelerle işlenmiş özellik haritalarını çıkarır. Her Conv2D katmanının ardından bir MaxPooling2D katmanı gelir (Pool1, Pool2, Pool3), bu katmanlar özellik haritalarındaki önemli bilgileri vurgular ve boyutlarını küçültür. Flatten katmanı, düzleştirme işlemi yaparak önceki katmanlardan elde edilen özellikleri tek boyutlu bir vektöre dönüştürür. Ardından iki adet Dense katmanı

gelir (Dense1, Dense2), bu katmanlar sinir ağının öğrenmesini sağlar. Her Dense katmanının ardından bir BatchNormalization katmanı (Norm1, Norm2) gelir, bu katmanlar ağı normalleştirerek eğitimi daha stabil hale getirir. Dropout katmanları (Dropout1, Dropout2) aşırı öğrenmeyi önlemek için kullanılır, eğitim sırasında belirli bir oranda rastgele nöronları devre dışı bırakır. Son katman Dense3, çıkış sınıf sayısına (Tumor, Taş, Kist, Normal) sahip bir softmax aktivasyon fonksiyonu içerir. Bu katman, modelin verilen girişlere dayanarak sınıflar arasında olasılıkları tahmin etmesini sağlar. Her bir katmanın içerdiği ağırlıklar (W) ve bias terimleri (b) Tablo.2'de belirtilmiştir.

Tablo 2. Poly-CNN Katman Yapısı ve Parametre Değerleri.

#	Katman Türü	Parametre Sayısı	Ağırlıklar (W)	Bias Terimleri (b)	Aktivasyon	Ek Bilgi
1	Rescaling (Rescale1)	0	-	-	-	Normalizasyon Faktörü: 1/255
2	Conv2D (Conv1)	160	(3, 3, 1, 16)	(16,)	ReLU	Filtre: 16, Çekirdek Boyutu: (3,3)
3	MaxPooling2D (Pool1)	0	-	-	-	Pooling Boyutu: (2, 2)
4	Conv2D (Conv2)	2320	(3, 3, 16, 16)	(16,)	ReLU	Filtre: 16, Çekirdek Boyutu: (3,3)
5	MaxPooling2D (Pool2)	0	-	-	-	Pooling Boyutu: (2, 2)
6	Conv2D (Conv3)	2320	(3, 3, 16, 16)	(16,)	ReLU	Filtre: 16, Çekirdek Boyutu: (3,3)
7	MaxPooling2D (Pool3)	0	-	-	-	Pooling Boyutu: (2, 2)
8	Flatten (Flatten1)	0	-	-	-	
9	Dense (Dense1)	4112	(1024, 16)	(16,)	ReLU	Birim Sayısı: 16
10	BatchNormalization (Norm1)	32	(16,)	(16,)	-	
11	Dropout (Dropout1)	0	-	-	-	Dropout Oranı: 0.5
12	Dense (Dense2)	272	(16, 16)	(16,)	ReLU	Birim Sayısı: 16
13	BatchNormalization (Norm2)	32	(16,)	(16,)	-	
14	Dropout (Dropout2)	0	-	-	-	Dropout Oranı: 0.5
15	Dense (Dense3)	4	(16, 4)	(4,)	Softmax	Softmax Aktivasyon Fonksiyonu, 4

### 3. BULGULAR VE DENEYSEL SONUÇLAR


Elde edilen sonuçlar, derin öğrenme modellerinin böbrek hastalıklarını başarılı bir şekilde tespit edebildiğini ve çeşitli alt tiplerini doğru bir şekilde sınıflandırabildiğini göstermektedir. Özellikle, geliştirilmiş Poly-CNN modeli, yüksek doğruluk oranları ve düşük hata payları ile

öne çıkmaktadır. Ayrıca kullanılan Classic CNN, ANN, ALEXNET, VGG16, VGG19 modelleri ve geliştirilmiş Poly-CNN modeli, böbrek hastalıklarının karmaşıklığını anlama ve spesifik alt tiplerini ayırt etme konusunda yüksek başarı elde etmiştir. Çalışma, derin öğrenme yöntemlerinin böbrek hastalıklarının tespiti ve çoklu sınıflandırma görevlerinde etkili bir şekilde kullanılabileceğini göstermektedir. Bu bulgular, klinik

uygulamalarda hastalık teşhis ve yönetim süreçlerini iyileştirmek için derin öğrenme teknolojilerinin potansiyelini vurgulamaktadır.

### 3.1. Kullanılan Modellerin Eğitim (Train), Doğrulama (Valid) ve Test Başarı Oranları

Çalışmanın bu aşamasında kullanılan Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağı Eğitim (Train), Doğrulama (Valid) ve Test Başarı Oranları (%) gösterilerek değerlendirilmiştir (Şekil 10). Uygulanan bu modellerde test için ayrılmış böbrek veri seti için yüksek doğruluk oranları sırasıyla %99,57 (Classic CNN), %99,78 (ANN), %89,44 (ALEXNET), %96,57 (VGG16), %99,78 (VGG19) ve %99,94 (Poly-CNN) gözlemlenmiştir. En yüksek doğruluğu %99,94 ile Poly-CNN sergilemiştir. Elde edilen bu sonuçlar doğrultusunda önerilen Poly-CNN araştırma çerçevesinin tekniği bilinen CNN modellerinden daha iyi performans göstermiştir.



Şekil 10. Tüm modellerin başarı oranları

Bu çalışma kapsamında, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ve Poly-CNN modelleri, böbrek hastalıklarının sınıflandırılması görevinde değerlendirilmiştir. Eğitim (Train), Doğrulama (Valid) ve Test aşamalarında elde edilen başarı oranları aşağıda verilen Tablo 3'de özetlenmiştir.

Tablo 3. Tüm modellerin başarı oranlarının karşılaştırması

MODEL	BAŞARI ORANLARI (%)		
	EĞİTİM (Train)	DOĞRULAMA A (Valid)	TEST
ANN	0,9997	0,9973	0,9978
ALEXNET	0,9211	0,8993	0,8944
VGG16	0,9807	0,9732	0,9657
VGG19	0,9988	0,9951	0,9978
<b>Poly-CNN</b>	<b>0,9997</b>	<b>0,9983</b>	<b>0,9994</b>
Classic CNN	0,9986	0,9957	0,9957

Çalışmada Sınıflandırıcının performansını ölçmek için accuracy, precision, recall ve F1-score değerlendirme metrikleri kullanıldı. Sınıflandırma doğruluğunu sayısal olarak göstermek için karışıklık matrisi kullanıldı. Bu matris, makine öğreniminde sıkça kullanılan bir tekniktir ve bir sınıflandırma sistemi tarafından gerçek ve tahmini


sınıfların elde edilmesiyle ilgili bilgi sağlar [27]. Karışıklık matrisi, iki boyuta sahiptir: gerçek ve tahmini sınıflar. Her satır, bir gerçek sınıf örneğini temsil ederken, her sütun bir tahmini sınıfın durumunu gösterir.

**Gerçek Pozitif (TP):** Sınıflandırıcının pozitif sınıfı pozitif olarak doğru bir şekilde tahmin ettiği tahmin sayısını ifade eder.

**Gerçek Negatif (TN):** Sınıflandırıcının negatif sınıfı negatif olarak doğru şekilde tahmin ettiği tahmin sayısını ifade eder.

**Yanlış Pozitif (FP):** Sınıflandırıcının negatif sınıfı hatalı bir şekilde pozitif olarak tahmin ettiği tahmin sayısını ifade eder.

**Yanlış Negatif (FN):** Sınıflandırıcının pozitif sınıfı hatalı olarak negatif olarak tahmin ettiği tahmin sayısını ifade eder.



Şekil 10. İkili sınıflandırma için karışıklık matrisi

**Accuracy:** Bir modelin doğru tahmin ettiği örneklerin toplam veri kümesine oranını temsil eder. Başka bir deyişle, doğru sınıflandırılan örneklerin, veri kümesindeki tüm örneklerin yüzdesidir. Bu metrik, modelin genel performansını ölçer ve ne kadarının doğru tahmin edildiğini gösterir.

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

**Precision:** Pozitif olarak tahmin edilen verilerin ne kadarının doğru tahmin edildiğini gösterir. Yani, yüksek bir precision, daha az yanlış pozitif anlamına gelir. Precision, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekte de pozitif olduğunu ölçer.

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

**Recall:** Sınıflandırıcının tamamlama yeteneğini ölçen bir metriktir. Yüksek recall, daha düşük yanlış negatifleri gösterirken, düşük recall daha yüksek yanlış negatifleri gösterir. Precision'daki iyileşme genellikle recall'daki azalmayla birlikte gelir. Recall, modelin gerçek pozitif örnekleri ne kadar iyi kapsayabildiğini belirtir ve bu, yanlış negatiflerin azalması anlamına gelir.

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

**F1-Score:** recall ve precision'in çarpımının, recall ve precision'in toplamına bölünmesiyle elde edilir. Bu metrik hem modelin tamamlama yeteneğini hem de doğruluk

oranını dengeli bir şekilde değerlendirir. Yani, F1-Score, yanlış negatiflerin azaltılmasıyla birlikte yanlış pozitiflerin de kontrol altında tutulup tutulmadığını gösteren bir ölçüdür.

$$\text{F1 Score} = \frac{\text{TP}}{\text{TP} + \frac{1}{2}(\text{FP} + \text{FN})}$$

**Tablo 4.** Test verisi için değerlendirme metrikleri

Classes	Evaluation Metrics	CNN Models					
		ANN	Classic CNN	VGG16	VGG19	AlexNet	Poly-CNN
Cyst	<i>precision</i>	1.0000	0.9982	0.9981	0.9982	0.9959	0.9964
	<i>recall</i>	0.9982	0.9910	0.9658	0.9946	0.8815	1.0000
	<i>f1-score</i>	0.9991	0.9946	0.9817	0.9964	0.9352	0.9982
Normal	<i>precision</i>	0.9974	0.9974	0.9303	1.0000	0.9484	1.0000
	<i>recall</i>	1.0000	1.0000	1.0000	1.0000	0.9895	1.0000
	<i>f1-score</i>	0.9987	0.9987	0.9639	1.0000	0.9685	1.0000
Stone	<i>precision</i>	0.9951	0.9760	0.9698	0.9856	0.5722	1.0000
	<i>recall</i>	0.9854	0.9854	0.9324	0.9952	1.0000	0.9903
	<i>f1-score</i>	0.9902	0.9807	0.9507	0.9904	0.7279	0.9951
Tumor	<i>precision</i>	0.9971	1.0000	1.0000	1.0000	1.0000	1.0000
	<i>recall</i>	1.0000	1.0000	0.9096	1.0000	0.6414	1.0000
	<i>f1-score</i>	0.9985	1.0000	0.9527	1.0000	0.7815	1.0000
<i>accuracy</i>		0.9979	0.9957	0.9657	0.9979	0.8945	<b>0.9989</b>

Farklı CNN modelleriyle yapılan böbrek rahatsızlığı sınıflandırma çalışmalarındaki değerlendirme metrikleri Tablo 4'te verilmiştir. Sonuçlar incelendiğinde genel olarak başarılı sonuçlar elde edilmiştir. Özellikle Cyst ve Tumor sınıflarında modeller yüksek doğruluk göstermiş, Poly-CNN modeli genel performans açısından diğer

modellere göre öne çıkmıştır. Ancak, Stone sınıfında recall değeri biraz düşük çıkmış, bu sınıfta daha fazla iyileştirme için çalışma yapılabilir. Sonuçlar, model seçiminin ve performansın sınıflara göre değişebileceğini göstererek, problem alanına özgü optimizasyonların önemini vurgular.

### 3.2. Kullanılan Modellerin Hata Çapraz Entropi Grafikleri

Böbrek veri setini kullanarak elde ettiğimiz çapraz entropi hata değerlerinin değişimini Şekil 11 üzerinde epoch değerlerine göre gösterdik. Grafikten anlaşılacağı üzere, Classic CNN'de 2. epoch'ta hata en yüksek seviyede, 15. epoch'ta hata en düşük seviyeye gerilemiştir. Aynı şekilde, ANN'de 2. epoch'ta hata en yüksek, 15. epoch'ta hata en düşük seviyededir. ALEXNET'te ise 8. epoch'ta hata en yüksek, 15. epoch'ta hata en düşük düzeydedir. VGG16 modelinde 2. epoch'ta hata en yüksek, 15. epoch'ta ise hata en düşük seviyededir. VGG19'da ise hata değerleri sabit kalmıştır. Poly-CNN modelinde ise 2. epoch'ta hata en yüksek, 15. epoch'ta ise hata en düşük seviyededir.

### 3.2. Kullanılan Modellerin Sınıflandırma Doğruluğu Grafikleri

Ağırlıklar sürekli güncellenmekte olup, en iyi öğrenmeler Şekil 12'de gösterilmiştir. Grafikte anlaşıldığı üzere en iyi öğrenmeler Classic CNN'de ANN'de, ALEXNET'de VGG16'da, VGG19'd ve Poly-CNN'de 15. epoch da görülmektedir.


### 4. TARTIŞMA VE SONUÇ

Bilgisayarlı görüntü işleme ve derin öğrenme teknolojilerindeki hızlı ilerlemeler, tıbbi görüntüleme alanında çeşitli uygulamalar için yeni olanaklar sağlamaktadır [28]. Bu alandaki en önemli uygulamalardan biri, medikal görüntü sınıflandırmasıdır [29]. Medikal görüntü sınıflandırması, uzmanların hastalıkları teşhis etmelerine, tedavi stratejilerini belirlemelerine ve hastaların durumlarını izlemelerine yardımcı olabilecek bir araç olarak büyük bir potansiyele sahiptir.


Böbrek hastalıkları, sağlık sorunları arasında önemli bir yer tutmaktadır ve erken teşhis, etkili tedavi ve hastalık izlemesi için kritik öneme sahiptir. Bu nedenle, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağırları ve geliştirilmiş Poly-CNN ağı gibi popüler derin öğrenme mimarileri kullanılarak böbrek görüntülerinin sınıflandırılması yapılmıştır. Derin öğrenme tabanlı sınıflandırma yöntemlerini kullanarak böbrek görüntülerini başarıyla sınıflandırılmış ve bu yöntemlerin klinik uygulamalardaki potansiyeli değerlendirilmiştir. Böbrek hastalıklarının sınıflandırmasında Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağırları ve geliştirilmiş Poly-CNN ağı gibi farklı derin öğrenme metodlarını kullanılarak veri seti üzerinde performans

analizleri yapılmıştır. Uygulanan bu modellerde böbrek veri seti için yüksek doğruluk oranları gözlemlenmiştir. En yüksek doğruluğu %0,9994 ile Poly-CNN sergilemiştir. Elde edilen bu sonuçlar doğrultusunda önerilen araştırma çerçevesinin tekniği bilinen Classic

CNN'den daha iyi performans gösteren Poly-CNN ortaya konulmuştur. Poly-CNN diğer çalışmalara kıyasla doğrulukta gözle görülebilir bir artış olduğundan dolayı önerilen yöntemin etkinliğini açıkça ortaya koymaktadır.



Şekil 11. Modellerin Hata Çapraz Entropi Grafikleri



Şekil 12. Modellerin Çapraz entropi hata grafikleri

Sonuç olarak bu çalışma, bilgisayar destekli tıbbi teşhis alanında bir katkı sağlamayı amaçlayan önemli bir araştırma çalışmasıdır. Derin öğrenme yöntemlerinin medikal görüntü sınıflandırması üzerindeki etkisini anlamak, hastaların daha hızlı ve doğru bir şekilde teşhis edilmesine ve tedavi edilmesine katkı sağlayabilmektedir. Bu çalışma, tıbbi görüntüleme ve derin öğrenme alanlarındaki araştırmacılara, doktorlara ve sağlık profesyonellerine faydalı olacaktır. Gelecekteki çalışmalar, daha fazla derin öğrenme modeli ve daha geniş veri setleri kullanarak bu yöntemlerin daha da optimize edilmesi hedeflenmektedir.

### Etik Hususlar

#### Etik kurallara uyum

Yazarlar olarak, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun çalıştığımızı deklare ederiz.

### Finansman

Yazarlar olarak, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almadık.

### Çıkar çatışması

Yazarlar olarak herhangi bir çıkar çatışması içinde bulunmadık.

### KAYNAKÇA

- [1] Tahir, M., Naeem, A., Malik, H., Tanveer, J., Naqvi, R.A., Lee, S.W. 2023. DSCC\_Net: Multi-Classification Deep Learning Models for Diagnosing of Skin Cancer Using Dermoscopic Images, *Cancers (Basel)*, 15(7). doi: 10.3390/cancers15072179.
- [2] Srikantamurthy, M.M., Rallabandi, V.P.S., Dudekula, D.B., Natarajan, S., Park, J. 2023. Classification of benign and malignant subtypes of breast cancer histopathology imaging using hybrid CNN-LSTM based transfer learning, *BMC Med.*

- Imaging, 23(1), 19. doi: 10.1186/s12880-023-00964-0.
- [3] Cıfci, M. 2022. Derin Öğrenme Metodu Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Derg., 24(71), 487–500. doi: 10.21205/deufmd.2022247114.
- [4] Gharaibeh, M., Alzu'bi, D., Abdullah, M., Hmeidi, I., Al Nasar, M.R. Abualigah, L. Gandomi, A.H. 2022. Radiology Imaging Scans for Early Diagnosis of Kidney Tumors: A Review of Data Analytics-Based Machine Learning and Deep Learning Approaches. Big Data Cogn. Comput. 6, 29. <https://doi.org/10.3390/bdcc6010029>
- [5] Aalami, N. 2020. Derin öğrenme yöntemlerini kullanarak görüntülerin analizi, Eskişehir Türk Dünyası Uygul. ve Araştırma Merk. Bilişim Derg., 1(1), 17–20.
- [6] Liu, X., Song, L., Liu, S., Zhang, Y. 2021. A Review of Deep-Learning-Based Medical Image Segmentation Methods, Sustainability, 13(3). doi: 10.3390/su13031224.
- [7] Özdemir, D., Tüzün, B.N. 2023. Classification of Brain Tumors With Deep Learning Models, J. Sci. Reports-A, 054, 296–306. doi: 10.59313/jsr-a.1293119.
- [8] Özdemir, D., Arslan, N.N. 2022. Analysis of Deep Transfer Learning Methods for Early Diagnosis of the Covid-19 Disease with Chest X-ray Images, Düzce Üniversitesi Bilim ve Teknol. Derg., 10(2), 628–640. doi: 10.29130/dubited.976118.
- [9] Krizhevsky, A., Sutskever, I., Hinton, G.E. 2012. Imagenet classification with deep convolutional neural networks, Adv. Neural Inf. Process. Syst., 25.
- [10] Rehman, A., Naz, S., Razzak, M.I., Akram, F., Imran, M. 2020. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning, Circuits Syst. Signal Process., 39(2), 757–775. doi: 10.1007/s00034-019-01246-3.
- [11] Bingol, H., Yildirim, M., Yildirim, K., Alatas, B. 2023. Automatic classification of kidney CT images with relief based novel hybrid deep model., Peer J. Comput. Sci., 9, e1717. doi: 10.7717/peerj-cs.1717.
- [12] N. Heller et al., 2021. The state of the art in kidney and kidney tumor segmentation in contrast-enhanced CT imaging: Results of the KiTS19 challenge, Med. Image Anal., 67, 101821. doi: <https://doi.org/10.1016/j.media.2020.101821>.
- [13] Bhandari, M., Yogarajah, P., Kavitha, M.S., Condell, J. 2023. Exploring the Capabilities of a Lightweight CNN Model in Accurately Identifying Renal Abnormalities: Cysts, Stones, and Tumors, Using LIME and SHAP, Appl. Sci., 13(5). doi: 10.3390/app13053125.
- [14] da Cruz, L.B., et al., 2022. Kidney tumor segmentation from computed tomography images using DeepLabv3+ 2.5D model, Expert Syst. Appl., 192, 116270. <https://doi.org/10.1016/j.eswa.2021.116270>.
- [15] Alzu'bi D., et al., 2022. Kidney Tumor Detection and Classification Based on Deep Learning Approaches: A New Dataset in CT Scans, J. Healthc. Eng. 3861161. doi: 10.1155/2022/3861161.
- [16] Islam, M.N., Hasan, M., Hossain, M.K., Alam, M. G. R., Uddin, M. Z., Soylu, A. 2022. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography, Sci. Rep., 12(1), 11440. doi: 10.1038/s41598-022-15634-4.
- [17] Sasikaladevi, N., Revathi, A. 2024. Digital twin of renal system with CT-radiography for the early diagnosis of chronic kidney diseases, Biomed. Signal Process. Control, 88, 105632. <https://doi.org/10.1016/j.bspc.2023.105632>.
- [18] Raza A., et al., 2022. A Hybrid Deep Learning-Based Approach for Brain Tumor Classification, Electronics, 11(7). doi: 10.3390/electronics11071146.
- [19] Yu, A.C., Mohajer, B., Eng, J. 2022. External Validation of Deep Learning Algorithms for Radiologic Diagnosis: A Systematic Review, Radiol. Artif. Intell., 4(3), e210064. doi: 10.1148/ryai.210064.
- [20] CT Kidney Dataset: Normal-Cyst-Tumor and Stone. (2023, 06 Haziran) Erişim Adresi.” <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>.
- [21] Tan, M., Emeksiz, C. 2023. Yüz Tanıma Sistemleri İçin Geliştirilmiş Veri Artırma Temelli Adaptif Yüz Tanıma Modeli, Düzce Üniversitesi Bilim ve Teknol. Derg., 11(2), 588–606. doi: 10.29130/dubited.1024670.
- [22] Koushik, J. 2016. Understanding Convolutional Neural Networks. <http://arxiv.org/abs/1605.09081>.
- [23] Tosunoğlu, N.G., Benli, Y.K. 2012. Forecasting of Morgan Stanley Capital International Turkey Index with Artificial Neural Networks, Ege Acad. Rev., 12(4), 541–547.
- [24] Krizhevsky, A., Sutskever, I., Hinton, G.E. 2017. ImageNet Classification with Deep Convolutional Neural Networks, Commun. ACM, 60(6), 84–90. doi: 10.1145/3065386.
- [25] da Rocha, D.A., Ferreira, F. M. F., Peixoto, Z. M. A. 2022. Diabetic retinopathy classification using VGG16 neural network, Res. Biomed. Eng., 38(2), 761–772. doi: 10.1007/s42600-022-00200-8.
- [26] Karacı, A. 2022. VGGCOV19-NET: automatic detection of COVID-19 cases from X-ray images using modified VGG19 CNN architecture and YOLO algorithm, Neural Comput. Appl., 34(10), 8253–8274. doi: 10.1007/s00521-022-06918-x.
- [27] Balasubramaniam, S., Velmurugan, Y., Jaganathan, D., Dhanasekaran, S. 2023. A Modified LeNet CNN for Breast Cancer Diagnosis in Ultrasound Images, Diagnostics, 13(17). doi: 10.3390/diagnostics13172746.
- [28] Maqsood, S., Damaševičius, R., Maskeliūnas, R. 2022. Multi-Modal Brain Tumor Detection Using Deep Neural Network and Multiclass SVM, Medicina (B. Aires), 58(8). doi: 10.3390/medicina58081090.
- [29] Rajpurkar, P., Chen, E., Banerjee, O., Topol, E.J. 2022. AI in health and medicine, Nat. Med., 28(1), 31–38. doi: 10.1038/s41591-021-01614-0.



**(Araştırma Makalesi)****Koroner Arter Hastalığı Sınıflandırılmasında Destek Vektör Makinelerinin Gri Kurt Optimizasyonuna Dayalı Özellik Seçim Yöntemi ile Geliştirilmesi****Büşra ER<sup>\*1</sup>, Uğur FİDAN<sup>2</sup>**<sup>1</sup> Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Bölümü, 03030, Afyon,ORCID No : <http://orcid.org/0000-0001-9682-8651><sup>2</sup> Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, 03030, Afyon,ORCID No : <http://orcid.org/0000-0003-0356-017X>**Anahtar Kelimeler:**Gri Kurt Optimizasyonu,  
Öznitelik Çıkarımı,  
Destek Vektör Makinesi,  
Koroner Arter Hastalığı,  
Çekirdek Matris

**Özet:** Makine öğrenmesi yöntemleri, büyük veri kümelerinin analiz edilmesine olanak sağlayarak koroner arter rahatsızlığı ve/veya buna benzer hastalık ve durumların tespit edilmesinde kullanılan etkili bir araçtır. Büyük veri kümelerinde işlem hızını ve sınıflandırma başarımını olumsuz etkileyen veriler bulunabilmektedir. Özellik seçim tekniklerinin uygulanması gereksiz verilerin ortadan kaldırılmasına olanak sağlamaktadır. Bu çalışmada, koroner arter hastalığını teşhis etmek amacıyla destek vektör makineleri ve gri kurt optimizasyon algoritmasının birlikte kullanıldığı bir yöntem önerilmektedir. Önerilen yöntem, öznitelik seçimi ve sınıflandırma olmak üzere iki ana aşamadan oluşmaktadır. Yöntemin performans doğrulaması için Cleveland kalp hastalığı veri seti kullanılmıştır. Yöntemin ilk aşamasında kullanılan veri setinden en uygun özellik alt kümesini belirlemek üzere gri kurt optimizasyon algoritması (GWO) kullanılmıştır. İkinci aşamada, GWO'nun uygunluk fonksiyonu, destek vektör makinesi (SVM) sınıflandırıcısı kullanılarak değerlendirilmiştir. İlk aşamadan elde edilen sonuçlara bakıldığında kullanılan veri setinde bulunan 13 parametre arasından belirlenen 7 parametre seçilmiş ve sınıflandırma işlemi bu parametreler üzerinden gerçekleştirilmiştir. Çalışmada belirlenen uygunluk fonksiyonları SVM'de kullanılan çekirdek matrislerin farklı varyasyonları ile değerlendirilmiştir. Bu aşamada en yüksek doğruluk elde edilen çekirdek matris belirlenmiştir. Deneysel sonuçlar, önerilen GWO-SVM'nin lineer çekirdek matris kullanılarak %95.91 doğrulukta, %95.64 duyarlılıkta ve %91.66 başarı ile mevcut çalışmalara kıyasla daha yüksek başarı sağlandığını göstermiştir.

**(Research Article)****Development of Support Vector Machines in The Classification of Coronary Artery Disease with Gray Wolf Optimization Based Feature Selection Method****Keywords:**Grey Wolf Optimization,  
Feature Selection,  
Support Vector Machine,  
Coronary Artery Disease,  
Kernel Matrix

**Abstract:** Machine learning methods are an effective tool used to detect coronary artery disease and/or similar diseases and conditions by allowing the analysis of large data sets. Large data sets may contain data that negatively affects processing speed and classification performance. Applying feature selection techniques allows the elimination of unnecessary data. In this study, a method that uses support vector machines and gray wolf optimization algorithm together to diagnose coronary artery disease is proposed. The proposed method consists of two main stages: feature selection and classification. The Cleveland heart disease dataset was used for performance validation of the method. The gray wolf optimization algorithm (GWO) was used to determine the most appropriate feature subset from the dataset used in the first stage of the method. In the second stage, the fitness function of GWO was evaluated using the support vector machine (SVM) classifier. Considering the results obtained from the first stage, 7 parameters were selected among the 13 parameters in the data set used and the classification process was carried out on these parameters. The fitness functions determined in the study were evaluated

with different variations of the kernel matrices used in SVM. At this stage, the core matrix with the highest accuracy was determined. Experimental results showed that the proposed GWO-SVM achieved higher performance compared to existing studies, with 95.91% accuracy, 95.64% sensitivity and 91.66% success using the linear kernel matrix.

## 1. GİRİŞ

Son yıllarda, tıbbi teşhis ve karar verme süreçlerinde makine öğrenimi ve veri madenciliği yöntemleri sıklıkla kullanılmaya başlanmıştır [1]. Tıp endüstrisinde [2], kalp hastalıkları [3-5] beyin tümörü [6-8] cilt kanseri [9,10], meme kanseri [11] vb. gibi çeşitli hastalık tahmin modellerinde veri madenciliği teknikleri kullanılmaktadır. Yüksek mortalite oranı ve hızı nedeni ile kalp hastalıkları en sık çalışılan konular içerisinde yer almaktadır. Kalp hastalıkları içerisinde en fazla prevalansa sahip olan rahatsızlıklar kardiyovasküler hastalıkları (KDH), koroner kalp hastalığı (KKH), koroner arter hastalığı (KAH), romatizmal kalp hastalığı, serebrovasküler hastalıklar (inme), hipertansiyon ve kalp yetmezliğidir [12]. Belirtilen kalp rahatsızlıkları arasındaki KAH, kalbe giden gerekli kan akışını bloke eden atardamarların iç duvarında yağ ve kolesterol birikmesi nedeniyle yaygın olarak ortaya çıkan bir kalp rahatsızlığıdır [13].

Konu ile ilgili olarak literatürde yapılan çalışmalar incelendiğinde; Abdar ve arkadaşları koroner arter hastalığı teşhisi için 10 farklı makine öğrenim tekniğini denemiş ve bunlardan en iyi sonuç veren 3 destek vektör makine algoritmasını sınıflandırma için seçmiştir. Sınıflandırmada optimizasyonu sağlamak için parçacık sürü optimizasyonu (Particle swarm optimization-PSO) ve genetik algoritmadan (Genetic algorithm-GA) oluşan sarmal bir yapı kullanılmıştır. Çalışmada %93.08 doğruluk ve %91.51 F1 skoru elde edilmiştir [14]. Al-Tashi ve arkadaşları tarafından 2019 yılında yapılan diğer bir çalışmada Cleveland kalp hastalığı veri seti üzerinde gri kurt optimizasyon algoritması (Grey wolf optimization-GWO) ile öznelik çıkarımı yapılarak destek vektör makinesi (Support vector machine-SVM) ile sınıflandırma yapılmıştır. Çalışmada sonucunda aynı veri setini kullanan diğer çalışmalara göre daha yüksek doğrulukta sınıflandırma başarımı elde edilmiştir [15]. Tama ve arkadaşları tarafından 2020 yılında yapılan çalışmada koroner kalp hastalığı tahmini için farklı veri setleri (Z-Alizadeh Sani, Statlog, Cleveland ve Hungarian) kullanılmıştır. Parçacık sürü optimizasyonu ile öznelik çıkarımlarının gerçekleştirilmesinin ardından sınıflandırma için 3 farklı makine öğrenmesinden oluşan mimari oluşturulmuştur. Bu çalışma o tarihe kadar yapılan diğer çalışmalara kıyasla daha yüksek doğrulukta sonuçlar üretmiştir [16]. Moturi ve arkadaşları tarafından yapılan çalışmada kalp hastalığı ve meme kanseri teşhisinde kullanılmak üzere; GWO ve yusufoçuk algoritması birleştirilmiş ve diğer popüler hibrid algoritmalarla elde edilen sonuçlar karşılaştırılmıştır [17]. Kalp yetmezliği erken teşhis edilebilmesi için 2021 yılında gerçekleştirilen bir başka çalışmada çok katmanlı perceptron mimarisi geliştirilmiştir. Girdi sayısını

azaltmak için PSO-GWO kullanan sarmal yapı öznelik seçimi önerilmiştir [18]. Yapılan bir diğer çalışmada kalp hastalığı tahmini için diferansiyel evrimli gri kurt optimizasyon algoritması ve ateşböceği algoritması kullanılmıştır. Önerilen sınıflandırma optimum ağırlıkları elde etmek için sinir ağını eğitmekte ve çok sayıda hiperparametreyi verimli bir şekilde ayarlamaktadır. Veri setleri üzerinde denenen sonuçlarda, kalp hastalığı tahmini için uygun hale getiren yöntemin etkinliğini ortaya koyulmuştur [19]. Krishna ve arkadaşları tarafından yapılan çalışmada ise özellik seçimi için hibrit gri kurt optimizasyon algoritması kullanılmıştır. PSO ve GWO'yu birleştiren algoritmalarda öznelik çıkarımı yapılırken k-en yakın komşu sınıflandırıcısı ve Öklid ayırma matrisi kullanılmıştır. Bu seçeneklerde en iyi sonuç veren algoritma GWOPSO-KNN olarak bulunmuştur. [20]. Arabasadi ve arkadaşlarının yaptığı çalışmada, koroner arter hastalığının teşhisi için Cleveland kalp hastalığı veri seti kullanılarak, hibrit bir yöntem önerilmiştir. Bu yöntemde yapay sinir ağının başlangıç ağırlıkları genetik algoritma ile belirlenmiştir. Daha sonra eğitim verileri kullanılarak yapay sinir ağı öğrenimi gerçekleştirilmiştir [21]. Paul ve arkadaşlarının yaptığı çalışmada kalp hastalığının risk düzeyini tahmin etmek için değiştirilmiş dinamik çok kümelili parçacık sürüsü optimizasyonuna (MDMS-PSO) ve genetik algoritmaya (GA) dayalı bir otomatik bulanık teşhis sistemi önerilmiştir [22]. Subanya ve arkadaşlarının yaptığı çalışmada, hastalık tanımlamasında optimal özellikleri elde etmek için yapay arı kolonisi (Artificial bee colony algorithm-ABC) algoritmasına ve SVM'ye dayalı bir özellik seçim yöntemi önerilmiştir. SVM sınıflandırması, ABC'nin uygunluğunu değerlendirmek için kullanılmıştır [23].

Literatürde yapılan çalışmalar incelendiğinde Cleveland veri seti ve farklı veri setleri makine öğrenmesi çalışmalarında kullanılmaktadır. Farklı optimizasyon teknikleri ve farklı sınıflandırıcılarla yapılan çalışmalarda tahmin başarısının ve sistem çalışma hızının arttığı görülmektedir. Bu çalışmada; Cleveland kalp hastalığı veri setinde gri kurt optimizasyon algoritmasıyla özellik seçimi gerçekleştirilecektir. Özellik seçimi öncesinde ve sonrasında SVM ile sınıflandırma yapılacaktır. SVM'de kullanılan çekirdek fonksiyonların da sınıflandırma başarımına olan etkisi incelenecektir. SVM'de kullanılan çekirdek fonksiyonlar değiştirilerek deneyler yeniden gerçekleştirilecek ve en yüksek doğrulukta sonuçlar elde edilmeye çalışılacaktır. Böylece koroner arter hastalığı teşhisinde daha az sayıda parametreler ile daha yüksek tahmin gücüne sahip ve daha hızlı çalışacak algoritmanın geliştirilmesi hedeflenmektedir.

## 2. MATERYAL VE METOT

### 2.1. Gri Kurt Optimizasyon Algoritması

Tablo 1’de GWO’nun kaba koduna yer verilmiştir. Gri kurt optimizasyon algoritması (Tablo 1), kurt sürüsünün avlanma davranışından ilham alınarak geliştirilmiş meta-sezgisel optimizasyon algoritmasıdır. Bu algoritma, karmaşık optimizasyon problemlerinin çözümünde etkilidir ve literatürde birçok çalışmada başarılı sonuçlar elde edilmiştir [15,17-19]. Algoritma, kurt sürüsünün davranışlarını taklit ederek çalışmaktadır. Her bir kurt, bir çözüm adayını temsil eder. Başlangıçta, kurtlar rasgele dağılır. Her bir kurt, mevcut çözümünün kalitesini değerlendiren uygunluk fonksiyonuna göre bir uygunluk değeri alır. Daha sonra, kurtlar arasında bilgi paylaşımı gerçekleşir. Algoritma keşif, kaçınma ve takip olmak üzere üç temel davranışı modellemektedir. Keşif davranışı, kurtların çevreyi araştırmak için hareket etmelerini sağlar. Kaçınma davranışı, düşük kaliteli çözümlerden kaçınmak amacıyla yapılan bir davranıştır. Takip davranışı ise yüksek kaliteli çözümleri takip etmek ve bunları geliştirmek için yapılan bir davranışı temsil etmektedir [24].

**Tablo 1.** Gri kurt optimizasyonu kaba kodu


<p>Maksimum yineleme sayısını ayarlayın (L)          Popülasyonu başlat <math>X_i</math> (<math>i = 1, 2, \dots, n</math>)          Başlat <math>\alpha</math>, A, ve C          Kurtların uygunluk durumunu hesapla  <math>X_\alpha</math> = En iyi arama ajanı  <math>X_\beta</math> = İkinci iyi arama ajanı  <math>X_\delta</math> = Üçüncü iyi arama ajanı  <b>while</b> (<math>t &lt; L</math>) <b>do</b>              <b>for</b> her aramayı ajan <b>do</b>                  Geçerli arama aracısının konumunu güncelle              <b>end for</b>              Başlat <math>\alpha</math>, A, ve C              Tüm ajanların uygunluk fonksiyonunu hesapla              Güncelle <math>X_\alpha</math>, <math>X_\beta</math> ve <math>X_\delta</math>              <math>T=t+1</math>  <b>end while</b>  <b>return</b> <math>X_\alpha</math></p>
--

### 2.1. Çekirdek Matris ve Destek Vektör Makineleri

Çekirdek matris (Kernel matrix), matris çarpımı işlemlerinde kullanılan matematiksel bir kavramdır. Çekirdek matris, genellikle bir matrisin içerdiği bilgileri özetlemek veya işlemek için kullanılmaktadır. Bu işlem veri analizi ve makine öğrenimi uygulamaları için faydalı veri üretimi sağlamaktadır [25, 26] Örneğin veri madenciliği uygulamalarında benzerlik veya uzaklık ölçümlerini temsil etmek için kullanılırken [27] görüntü işleme uygulamalarında nesne tanıma, yüz tanıma ve diğer görüntü analizi işlemlerinde kullanılmaktadır [28].

Destek vektör makineleri istatistiksel öğrenme teorisinde kullanılan yeni bir makine öğrenme tekniğidir. Özellikle non-lineer sınıflandırma problemlerini çözmede etkilidir

[29]. SVM'nin temel mantığı, non-lineer eğitim verilerinin çekirdek matrisler aracılığıyla daha yüksek boyutlu özellik uzayına eşlenmesi işlemidir. SVM algoritmaları, çekirdek matrislerle birlikte sıralı matematiksel işlemlere tabi olurlar. SVM’de Lagrange çarpanları ve çekirdek matrislerle optimizasyon sağlayan diskriminasyon (optimal) hiperdüzlemleri (Şekil 1) oluşturulmaktadır. Lagrange çarpanları ve çekirdek matrisleri yanlış sınıflandırma olasılığı bulunmayan durumlarda lineer ayrılabilir hiperdüzlemler oluşturabilir. SVM’ler aşırı takılmayı önlediklerinden dolayı meydana gelen sorunları göz ardı etme yeteneğine sahiptir.



**Şekil 1.** Lineer regresyon grafiksel gösterimi [30]

SVM eğitimi her zaman evrensel olarak optimize bir çözüm uzayı arayışındadır. Lineer ayrılabilir veri uzaylarında, hiperdüzlem fonksiyonu Denklem (1)’deki gibidir.

$$w \bullet x + b = 0 \quad w \in \mathbb{R}^N, \quad b \in \mathbb{R} \quad (1)$$

Denklem (2)’de, optimize lineer bölme işlemi için iki sınıfı ayıran bir hiperdüzlem oluşturulur.

$$y_i (w \bullet x + b) \geq 1, \quad i = 1, \dots, N \quad (2)$$

SVM yaklaşımı, bu şartlarda  $\|w\|$ ’yi en aza indirgeyerek en uygun hiperdüzlemi bulmaya çalışır. Burada  $\|w\|$ ,  $w$  vektörünün Öklidyen normunu ifade eder ve hiperdüzlem ile her sınıfın en yakın veri noktaları arasındaki mesafe  $1/\|w\|$ ’dir. Lagrange çarpanları  $\alpha_i$  olarak belirlenmesiyle, SVM eğitim işlemi konveks kare problemini çözmekle eşdeğerdir. Denklem (3) evrensel optimizasyon çözümünü vermektedir.

$$w = \sum_i^N \alpha_i y_i x_i \quad (3)$$

Denklem 3’te,  $\alpha_i$  0’den farklı bir sayı olmak üzere  $x_i$  destek vektörü olarak adlandırılır. SVM eğitiminde her yeni  $x$  yalnızca destek vektör  $\{x_i\}$  ile karşılaştırılarak karar alınır. ( $\{x_i\}, i \in SV$ ) (Denklem (4))

$$y = \text{sign}(\sum_{i \in SV} \alpha_i y_i) (x_i \bullet x^T) + b \quad (4)$$

SVM, ayrılabilir non-lineer olan durumlarda, giriş vektörü  $x$ ’i, verilerin çekirdek işlevi tarafından belirlenen daha yüksek boyutlu bir özellik uzayına non-lineer olarak eşlemek için kullanılır. SVM algoritmaları farklı çekirdek fonksiyonlarıyla kullanılabilir. Lineer, non-lineer,

radyal baz fonksiyonu, sigmoid fonksiyon ve polinom fonksiyonları şeklinde farklı çekirdek matris fonksiyonu bulunmaktadır. Veri sınıflandırmasında yaygın olarak kullanılan tipik çekirdek işlevleri Tablo 2'de listelenmiştir.

**Tablo 2.** Çekirdek matrislerin formülasyonları

Çekirdek (Kernel)	$K(x, x_i)$
Lineer	$x^T \cdot x_j$
Polinom	$(x^T \cdot x_j + 1)^d$
Radyan Tabanlı Fonksiyon (RBF)	$exp(-  x - x_j  ^2 / 2\sigma^2)$

Çekirdek matrislerin seçimi verilere bağlı olarak yapılmaktadır. Optimum sınıflandırma sonucu elde etmek için farklı çekirdek yapısı kullanılabilir.

### 2.3. Önerilen Yöntem

Bu çalışma, koroner arter hastalığını teşhis etmek için etkili bir özellik seçme yöntemi olan GWO-SVM'yi önermektedir. İlk aşamada GWO yöntemi, Cleveland koroner arter veri setindeki en iyi özellikleri arayarak gereksiz ve ilgisiz özellikleri ortadan kaldırmak için kullanılır. GWO ilk olarak, popülasyon başlangıç konumlarını üretir ve ardından ayırık arama uzayında popülasyonun mevcut konumlarını günceller. GWO, popülasyonun mevcut konumlarını güncelledikten sonra, her bir bireyin uyum değerlerini değerlendirir ve en iyi performans gösteren bireyleri belirler. Bu aşamada, bireyler arasındaki benzerlikleri ve farklılıkları analiz ederek, popülasyonun genetik çeşitliliğini artırmak ve daha etkili bir arama stratejisi oluşturmak için özellik çıkarımı yapılır. İkinci aşamada, birinci aşamada elde edilen optimal özellik alt kümesine dayalı olan özellikler destek vektör makineleri ile sınıflandırılır. Destek vektör makinelerinde kullanılmış olan çekirdek fonksiyonları değiştirilerek ve GWO ile özellik seçimi yapılarak sisteminin doğruluğu ve hassasiyetinin artırılması bu çalışmada amaçlanmıştır. Özellik seçimi ile sistemin daha hızlı yanıt verebilmesi ve gereksiz verilerden kaynaklı gürültünün engellenmesi sağlanmaktadır. Önerilen yöntem Python dilinde Jupyter derleyicisinde gerçekleştirilmiştir.

Veri seti olarak UCI üzerinden edinilen Cleveland koroner arter hastalığına ait veriler kullanılmıştır. Veri setine ait özniteliklerin açıklaması Tablo 3'te yer almaktadır.

**Tablo 3.** Cleveland veri kümesi özellikleri

No	Özellikler	Değerler
1	Age	Yaş
2	Sex	0 Kadın/ 1 erkek
3	Cp	Göğüs ağrısı tipi
		Durum 1: Tipik anjina
		Durum 2: Atipik anjina
		Durum 3: Anjinal olmayan ağrı
4	Trestbps	Durum 4: Asemptomatik
		Kan şekeri
5	Chol	Kolestrol
6	Fbd	(Açlık kan şekeri > 120 mg/dl) (1=Doğru; 0= Yanlış)
7	Rest-Ecg	EKG
8	Thalach	Maksimum kalp atışı
9	Exang	Egzersize bağlı angina

10	Oldpeak	Dinlenmeye göre egzersizin neden olduğu ST düşümü
11	Slope	Egzersiz sırasındaki ST'nin eğim ve tepe değeri
12	Ca	Floroskopide renklenmiş damar sayısı
13	Thal	Kusur tipi

Tablo 4'te önerilen yöntemde kullanılan parametrelerin değerleri belirtilmiştir. Uygunluk fonksiyonu için  $\alpha$  ve  $\beta$  parametreleri bildirilmiştir.

**Tablo 4.** Cleveland veri kümesi özellikleri

Parametre	Değer
İterasyon Sayısı	100
Kurt Sayısı	5
Boyut Sayısı	13
Arama Alanı	[0,1]
Uygunluk fonksiyonundaki $\alpha$	0.99
Uygunluk fonksiyonundaki $\beta$	0.01

### 2.3. İkili sınıflandırma için performans ölçütleri

Önerilen yöntemin performansı, doğru pozitif (TP), doğru negatif (TN), yanlış negatif (FN) ve yanlış pozitif (FP) terimlerini kullanan duyarlılık, özgüllük ve doğruluk testlerine dayalı olarak değerlendirilmiştir. Bu performans ölçütleri Denklem (5), Denklem (6) ve Denklem (7)'deki gibi hesaplanır [31].

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \times 100\% \quad (5)$$

$$\text{Özgüllük} = \frac{TN}{FP+TN} \times 100\% \quad (6)$$

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (7)$$

## 3. BULGULAR

Çalışma sırasında SVM'de kullanılan farklı çekirdek fonksiyonları ile deneyler gerçekleştirilmiştir. Çalışma sırasında destek vektör makinelerinde kullanılan çekirdek matrislerde lineer matris, polinom matrisi ve radyan tabanlı fonksiyon matrisleri kullanılmıştır.

Her matrisle deney 10 kez gerçekleştirilmiş ve en iyi sınıflandırma sonuçlarının lineer matrisin kullanıldığı destek vektör makineleri sisteminde elde edildiği görülmüştür. Çalışmada özellik seçimlerinde 7 ayrı özellik belirlenmiştir. Bu özelliklerle yapılan farklı çekirdek matrisler kullanılarak yapılan çalışmanın sonuçları Tablo 5'te verilmiştir.


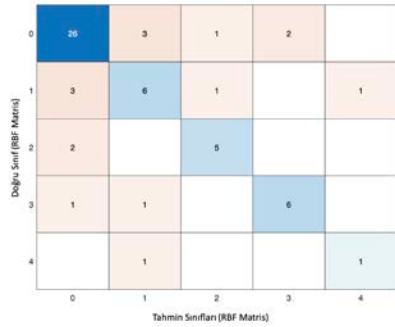

GWO-SVM'nin lineer çekirdek matris kullanılarak veri setinde kullanılan 7 ayrı özellikle en doğru sonucun elde edildiği bulunmuştur. Bu deney sonucunda veri seti teşhis sınıflandırmasının %95.36 doğruluk, %95.64 duyarlılık ve %95.91 oranında özgüllük oranına sahip olduğu görülmüştür.

GWO'da özellik seçimi gerçekleştirilmeden yalnızca SVM kullanılarak ve SVM'de çekirdek matris olarak lineer matris kullanıldığı durumda sınıflandırmadan elde edilen doğruluk oranı %59.83 olarak bulunmuştur. GWO ile özellik seçim parametrelerinin tamamlanması ardından tekrar destek vektör makineleri ile sınıflandırma gerçekleştirilmiş ve doğruluk oranı %95.36'ya yükselmiştir.


**Tablo 5.** Cleveland veri kümesi özellikleri

SVM (Test) Çekirdek Matris	Doğruluk	Özellik Seçimi (GWO)	SVM (Test) Çekirdek Matris	Doğruluk	Duyarlılık	Özgüllük
Lineer	%59,83	1,2,3,6,7,8,9 (Tablo 3)	Lineer	%95,36	%95,64	%95,91
Polinom	%59,83	1,2,3,6,7,8,9 (Tablo 3)	Polinom	%76,22	%79,54	%80
RBF	%63,93	1,2,3,6,7,8,9 (Tablo 3)	RBF	%87,70	%83,45	%82,92

Tablo 5'te lineer matristen elde edilen sonuçların yanı sıra, polinom matris ve RBF matris kullanılarak elde edilmiş SVM sınıflandırma sonuçları görülmektedir. Şekil 2, şekil 3 ve şekil 4'te sırasıyla lineer matris, RBF matris ve poly matrisin kullanıldığı destek vektör makinelerinden elde edilen sonuçlara ait hata matrislerine (Confusion matrix) yer verilmiştir. Şekillerde yer 0,1,2,3 ve 4 ile tanımlanmış sınıflarda; 0-sağlıklı bireyi, 1,2,3 ve 4 ise kalp hastalığı varlığını tanımlamaktadır.

**Şekil 2.** SVM sonunda elde edilen test verilerine ait hata matrisi (Lineer Kernel)**Şekil 3.** SVM sonunda elde edilen test verilerine ait hata matrisi (RBF Kernel)**Şekil 4.** SVM sonunda elde edilen test verilerine ait hata matrisi (Poly Kernel)

Şekil 6'da lineer kernel kullanılan SVM'den elde edilen ROC eğrisine ait grafik sunulmuştur.

**Şekil 5.** Lineer kernel kullanılmış SVM'ye ait ROC eğrisi

#### 4. TARTIŞMA VE SONUÇ

Önerilen yöntem ve literatürde yapılan çalışmaların karşılaştırılması Tablo 6'da özetlenmiştir. Yöntemin tarafsız olarak karşılaştırılabilmesi için Cleveland veri setini kullanılan çalışmalar referans olarak seçilmiştir. Tablo 6'ya bakıldığında, bu çalışmada gerçekleştirilen GWO-SVM (Lineer), GWO-SVM (RBF) yöntemiyle elde edilen doğruluk değerlerinin Subanya ve arkadaşları tarafından önerilen ABC-SVM yönteminden elde edilen doğruluk değerlerine göre sırasıyla %11,18 ve %2,26 oranında artmıştır [23]. Bu çalışmada doğruluk değerleri hesaplanmadığı için duyarlılık ve özgüllük değerleri kıyaslanamamıştır.

**Tablo 6.** Referans çalışmalar ve bu çalışmadan elde edilen sonuçlar

Referans	Yöntem	Doğruluk	Duyarlılık	Özgüllük
[23]	ABC-SVM	%86,76	N/A	N/A
[22]	GA-FBSS	%80,00	%84,00	%75,00
[21]	GA-NN	%89,40	%88,00	%91,00
[15]	GWO-SVM	%89,83	%93,00	%91,00
Bu çalışma	GWO-SVM (Poly)	%76,22	%79,54	%80,00
Bu çalışma	GWO-SVM (Lineer)	%95,36	%95,64	%95,91
Bu çalışma	GWO-SVM (RBF)	%87,70	%83,45	%82,92

Paul ve arkadaşları tarafından önerilen GA-FBSS yöntemde doğruluk, duyarlılık ve özgüllük değerleri bu çalışmada gerçekleştirilen GWO-SVM (Lineer) yöntemine göre daha düşük başarımları vermiştir [22]. Bu çalışma ile GWO-SVM (Lineer) yöntemi kıyaslandığında; doğruluk değeri %19.2, duyarlılık değeri %13.86 ve özgüllük değeri %27.88 arttığı görülmektedir. Paul ve arkadaşları tarafından yapılan çalışmada elde edilen performans değerleri ve bu çalışmada GWO-SVM (RBF) değeri ile elde edilen sonuçlar karşılaştırıldığında bu çalışmada elde edilen doğruluk değeri %9.62, özgüllük değeri %10.56 oranında artmış ve duyarlılık değeri % 0.65 oranında azalmıştır. Paul ve arkadaşları tarafından gerçekleştirilen çalışma ve bu yöntemle gerçekleştirilen GWO-SVM (Poly) yöntemi kıyaslandığında ise GWO-SVM (Poly) yönteminin performans metriklerinin daha düşük olduğu görülmektedir.

Arabasadi ve arkadaşları tarafından yapılan çalışmada GA-NN yöntemi ile farklı veri setleri ve Cleveland veri seti bulguları değerlendirilmiştir [21]. Arabasadi ve arkadaşları tarafından yapılan çalışmada elde edilen performans metrikleri, bu çalışmada elde edilen GWO-SVM (Poly) ve GWO-SVM (RBF) yöntemine göre daha iyi performans göstermiştir. Fakat bu çalışmada gerçekleştirilen GWO-SVM (Lineer) yöntemi doğruluk, duyarlılık ve hassasiyet metriklerinde sırasıyla %6.67, %6.98 ve %5.40 daha fazla başarımları göstermiştir.

Al-Tashi ve arkadaşları [15] tarafından yapılan GWO-SVM yöntemi bu çalışma ile benzerlik göstermektedir. Bu çalışmada optimizasyon sürecinde SVM'de kullanılan çekirdek matrisler değiştirilerek bulguların performansları karşılaştırılmıştır. Elde edilen sonuçlarda bu çalışmada gerçekleştirilen GWO-SVM (Lineer) yöntemi ile Al-Tashi ve arkadaşları tarafından yapılan çalışmayla arasındaki doğruluk değerinde %6.65, duyarlılık değerinde %2.84 ve hassasiyet değerinde %5.40 daha fazla başarımları sağlamıştır.

Sonuç olarak bu çalışmada gri kurt optimizasyonuna dayalı özellik seçim yöntemi ve destek vektör makineleriyle sınıflandırma işlemi önerilmiştir. Önerilen yöntem veri setinden gereksiz ve ilgisiz özellikleri kaldırmayı sağlamıştır. Cleveland veri setinden elde edilen özellik seçimleri sonucu veri setinde bulunan 13 ayrı parametre arasından, tanı koymaya en uygun 7 parametre belirlenmiştir. Bu parametreler yaş, cinsiyet, göğüs ağrısı tipi, açlık kan şekeri, EKG verileri, maksimum kalp atış hızı ve egzersize bağlı anjina olarak tespit edilmiştir. Deneysel sonuçlar, önerilen yöntemin doğruluk, duyarlılık ve özgüllük açısından performansı arttığını göstermektedir. Gerçekleştirilen çalışmada 7 ayrı parametre ile kalp hasatlığı teşhis yöntemi üzerine yeni bir yöntem önerilmektedir ve önerilen yöntemin optimum teşhis parametresi gerektirdiğinden dolayı emsal yöntemlere göre daha hızlı ve performans metrikleri bakımından yüksek doğrulukta olduğu bulunmuştur.

Gelecekte yapılacak araştırmalarda uygulanan yöntemde bulunan öznelik seçim yöntemiyle farklı makine öğrenmesi yöntemleri birleştirilerek yapay zeka destekli sistemlerin başarımları artırılabilir.

## Etik Hususlar

## Etik Kurallara Uyum

Bu araştırma, planlamadan uygulamaya, veri toplama sürecinden veri analizine kadar tüm aşamalarda "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" çerçevesinde belirlenen kurallara uygunluk göstermiştir. Yönergenin ikinci bölümü olan "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altındaki kurallarda herhangi bir ihlal gerçekleştirilmemiştir. Çalışmanın yazım sürecinde bilimsel etik ve alıntı kurallarına tam olarak uyulmuş, toplanan veriler üzerinde herhangi bir manipülasyon yapılmamış, ayrıca bu çalışma, başka herhangi bir akademik yayın ortamında değerlendirme için gönderilmemiştir.

## Finansman

Yazarlar, bu çalışma için kamu, ticari veya kâr amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almadıklarını beyan ederler.

## Çıkar çatışması

Yazarlar olarak, bu çalışma ile ilgili herhangi bir kişi veya kurumla çıkar çatışması bulunmadığını onaylıyoruz.

## KAYNAKÇA

- [1] Shouman, M., Turner, T. & Stocker, R. 2012. Using data mining techniques in heart disease diagnosis and treatment. Japan-Egypt Conference on Electronics, Communications and Computers, 173-177. DOI: 10.1109/JEC-ECC.2012.6186978
- [2] Shehab, M., Abualigah, L., Shambour, Q., Abu-Hashem, M. A., Shambour, M. K. Y., Alslibi, A. I., & Gandomi, A. H. 2022. Machine learning in medical applications: A review of state-of-the-art methods. Computers in Biology and Medicine, 145, 105458. DOI: 10.1016/j.compbimed.2022.105458
- [3] Ahsan, M. M., Siddique, Z., 2022. Machine learning-based heart disease diagnosis: A systematic literature review. Artificial Intelligence in Medicine, 128, 102289. DOI: 10.1016/j.artmed.2022.102289
- [4] Averbuch, T., Sullivan, K., Sauer, A., Mamas, M. A., Voors, A. A., Gale, C. P., Van Spall, H. G. 2022. Applications of artificial intelligence and machine learning in heart failure. European Heart Journal-Digital Health, 3(2), 311-322. DOI: 10.1093/ehjdh/ztac025
- [5] Ramesh, T. R., Lilhore, U. K., Poongodi, M., Simaiya, S., Kaur, A., Hamdi, M. 2022. Predictive analysis of heart diseases with machine learning approaches. Malaysian Journal of Computer Science, 132-148. DOI: 10.22452/mjcs.sp2022no1.10

- [6] Taha, B., Liza, F. R., Masud, M. A., Bepery, C., Islam, M. T., Samsuzzaman, M. 2023. BrainVisionNet: A Deep Learning-based approach to evaluate the potential of microwave imaging for classification of brain tumors. In 2023 International Conference on Next-Generation Computing, IoT and Machine Learning, 1-6.  
DOI: 10.3390/healthcare9020153
- [7] Arabahmadi, M., Farahbakhsh, R., Rezazadeh, J. 2022. Deep learning for smart Healthcare-A survey on brain tumor detection from medical imaging. *Sensors*, 22(5).  
DOI: 10.3390/s22051960
- [8] Shoeibi, A., Khodatars, M., Jafari, M., Ghassemi, N., Moridian, P., Alizadesani, R., Gorriz, J. M. 2022. Diagnosis of brain diseases in fusion of neuroimaging modalities using deep learning: A review. *Information Fusion*.  
DOI: 10.1016/j.inffus.2022.12.010
- [9] Mazhar, T., Haq, I., Ditta, A., Mohsan, S. A. H., Rehman, F., Zafar, I., Goh, L. P. W. 2023. The role of machine learning and deep learning approaches for the detection of skin cancer. In *Healthcare*, 11(3), 415.  
DOI: 10.3390/healthcare11030415
- [10] Tembhurne, J. V., Hebbar, N., Patil, H. Y., Diwan, T. 2023. Skin cancer detection using ensemble of machine learning and deep learning techniques. *Multimedia Tools and Applications*, 1-24.  
DOI: 10.1007/s11042-023-14697-3
- [11] Humayun, M., Khalil, M. I., Almuayqil, S. N., Jhanjhi, N. Z. 2023. Framework for detecting breast cancer risk presence using deep learning. *Electronics*, 12(2), 403.  
DOI: 10.3390/electronics12020403
- [12] Krishnaiah, V., Narsimha, G., Chandra, N.S. (2015) Heart disease prediction system using data mining technique by fuzzy K-NN approach. *Emerging ICT for Bridging the Future Proceedings of the 49th Annual Convention of the Computer Society of India (CSI)*, 1, 371–384.  
DOI: 10.1007/978-3-319-13728-5\_42
- [13] Libby, P., Theroux, P. 2005. Pathophysiology of coronary artery disease. *Circulation*, 111(25), 3481-3488.  
DOI: 10.1161/CIRCULATIONAHA.105.537878
- [14] Abdar, M., Książek, W., Acharya, U. R., Tan, R. S., Makarenkov, V., Pławiak, P. 2019. A new machine learning technique for an accurate diagnosis of coronary artery disease. *Computer methods and programs in biomedicine*, 179, 104992.  
DOI: 10.1016/j.cmpb.2019.104992
- [15] Al-Tashi, Q., Rais, H., Jadid, S. 2019. Feature selection method based on grey wolf optimization for coronary artery disease classification. In *Recent Trends in Data Science and Soft Computing: Proceedings of the 3rd International Conference of Reliable Information and Communication Technology*, 257-266.  
DOI: 10.1007/978-3-319-99007-1\_25
- [16] Tama, B. A., Im, S., Lee, S. 2020. Improving an intelligent detection system for coronary heart disease using a two-tier classifier ensemble. *BioMed Research International*, 2020.  
DOI: 10.1155/2020/9816142
- [17] Moturi, S., Rao, S. T., Vemuru, S. 2021. Grey wolf assisted dragonfly-based weighted rule generation for predicting heart disease and breast cancer. *Computerized Medical Imaging and Graphics*, 91, 101936.  
DOI: 10.1016/j.compmedimag.2021.101936
- [18] Le, T.M., Pham, T.N., Dao, S.V. 2021. A novel wrapper-based feature selection for heart failure prediction using an adaptive particle swarm grey wolf optimization. *Enhanced Telemedicine and e-Health: Advanced IoT Enabled Soft Computing Framework*, 315-336.  
DOI: 10.1007/978-3-030-70111-6\_15
- [19] Deepika, D., Balaji, N. 2022. Effective heart disease prediction with Grey-wolf with Firefly algorithm-differential evolution (GF-DE) for feature selection and weighted ANN classification. *Computer Methods in Biomechanics and Biomedical Engineering*, 25, 1409 - 1427.  
DOI: 10.1080/10255842.2022.2078966
- [20] Krishna, E. R., Devarakonda, N. 2023. Feature selection method based on GWO-PSO for coronary artery disease classification. *Third International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies*. 1-8.  
DOI: 10.1109/ICAECT57570.2023.10118351
- [21] Arabasadi, Z., Alizadehsani, R., Roshanzamir, M., Moosaei, H., Yarifard, A.A. 2017. Computer aided decision making for heart disease detection using hybrid neural network-Genetic algorithm. *Comput. Methods Programs Biomed.* 141, 19–26  
DOI: 10.1016/j.cmpb.2017.01.004
- [22] Paul, A.K., Shill, P.C., Rabin, M.R.I., Akhand, M. A. H. 2016. Genetic algorithm based fuzzy decision support system for the diagnosis of heart disease. *2016 5th International Conference on Informatics, Electronics and Vision*, 145–150  
DOI: 10.1109/ICIEV.2016.7759984
- [23] Subanya, B., Rajalaxmi, R. R. 2014. Feature selection using artificial bee colony for cardiovascular disease classification. 2014

International Conference on Electronics and  
Communication Systems.  
DOI: 10.1109/ECS.2014.6892729

- [24] Mirjalili, S., Mirjalili, S. M., Lewis, A. 2014. Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.  
DOI: 10.1016/j.advengsoft.2013.12.007
- [25] Lanckriet, G. R., Cristianini, N., Bartlett, P., Ghaoui, L. E., Jordan, M. I. 2004. Learning the kernel matrix with semidefinite programming. *Journal of Machine learning research*, 27-72.
- [26] Weinberger, K. Q., Sha, F., Saul, L. K. 2004. Learning a kernel matrix for nonlinear dimensionality reduction. In *Proceedings of the twenty-first international conference on Machine learning* (106).  
DOI: 10.1145/1015330.1015345
- [27] Huang, T. M., Kecman, V., Kopriva, I. 2006. Kernel based algorithms for mining huge data sets (1).  
DOI: 10.1007/3-540-31689-2
- [28] Takeda, H., Farsiu, S., Milanfar, P. 2007. Kernel regression for image processing and reconstruction. *IEEE Transactions on image processing*, 16(2), 349-366.  
DOI: 10.1109/tip.2006.888330
- [29] Zhang, K., Lan, L., Wang, Z., Moerchen, F. 2012. Scaling up kernel SVM on limited resources: A low-rank linearization approach. In *Artificial intelligence and statistics*, 1425-1434.
- [30] Astuti, W., Fadli, A., Tan, S., Akmeliawati, R. 2019. Brain signal recognition system based on One-Against-One Multiclass Support Vector Machines: a comparison with Multiclass Neural Network. In *Journal of Physics: Conference Series*, 1367(1), 012027.  
DOI: 10.1088/1742-6596/1367/1/012027
- [31] Cengil, E., Çınar, A. 2020. Göğüs verileri metrikleri üzerinden kanser sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(2), 513-519.  
DOI: 10.24012/dumf.578606



## (Araştırma Makalesi)

**Silis Dumanı İkameli Çimentoların Priz Sürelerinin ANFIS ile Tahmini**Yasemin Erdem<sup>1</sup>, Yılmaz KOÇAK<sup>\*2</sup><sup>1</sup>Düzce Üniversitesi, Lisansüstü Eğitim Enstitüsü, İnşaat Mühendisliği Anabilim Dalı, 81600, Düzce,ORCID No: <http://orcid.org/0000-0002-8640-1758><sup>2</sup>Düzce Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 81600, Düzce,ORCID No: <http://orcid.org/0000-0002-5281-5450>**Anahtar Kelimeler:**Priz süresi,  
Portland çimento,  
Silis dumanı,  
ANFIS

**Özet:** Bu çalışma, silis dumanı ikameli çimento hamurlarının priz sürelerinin ANFIS ile tahmin edilmesi amacıyla gerçekleştirilmiştir. Çalışmanın ilk bölümünde, Portland çimentosuna %0, %2.5, %5, %7.5 ve %10 oranlarında silis dumanı ikame edilerek elde edilmiş çimento hamurlarının priz başlama ve priz sonu süreleri tespit edilmiştir. İkinci bölümde, deneysel sonuçlarla Üçgen ve Gauss üyelik fonksiyonlarıyla iki model oluşturularak priz başlama ve priz sonu süreleri tahmin edilmiştir. Üçüncü bölümdeyse tahmin sonuçlarının güvenilirliği belirtebilmek için R<sup>2</sup>, MAPE ve RMSE istatistiksel yöntemlerinden yararlanılmıştır. Sonuç olarak R<sup>2</sup>, MAPE ve RMSE değerleri priz başlama ve priz sonu sürelerine göre sırasıyla; Üçgen üyelik fonksiyonu için 0.9882-0.9778, 0.015156-0.018960 ve 3.8027-5.8689, Gauss üyelik fonksiyonu için ise 0.9882-0.9778, 0.015226-0.018956 ve 3.8006-5.8689 olarak tespit edilmiştir. Bu sonuçlara göre hem priz başlama ve hem de priz sonu sürelerinin Üçgen ve Gauss üyelik fonksiyonlarıyla oluşturulan modellerle “çok iyi” veya “yüksek doğruluk derecesinde” tahmin edilebileceği ifade edilebilir.

## (Research Article)

**Prediction of the Effect of Silica Fume on Portland Cement Setting Times by ANFIS****Keywords:**Setting time,  
Portland cement,  
Silica fume,  
ANFIS

**Abstract:** This study was carried out to predict the setting times of silica fume substituted cement pastes using ANFIS. In the first part of the study, the initial and final setting time of cement pastes obtained by substituting silica fume into Portland cement at 0%, 2.5%, 5%, 7.5% and 10% were determined. In the second part, two models with Triangular and Gaussian membership functions were created with the experimental results and the initial and final setting time were predicted. In the third part, R<sup>2</sup>, MAPE and RMSE statistical methods were utilized to indicate the reliability of the prediction results. As a presentation, R<sup>2</sup>, MAPE and RMSE values were determined as 0.9882-0.9778, 0.015156-0.018960 and 3.8027-5.8689 for Triangular membership function and 0.9882-0.9778, 0.015226-0.018956 and 3.8006-5.8689 for Gaussian membership function, respectively. According to these results, it can be stated that both initial setting time and final setting time can be predicted "very well" or "with a high degree of accuracy" with the models constructed with Triangle and Gaussian membership functions.

**1. GİRİŞ**

Portland çimentosu (PÇ) küresel endüstriyel enerjinin yaklaşık %5'ini kullanmakta ve bu üretim sürecinde kalker, kil, marn gibi çok miktarda hammadde tüketilmektedir [1]. Ayrıca PÇ, yüksek düzeyde karbondioksit (CO<sub>2</sub>) emisyonuna sahiptir (1 ton çimento

0.8-1 ton CO<sub>2</sub> üretir). Dolayısı ile atmosfere büyük miktarda CO<sub>2</sub> salınımı iklim değişikliğine yol açtığı için PÇ'nin çevre dostu bir malzeme olmadığı düşünülmektedir [2]. PÇ üretimindeki klinker miktarını azaltmak ve çimentonun harçlarının ve betonun dayanım ve dayanıklılık gibi özelliklerini iyileştirmek için gerek doğal (pomza, zeolit, diatomit, tras gibi) [3-6] gerek yapay (uçucu kül, yüksek fırın cürufu, metakaolin, prinç

kabuğu külü gibi) [7-10] mineral katkıları yoğun olarak kullanılmaktadır.

Yapay mineral katkıları içerisinde yer alan silis dumanı (SD) çimento ve beton özelliklerindeki gelişmelere olumlu katkılarından dolayı üzerinde yoğun araştırmaların yapıldığı bir malzemedir. SD, silisyum metali veya ferrosilisyum alaşımlarının elektrik arki fırınlarındaki imalatından ortaya çıkan bir yan üründür ve mikro silika, uçucu silika veya silis tozu olarak da bilinmektedir. SD, yüzey alanı 13000 ile 30000 m<sup>2</sup>/kg arasında olan çok ince camsı parçacıklardan oluşan gri renkli bir malzemedir [11]. SD amarf yapıya sahip olup, ortalama büyüklüğü 0.1 µm ile 0.3 µm arasında değişen çok ince küresel şekilli tanelerden oluşmaktadır [12]. SD'nin bu çok ince küresel tane şekli ve yüksek silika içeriği, SD ile üretilen betonların geçirgenliğini azaltmakta ve bu özelliği sayesinde betonun korozyona karşı direncini artırmaktadır. Ayrıca betonun basınç dayanımı ve aşınma direnci gibi özelliklerini de artırmaktadır [11, 13].

SD'nin çimento özelliklerine etkisinin araştırıldığı standart çimento deneylerinden biri de priz süresi deneyleridir. Çimento ile suyun birleşimi esnasındaki kimyasal reaksiyon sonucunda meydana gelen çimento hamurundaki sertleşme, farklı aşamalarda gerçekleşmektedir. Dolayısı ile priz başlangıcı ve priz sonu sürelerinin standartlar içerisinde yer alması önemlidir. Priz başlangıcının çok kısa bir sürede gerçekleşmesi; taze betonun karılması, yerine götürülmesi, yerleştirilmesi, sıkıştırılması, yüzeyinin düzeltilmesi gibi işlemlerde sorunlar ortaya çıkarmaktadır. Bu sorunlar da betonun dayanım ve dayanıklılık gibi özelliklerini olumsuz etkilemektedir. Priz sonu süresi istenen süreden daha uzun olduğunda ise, betonun dayanımı daha uzun sürelerde gerçekleşmektedir. Dolayısı ile gerek betonun korunması gerekse kalıpların alınması için gereken süreler daha uzun olmaktadır. Bu yüzden de standartlar, çimento tiplerine göre minimum priz başlama süresini sınırlamaktadır [14]. Bu sürelerin istenen şekilde gerçekleşmesi için gerek kimyasal katkıları gerekse silis dumanı gibi mineral katkıları çimento veya betona belirli oranlarda katılmaktadır.

Ancak standart çimento deneylerinden olan basınç dayanımı ve priz sürelerinin belirlenmesi zaman alıcı, zahmetli ve enerji tüketimi gerektiren çalışmalardır. Bu nedenle araştırmacılar, mineral katkıların beton veya çimento özelliklerine farklı etkilerini tahmin edebilmek için farklı yapay zeka tabanlı modeller geliştirmeye çalışmaktadır. Bu uygulamalardan biri de uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) olarak dikkat çekmektedir.

Bu çalışmalardan birinde Gevenç ve Koçak (2022), pomza ve/veya diatomit ile ikame ettikleri toplam 7 tip çimento harcının basınç dayanımlarını ANFIS ile tahmin etmişlerdir. Bu modellerin performansı R<sup>2</sup>, MAPE ve RMSE ile karşılaştırılmış ve bu istatistiksel verilerin sırasıyla 0.96, 6.66 ve 2.55 olduğunu belirlenmiştir. Elde ettikleri bu değerlere göre geliştirdikleri modelin güçlü ve

faydalı bir model olduğunu ve ANFIS ile oldukça iyi basınç dayanımı tahminlerinin yapılabileceğini belirtmişlerdir [15]. Bir diğer çalışmada Ozcan vd. (2018), zeolit ve/veya diatomit içerikli yedi farklı karışımından oluşan betonların basınç dayanımlarını ANN ve ANFIS ile tahmin etmeye çalışmışlardır. Sonuçları, R<sup>2</sup>, MAPE ve RMSE ile karşılaştırmışlar ve test aşamasında bu değerleri YSA modeli için sırasıyla 0.9976, 0.0042 ve 0.3521, ANFIS modeli için ise 0.9879, 0.0106 ve 0.7827 olarak elde etmişlerdir. Bu sonuçları dikkate alarak her iki uzman sistem modelinin de anlamlı sonuçlar verdiğini ve çimento harçları ve betonların hazırlanması sırasında hem zaman hem de maliyet açısından fayda sağlayabileceğini belirtmişlerdir [16]. Farklı bir çalışmada Koçak vd. (2023), yüksek fırın cürufu ile ikame ettikleri çimento harçlarının eğilme dayanımlarını bulanık mantık ve ANFIS ile tahmin etmişlerdir. Bu iki modelin performanslarını kıyaslamak için korelasyon katsayısından yararlanmışlar ve bulanık mantık için R<sup>2</sup> değerini 0.76, ANFIS için ise 0.90 olarak elde etmişlerdir. Bu verilere göre her iki modelin çimento teknolojisindeki eğilme dayanımlarının tahmininde başarıyla kullanılabileceğini, ancak ANFIS'in daha iyi olduğunu ve bu modelin kullanılmasının daha yararlı olacağını ifade etmişlerdir [17]. Gülbandır vd. (2023) gerçekleştirdikleri çalışmada ise, Portland çimentosu içerisine %0, %2.5, %5, %7.5, %10, %12.5 ve %15 oranlarında pirinç kabuğu külü ikame etmiş ve Gauss ile Üçgen üyelik fonksiyonları kullanılarak oluşturdukları iki ANFIS modeli ile bu çimentoların priz başlama ve priz sonu sürelerini tespit etmeye çalışmışlardır. Sonuçlarının güvenilirliğinin anlaşılabilmesi amacıyla da, R<sup>2</sup>, MAPE ve RMSE değerlerini belirlemişlerdir. Priz başlama ve priz sonu sürelerine göre R<sup>2</sup>, MAPE ve RMSE değerlerini sırasıyla Gauss üyelik fonksiyonlarıyla 0.9912-0.9909, 0.0167-0.0144 ve 5.6537-5.8693; Üçgen üyelik fonksiyonlarıyla ise 0.9957-0.9939, 0.0119-0.0127 ve 3.9661-4.8125 olarak tespit etmişlerdir. İstatistiksel endekslerin sonuçlarına göre, priz başlama ve priz sonu süreleri açısından bu iki üyelik fonksiyonuyla gerçek değerlere çok yakın sonuçlar elde edildiğini ve priz sürelerini tahmin etmek için güçlü modeller olduklarını belirtmişlerdir [18]. Bu çalışmaların dışında çimento ve beton özelliklerini tahmin etmek üzere ANFIS ile oluşturulan bir çok modelin olduğu ve bu modellerle başarılı sonuçlar elde edildiği literatür incelemesinde görülmektedir [19-24].

Bu çalışmada, silis dumanı ikameli çimento hamurlarının priz süreleri ANFIS ile tahmin edilmeye çalışılmaktadır. Çalışmanın ilk aşamasında, %0, %2.5, %5, %7.5 ve %10 oranlarında Portland çimentosu içerisine SD ikame edilmiş toplam 5 tip çimento hamurunun priz başlama ve priz sonu süreleri belirlenmiştir. İkinci aşamada ise, Üçgen ve Gauss üyelik fonksiyonları ile iki model oluşturulmuş ve bu çimentolarla hazırlanmış hamurların priz başlama ve priz sonu süreleri tahmin edilmiştir. Son aşamada ise tahmin edilen bu sonuçların güvenilirliğini belirleyebilmek için R<sup>2</sup>, MAPE ve RMSE istatistiksel yöntemleri kullanılmış ve elde edilen sonuçlar ilgili bölümlerde tartışılmıştır.

## 2. MALZEME VE YÖNTEM

### 2.1. Malzeme

Bağlayıcı malzeme olarak “LİMAK ANKA” çimento fabrikasında (Ankara) TS EN 197-1 standardı esas alınarak üretimi gerçekleştirilen CEM I 42.5 R tip (Portland çimento) çimento kullanılmıştır [14]. Mineral katkı olarak kullanılan SD, Dost Kimya isimli bir şirketten tedarik edilmiştir. Çimento hamurlarının hazırlanmasında kullanılan su, Ankara iline ait şehir şebeke suyudur. PÇ ve SD'nin kimyasal ve fiziksel özellikleri Tablo 1'den izlenmektedir.

**Tablo 1.** PÇ ve SD'nin kimyasal ve fiziksel özellikleri

Malzeme	PÇ	SD
Kimyasal özellikler, %		
SiO <sub>2</sub>	19.51	91.60
Al <sub>2</sub> O <sub>3</sub>	4.95	0.73
Fe <sub>2</sub> O <sub>3</sub>	2.85	1.23
CaO	62.67	0.59
MgO	2.24	1.08
SO <sub>3</sub>	2.86	0.11
Na <sub>2</sub> O	0.15	0.50
K <sub>2</sub> O	0.72	1.31
Cl	0.0328	0.10
Kızdırma kaybı	3.75	2.85
Fiziksel özellikler		
Özgül ağırlık, g/cm <sup>3</sup>	3.13	2.13
Özgül yüzey (Blaine), cm <sup>2</sup> /g	3233	14465

### 2.2. Yöntem

Çalışmada, %0, %2.5, %5, %7.5 ve %10 oranlarında SD ikamesi ile elde edilen beş tip çimento için belirlenen isimler Tablo 2'de sunulmuştur.

**Tablo 2.** Çimento isimleri

No	Çimento	İsmi
1	%0 SD ikameli çimento (PÇ)	<b>R</b>
2	%2.5 SD ikameli çimento	<b>SD1</b>
3	%5 SD ikameli çimento	<b>SD2</b>
4	%7.5 SD ikameli çimento	<b>SD3</b>
5	%10 SD ikameli çimento	<b>SD4</b>

Çimento hamurlarının priz süreleri, TS EN 196-3 esasları dikkate alınarak ve 3'er deney gerçekleştirilerek tespit edilmiştir [25]. Priz başlama ve priz sonu süreleri, Ankara ilinde bulunan LİMAK ANKA Çimento fabrikasında Vicat halkası ve iğnesi kullanılarak, sıcaklığı 20 °C ve bağıl nemi %65 olan bir laboratuvar ortamında belirlenmiştir.

## 3. UYARLAMALI AĞ TABANLI BULANIK ÇIKARIM SİSTEMİ

ANFIS, diğer klasik yaklaşımların başarısız olduğu karmaşık doğrusal olmayan problemlerle uğraşırken, insan muhakemesini simüle eden Takagi-Sugeno bulanık sistemine dayanan bir sinir ağıdır. ANFIS, bulanık çıkarım sistemleri ve sinir ağlarından oluşan iki ayrı tekniği birleştirerek daha verimli üyelik fonksiyonları üretmek için tahmin modelinin verilerinin girilmesiyle

kural sistemleri oluşturma yöntemi olarak kullanılan bulanık bir modeldir. ANFIS'in üyelik fonksiyonu parametreleri Yapay sinir ağlarına dayalı yöntemlerin kullanımıyla ayarlanır. ANFIS'te akıl yürütme adımları bulanık çıkarım sistemi ile gerçekleştirilmekte ve bir mühendislik sisteminin girdi ve çıktı değişkenleri arasındaki bilgiler IF-THEN bulanık kuralları olarak tanımlanmakta ve Denklem (1) ve (2)'deki gibi gösterilmektedir [26-28].

*Kural 1:*

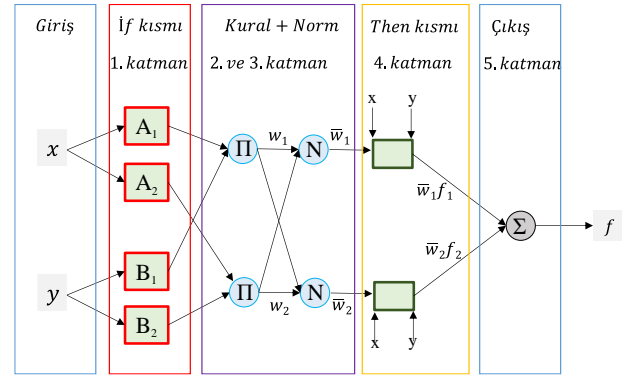
$$IF x \text{ is } A_1, \text{ and } y \text{ is } B_1 \text{ THEN } f_1 = p_1 x + q_1 y + r_1 \quad (1)$$

*Kural 2:*

$$IF x \text{ is } A_2, \text{ and } y \text{ is } B_2 \text{ THEN } f_2 = p_2 x + q_2 y + r_2 \quad (2)$$

Kural 1 ve 2'de A<sub>i</sub> ve B<sub>i</sub>, sırasıyla x ve y girişleri için üyelik fonksiyonlarını temsil etmektedir. f<sub>1</sub> ve f<sub>2</sub> çıkış fonksiyonunu belirtmektedir. p<sub>i</sub>, q<sub>i</sub> ve r<sub>i</sub> sonuç parametrelerini ifade etmekte ve her kural için bir çıktı değeri sağlanmaktadır [26].

İki giriş değişkeni olan x ve y için bir ANFIS algoritmasının temel mimarisi Şekil 1'de gösterilmektedir [26, 28].



**Şekil 1.** ANFIS algoritmasının temel mimarisi

Şekil 1'de örneklenen ANFIS mimarisi, 5 temel katmandan oluşmaktadır [26, 28].

**1. Katman:** Bulanıklaştırma katmanı olarak ifade edilen bu katmandaki nöronlar, öncül parametreleri içeren uyarlanabilir düğümler olarak kabul edilmektedir.

**2. Katman:** Uygulama katmanı olarak adlandırılan bu katmandaki nöronlar II olarak etiketlenir ve bir daire ile gösterilir. Çıkış düğümü, gelen sinyallere göre oluşturulur. Çıkış düğümü w<sub>i</sub>, bir kuralın ateşleme gücünü gösterir.

**3. Katman:** Normalleştirme katmanı olarak adlandırılan bu katmandaki her nöron, bir daire ile tanımlanacak ve N olarak etiketlenecek sabit bir nörondur. Çıktı, i'inci kuralın ateşleme gücünün, tüm kuralların ateşleme gücünün toplamına oranına göre elde edilir.

**4. Katman:** Arındırma katmanı olarak ifade bu katmanda bulunan nöronlar, aslında sonuç parametrelerini içeren adaptif nöronlardır.

**5. Katman:** Birleştirme katmanı olarak isimlendirilen bu katman, tüm girdileri toplayan tek bir nöron içermektedir.

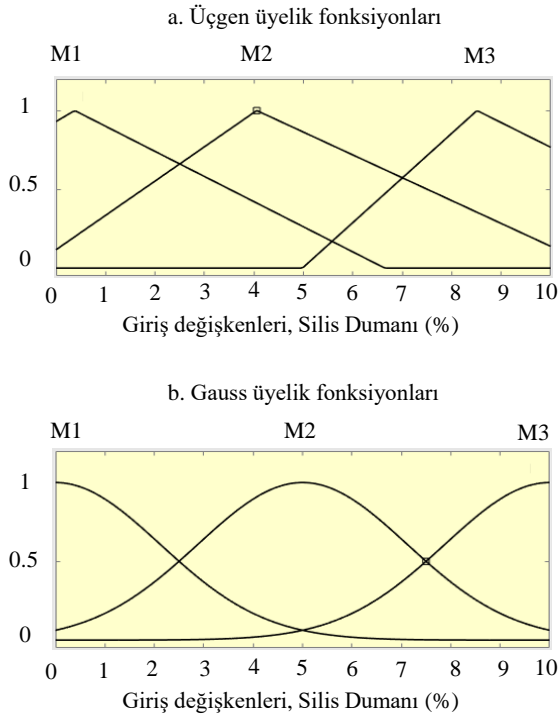
ANFIS ile ilgili daha fazla bilgi için farklı kaynaklardan yararlanılabilir [29-32].

#### 4. ANFIS TASARIM VE MODEL PARAMETRELERİ


SD ikameli çimento hamurlarının priz başlama ve priz sonu sürelerinin tahmininde MATLAB programında yer alan ANFIS editöründeki “Üçgen” ve “Gauss” üyelik fonksiyonlarından yararlanılmıştır. Priz başlama ve priz sonu süreleri için kullanılan Üçgen ve Gauss üyelik fonksiyonlarının parametreleri Tablo 3’te, giriş değişkenlerinin üyelik fonksiyonları ise sırasıyla Şekil 2 ve Şekil 3’te verilmiştir.

**Tablo 3.** Üçgen ve Gauss üyelik fonksiyonlarının priz başlama ve priz sonu sürelerinin parametreleri

Parametre	Üçgen	Gauss
Düğüm sayısı	16	16
Eğitim veri çifti sayısı	15	15
Veri çifti kontrol sayısı	0	0
Toplam bulanık kural sayısı	3	3
Doğrusal parametre sayısı	3	3
Doğrusal olmayan parametre sayısı	6	6
Toplam parametre sayısı	9	9



**Şekil 2.** Üçgen ve Gauss için priz başlama sürelerinin giriş değişkenlerinin üyelik fonksiyonları



**Şekil 3.** Üçgen ve Gauss için priz sonu sürelerinin giriş değişkenlerinin üyelik fonksiyonları

#### 4. BULGULAR

Çalışmada kullanılan %0, 2.5, 5, 7.5 ve 10 oranlarında SD ikamesi ile elde edilen beş farklı çimento hamurunun deneylerden ve modellerden belirlenen priz başlama ve priz sonu süreleri sırasıyla Tablo 4 ve Tablo 5’te gösterilmiştir.

**Tablo 4.** Priz başlama süreleri (dakika)

Numune no	Çimento hamurları				
	R	SD1	SD2	SD3	SD4
1	155	175	195	240	255
2	155	180	200	235	245
3	150	185	200	235	240
<b>Ortalama</b>	153	180	198	237	247
Endeks, %	100	117	129	154	161
<b>Üçgen</b>	153	180	199	237	247
Max. Hata, dakika	3	5	4	-3	7
Hata, %	2.0	2.8	2.0	1.3	2.8
<b>Gauss</b>	153	179	198	236	246
Max. Hata, dakika	3	-6	3	-4	-9
Hata, %	2.0	-3.4	1.5	-1.7	-3.7

**Tablo 5.** Priz sonu süreleri (dakika)

Numune no	Çimento hamurları				
	R	SD1	SD2	SD3	SD4
1	210	240	280	300	330
2	220	250	290	310	320
3	220	260	290	315	320
<b>Ortalama</b>	217	250	287	308	323
Endeks, %	100	107	119	133	163
<b>Üçgen</b>	217	250	287	308	323
Max. Hata, dakika	7	10	7	8	-7
Hata, %	3.2	4.0	2.4	2.6	-2.2
<b>Gauss</b>	217	250	287	308	323
Max. Hata, dakika	7	10	7	8	-7
Hata, %	3.2	4.0	2.4	2.6	-2.2

DeneySEL sonuçlar, SD ikameli çimento hamurlarının tümünde priz başlama ve priz sonu sürelerinin arttığını göstermektedir (Tablo 4 ve Tablo 5). Tablo 4 ve 5’de yer alan veriler, en küçük priz başlama ve priz sonu sürelerinin sırası ile 153 ve 217 dakikayla referans çimento hamurunda; en büyük sürelerin ise %10 SD ikameli SD4 isimli çimento hamurunda olduğunu göstermektedir. Priz başlama süreleri referans çimento hamuruyla kıyaslandığında, SD1, SD2, SD3 ve SD4 isimli çimento hamurlarında sırasıyla %17, %29, %54 ve %61 oranlarında artmaktadır (Tablo 4). Priz sonu süreleri ise, SD1, SD2, SD3 ve SD4 isimli çimento hamurlarında sırasıyla %7, %19, %33 ve %63 oranlarında artmaktadır (Tablo 5). Priz başlama süreleri bir bütün olarak değerlendirildiğinde, TS EN 197-1 [14] standardı esasları çerçevesinde sınırlanan 42.5 MPa çimento dayanım sınıfı için minimum süre olan 60 dakikanın ve 32.5 MPa dayanım sınıfı için minimum süre olan 75 dakikanın üzerinde olduğu ve tüm çimentolar için standartları sağladığı söylenebilir.

Çalışmada tercih edilen Üçgen ve Gauss üyelik fonksiyonlarıyla elde edilen priz sürelerinin, deneylerden elde edilen priz sürelerine çok yakın olduğu ifade edilebilir. Modellerdeki maksimum hata oranları değerlendirilirken, her çimento hamuru için belirlenen üç sonuç arasında tahmin değerine en uzak süre esas alınmıştır. Buna göre Üçgen üyelik fonksiyonuyla belirlenen priz başlama sürelerindeki en büyük farkın %2.8 hata ile SD1 ve SD4 isimli (Tablo 4), priz sonu sürelerindeki en büyük farkın ise %4.0 hata ile SD4 isimli (Tablo 5) çimento hamurunda olduğu görülmektedir. Gauss üyelik fonksiyonuyla belirlenen priz başlama sürelerindeki en büyük farkın %3.7 hata ile SD1 isimli (Tablo 4), priz sonu sürelerindeki en büyük farkın ise %4.0 hata ile yine SD1 isimli (Tablo 5) çimento hamurunda olduğu izlenmektedir. Dolayısıyla ile hem Üçgen hem de Gauss üyelik fonksiyonlarıyla tahmin edilen priz başlama ve priz sonu sürelerinin çok küçük hata oranlarıyla belirlenebildiği söylenebilir.

Ayrıca Üçgen üyelik fonksiyonuyla oluştural model ile tahmin edilen priz başlama ve priz sonu süreleri için en kötü tahminin bile sırasıyla %97.2 ve %96.0 doğrulukla olduğu; Gauss üyelik fonksiyonuyla oluştural model ile tahmin edilen priz başlama ve priz sonu süreleri için en kötü tahminin bile sırasıyla %96.3 ve %96.0 doğrulukla olduğu belirlenmiştir. Tahmin süreleri ile ortalama priz başlama ve priz sonu süreleri kıyaslandığında ise neredeyse gerçek sonuçlara benzer bir tahmin yapıldığı ifade edilebilir.


Deneyler ile modellerden elde edilen priz sürelerinin tahminindeki güvenilirliğin belirlenmesi için regresyon analizi ( $R^2$ ), ortalama mutlak yüzde hata (MAPE) ve hata kareleri ortalamasının karekökü (RMSE) istatistiksel yöntemlerinden yararlanılmıştır. Bunlar sırasıyla Denklem (3), (4) ve (5)’de gösterilmiştir [16, 26, 30].

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - r_i)^2}{\sum_{i=1}^N (r_i - y_m)^2} \quad (3)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^N \left| \frac{r_i - y_i}{r_i} \right| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - r_i)^2} \quad (5)$$


Üçgen ve Gauss üyelik fonksiyonları ile tahmin edilen priz başlama ve priz sonu sürelerinin güvenilirliğinin belirlenmesi için Denklem (3), (4) ve (5)’ten hesaplanan  $R^2$ , MAPE ve RMSE değerleri sırasıyla Şekil 4 (a, b) ve Şekil 5 (a, b)’de verilmiştir.



Şekil 4. Üçgen ve Gauss üyelik fonksiyonları ile tahmin edilen priz başlama sürelerinin karşılaştırılması

Priz başlama sürelerine ait  $R^2$ , MAPE ve RMSE değerleri sırasıyla Üçgen üyelik fonksiyonu için 0.9882, 0.0151 ve 3.8027 olarak belirlenirken (Şekil 4.a), Gauss üyelik fonksiyonu için 0.9882, 0.0152 ve 3.8006 olarak belirlenmiştir (Şekil 4.b). Bu verilere göre modellerdeki  $R^2$ 'nin en küçük değeri olan 0.9882 ile 1'e çok yakın değerde olduğu, dolayısıyla ile tahmin edilen priz başlama süresinin doğruyu kuvvetli bir şekilde yansıttığı ifade edilebilir. MAPE için hesaplanan değerlerin %10'un altında olması ise priz başlama sürelerinin tahmin sonuçlarının "çok iyi" ya da "yüksek doğruluk derecesine sahip" olduğunu göstermektedir. Dolayısıyla ile hem  $R^2$  hem de MAPE verilerine göre priz başlama sürelerinin, her iki üyelik fonksiyonu için de en az %98 doğrulukla tahmin edilebileceği görülmektedir. RMSE değerine göre her iki modelin sıfır değerine yakınlığı, tahmin sonuçlarının iyi

olduğunu göstermektedir. Dolayısı ile istatistiksel endekslere göre tahmin edilen priz başlama sürelerinin gerçek değerlere çok yakın olduğu göstermektedir.



Şekil 5. Üçgen ve Gauss üyelik fonksiyonları ile tahmin edilen priz sonu sürelerinin karşılaştırılması

Priz sonu sürelerinin  $R^2$ , MAPE ve RMSE sonuçları, her iki üyelik fonksiyonları için 0.9778, 0.0189 ve 5.8689 olarak hesaplanmıştır (Şekil 5). Priz sonu süreleri, priz başlama sürelerine göre istatistiksel olarak nispeten daha kötü tahmin sonuçları olduğunu düşündürse bile, bu değerlerin de çok iyi olduğu ve %97 doğrulukla tahmin sağlayabildiği belirtilebilir.

Bu modellerin etkinliğini değerlendirmek için sonuçlar, priz sürelerinin tahmini için yapılan çalışmalardan elde edilen verilerle karşılaştırılmıştır. Yapılan bir çalışmada uçucu kül ve silis dumanının, Portland çimentosunun priz süresine etkisi, bulanık mantıkla tahmin edilmiş ve deney sonuçları ile bulanık mantık sonuçları karşılaştırılmıştır. Elde edilen sonuçlara göre priz başlama ve priz sonu süreleri için korelasyon katsayılarının ( $R^2$ ) sırasıyla 0.96 ve 0.92 olduğu bildirilmiştir [33]. Bir diğer çalışmada yüksek fırın cürufu ve atık lastik tozunun Portland çimentosunun priz süresine etkileri bulanık mantık ile tahmin edilmiş ve  $R^2$  değerleri Priz başlama süresi için 0.93, priz sonu süresi için ise 0.95 olarak belirlenmiştir [34]. Başka bir çalışmada ise Portland kompoze çimentosunun priz süresine metakaolin etkisini bulanık

mantıkla tahmin edilmeye çalışılmıştır. Oluşturulan modellerde elde edilen  $R^2$  değeri priz başlama süresi için 0.985, priz sonu süresi için 0.969 olarak belirlenmiştir [35]. Bulanık mantıkla yapılan başka bir çalışmada, krom magnezit tuğla tozunun Portland çimentosunun priz başlama ve bitiş sürelerine etkisi araştırılmış ve  $R^2$  değerleri priz başlama süresi için 0.92, priz sonu süresi için 0.89 olarak bulunmuştur [36]. Diğer bir çalışmada ise Portland çimentosu priz sürelerine pirinç kabuğu külü etkisi ANFIS ile tahmin edilmiştir. Elde edilen priz başlama ve priz sonu sürelerinin  $R^2$ , MAPE ve RMSE değerleri sırasıyla; gauss üyelik fonksiyonları için 0.9912-0.9909, 0.0167-0.0144 ve 5.6537-5.8693, üçgen üyelik fonksiyonları için ise 0.9957-0.9939, 0.0119-0.0127 ve 3.9661-4.8125 olarak bulunmuştur [18]. Dolayısı ile hem istatistiksel endekslere göre, hem de priz sürelerinin tahmini ile ilgili benzer çalışmalara göre tahmin edilen priz sürelerinin gerçek değerlere çok yakın olduğu ve her iki modelin de priz sürelerinin tahmininde başarıyla kullanılabileceği ifade edilebilir.

## 5. SONUÇLAR

Bu çalışmada, öncelikle CEM I 42.5 R tip Portland çimentosuna %0, %2.5, %5, %7.5 ve %10 oranlarında SD ikamesiyle elde edilmiş beş çimentonun priz başlama ve priz sonu süreleri 3'er deney yapılarak belirlenmiş, daha sonra ANFIS'e ait Üçgen ve Gauss üyelik fonksiyonlarıyla bu süreler tahmin edilmiştir. Elde edilen bulgulara dayanarak;

- Tüm çimento hamurlarında TS EN 197-1 standardı esasları çerçevesinde sınırlanan 42.5 MPa çimento dayanım sınıfı için minimum süre olan 60 dakikanın ve 32.5 MPa dayanım sınıfı için minimum süre olan 75 dakikanın üzerinde olduğu ve priz süresi açısından bir sorun olmadığı,
- Üçgen üyelik fonksiyonuna göre belirlenen en kötü tahminin priz başlama süresi için %97.2, priz sonu süresi için ise %96.0 doğrulukla elde edildiği,
- Gauss üyelik fonksiyonuna göre belirlenen en kötü tahminin priz başlama süresi için %96.3, priz sonu süresi için ise %96.0 doğrulukla elde edildiği,
- Priz başlama süresindeki  $R^2$ , MAPE ve RMS değerlerinin; Üçgen üyelik fonksiyonu için sırasıyla 0.9882, 0.015156 ve 3.8027 olarak; Gauss üyelik fonksiyonu için ise sırasıyla 0.9882, 0.015226 ve 3.8006 olarak belirlendiği, bu nedenle de "yüksek doğruluk" veya "çok iyi" derecesinde tahmin sonuçları olarak değerlendirilebileceği,
- Priz sonu süresindeki  $R^2$ , MAPE ve RMS değerleri; Üçgen üyelik fonksiyonu için sırasıyla 0.9778, 0.018960 ve 5.8689 olarak; Gauss üyelik fonksiyonu için ise sırasıyla 0.9778, 0.018956 ve 5.8689 olarak tespit edildiği, bu nedenle de "yüksek doğruluk" veya "çok iyi" derecesinde tahmin sonuçları olarak değerlendirilebileceği söylenebilir.

Bu sonuçlar bir bütün olarak değerlendirildiğinde her iki modelin de güçlü ve faydalı modeller olarak değerlendirilebileceği ve priz sürelerinin tahmininde başarıyla kullanılabileceği ifade edilebilir.

## Etik Hususlar

### Etik kurallara uyum

Yazarlar bu çalışmanın özgün olduğunu, etik görev ve sorumluluklara uyduklarını beyan eder.

### Finansman

Düzce Üniversitesi Bilimsel Araştırma Projesi Komisyon Başkanlığı, çimento deneyleri ve analizleri için 2024.06.05.1461 proje kod numarası ile destek sağlamıştır.

### Çıkar çatışması

Yazarlar çalışmayla ilgili herhangi bir kişi ya da kurumla çıkar çatışmasının olmadığını beyan eder.

### Teşekkür

Yazarlar, çimento deneyleri ve analizlerinin yapılmasında katkıda bulunan Ankara "LİMAK ANKA" Çimento Fabrikası çalışanlarına ve yöneticilerine ile Finansal destekleri için Düzce Üniversitesi Bilimsel Araştırma Projesi Komisyon Başkanlığına (Proje kod numarası: 2024.06.05.1461) teşekkürlerini sunarlar.

## KAYNAKÇA

- [1] Okoji, A. I., Anozie, A. N., & Omoleye, J. A. (2022). Evaluating the thermodynamic efficiency of the cement grate clinker cooler process using artificial neural networks and ANFIS. *Ain Shams Engineering Journal*, 13(5), 101704. <https://doi.org/10.1016/j.asej.2022.101704>
- [2] Singh, N. B., & Middendorf, B. (2020). Geopolymers as an alternative to Portland cement: An overview. *Construction and Building Materials*, 237, 117455. <https://doi.org/10.1016/j.conbuildmat.2019.117455>
- [3] Dong, E., Yu, R., Fan, D., Chen, Z., & Ma, X. (2022). Absorption-desorption process of internal curing water in ultra-high performance concrete (UHPC) incorporating pumice: From relaxation theory to dynamic migration model. *Cement and Concrete Composites*, 133, 104659. <https://doi.org/10.1016/j.cemconcomp.2022.104659>
- [4] Lehner, P., & Hrabová, K. (2023). Evaluation of degradation and mechanical parameters and sustainability indicators of zeolite concretes. *Construction and Building Materials*, 371, 130791. <https://doi.org/10.1016/j.conbuildmat.2023.130791>
- [5] Kurtay, M., Gerengi, H., Kocak, Y., Chidiebere, M. A., & Yildiz, M. (2020). The potency of zeolite and diatomite on the corrosive destruction of reinforcing steel in 1 M HNO<sub>3</sub> environment. *Construction and Building Materials*, 236, 117572. <https://doi.org/10.1016/j.conbuildmat.2019.117572>
- [6] Kocak, Y. (2017). The effects of super plasticizer and trass on the cement hydration. *Pamukkale University Journal of Engineering Sciences*, 23(3), 184-192. <https://dx.doi.org/10.5505/pajes.2016.80008>
- [7] Venkatasamy, V., Santhanam, M., Rao, B. P. C., Balakrishnan, S., & Kumar, A. (2024). Mechanical and durability properties of structural grade heavy weight concrete with fly ash and slag. *Cement and Concrete Composites*, 145, 105362. <https://doi.org/10.1016/j.cemconcomp.2023.105362>
- [8] Mardmomen, S., & Chen, H. L. R. (2023). Modeling the thermal and mechanical properties of early age concrete containing ground granulated blast furnace slag. *Construction and Building Materials*, 401, 132902. <https://doi.org/10.1016/j.conbuildmat.2023.132902>
- [9] Kocak, Y. (2020). Effects of metakaolin on the hydration development of Portland-composite cement. *Journal of building engineering*, 31, 101419. <https://doi.org/10.1016/j.job.2020.101419>
- [10] Das, S. K., Behera, N., Patro, S. K., Mustakim, S. M., Suda, Y., & Leklou, N. (2024). Effectiveness of rice husk ash-derived alkali activator in fresh, mechanical, and microstructure properties of geopolymer mortar at ambient temperature curing. *Journal of Sustainable Cement-Based Materials*, 13(2), 213-221. <https://doi.org/10.1080/21650373.2023.2262465>
- [11] Khan, M. I., & Siddique, R. (2011). Utilization of silica fume in concrete: Review of durability properties. *Resources, Conservation and Recycling*, 57, 30-35.
- [12] Jain, B., & Sancheti, G. (2023). Influence of silica fume and iron dust on mechanical properties of concrete. *Construction and Building Materials*, 409, 133910. <https://doi.org/10.1016/j.conbuildmat.2023.133910>
- [13] Song, H. W., Pack, S. W., Nam, S. H., Jang, J. C., & Saraswathy, V. (2010). Estimation of the permeability of silica fume cement concrete. *Construction and Building Materials*, 24(3), 315-321. <https://doi.org/10.1016/j.conbuildmat.2009.08.033>
- [14] TS EN 197-1. Çimento- Bölüm 1: Genel Çimentolar Bileşim, Özellikler ve Uygunluk Kriterleri. Türk Standartları, Ankara, 2012.
- [15] Güvenç, U., & Koçak, B. (2022). Pomza ve Diatomitin Portland Çimentosunun Basınç Dayanımına Etkilerinin ANFIS ile Tahmini. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 3(1), 18-25. <https://doi.org/10.53608/estudambilisim.1051136>
- [16] Ozcan, G., Kocak, Y., & Gulbandilar, E. (2018). Compressive strength estimation of concrete containing zeolite and diatomite: an expert system implementation. *Computers and Concrete, An International Journal*, 21(1), 21-30.
- [17] Koçak, B., Şahin, Y. İ., & Koçak, Y. (2023). Portland Çimentosunun Eğilme Dayanımına Yüksek Fırın Cürufu Etkisinin Bulanık Mantık ve ANFIS ile Tahmini. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 4(1), 17-24. <https://doi.org/10.53608/estudambilisim.1227733>
- [18] Gülbandılar, E., Koçak, B., Özdemir, İ., & Koçak, Y. (2023). Portland Çimentosu Priz Sürelerine Pirinç Kabuğu Külü Etkisinin ANFIS ile Tahmini. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 4(2), 34-42. <https://doi.org/10.53608/estudambilisim.1298231>
- [19] Golafshani, E. M., Behnood, A., & Arashpour, M. (2020). Predicting the compressive strength of normal and High-Performance Concretes using ANN and ANFIS hybridized with Grey Wolf Optimizer. *Construction and Building Materials*, 232, 117266. <https://doi.org/10.1016/j.conbuildmat.2019.117266>
- [20] Vakhshouri, B., & Nejadi, S. (2018). Prediction of compressive strength of self-compacting concrete by ANFIS models. *Neurocomputing*, 280, 13-22. <https://doi.org/10.1016/j.neucom.2017.09.099>
- [21] Li, J., Yan, G., Abbud, L. H., Alkhalifah, T., Alturise, F., Khadimallah, M. A., & Marzouki, R. (2023). Predicting the shear strength of concrete beam through ANFIS-GA-PSO hybrid modeling. *Advances in Engineering Software*, 181, 103475. <https://doi.org/10.1016/j.advengsoft.2023.103475>

- [22] Ly, H. B., Pham, B. T., Dao, D. V., Le, V. M., Le, L. M., & Le, T. T. (2019). Improvement of ANFIS model for prediction of compressive strength of manufactured sand concrete. *Applied Sciences*, 9(18), 3841. <https://doi.org/10.3390/app9183841>
- [23] Keshavarz, Z., & Torkian, H. (2018). Application of ANN and ANFIS models in determining compressive strength of concrete. *Journal of Soft Computing in Civil Engineering*, 2(1), 62-70. <https://doi.org/10.22115/SCCE.2018.51114>
- [24] Nafees, A., Javed, M. F., Khan, S., Nazir, K., Farooq, F., Aslam, F., ... & Vatin, N. I. (2021). Predictive modeling of mechanical properties of silica fume-based green concrete using artificial intelligence approaches: MLPNN, ANFIS, and GEP. *Materials*, 14(24), 7531. <https://doi.org/10.3390/ma14247531>
- [25] TS EN 196-3. Çimento deney metotları- Bölüm 3: Priz süresi ve hacim genleşme tayini. Türk Standartları, Ankara, 2010.
- [26] Kocak, B., Pınarcı, İ., Güvenç, U., & Kocak, Y. (2023). Prediction of compressive strengths of pumice-and diatomite-containing cement mortars with artificial intelligence-based applications. *Construction and Building Materials*, 385, 131516. <https://doi.org/10.1016/j.conbuildmat.2023.131516>
- [27] Gkoutakou, F., & Papadopoulos, B. (2020). The use of fuzzy linear regression and ANFIS methods to predict the compressive strength of cement. *Symmetry* 12: 1295. <https://doi.org/10.3390/sym12081295>
- [28] Armaghani, D. J., & Asteris, P. G. (2021). A comparative study of ANN and ANFIS models for the prediction of cement-based mortar materials compressive strength. *Neural Computing and Applications*, 33(9), 4501-4532. <https://doi.org/10.1007/s00521-020-05244-4>
- [29] Temel R. (2017). Uçak Kara Kutusundan Alınan Veriler Kullanılarak Hücüm Açısı Ve Mach Sayısının YSA Ve ANFIS İle Tahmini. Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- [30] Aali, K. A., Parsinejad, M., & Rahmani, B. (2009). Estimation of Saturation Percentage of Soil Using Multiple Regression, YSA, and ANFIS Techniques. *Computing and Information Science*, 2(3), 127-136.
- [31] Jang, J. S. (1996, September). Input selection for ANFIS learning. In *Proceedings of IEEE 5th International Fuzzy Systems (Vol. 2, pp. 1493-1499)*. IEEE.
- [32] Bhavani Chowdary, T., & Ranga Rao, V. (2021). Design and Analysis of Lightweight Alkali-Activated Slag and Fly Ash Geopolymer Mortars using ANFIS-SSO. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 1-14. <https://doi.org/10.1007/s40996-021-00702-y>
- [33] Gulbandilar, E., & Kocak, Y. (2013). Prediction of the effects of fly ash and silica fume on the setting time of Portland cement with fuzzy logic. *Neural Computing and Applications*, 22, 1485-1491. <https://doi.org/10.1007/s00521-012-1049-4>
- [34] Kocak, Y., Gulbandilar, E., & Alpaslan, L. (2015). Prediction the effects of blast furnace slag and waste tire rubber powder on the setting time of Portland cement with fuzzy logic. *Materials and Methods Technology*, 9, 298-307.
- [35] Güvenç, U., Koçak, B., & Koçak, Y. (2021). Portland Kompoze Çimentosunun Priz Süresine Metakaolin Etkisinin Bulanık Mantıkla Tahmini. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 2(2), 29-34.
- [36] Özgan, E., & Yıldız, K. (2009). Krom Magnezit Tuğla Tozunun Portland Çimentosunun Priz Başlama Ve Bitiş Sürelerine Etkisinin Bulanık Mantıkla Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 24(2), 257-264.



**(Research Article)****3D Modelling and Simulation Based on Kinematic Analysis for Hippotherapy****Bilal ADOUM OURADA<sup>\*1</sup>, Uğur FİDAN<sup>2</sup>**<sup>1</sup>Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Ana Bilim Dalı, 03030, Afyonkarahisar, ORCID No : <https://orcid.org/0000-0002-0772-3741><sup>2</sup>Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Ana Bilim Dalı, 03030, Afyonkarahisar, ORCID No : <https://orcid.org/0000-0003-0356-017X>**Keywords:**

Biomimetics,  
Denativ Hartenberg Method,  
Hippotherapy,  
Robot Kinematics

**Abstract:** The engineering perspective on the physiology and anatomy of living things has led to the emergence of the science of biomechanics. Developing computer technologies have made it possible to examine the behaviour of living things in more detail and to develop technologies that enable kinetic and kinematic analysis of movements to imitate real limbs. In this study, the natural gaits of horses (Walk, Canter and Trot) were analysed with image processing techniques, kinematic analyses were made and three-dimensional solid models were created. Giving movement ability to the extracted solid models was carried out with the simulation software prepared on the Matlab-SimMechanic platform. By comparing the findings obtained as a result of image processing and simulation, the success of transferring the movements to a developed system was evaluated. After mathematical equations were created in the MATLAB environment, the equations were tested on the developed system and their performance rates were determined. With the developed system, joint angles, ability to reach the correct position and movement ability were analysed and it was shown how the mathematical equations required to perform the movements could be derived. As a result, a design process model for movement analysis, simulation and control of different living groups is presented with the equations obtained by formulating the information obtained from the developed system.

**(Araştırma Makalesi)****Hipoterapi İçin Kinematik Analize Dayalı 3 Boyutlu Modelleme Ve Simülasyon****Anahtar Kelimeler:**

Biyomimetik,  
Denativ Hartenberg Yöntemi,  
Hipoterapi,  
Robot Kinematığı

**Özet:** Canlıların fizyolojisine ve anatomisine olan mühendislik bakış açısı biyomekanik biliminin ortaya çıkmasını sağlamıştır. Gelişen bilgisayar teknolojileri, canlıların davranışlarını daha detaylı incelemeye, hareketlerin kinetik ve kinematik analizlerini yaparak gerçek uzuvları taklit etmeyi sağlayan teknolojilerin geliştirilmesine olanak sağlamıştır. Bu çalışmada atların doğal yürüyüşleri (Normal, Kenter ve Tırs) görüntü işleme teknikleri ile analiz edilerek kinematik analizleri yapılmış ve üç boyutlu katı modelleri çıkartılmıştır. Çıkarılan katı modellere hareket yeteneğinin kazandırılması Matlab-SimMechanic platformunda hazırlanmış olan simülasyon yazılımı ile gerçekleştirilmiştir. Görüntü işleme ve simülasyon sonucunda elde edilen bulgular kıyaslanarak hareketlerin geliştirilen bir sisteme aktarma başarımı değerlendirilmiştir. Matlab ortamında matematiksel denklemler çıkarıldıktan sonra denklemler geliştirilen sistem üzerinde denenmiş ve başarı oranları tespit edilmiştir. Geliştirilen sistem ile eklem açıları, doğru konuma ulaşma becerileri ve hareket yapabilme yeteneğini analiz edilmiş olup hareketlerin gerçekleştirilmesi için gereken matematiksel denklemlerin nasıl çıkarılabileceği gösterilmiştir. Sonuç olarak, geliştirilen sistemden edinen bilgiler formülize edilerek elde edilen denklemler ile farklı canlı gruplarının hareket analizi, simülasyonu ve kontrolü için bir tasarım süreci modeli sunulmuştur.

## 1. INTRODUCTION

Scientific analysis of the movements of living things on the 3-dimensional (3D) universe was initiated by Giovanni Alfonso Borelli between 1608 and 1679 [1]. Between 1830 and 1904, Eadweard Muybridge took sequential photographs of a movement, increasing the interest in research on the movements of living things. Northeastern University, developed the first biomimetic robot, a lobster, in 1970, and programmed a library of actions that gave the robotic lobster similar behaviour to real ones [2]. After these first studies, many biomimetic robots that entered the literature were designed and started to be used. These robots are used to perform multiple tasks in diverse fields including the field of biomedical such as diagnosis, surgery, emergency rescue, etc. As an example of its use in the health field, it can be given as a sensory and motor input therapy method to individuals with physical and/or mental problems such as autism by mimicking the characteristic movements of horses [3].

Baniqued and his friends designed a 5-degree-of-freedom robotic exoskeleton for upper extremity treatment using the biomimetic approach. The design of the robotic connections was inspired by the natural morphology of the spongy and cortical bones and their ability to respond to mechanical stress [4]. Solid modelling of the design was carried out in the CAD program CATIA. The use of a biomimetic approach in the design and development of the robotic exoskeleton for rehabilitation holds great promise in promoting the safety and biocompatibility of the device. Ziegler focused on motion synthesis based on 3D motion capture data so that robotic systems used in hippotherapy could create realistic trajectories [5]. A marker selection approach has been developed to extract data describing the rigid body motion of the horseback. The Fourier series method is used to create smooth, cyclic and realistic trajectories, in which the position and direction components of the motion are determined by the least squares point matching algorithm and can be executed effectively by robotic systems. In 2021 Top, inspired by the anatomical features of armido and rosary beetles, developed a functional walker for individuals with orthopaedic disorders. The developed walker, having the anatomical features of the inspired creatures, has the ability to be folded at different angles and also provides individuals with the opportunity to make different postures and sitting positions during walking. The 3D model of the developed walker was created in the CAD environment. Ergonomic risk analysis of the design was carried out with Digital Human Modelling (DHM) using Rapid Upper Extremity Assessment (RULA- Rapid Upper Limb Assessment) and Rapid Entire Body Assessment (REBA) tools of the CATIA V5 program [6]. Trusaji and his friends designed a horse-riding simulator to replicate human gait for hippotherapy in cerebral palsy rehabilitation. In the study, they stated that most of the mechanical horse simulators were designed as an exercise device, not as a rehabilitation device [7].

Literature reviews show that modelling, simulation, and analysis of solid models can be performed in computer

aided environments. For the biomimetic analysis of the developed solid models, the Matlab-SimMechanics tool is preferred in the literature and is used for the control of the systems. Imaging tools (High-speed camera, Kinect sensor, etc.) and different image processing algorithms are used to evaluate the performance of the developed systems. However, the performance rates of biomimetic analyses are not given in those studies, and they are not specified in the mathematical equations. In this study, 3D solid models were created in Solidworks environment after performing kinematic analyses of horses' natural gait types such as Walk gait, Canter and Trot gaits, using image processing techniques in Kinovea environment. Gaining the motion capability to the extracted solid models was carried out with the simulation software prepared on the Matlab-SimMechanic platform. By comparing the findings obtained as a result of image processing and simulation, the performance of transferring movements to a developed system was evaluated. With the developed system, joint angles, ability to reach the right position, and ability to move were analysed and it was shown how the mathematical equations needed to perform the movements could be derived.

## 2. MATERIALS AND METHODS

The American Robotics Institute defines a robot as a "multifunctional and programmable manipulator designed to move materials, parts and tools, or a special tool that can perform variable programmed movements to perform different tasks". Developing hardware components such as high-speed camera, high-torque actuator, analog and digital converters have increased the mobility of robotic systems. In this way, it has become possible to be used in many areas such as space, military, medical, search and rescue, service sector and home applications [8,9]. With the developments in hardware components, the developments in control algorithms and methods in embedded system software have led to the research of robotic systems, development and the creation of different application examples [10]. Robotic systems are categorized based on various factors that encompass their joint structures, specialized functions, operational principles, application domains, and control methods. In the realm of industrial robotics, classification is based on the functional features they possess and the number of joints they employ. Meanwhile, mobile robots undergo categorization based on the specific areas in which they are deployed and the mechanisms they employ for their operations. Fixed robots are divided into categories like Cartesian robots, cylindrical robots, and more, based on how their parts move. Mobile robots, on the other hand, are split into categories like humanoid, swarm (biomimetic), micro/nano, bio-inspired and collaborative robots depending on their shapes and functions [11].

### 2.1. Kinematics

Kinematics is the science that studies the structure and movements of a system. The position, acceleration and velocity parameters of the motion are examined using

kinematics. Relationships in kinematic analysis are defined between the end function and the joint angles. Kinematic analyses are divided into two as forward and reverse kinematics [12,13]. Forward kinematics aims to find the position and orientation of the end functionalist with the help of the joint variables (angles) of the robot. It consists of serial limbs connected to each other by prismatic or rotational joints, from a robot body to its end functional. In forward direction kinematics, the position and orientation of the terminal operator is calculated relative to the main frame by giving the joint variables. The relationship between the two limbs is explained by the homogeneous transformation matrix. By using transformation matrices in consecutive joints, the relationship between the base and the end function is defined. Different kinematic methods have been developed to determine the joint variables of robots. These methods can be cited as: homogeneous transformation, Denavit-Hartenberg, Pieper-Roth, zero reference and exponential methods. The Denavit-Hartenberg method is the most preferred method in the literature because it offers a simple and systematic approach for forward and inverse kinematics calculations [14].

**2.2 Denavit-Hartenberg Method**

The Denavit-Hartenberg Method, which is the most preferred while producing the kinematic model of robots, stands out with its homogeneous transformation matrix (Figure 1). In this method, robot kinematics is determined using four main variables.

$${}_{i-1}T_i = \begin{bmatrix} c\theta_i & -s\theta_i & 0 & a_{i-1} \\ s\theta_i c\alpha_{i-1} & c\theta_i c\alpha_{i-1} & -s\alpha_{i-1} & -s\alpha_{i-1}d_i \\ s\theta_i s\alpha_{i-1} & c\theta_i s\alpha_{i-1} & c\alpha_{i-1} & c\alpha_{i-1}d_i \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

**Figure 1.** General homogeneous matrix [6].

These variables are:

- $a_{i-1}$ , distance between  $Z_{i-1}$  and  $Z_i$
- $\alpha_{i-1}$ , axis angle between  $Z_{i-1}$  and  $Z_i$
- $d_i$  is the distance  $Z_i$  between  $X_{i-1}$  and  $X_i$
- $\theta_i$  is the axis angle between  $X_{i-1}$  and  $X_i$  and  $Z_i$


The above-mentioned main variables are called DH variables. The variables belonging to each addition to the DH table in Table1 are substituted in the general matrix and the transformation matrices are found. The transformation matrix between the main starting point and the end functional position of the robot is obtained by multiplying the transformation matrices of each joint.

**Table 1.** DH table.

Joint	Alpha	Joint length	Offset Angle	Joint Angle	Joint Variable
i	$\alpha_{i-1}$	$a_{i-1}$	$d_i$	$\theta_i$	$\theta_i / d_i$
1	0	0	0	$\theta_1$	$\theta_1$
2	0	L1	0	$\theta_2$	$\theta_2$
3	0	L2	0	0	0

In order to make kinematic calculations, coordinate systems must be added to the joints of the robot arm as shown in Figure 3 [12].

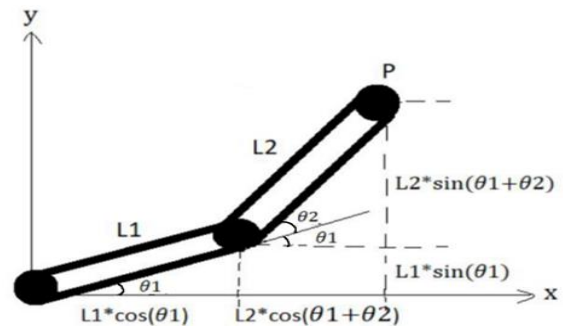
- First, the sliding directions or the rotation of the joint axes are determined.
- The direction of rotation for rotary axes and the sliding direction for prismatic joints are defined as the Z axis.
- The bond length perpendicular to the Z axis is defined as the X axis.
- After the X and Z axes are determined, the Y axis is determined according to the right-hand rule.
- In the right-hand rule, the thumb indicates the Z axis, the index finger the X axis and the middle finger the Y axis [13,14].



**Figure 2.** Placing coordinates on joints.

**2.2.1 Calculation of Forward Kinematics**

The position of the robot's end- effectors, referred to as point P, in Figure 4, can be determined through the utilization of geometric operations and the application of the Denavit-Hartenberg Method, as depicted in Figure 5 and Figure 6. X and Y coordinates can be calculated with the equations given in Equation 1 and Equation 2 .

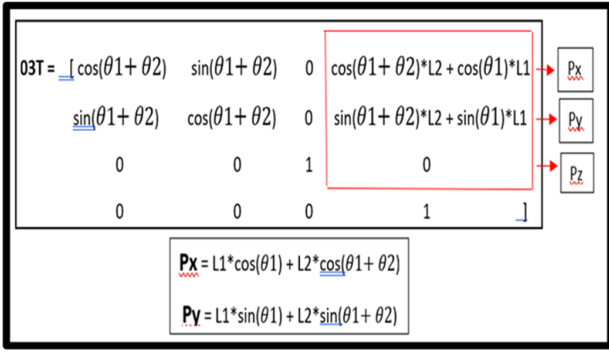


**Figure 3.** Two-dimensional representation of the robot arm

$${}_{01}T = \begin{bmatrix} \cos(\theta_1) & -\sin(\theta_1) & 0 & 0 \\ \sin(\theta_1) & \cos(\theta_1) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad {}_{12}T = \begin{bmatrix} \cos(\theta_2) & -\sin(\theta_2) & 0 & L1 \\ \sin(\theta_2) & \cos(\theta_2) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$${}_{23}T = \begin{bmatrix} \cos(\theta_2) & -\sin(\theta_2) & 0 & L1 \\ \sin(\theta_2) & \cos(\theta_2) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

**Figure 4.** Advanced kinematic computation of the end effector with the Denavit-Hartenberg method




**Figure 5.** Advanced kinematics calculation of end effector - with Denavit-Hartenberg method

$$Px = L1 * \cos(\theta1) + L2 * \cos(\theta1 + \theta2)^2 \quad (1)$$

$$Py = L1 * \sin(\theta1) + L2 * \sin(\theta1 + \theta2)^2 \quad (2)$$

### 2.2.2 Calculation of Inverse Kinematics

The inverse kinematics of the robot (Figure 7) aims to reach the joint variables (angles) that the robot should have in cases where the position and orientation of the end point of the robot arm are known. In robotics, inverse kinematics uses kinematic equations to determine the joint parameters that provide the desired position for each of the robot's end-effectors. A good trajectory planning enables the robot to reach the right point with minimum requirements with optimum movements [14,15].



**Figure 6.** Inverse kinematics analysis [12].

The trigonometric equations used in performing the inverse kinematics solution are given in the equations between Equation 3 and Equation 8.

$$\cos\theta = a \text{ ise } \theta = \arctan2(\pm\sqrt{1 - a^2}, a) \quad (3)$$

$$\sin\theta = a \text{ ise } \theta = \arctan2(a, \pm(\sqrt{1 - a^2})) \quad (4)$$

$$\cos\theta = a \text{ ve } \sin\theta = b \text{ ise } \theta = \arctan2(b, a) \quad (5)$$

$$a\sin\theta + b\cos\theta = 0 \text{ ise } \theta = \arctan2(-b, a) \text{ or } \arctan2(b, -a) \quad (6)$$

$$a\sin\theta + b\cos\theta = c \text{ ise } \theta = \arctan2(a, b) \pm \arctan2(\sqrt{a^2 + b^2 - c^2}, c) \quad (7)$$

$$\sin(\theta1 + \theta2) = \sin\theta1 * \cos\theta2 + \cos\theta1 * \sin\theta2 \quad (8)$$

### 2.3 Image-Based Motion Analysis

Image-based motion analysis makes it possible to examine a motion within a certain time frame relative to the reference plane. Image recording not only makes it possible to view the motion being examined in the desired time, but also allows freezing of image frames, slow motion, and facilitates analysis [16]. Image-based motion

analysis has become indispensable for the evaluation of motion in the 3D universe. Motion analysis is available in different package programs. Examples of these programs are Kinovea, V1 Home, PhysMo, Tracker, Motion Analysis Tools, Yessoft Sport Video Player and Sports Video Analysis [17]. In this study, the Kinovea software program was preferred for motion analysis. This program is designed to capture, compare, slow down, measure, and compare desired parameters and performances.

### 2.4 Computer Aided Solid Modelling

Solidworks is a computer-aided engineering (CAE) design program that allows the creation of solid models. This software includes a range of features such as solid part modeling, simulation, motion, assembly, toolbox, tool analyst, e-drawings, Photoview 360, ScanTo3D, and DWG editor [18]. The main advantages of this program to users can be listed as follows:

- In addition to having a simple interface, advanced modeling can be done.
- Analysis, simulation and animation can be done on the designed solid model.
- It is possible to design and assemble machine parts with many sub-components.
- It provides the opportunity to improve their visuals by coloring their designs.
- Design files can be run in analysis programs such as ANSYS.

#### 2.4.1 Matlab –SimMechanic

It is a package program that works in SimMechanics Simulink environment, which provides 3D modelling of mechanical systems. The 3D representation of the models created with this package program can be seen and movements can be monitored during simultaneous simulation. Since SimMechanics works under Simulink, it provides an integrated use of all the possibilities of MATLAB and Simulink software. It is possible to control the mechanical system designed with SimMechanics by combining it with electrical, pneumatic and hydraulic models thanks to Simulink [18].

### 2.5 3D Modelling Simulation and Application System Based on Kinematic Analysis

The block diagram of the simulation of the implemented system is given in Figure 8. After the images of the living thing were taken from the database, each section was analysed in the Kinovea medium and the data on the joint angles were extracted. Following the completion of the kinematic analysis of the creature's solid model, which was designed within the Solidworks environment, mechanical block diagrams corresponding to the model were generated in alignment with MATLAB SimMechanics. The motion capability of the solid model was simulated by calculating the forward and inverse kinematics of the system in MATLAB's Simulink and GUI environments. The accuracy of the simulation system was determined by transferring the kinematic information obtained as a result of the simulation to the box plot.

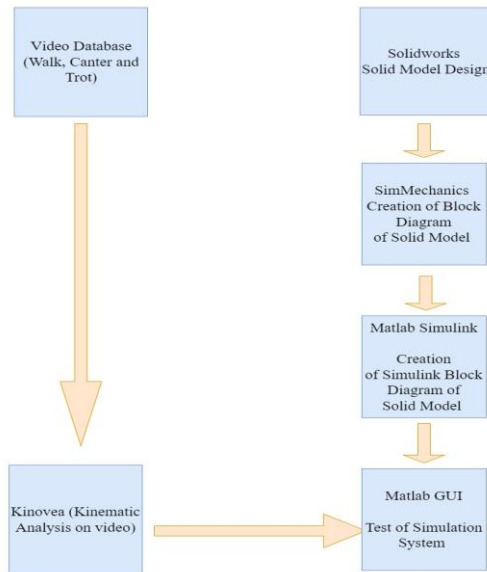


Figure 7. Block diagram of the simulation system

In Figure 8, the block diagram of the application system is given. The real model of the solid model designed in the Solidworks environment was produced with a 3D printer. Then, using the kinematic information obtained as a result of the Kinovea analysis, the conversion equation to the PWM signal was derived by using the curve fitting method. The extracted equations were converted to PWM signals according to the angle information via microcontroller (Atmega 238) and tested on the real system using Futaba S3003 servo motor with the help of PCA9685 servo motor driver. The image recording of the system was taken to analyse the test data. The kinematic analysis of the captured images was carried out in Kinovea environment. The information obtained from the kinematic analysis was transferred to the box graph and the motion capability of the solid model was compared with the real, live motion.

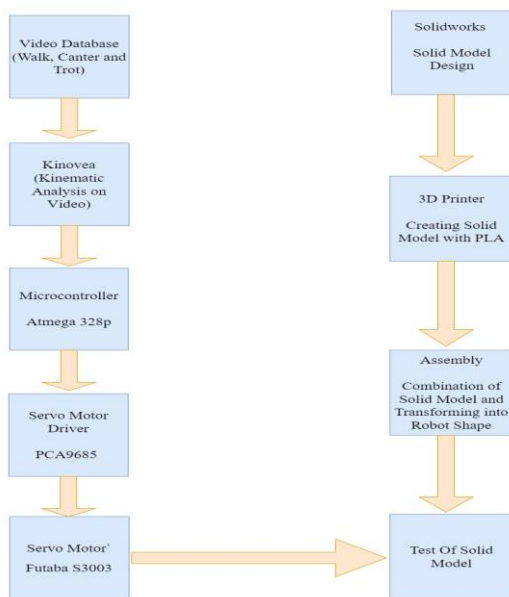


Figure 8. Block diagram of the application system  
2.5.1 Performance Test of the System

The flow diagram of the performance test of the system is depicted in Figure 10. Once the images were extracted from the database, a motion analysis was conducted within the Kinovea environment, leading to the acquisition of kinematic data. The acquired information was tested in the developed system. Subsequently, image recordings of the system were captured, and kinematic analysis was executed within the Kinovea environment. The results obtained from the simulation and application system and the actual motion information were transferred to the box graph and the success rate of the developed system was determined.

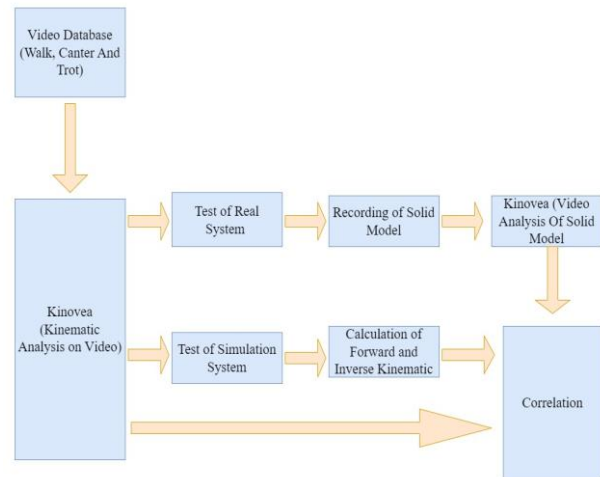


Figure 9. Performance test flowchart

### 3. RESULTS

In this study, the following findings are presented: the kinematic analysis of live images conducted within the Kinovea environment, the development of a solid model within the Solidworks environment, the simulation of the solid model and subsequent system testing, the creation of an application system, the kinematic analysis of images acquired through the application system, and the exploration of relationships between the simulation system and the application system for the living organism.

#### 3.1 Kinematic Analysis on Live Image in Kinovea Environment

Within the scope of the study, images of Walk gait, Canter gait and Trot gait, which are natural gaits of horses, were taken from the “Horse and Us” blog site [19]. Angle information were obtained using the protractor tool in Kinovea by determining the reference point of the arms ( $\theta_1$ ) and knee ( $\theta_2$ ) on the front legs of the horse, and the hip ( $\theta_1$ ) and knee ( $\theta_2$ ) sections on the hind legs of the horse in the Kinovea environment. The time-varying angle information during Walk gait, Canter gait and trot gait are given in Figure 11. The analysis revealed that both the walk and trot gaits exhibited symmetry, meaning that the movements observed on one side were consistently mirrored on the other side. In contrast, the Canter gait exhibited asymmetrical behaviour, indicating that the movements on the right and left sides were distinct from each other.

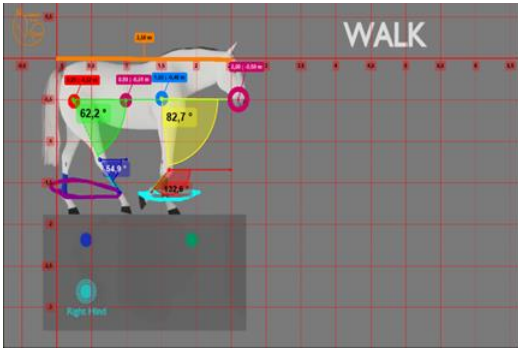


Figure 11a. Reference point and protractor display




Figure 11b. Walk




Figure 11c. Canter




Figure 11d. Trot

Figure 11. Kinematic analysis of the walk, Canter and Trot gait of the living organism in the Kinovea environment.

### 3.2 Solid Model Design and Simulation

The legs of the solid model (Figure 12a) are designed as humanoids. The legs are aligned side by side and mounted on a flat plate-shaped body. The designed model is 290 cm wide, 46 cm long and 15 cm high. After the solid model was designed in the Solidworks environment, the Simulink model of the model (Figure 12b) was created using the MATLAB SimMechanics plugin.




Figure 12a. Solid model design

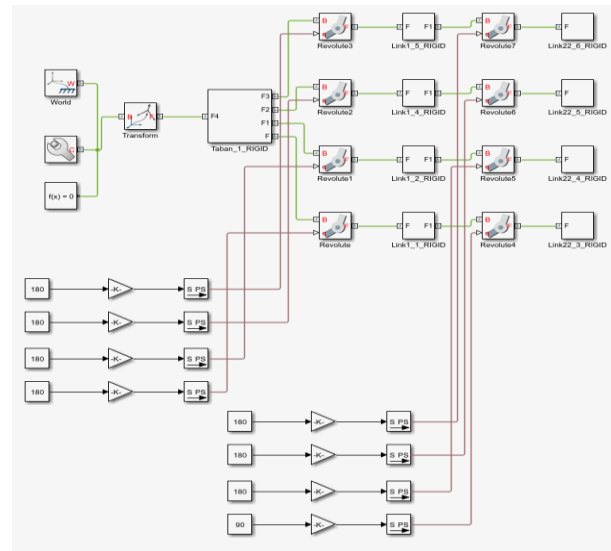


Figure 12b. Simulink model

Figure 12. Solid model design and simulink block diagram

In order to test the kinematic results of the extracted Simulink model in the solid model, the MATLAB GUI interface given in Figure 13 was developed. The program's interface features six buttons. Clicking the "start" button loads and initiates the Simulink model, while clicking the "stop" button halts the Simulink model. If the "Default" button is pressed, all legs of the solid model are automatically maintained in an upright position.

Pressing the Canter, Walk, or Trot buttons performs the calculation of position information using advanced kinematic equations (Equation 4.1 and Equation 4.2). These equations utilize kinematic data previously extracted from the Kinovea analysis and processed through the Denavit-Hartenberg method. The acquired position information was input into Equation 9 until

Equation 16, which represent one of the inverse kinematics equations.

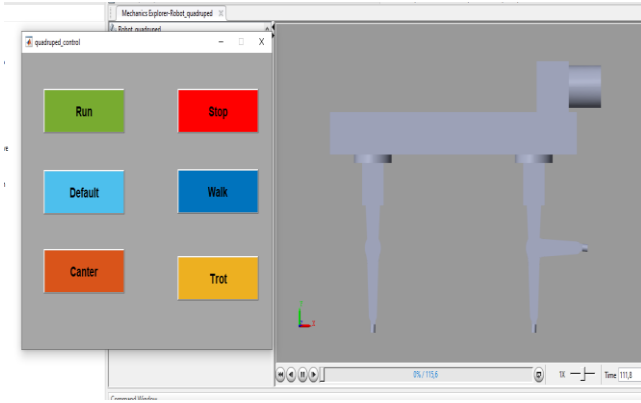


Figure 13. Simulation software

This input yielded angle information, resulting in the emergence of four distinct solution spaces from Equation 9 and Equation 16, which are:

**First Solution Space:**

$$\theta_2 = \arctan2\left(\sqrt{1 - \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}}, \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}\right) \quad (9)$$

$$\theta_1 = \arctan2(px, py) + \arctan2(\sqrt{px^2 + py^2 - (a2 * \cos\theta_2 + a1^2)^2}, a2 * \cos\theta_2 + a1) \quad (10)$$

**Second Solution Space**

$$\theta_2 = \arctan2\left(-\sqrt{1 - \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}}, \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}\right) \quad (11)$$

$$\theta_1 = \arctan2(px, py) + \arctan2(\sqrt{px^2 + py^2 - (a2 * \cos\theta_2 + a1^2)^2}, a2 * \cos\theta_2 + a1) \quad (12)$$

**Third Solution Space**

$$\theta_2 = \arctan2\left(\sqrt{1 - \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}}, \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}\right) \quad (13)$$

$$\theta_1 = \arctan2(px, py) - \arctan2(\sqrt{px^2 + py^2 - (a2 * \cos\theta_2 + a1^2)^2}, a2 * \cos\theta_2 + a1) \quad (14)$$

**Fourth Solution Space**

$$\theta_2 = \arctan2\left(-\sqrt{1 - \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}}, \frac{px^2 + py^2 - (a2^2 + a1^2)}{2 * a1 * a2}\right) \quad (15)$$

$$\theta_1 = \arctan2(px, py) - \arctan2(\sqrt{px^2 + py^2 - (a2 * \cos\theta_2 + a1^2)^2}, a2 * \cos\theta_2 + a1) \quad (16)$$

It has been determined that the equations belonging to the third solution space from the solution spaces given above gave correct results. As a result of inverse kinematics equations, the correct solution spaces of inverse kinematics were determined by calculating the Euclidean distance between the angle information obtained from the Kinovea analysis and the position information of the newly calculated angle information. According to the simulation results, in the first, second and fourth solution spaces, the lower and upper joint angles (THETA1 and THETA2) showed opposite relationships from each other, while in the third solution space, both lower joint angles and upper joint angles showed a linear relationship. Therefore, in this study, the third solution space was determined as the most successful solution space among the solution spaces.

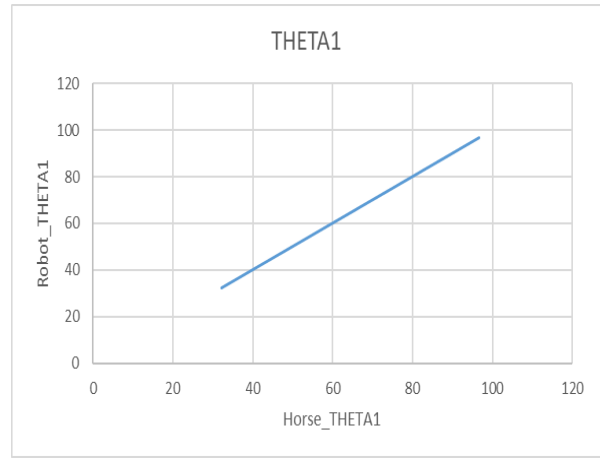


Figure 14a. Upper joint angle




Figure 14b. Lower joint angle

Figure 14. simulation results of third solution space

**3.3 Creation of the Application System**

After the solid model was designed in Solidworks environment, STL files were extracted, and parts were produced using PLA material from a 3D printer. The solid model created has a width of 46 cm, a length of 29 cm and a height of 36 cm. The humanoid legs of the solid model are formed by combining the produced parts with Futaba S3003 servo motors that act as joints, as seen in Figure 15.

Equations for controlling servo motors are given to Atmega 328 microcontroller. The PWM signal of the servo motors is set at 400 micro seconds (0 degrees), 1.2 milliseconds (90 degrees), and 2 milliseconds (180 degrees).




Figure 15. Implemented application system.

The kinematic information (angle) is adjusted to the PWM signal with the help of curve fitting method. As a result of the curve fitting method, two equations were obtained according to the mounting directions of the servo motors. These are given in Equation 17 and Equation 18 as m1 and m2.

$$m1 = (8.8889 * \theta) + 400 \quad (17)$$

$$m2 = 2000 - (8.8889 * \theta) \quad (18)$$

### 3.4 Comparison of Simulation System and Real System

The kinematic analysis (Figure 16) was carried out by using the method applied in the analysis of the living organism in the Kinovea medium, also in the solid model. Kinematic analysis was performed separately for each of the walk, canter and trot gaits.




Figure 16a. Reference point and protractor display




Figure 16b. Joint angle change over time

Figure 16. Kinematic analysis of the walk gait of the solid model in the Kinovea environment.

The correlation relations between the real images of the horse and the system realized are given in Table 2. Upon examining the correlation table presented in Table 2 it is evident that the gait model exhibiting the lowest average correlation is the walk gait, whereas the highest correlation among the gait models was observed in the trot gait.

Table 2. Correlation between different walking patterns of solid model (Robot)

Joint	Walk	Canter	Trot	Overall average of joints
Front Leg Lower	0.9013	0.8901	0.8310	0.8741
Front Leg Upper	0.9463	0.9400	0.9891	0.9584
Hind Leg Lower	0.7700	0.8143	0.8746	0.8196
Hind Leg Upper	0.9279	0.9807	0.9411	0.9499
Overall Average of Gaits	0.8863	0.9062	0.9089	

In each gait model, it is seen that the least correlation relationship is in the lower joints and the most correlation relationship is in the upper joints. The reason for this might be due to the fact that the upper joints are connected to the body and the lower joints are connected to the body in a distant position. Moreover, because the solid model is made with PLA material and depending on the continuous movement, deformation occurs at the joint points of the material.

### 4. DISCUSSION AND CONCLUSION

In this study, it is aimed to develop a system that allows the testing of biomimetic systems, which are costly in design and construction, before they are physically implemented. Within the scope of the study, the natural gaits of horses (Walk, Canter and Trot) whose anatomy is similar to human anatomy were determined in Kinovea environment and 3D solid models were created in Solidworks environment. Gaining mobility to the



extracted solid models is provided by the simulation interface software prepared on the Matlab-SimMechanics platform. By comparing the findings obtained as a result of image processing and simulation, the performance of transferring movements to a developed system was evaluated.

In the studies in the literature, it is seen that computer aided environments are used for modeling, simulation and analysis of solid models. Matlab-SimMechanics tool was also preferred in the literature for biomimetic analysis of the developed solid models and kinematic analyzes were made to control the systems. Image analysis method was used to evaluate the performance of the developed systems. Nevertheless, these studies do not provide performance metrics for biomimetic analyses, nor do they present the mathematical equations employed for these analyses. The equations used in the analysis are given together with their coefficients in Appendix A. A review of the literature in this domain reveals that there is a gap in this regard.

In this study, the mathematical equations of biomimetic analyzes were calculated in Matlab, tested in a real system, and the success rates were calculated. With the developed system, joint angles, ability to reach the right position and ability to move were analyzed and it was shown how to derive the mathematical equations required for the realization of movements. To address this issue, the process involved capturing images of the living organism, which were subsequently input into the database. Following this step, kinematic data was extracted within the Kinovea environment. The correct solution space was determined by transferring the extracted information to the simulation system. Then, the angle equation of the gait models was found by using the Curve Fitting tool, which is one of the Matlab tools for the same kinematic information. As a result, the information obtained from the developed system was formulated and the movement analysis of different living groups.

During the investigation of these analyses, several problems were encountered that affected the performance rate of the system. One of the biggest challenges in the simulation was the accurate transfer of the kinematic data extracted from Kinovea into the simulation environment. Inaccuracies in calibration and noise in the data complicated this process and required careful fitting and validation procedures.

One of these problems was that the motor drivers available on the market did not have the required resolution. This affected the stable operation of the control system, as the operating voltage range of the motors used in the system and the currents they drew caused disturbances in the system. The study concluded that to solve this problem, optical isolation should be used between the control unit and the motor drivers. In addition, since the construction of the system was made of PLA material, the stiffness of the system was lost due to deformation over time. Some improvements are suggested below that could make the system work better in future studies:

- Since the resolution of the system's motor driver is important, high-resolution motor driver circuits should be designed or used.
- The construction material should be made of a lighter material, such as aluminium, so that it is stiff and stable and is not deformed by the friction that occurs during motion.
- A high torque must be selected so that the joints of the system move more rhythmically and are balanced.

the expected effects of using high-resolution motor drivers and lighter construction materials on the overall stability and performance of the biomimetic system are as follows:

High resolution motor drivers:

*Improved precision:* High-resolution motor drivers offer finer control over the movement of the system's components. This precision is particularly important in biomimetic systems where it is important to accurately mimic natural movements.

*Smooth movement:* With higher resolution, the system can perform smoother movements, reducing jerky movements that could affect stability or accuracy.

*Better responsiveness:* The system can react faster to commands or changes in environmental conditions, allowing for real-time adjustments and better interaction with the environment.

*Reduced vibration:* Higher resolution can mitigate vibrations that may occur during movement, which is especially important for delicate tasks or when interacting with sensitive environments or organisms.

Lighter construction materials (e.g. aluminum):

*Increased agility:* Lighter materials reduce the overall weight of the system and improve its agility and maneuverability. This is particularly beneficial for biomimetic systems, which are designed to mimic the agility of natural organisms.

*Improved energy efficiency:* With less mass to move, the system requires less energy to operate, resulting in improved energy efficiency and potentially longer operating times, especially for battery-powered systems.

*Minimized deformation:* Lighter materials such as aluminum are less susceptible to deformation due to friction or stress during movement. This helps maintain the structural integrity of the system over time and ensures consistent performance.

*Better portability:* A lighter system is easier to transport and use in different environments, making it more versatile and adaptable for different applications or research scenarios.

Overall impact:

*Increased stability:* The combined use of high-resolution motor drivers and lighter construction materials can result in an overall more stable system. The precise control provided by the motors, combined with the structural stability provided by lightweight materials, helps to minimize deviation from intended movements and prevent instability or wobble during operation.

*Improved performance:* By optimizing both control precision and structural integrity, the biomimetic system can achieve a higher level of performance in terms of accuracy, reliability and adaptability to dynamic conditions. This can be critical in applications such as robotic surgery, prosthetics or environmental monitoring where precision and stability are essential.

In summary, the integration of high-resolution motor drivers and lighter construction materials into a biomimetic system can significantly improve its stability, precision and overall performance, enabling more effective mimicking of natural behaviors and better interaction with the environment.

The developed system can thus be used to study and analyze the behavior of living beings, whether as a hippotherapy simulator or in the field of biomimetics. In order to increase the functionality of the system, bidirectional servomotors or stepper motors with compact design, zero backlash, high dynamics, high torsional and tilting stiffness, small size, low mass, easy installation, high load capacity of the radial-axial output bearing and easy maintenance can be used as an alternative to the servomotor model used in this study. It is therefore expected that the errors that can occur will be reduced and the system can be used in the laboratory environment.

In summary, the developed system offers immense potential for a wide range of applications in various research and therapeutic contexts due to its ability to study and analyze the behavior of living organisms with remarkable precision.

#### Biomedical research:

The system can be used as a valuable tool in biomedical research, allowing scientists to study and understand the intricacies of animal behavior and physiology. This can help in the development of new treatments and therapies for various medical conditions. By simulating certain animal movements or behaviors, researchers can study biomechanics, neurology and other areas related to human and animal health. For example, studying the gait patterns of animals could contribute to the development of better prostheses or rehabilitation strategies for people with mobility impairments.

#### Therapeutic applications:

In addition to its applications in research, the system also has considerable potential in therapeutic areas. In hippotherapy, for example, where the movements of horses are used as a therapeutic measure for people with physical or cognitive impairments, the system can serve as a realistic simulator to supplement conventional therapy sessions. In addition, the system can be adapted for use in sensory integration therapy, where precise sensory input is provided to individuals with sensory processing disorders or autism spectrum disorders. By mimicking the movements of different animals, the system can provide customized sensory experiences that promote relaxation, sensory regulation and social interaction.

#### Educational tools:

The system can also be used as an educational tool in academic institutions and rehabilitation centers. It can provide students and therapists with hands-on experience in understanding animal behavior and its application in therapy and rehabilitation. In addition, the versatility of the system allows for customization and integration into curricula tailored to specific learning objectives, enhancing the learning experience for students and professionals alike.

#### Robotics and biomimetics:

In addition to therapeutic and research applications, the system can also contribute to advances in robotics and biomimetics. By accurately replicating the movements and behaviors of animals, it can inspire the development of more agile and adaptable robotic systems for tasks such as search and rescue, environmental monitoring and exploration of difficult terrain. To summarize, the developed system represents a versatile platform with broad applications in biomedical research, therapy, education and robotics. The precise control and realistic simulation capabilities make it a valuable tool to advance scientific knowledge, improve therapeutic interventions and stimulate innovation in various fields. As the technology continues to evolve, the potential for further innovation and refinement of the system's capabilities is virtually limitless and promises further contributions to research, therapy and education in the years to come.

#### Ethical concerns

##### compliance with ethical rules

This research has shown compliance with the rules determined within the framework of the "Higher Education Institutions Scientific Research and Publication Ethics Directive" at all stages from planning to implementation, from data collection process to data analysis. There has not been any violation of the rules under the title "Actions Contrary to Scientific Research and Publication Ethics", which is the second part of the Directive. Scientific ethics and citation rules were fully followed during the writing process of the study, no manipulation was made on the collected data, and this study was not sent for evaluation in any other academic publication environment.

#### Finance

The authors declare that they have not received a special grant from funding organizations in the public, commercial or non-profit sectors for this study.

#### Conflict of interest

As the authors, we confirm that there is no conflict of interest with any person or institution related to this study.

#### REFERENCES

- [1] <https://www.sci-sport.com/en/theory/chapter-1-history-and-rise-of-biomechanics.php>.

- [2] Ayers, J., Witting, J. (2007). Biomimetic approaches to the control of underwater walking machines. *Philos Trans A Math Phys Eng Sci.*, 15; 365 (1850): 273-95. doi: 10.1098/rsta.2006.1910. PMID: 17148060.
- [3] Koca, T. T., Ataseven, H., (2015). What is hippotherapy? The indications and effectiveness of hippotherapy. *Northern clinics of Istanbul*, 2(3), 247.
- [4] Baniqued, P.D.E., Dungao, J.R., Manguerra, M.V., Manguerra, R.G., Abad, A.C., Bugtai, N.T. (2018). Biomimetics in the Design of a Robotic Exoskeleton for Upper Limb Therapy, *AIP Conference Proceedings*, 1993, 040006.
- [5] Ziegler, J., Gattringer, H., Reiter, A., Hormandinger, P., Müller, A., Mitterhumer, M. (2018). Generation of realistic saddle trajectories from captured horseback motion, *Multibody System Dynamics*, 52, 117-133.
- [6] Top, N., Başak, H., Şahin, İ. (2021). Biyomimetik Tabanlı Fonksiyonel Yürüteç Tasarımı ve Dijital İnsan Modelleme ile Ergonomik Analizi, *El-Cezeri*, 8, 618-634.
- [7] Trusaji, W., Satriawan, A., Rahadini, S. S., Hasanuddin, M.O., Setianingsih, G., Pratomo, N, vd. (2022). Horse Riding Simulator Design to Replicate Human Walking Gait for Hippotherapy in Cerebral Palsy Rehabilitation, *Machines*, 10, 1060.
- [8] Jones, J.L., Flynn, A.M., Seiger, B.A. (1993). *Mobile Robots-Inspiration to Implementation*, AK Peters Ltd. Wellesley, Massachusetts.
- [9] Everett, H. R (1995). *Sensors for Mobile Robots*, CRC Press, 542p, Ney work.
- [10] Gürgüze, G., Türkoğlu, İ. (2019). Robot sistemlerinde kullanılan algoritmalar, *Türk Doğa ve Fen Dergisi*, 8, 17-31.
- [11] Çengelci, B., Çimen, H. (2005). Endüstriyel robotlar, *Makine Teknolojileri Elektronik Dergisi*, 2, 69-78.
- [12] Kyriakopoulos, K.J., Loizou, S. G. (2006). *Robotics: Fundamentals and Prospects*, Çev.: Demircioğlu P, Bögrekci İ, 15s.
- [13] Kuşcu H. (2007). DersNotları Temel Robotik, [https://hilmi.kulubevet.com/ders\\_notlari/robotik/Temel%20Robotik2.pdf](https://hilmi.kulubevet.com/ders_notlari/robotik/Temel%20Robotik2.pdf) (Erişim Tarihi: 03.06.2023).
- [14] Küçük, S., Bingül, Z. (2004). Robot sistemlerinde kinematik yöntemlerin karşılaştırılması, *Politeknik Dergisi*, 7, 107-117.
- [15] Ünver, B. (2005). Artık robot kollarının ters kinematik problemlerinin çözümü ve gerçekleştirilmesi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- [16] Armand, S., Bonnefoy, A., Sagawa, Y., Turcot, K. (2014). *Analyse Du Mouvement Dans Un Contexte*

*Clinique, Manuel pratique de chirurgie orthopédique*, 3-33.

- [17] Guzmán-Valdivia, C.H., Blanco-Ortega, A., Oliver-Salazar, M.Y., Carrera-Escobedo, J.L. (2013). Therapeutic motion analysis of lower limbs using Kinovea, *Int J Soft Comput Eng*, 3, 2231-307.
- [18] Vural, A., Çiçekoğlu, B., Tuncer, S. (2020). *Bilgisayarda\_Kati\_Modelleme*. [http://meslek.eba.gov.tr/upload/dk10/Bilgisayarda\\_Kati\\_Modelleme\\_10\\_29\\_30.pdf](http://meslek.eba.gov.tr/upload/dk10/Bilgisayarda_Kati_Modelleme_10_29_30.pdf). (Erişim Tarihi: 03.06.2023).
- [19] Maria, 2023. The 4 basic horse gait. <https://www.horsesandus.com/the-4-basic-horse-gaits-explained/> (Erişim Tarihi: 03.06.2023).

## Appendices

The equations below were determined as sixth-degree sine functions using curve fitting methods in Matlab, based on the image processing data acquired in the Kinovea environment.

*Front Leg Lower :*

$$f(x) = a1 * \sin(b1 * x + c1) + a2 * \sin(b2 * x + c2) + a3 * \sin(b3 * x + c3) + a4 * \sin(b4 * x + c4) + a5 * \sin(b5 * x + c5) + a6 * \sin(b6 * x + c6)$$

Coefficients (with 95% confidence bounds):

a1 = 160.7	b1 = 0.002092	c1 = 0.04154
a2 = 106.2	b2 = 0.004170	c2 = 1.65400
a3 = 15.21	b3 = 0.008079	c3 = 1.42600
a4 = 5.281	b4 = 0.016070	c4 = 0.38690
a5 = 57.46	b5 = 0.020030	c5 = 0.94430
a6 = 55.60	b6 = 0.020320	c6 = 3.89200

*Front Leg Upper:*

$$f(x) = a1 * \sin(b1 * x + c1) + a2 * \sin(b2 * x + c2) + a3 * \sin(b3 * x + c3) + a4 * \sin(b4 * x + c4) + a5 * \sin(b5 * x + c5) + a6 * \sin(b6 * x + c6)$$

Coefficients (with 95% confidence bounds):

a1 = 146.1	b1 = 0.001203	c1 = 1.7170
a2 = 92.95	b2 = 0.002749	c2 = 4.2290
a3 = 6.483	b3 = 0.011640	c3 = 0.4364
a4 = 409.2	b4 = 0.029870	c4 = -0.837
a5 = 1.954	b5 = 0.018910	c5 = 3.5290
a6 = 408.8	b6 = 0.029870	c6 = 2.3020

*Hind Leg Lower:*

$$f(x) = a1 * \sin(b1 * x + c1) + a2 * \sin(b2 * x + c2) + a3 * \sin(b3 * x + c3) + a4 * \sin(b4 * x + c4) + a5 * \sin(b5 * x + c5) + a6 * \sin(b6 * x + c6)$$

Coefficients (with 95% confidence bounds):

a1 = 103.8	b1 = 0.002182	c1 = -0.1692
a2 = 16.62	b2 = 0.008154	c2 = 1.83600
a3 = 6.674	b3 = 0.012120	c3 = 2.122
a4 = 26.56	b4 = 0.003266	c4 = 1.412
a5 = 2.041	b5 = 0.021950	c5 = 3.598
a6 = 1.268	b6 = 0.019040	c6 = 2.959

*Hind Leg Upper1:*

$$f(x) = a1 * \sin(b1 * x + c1) + a2 * \sin(b2 * x + c2) + a3 * \sin(b3 * x + c3) + a4 * \sin(b4 * x + c4) + a5 * \sin(b5 * x + c5) + a6 * \sin(b6 * x + c6)$$

Coefficients (with 95% confidence bounds):

a1 = 165.1	b1 = 0.001977	c1 = 0.3713
a2 = 60.64	b2 = 0.003418	c2 = 2.9340
a3 = 9.637	b3 = 0.008457	c3 = 2.2900
a4 = 10.93	b4 = 0.011580	c4 = 2.7030
a5 = 152.4	b5 = 0.022400	c5 = -2.900
a6 = -151.4	b6 = 0.022410	c6 = 3.3680