

YAPAY ZEKA İLE GELECEĐE YÖN VEREN TEKNOLOJİK STRATEJİ VE YENİLİKLER

EDİTÖRLER

DR. ÖĐR ÜYESİ SEMA SERVİ

ÖĐR. GÖR. ABDULLAH CEM AĐAÇAYAK

EĐİTİM
yayınevi

YAPAY ZEKA İLE GELECEĞE YÖN VEREN TEKNOLOJİK STRATEJİ VE YENİLİKLER

Editörler: Dr. Öğr Üyesi Sema Servi, Öğr. Gör. Abdullah Cem Ağa ayak

Genel Yayın Yönetmeni: Yusuf Ziya Aydođan (yza@egitimyayinevi.com)

Genel Yayın Koordinatörü: Yusuf Yavuz (yusufyavuz@egitimyayinevi.com)

Sayfa Tasarımı: Kübra Konca Nam

Kapak Tasarımı: Eğitim Yayınevi Grafik Birimi

T.C. Kültür ve Turizm Bakanlığı

Yayıncı Sertifika No: 76780

E-ISBN: 978-625-385-012-8

1. Baskı, Aralık 2024

Kütüphane Kimlik Kartı

YAPAY ZEKA İLE GELECEĞE YÖN VEREN TEKNOLOJİK STRATEJİ VE YENİLİKLER

Editörler: Dr. Öğr Üyesi Sema Servi, Öğr. Gör. Abdullah Cem Ağa ayak

148 s., 160x240 mm

Kaynakça var, dizin yok.

E-ISBN: 978-625-385-012-8

Copyright © Bu kitabın Türkiye'deki her türlü yayın hakkı Eğitim Yayınevi'ne aittir. Bütün hakları saklıdır. Kitabın tamamı veya bir kısmı 5846 sayılı yasanın hükümlerine göre kitabı yayımlayan firmanın ve yazarlarının önceden izni olmadan elektronik/meکانیک yolla, fotokopi yoluyla ya da herhangi bir kayıt sistemi ile çođaltılamaz, yayımlanamaz.

EĞİTİM

yayınevi

Yayınevi Türkiye Ofis: İstanbul: Eğitim Yayınevi Tic. Ltd. Şti., Atakent mah. Yasemen sok. No: 4/B, Ümraniye, İstanbul, Türkiye

Konya: Eğitim Yayınevi Tic. Ltd. Şti., Fevzi Çakmak Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye
+90 332 351 92 85, +90 533 151 50 42, 0 332 502 50 42
bilgi@egitimyayinevi.com

Yayınevi Amerika Ofis: New York: Egitim Publishing Group, Inc. P.O. Box 768/Armonk, New York, 10504-0768, United States of America
americaoffice@egitimyayinevi.com

Lojistik ve Sevkiyat Merkezi: Kitapmatik Lojistik ve Sevkiyat Merkezi, Fevzi Çakmak Mah. 10721 Sok. B Blok, No: 16/B, Safakent, Karatay, Konya, Türkiye
sevkiyat@egitimyayinevi.com

Kitabevi Şubesi: Eğitim Kitabevi, Şükran mah. Rampalı 121, Meram, Konya, Türkiye
+90 332 499 90 00
bilgi@egitimkitabevi.com

İnternet Satış: www.kitapmatik.com.tr
+90 537 512 43 00
bilgi@kitapmatik.com.tr

 **kitapmatik**
İnternetteki kitaplarınız

İÇİNDEKİLER

ÖNSÖZiii

**BÖLÜM 1: XGBOOST İLE OTOMATİK MÜZİK TÜRÜ
SINIFLANDIRMASI..... 1**

Rabia DOĞANAY, Fatih AKKUŞ, Onur İNAN

**BÖLÜM 2: EEG TABANLI BİLİŞSEL DURUM
SINIFLANDIRMASI İÇİN BEYİN-BİLGİSAYAR ARAYÜZÜ
ÇERÇEVESİ..... 17**

Mecit Mert BIŞGİN, İrem DEMİR, Burak YILMAZ

BÖLÜM 3: FİDE: DOĞAYI TANI, SEV, KORU 33

Fatih AKKUŞ, Muhammed Esad DOĞAN, Diyar TÜRK, Sema SERVİ

**BÖLÜM 4: KARA KANATLI UÇURTMA ALGORİTMASI İLE
DİŞLİ TREN TASARIMININ OPTİMİZASYON 49**

Taybe ALABED, Sema SERVİ, Onur İNAN

**BÖLÜM 5: YAPAY ZEKÂ DESTEKLİ MOBİL
TELEREHABİLİTASYON 63**

Cafer Karaltı, Fatih Emirhan Türker, Burak YILMAZ

BÖLÜM 6: MEOWSIC 71

Rabia DOĞANAY, Sema SERVİ

**BÖLÜM 7: TERMAL VE KAMERAYLA GÖRÜNTÜ
İŞLEMENE DAYALI AKILLI GÜVENLİK SİSTEMİ: OLASI
TEHDİTLERİ TESPİT VE ERKEN UYARI MEKANİZMASI85**

Salih Mübin BÖCÜ, Sema SERVİ

**BÖLÜM 8: HAFİF DONANIMLAR İÇİN GERÇEK ZAMANLI
HEDEF ALGILAMA VE YOK ETME SİSTEMİ..... 91**

Yusuf NURDOĞDU, Hakan TERZİOĞLU

**BÖLÜM 9: ZAMAN SERİSİ VERİLERİ VE UZUN KISA
SÜRELİ BELLEK (LSTM) AĞLARI KULLANILARAK**

**İHA'LARDA KULLANILAN FIRÇASIZ MOTOR
ARIZALARININ SINIFLANDIRILMASI..... 107**

*Sevdanur BEKLER, Burak YILMAZ, Güzin ÖZMEN, Yusuf NURDOĞDU,
Hakan TERZİOĞLU*

**BÖLÜM 10: ÜNİVERSİTE ÖĞRENCİLERİNE VE
AKADEMİSYENLERE ÜNİVERSİTE ETKİNLİKLERİNİ
BİLDİREN MOBİL UYGULAMA (UBI) 121**

*Ayşe Nur YÜZÜGÜLLÜ, Fatma Betül TERZİOĞLU, Beyza MUTLU,
Mehmet Fikret MİRALOĞLU, Sema SERVİ*

**BÖLÜM 11: ENDÜSTRİYEL MAKİNELERDE ARIZA
TESPİTİ İÇİN KSA İLE AKUSTİK SİNYAL ANALİZİ 129**

Mustafa YURDAKUL, Şakir TAŞDEMİR

ÖNSÖZ

Yapay zeka, günümüzde birçok sektörde devrim yaratan bir güç haline gelmiştir. Gelecekte de çeşitli teknolojik strateji ve yeniliklerle hayatımızı daha fazla etkilemesi beklenmektedir. Yapay zeka, büyük veri analizi, makine öğrenimi, derin öğrenme ve doğal dil işleme gibi alanlarda sağladığı ilerlemelerle birçok sektörde önemli değişikliklere yol açmaktadır. Müzik, resim ve edebiyat gibi alanlarda yaratıcı çalışmalar yapabilen yapay zeka sistemleri geliştirilmektedir. Ayrıca yapay zeka, hastalık teşhisi, tedavi planlaması ve kişisel sağlık yönetimi gibi alanlarda devrim yaratabileceği sağlık hizmetlerinde, otonom araçlar sayesinde daha güvenli ve verimli ulaşım sistemleri geliştirilmesinde, akıllı güvenlik sistemleriyle birleştirilerek olası tehditleri tespiti ve erken uyarı mekanizmasında, kişiselleştirilmiş eğitim çözümleri geliştirerek her öğrencinin ihtiyaçlarına uygun eğitim sunmada kullanılabilir.

Bu kitap akademisyenler ve mühendislik öğrencilerinin ortak çalışmanın sonucudur. Bu çalışmada yapay zeka ile geleceğe yön veren teknolojik strateji ve yeniliklere ilişkin teorik bilgilerin yanı sıra güncel araştırma ve uygulama örnekleri de yer almaktadır. Farklı bakış açılarını bir araya getiren bu kitap, bu alandaki bilgiyi genişletmeyi ve gelecekteki araştırmalara ilham vermeyi amaçlamaktadır.

Kitabın oluşmasında emeği geçen değerli araştırmacı yazarlara, teşekkür ederiz. Kitapta yer alan çalışmaların yapay zeka alanında çalışan akademisyenlere, öğrencilere ve sektör içinde olanlara faydalı olmasını umuyoruz.

Editörler

Dr. Öğr. Üyesi Sema SERVİ

Öğr. Gör. Dr. Abdullah Cem AĞAÇAYAK

BÖLÜM-1

XGBOOST İLE OTOMATİK MÜZİK TÜRÜ SINIFLANDIRMASI

Rabia DOĞANAY¹

Fatih AKKUŞ²

Onur İNAN³

¹<https://orcid.org/0009-0008-8420-1825>

²<https://orcid.org/0000-0002-4673-8647>

³<https://orcid.org/0000-0003-4573-7025>

XGBOOST İLE OTOMATİK MÜZİK TÜRÜ SINIFLANDIRMASI

1. GİRİŞ

Dijital müzik verilerinin otomatik sınıflandırılması, müzik bilgi erişimi (Music Information Retrieval - MIR) alanında önemli bir araştırma konusu olup, bu çalışmada spektral özellikler, Mel-frekans keprstral katsayıları (MFCC) ve kroma özellikleri gibi akustik nitelikler kullanılarak Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN) tabanlı bir müzik tür sınıflandırma modeli geliştirilmesi hedeflenmektedir. Müzik türü sınıflandırması, dijital müzik kütüphanelerinin organizasyonu, müzik önerisi sistemleri ve müzik arama motorları gibi çeşitli uygulamalar için temel bir öneme sahiptir. Son yıllarda, derin öğrenme tekniklerinin gelişmesiyle birlikte, özellikle CNN'ler görüntü işleme alanında olduğu gibi ses verilerinin analizinde de etkileyici sonuçlar göstermiştir. Bu çalışmada, GTZAN veri seti üzerinde, her biri 30 saniyelik ses kayıtlarından oluşan 10 farklı müzik türünü içeren kapsamlı bir veri seti kullanılarak, müzik türü sınıflandırması için güçlü bir model oluşturulması amaçlanmaktadır [4]. Özellik çıkarımı aşamasında, ses sinyallerinin hem zamansal hem de spektral özelliklerini yakalayan çeşitli akustik parametreler kullanılmıştır. Bu özellikler arasında spektral merkez (spectral centroid - sesin parlaklığını ölçen metrik), spektral bant genişliği (spectral bandwidth - ses sinyalinin frekans dağılımının genişliği), kroma özellikleri (chroma features - müziğin tonal içeriğini temsil eden özellikler) ve MFCC katsayıları (Mel Frequency Cepstral Coefficients - insan işitme sistemini taklit eden frekans tabanlı özellikler) bulunmaktadır. Geliştirilen CNN modeli, bu akustik özellikleri kullanarak müzik türlerini otomatik olarak sınıflandırmayı hedeflemektedir.

2. MATERYAL VE METOD

Çalışmada kullanılacak veri setine erişim ve veri analizi için Kaggle platformu tercih edilmiştir. Kaggle'ın sağladığı Docker tabanlı Python ortamı kullanılmış olup, bu ortam veri bilimi çalışmaları için optimize edilmiş çeşitli analitik kütüphaneleri içermektedir. Veri seti dosyalarına erişim, programatik olarak gerçekleştirilmiş ve dosya sistemi üzerindeki tüm giriş dosyaları otomatik olarak listelenmiştir. Çalışma ortamında, geçici dosyalar için '/kaggle/temp/' dizini ve kalıcı çıktılar için 20GB'a kadar depolama kapasitesine sahip

'/kaggle/working/' dizini kullanılmıştır. Veri seti, features_3_sec.csv dosyasından Pandas kütüphanesi aracılığıyla okunmuştur. Veri setinin yapısal analizi sonucunda toplam 9990 örnek ve 60 sütundan oluştuğu gözlemlenmiştir. Veri seti içerisinde ses dosyasının adını içeren 'filename' ve müzik türü etiketini içeren 'label' sütunları kategorik değişkenler olarak object veri tipinde bulunmaktadır. Ses dosyasının uzunluğunu temsil eden 'length' sütunu integer veri tipinde yer alırken, geri kalan 57 sütun float64 veri tipinde akustik özellikleri içermektedir. Tablo 1’de en önemli özelliklerle ilk 5 satır getirilmiştir.

Filename	Length	Chroma SIFT Mean	Chroma SIFT Var	RMS Mean	RMS Var	Spectral Centroid Mean	Spectral Centroid Var	Spectral Bandwidth Mean	Spectral Bandwidth Var	Label
blues.00000.0.wav	66149	335	91.048	130	3.521	1.773	167.54	1.972	117.33	blues
blues.00000.1.wav	66149	343	86.147	112	145	1.816	90.525	2.010	65.671	blues
blues.00000.2.wav	66149	346.81	92.243	132.00	462	1.788	111.40	2.084	75.124	blues
blues.00000.3.wav	66149	363.63	86.856	132.56	2.448	1.655	111.95	1.960	82.913	blues
blues.00000.4.wav	66149	335.57	88.129	143.28	1.701	1.630	79.667	1.948	60.204	blues

Tablo 1: Veri setinde önemli özellikler

Bu akustik özellikler arasında kroma özellikleri, RMS enerji değerleri, spektral özellikler, sıfır geçiş oranı, armoni ve algısal özellikler, tempo ve MFCC katsayıları bulunmaktadır. Her bir akustik özellik için ortalama (mean) ve varyans (var) değerleri hesaplanmış olup, veri setinde eksik değer bulunmamaktadır. Bu şekilde ses sinyallerinin istatistiksel özellikleri kapsamlı bir şekilde temsil edilmiştir.

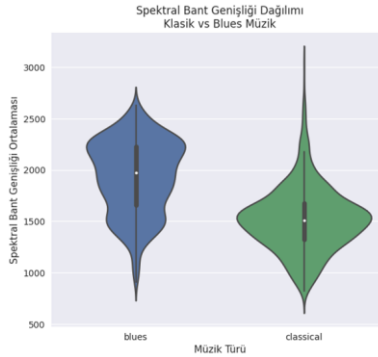
2.1. Veri Seti Sütunlarının Anlamlandırılması

Mel Frekans Kepstral Katsayıları (MFCC), insan işitme sisteminin algılama mekanizmasını taklit ederek sesin spektral özelliklerini temsil etmektedir [3]. Bu katsayılar, özellikle müziğin tını ve enstrümantal karakteristiklerini yakalamada etkili olup, farklı müzik türlerinin ayırt edilmesinde önemli rol oynamaktadır. Spektral özellikler arasında yer alan spektral merkez (centroid) ve bant genişliği (bandwidth), sesin frekans dağılımını ve "parlaklığını" ölçerek, örneğin klasik müzik ile rock müzik arasındaki timbre farklılıklarını ortaya koymaktadır. Kroma özellikleri, müziğin tonal

içeriğini 12 yarım tonluk bir oktav içinde temsil ederek, müzik türlerinin harmonik yapısını analiz etmede kullanılmaktadır.

RMS (Root Mean Square) enerji değerleri, ses sinyalinin genel enerji seviyesini ve dinamik aralığını göstererek, örneğin metal müzik ile jazz arasındaki yoğunluk farklarını belirlemeye yardımcı olmaktadır. Sıfır geçiş oranı (zero crossing rate) özelliği ise, ses sinyalinin frekans içeriği hakkında bilgi vererek, özellikle perküsyif elementlerin yoğun olduğu türlerin tanımlanmasında önem taşımaktadır.


Bu özelliklerin hem ortalama hem de varyans değerlerinin hesaplanması, müzik parçalarının zamansal değişimlerini ve dinamik yapısını yakalamak açısından önemlidir. Örneğin, klasik müzikte görülen daha sabit değişimler ile blues müziğin daha dinamik yapısı, bu istatistiksel ölçümler sayesinde ayırt edilebilmektedir. Şekil 1’de klasik ve blues müziğinin MFCC özelliklerinin dağılımını gösteren violin plot bulunmaktadır. Bu grafikte, Blues müzikte spektral bant genişliğinin daha yüksek ve geniş bir aralıkta dağıldığı görülmektedir. Bu durum, Blues müziğin daha zengin ve çeşitli frekans içeriğine sahip olduğunu göstermektedir. Buna karşılık, Klasik müzikte spektral bant genişliği daha düşük değerlerde yoğunlaşarak daha düzenli ve tekdüze bir yapı sergilemektedir.



Şekil 1. Spektral Bant Genişliği Karşılaştırma Grafiği- Blues ve Klasik Müzik Türlerinin Frekans Dağılımlarını Gösteren Violin Grafiği.

Aynı zamanda Şekil 2’de yapılan RMS varyans analizi, Blues ve Klasik müzik türlerinin dinamik yapılarını karakterize etmede önemli bir metrik olarak öne çıkmaktadır. Root Mean Square varyansı, ses

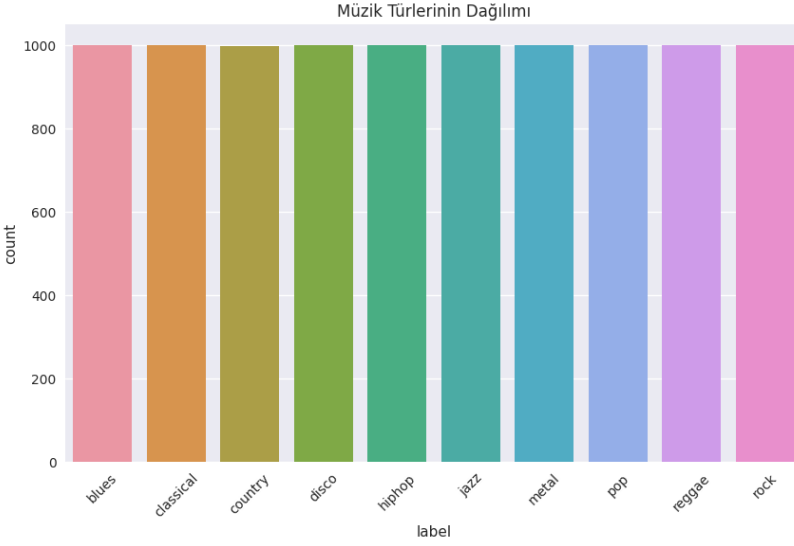
sinyalinin güç seviyesindeki temporal değişkenliği quantitative olarak ölçmektedir. Analiz sonuçları, Blues müziğin geniş bir RMS varyans dağılımı ve belirgin aykırı değerler sergilediğini göstermektedir; bu durum, türün dinamik yapısının yüksek değişkenliğine işaret etmektedir. Buna karşılık, Klasik müziğin RMS varyans değerleri daha düşük bir aralıkta yoğunlaşmakta, bu da ses gücü açısından daha homojen ve regüle bir karakteristiğe sahip olduğunu ortaya koymaktadır. Bu belirgin farklılıklar, iki müzik türünün kompozisyonel ve performatif özelliklerindeki temel ayrışmayı yansıtmaktadır.



Şekil 2. RMS Varyans Dağılımı

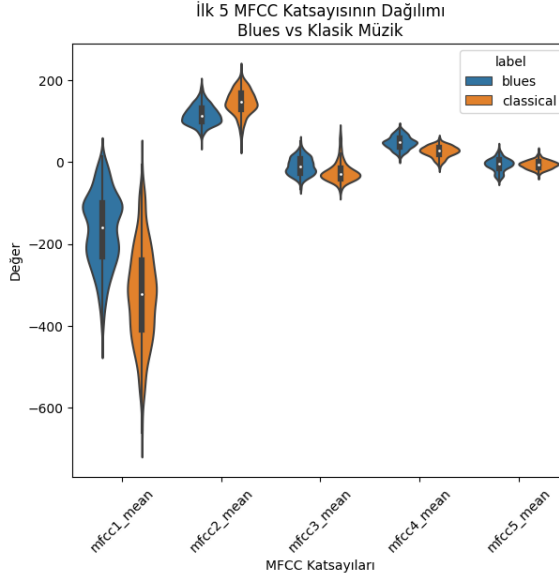
2.2. Veri Setinin İstatistiksel Analizi ve Görselleştirilmesi

Veri setindeki müzik türlerinin dağılımı incelendiğinde, her bir türün eşit sayıda örnek içerdiği gözlemlenmiştir (Şekil 3). Bu dengeli dağılım, sınıflandırma modelinin eğitimi açısından önemli bir avantaj sağlamaktadır.



Şekil 3. Veri Setinde Label (Etiket) Dağılımı

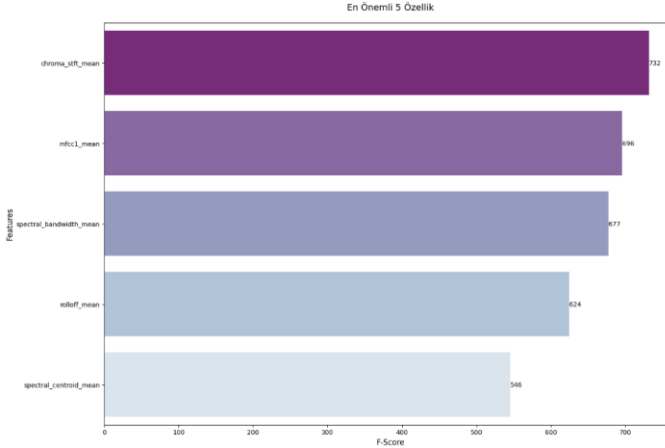
Şekil 4’de görülen MFCC katsayılarının violin plot analizi, Blues ve Klasik müzik türleri arasındaki spektral karakteristiklerin dağılımını ortaya koymaktadır. İlk MFCC katsayısı (mfcc1_mean) incelendiğinde, Klasik müziğin -600 ile 50 aralığında geniş bir dağılım sergilediği, buna karşın Blues müziğinin -450 ile 50 bandında daha konsantre bir yapıda olduğu gözlemlenmektedir. İkinci MFCC katsayısında (mfcc2_mean) her iki tür de pozitif değerler (0-200 arası) göstermekle birlikte, Klasik müziğin görece daha yüksek değerlere sahip olduğu tespit edilmiştir. Üçüncü, dördüncü ve beşinci MFCC katsayıları (-50 ile 50 aralığı) türler arasında daha homojen bir dağılım sergilemekte olup, ayırt edici karakteristikleri daha az belirgindir. Bu analiz sonuçları, özellikle ilk iki MFCC katsayısının, türler arasındaki tınsal ve spektral farklılıkları karakterize etmede önemli belirteçler olduğunu göstermektedir.



Şekil 4. İlk 5 MFCC Özellikleri

Şekil 4’te ilk 5 MFCC özelliklerinin analizi ilk 2 özelliğin ayırt edici özelliklere sahip olduğu görülmektedir.

Bir müziğin sınıflandırılmasında bazı özelliklerin diğerlerine göre daha önemli olduğunu ve analiz sürecinde etkilerinin daha etkisinin daha yüksek olduğu düşünülmektedir. Bu yüzden yapılan araştırma sonucunda en önemli özelliklerin neler olduğuna dair sonuçlar Şekil 5 de grafikte gösterilmiştir.



Şekil 5. GTZAN Veri Setinde Bulunan En Önemli 5 Özellik

SelectKBest yöntemi kullanılarak özellik seçimi gerçekleştirilmiştir. Bu yöntem, F-sınıflandırma (ANOVA F-değeri) istatistiğini kullanarak, bağımlı değişken (müzik türü) ile en güçlü ilişkiye sahip

olan özellikleri belirlemektedir. F-sınıflandırma istatistiği, özellikler ile hedef değişken arasındaki ilişkinin gücünü ölçmekte olup, yüksek F-değerleri, ilgili özelliğin sınıflar arasında daha belirgin bir ayırt edici güce sahip olduğunu göstermektedir. Bu analiz kapsamında, $k=10$ parametresi ile en yüksek ayırt edici güce sahip 10 özellik seçilmiştir. Özellik puanları, her bir özelliğin sınıflandırma performansına potansiyel katkısını yansıtmaktadır. Özellikler, F-istatistik değerlerine göre azalan sırada sıralanmış ve böylece en etkili özelliklerin belirlenmesi sağlanmıştır.

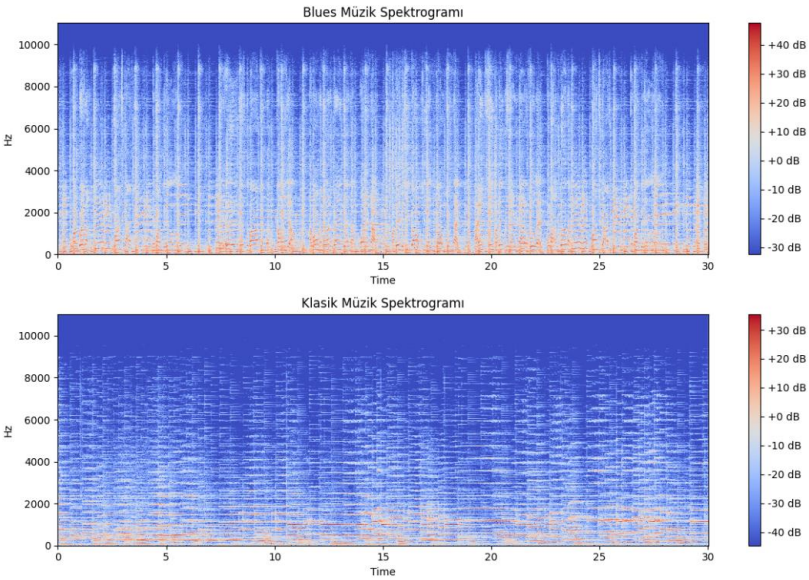
Önemli özelliklerin F-Score dağılımları incelendiğinde (Şekil 6); Dağılım, -200 ile 1000 arasında değişen bir F-skor aralığını kapsamakta olup, en yüksek yoğunluğun yaklaşık 200 F-skor değeri olduğu gözlemlenmektedir. Grafik asimetric bir yapı sergilemekte ve sağa çarpık bir dağılım göstermektedir. 400 ile 800 arasındaki F-skor değerlerinde görülen ikincil yoğunluk artışı, bazı özelliklerin yüksek ayırt edici güce sahip olduğuna işaret etmektedir. Bu dağılım, modelde kullanılan özelliklerin müzik türü sınıflandırmasındaki etkinlik seviyelerinin heterojen bir yapıda olduğunu ve belirli özelliklerin sınıflandırma performansına daha fazla katkı sağladığı kanıtlanmıştır.



Şekil 6. İlk 5 Özelliğin Dağılımı

MFCC özelliklerinde bahsettiğimiz blues türünün klasik müziğe göre daha harmonik olduğunu kanıtlamak için spektrogram analizi gerçekleştirilmiştir. Bu iki farklı müzik türünün spektrogram analizleri karşılaştırıldığında, belirgin spektral karakteristik farklılıklar gözlemlenmektedir. Her iki spektrogram da 0-10000 Hz frekans aralığında ve 30 saniyelik zaman diliminde analiz edilmiş olup, klasik müzik için -40 dB'den +30 dB'ye, blues müzik için -30 dB'den +40 dB'ye uzanan enerji skalaları kullanılmıştır. Düşük frekans bantlarında (0-2000 Hz), klasik müzikte belirgin harmonik yapılar ve düzenli enerji dağılımı gözlemlenirken, blues müziğinde daha yoğun ve sürekli bir enerji dağılımı dikkat çekmektedir. Blues'daki bu yoğun enerji dağılımı, türün karakteristik bas yapısını ve ritmik elementlerini yansıtmaktadır. Orta frekans bölgesinde


(2000-4000 Hz), klasik müzik daha düzenli ve homojen bir dağılım sergilerken, blues müziği daha değişken ve dinamik bir spektral yapı göstermektedir. Bu farklılık, blues müziğinin vokal ve enstrümental çeşitliliğini ortaya koyarken, klasik müziğin dengeli tınısal karakteristiğini vurgulamaktadır. Yüksek frekans bölgesinde (4000-10000 Hz), klasik müzikte enerji yoğunluğunun azaldığı ve kontrollü bir spektral içerik gözlemlenirken, blues müziğinde düzenli aralıklarla tekrarlanan dikey çizgiler ve daha yoğun spektral aktivite görülmektedir. Bu durum, blues müziğinin perküsif elementlerini ve harmonik zenginliğini yansıtırken, klasik müziğin yüksek frekanslarda daha kontrollü bir yapıya sahip olduğunu göstermektedir. Şekil 7’de iki müzik türüne ait spektrogram gösterilmiştir.



Şekil 7. İki Müzik Türüne De Ait Spektrogram Dağılımı

En önemli özellikleri listelediğimizde ilk sırada kroma özellikleri karşımıza çıktığı için bu değişkenin analizinin yapılması ve anlaşılması önemli bir husustur. Kroma özellikleri (Chroma Features) veya Chromagram, müzikal ses analizinde kullanılan önemli bir spektral gösterimdir. Bu özellikler, müziğin harmonik ve tonal içeriğini 12 yarım tonluk batı müziği skalasına indirgeyerek kompakt bir temsil sağlar. Bir oktav içindeki 12 pitch sınıfının (C, C#, D, D#, E, F, F#, G, G#, A, A#, B) enerji dağılımını yansıtır. Bu özellikler, müzik sinyallerinin analizi ve sınıflandırılmasında çeşitli avantajlar sunar. Öncelikle, farklı oktavlardaki aynı notaları tek bir değere haritalayarak oktav-invariant bir temsil oluşturur. Bu özellik, harmonik yapıların daha etkili analiz edilmesini sağlar. Ayrıca,

müzikal eserlerin akor progression'larının ve tonal özelliklerinin belirlenmesinde kritik rol oynar. Sınıflandırma bağlamında kroma özellikleri, müzik türü tanıma (Music Genre Recognition - MGR), akor tanıma (Chord Recognition), cover şarkı tespiti (Cover Song Identification) ve müzik benzerlik analizi gibi çeşitli uygulamalarda kullanılır. Bu özelliklerin boyut indirgenmiş yapısı, hesaplama karmaşıklığını azaltırken, müziğin harmonik yapısı hakkında zengin bilgi sağlar. Örneklerimizden devam edersek; klasik müziğe ait kroma özellikleri analizi (Şekil 8), 30 saniyelik bir zaman diliminde müziğin tonal içeriğindeki değişimleri görselleştirmektedir. Kroma grafiği, müzikal notaların (C'den B'ye) zaman içindeki yoğunluğunu 0 ile 1 arasında değişen bir ölçekte göstermektedir. Özellikle D ve E notalarında 15-20 saniye aralığında gözlemlenen yüksek yoğunluklu bölgeler (koyu mor renkli alanlar), bu zaman diliminde belirgin bir harmonik vurgu olduğunu göstermektedir. Grafikte, farklı pitch sınıflarının düzenli ve sistematik bir şekilde değişim gösterdiği, bu da klasik müziğin yapılandırılmış harmonik yapısını yansıtmaktadır. Ayrıca, C ve G notalarında gözlemlenen periyodik yoğunlaşmalar, klasik müziğin tonal merkezinin ve dominant-tonik ilişkisinin belirgin özelliklerini ortaya koymaktadır. Aynı zamanda blues müziğinin karakteristik nota geçişlerini ve harmonik yapısı Şekil 8'de görülmektedir. Özellikle B, A ve G notalarında gözlemlenen yüksek yoğunluklu bölgeler (koyu mor alanlar), blues müziğinin pentatonik skalaya dayalı karakteristik yapısını vurgulamaktadır. Zaman eksenini boyunca daha sık ve düzensiz aralıklarla değişen nota yoğunlukları, blues müziğinin doğaçlama ve esnek tonal yapısını göstermektedir. D ve C notalarında görülen sürekli ve değişken yoğunluklar, blues müziğinin temel tonalitesindeki mikrotonal değişimleri ve "blue note" kullanımını işaret etmektedir. Bu kroma analizi, blues müziğinin klasik müzikten farklı olarak daha spontane ve dinamik bir harmonik yapıya sahip olduğunu quantitative olarak ortaya koymaktadır.




Şekil 8. Blues ve Klasik Müziğin Kroma Özellikleri

Bu analiz sonuçları, kroma özelliklerinin müzik türlerinin harmonik ve tonal karakteristiklerini başarıyla ayırt edebildiğini göstermekte olup, özellikle blues ve klasik müzik arasındaki yapısal farklılıkları nicel olarak ortaya koymaktadır [3,6,7]. Kroma analizinin sağladığı bu detaylı görselleştirme ve kantitatif veriler, müzik türü sınıflandırma sistemlerinin geliştirilmesinde önemli bir temel oluşturmaktadır.

2.3. Modelin Eğitiminde Xgboost Kullanılması Ve Sonuçları

Sınıflandırma görevi için XGBoost (eXtreme Gradient Boosting) algoritması tercih edilmiştir. Model, 1000 ağaç ($n_estimators=1000$) içerecek şekilde yapılandırılmıştır. XGBoost, gradyan artırma (gradient boosting) prensibine dayanan, yüksek performanslı bir topluluk öğrenme algoritmasıdır [1,8-10]. Model eğitimi sırasında değerlendirme metriği olarak 'merror' (multiclass classification error) kullanılmıştır. Bu metrik, çok sınıflı sınıflandırma problemlerinde yanlış sınıflandırılan örneklerin oranını ölçmektedir. Eğitim süreci, daha önce oluşturulan X_train ve y_train veri setleri üzerinde gerçekleştirilmiştir. XGBoost algoritması, her iterasyonda bir önceki modelin hatalarını düzeltmeye çalışan karar ağaçlarını sıralı bir şekilde oluşturmaktadır. Bu yaklaşım, modelin karmaşık örüntüleri öğrenmesine ve yüksek tahmin performansı elde etmesine olanak

sağlamaktadır. Algoritma ayrıca, aşırı öğrenmeyi önlemek için düzenleme (regularization) teknikleri de içermektedir. Şekil 9'da eğitim sonucunda elde edilen konfüzyon matrisi görülmektedir.



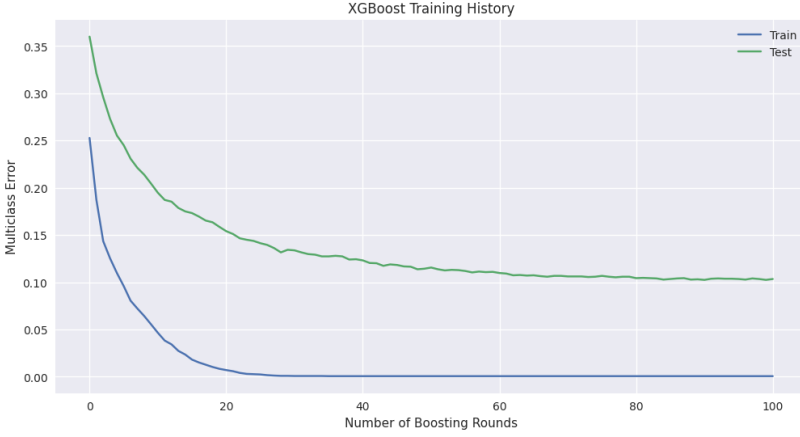
Şekil 9. XGBoost Konfüzyon Matrisi

Analiz sonuçlarına göre, model her bir sınıf için yaklaşık 300 (3e+02) civarında doğru tahmin gerçekleştirmiştir. Bu durum, modelin genel olarak tutarlı bir performans sergilediğini göstermektedir. Özellikle 6. sınıfta 310 (3.1e+02) doğru tahmin ile en yüksek başarı elde edilirken, 9. sınıfta 270 (2.7e+02) doğru tahmin ile görece daha düşük bir performans gözlemlenmiştir.

Yanlış sınıflandırmaların analizi incelendiğinde, bazı sınıflar arasında dikkat çekici karışmalar gözlemlenmektedir. Örneğin:

1. 2. ve 5. sınıflar arasında karşılıklı olarak 13'er örnek yanlış sınıflandırılmıştır
2. 9. sınıf ile 2. sınıf arasında 13 örnek karışması mevcuttur
3. 6. ve 9. sınıflar arasında sırasıyla 11 ve 12 örnek yanlış sınıflandırılmıştır

Bu karışmaların varlığı, ilgili sınıflar arasında benzer özellikler bulunduğunu ve modelin bu özellikleri ayırt etmekte zorlandığını göstermektedir. Bununla birlikte, köşegen üzerindeki yüksek değerler ve köşegen dışındaki görece düşük değerler, modelin genel olarak başarılı bir sınıflandırma performansı sergilediğini ortaya koymaktadır.



Şekil 9. XGBoost Eğitim Eğrisi

XGBoost modelinin eğitim ve test performansı analiz edildiğinde, iterasyon sayısının artışıyla birlikte hata oranlarında belirgin bir azalma gözlemlenmiştir (Şekil 9). Model, eğitimin ilk aşamalarında yaklaşık 0.35 düzeyinde başlayan hata oranından, eğitim seti için neredeyse 0'a yakın, test seti için ise 0.10 civarında bir hata oranına ulaşmıştır. Özellikle ilk 40 iterasyon boyunca hata oranlarında hızlı bir düşüş gözlemlenirken, sonraki iterasyonlarda öğrenme eğrisi kararlı bir platoya ulaşmıştır. Modelin eğitim ve test setlerindeki performans farklılığı incelendiğinde, eğitim setindeki hata oranının test setine kıyasla daha düşük seviyelere inmesi, modelde bir miktar aşırı öğrenme eğilimi olduğunu göstermektedir. Bununla birlikte, test setindeki hata oranının 0.10 civarında stabilize olması, modelin genelleme yeteneğinin kabul edilebilir düzeyde olduğunu ve yaklaşık %90'lık bir sınıflandırma doğruluğuna ulaştığını ortaya koymaktadır. Model performansının iterasyonlar boyunca gösterdiği gelişim, boosting algoritmasının sınıflandırma görevindeki etkinliğini kanıtlamaktadır. Özellikle 40. iterasyondan sonra test hatasının kararlı bir seviyede seyretmesi, modelin optimal performansa ulaştığını ve daha fazla iterasyonun belirgin bir iyileşme sağlamayacağını göstermektedir.

3. SONUÇ

GTZAN veri seti kullanılarak geliştirilen müzik türü sınıflandırma modeli, hem teknik başarısı hem de pratik uygulanabilirliği açısından önemli sonuçlar ortaya koymuştur. XGBoost algoritması ile eğitilen model, %90'lık doğruluk oranıyla müzik türlerini başarılı bir şekilde sınıflandırabilmektedir. Özellikle spektral özellikler, MFCC

katsayıları ve kroma özellikleri gibi akustik parametrelerin etkin kullanımı, modelin performansına önemli katkı sağlamıştır. Çalışmanın en dikkat çekici sonuçlarından biri, farklı müzik türleri arasındaki karakteristik özelliklerin nicel olarak ortaya konmasıdır. Özellikle blues ve klasik müzik arasındaki spektral ve harmonik farklılıkların detaylı analizi, müzik türlerinin matematiksel olarak ayırt edilebilir özellikler taşıdığını göstermiştir. Geliştirilen modelin Meowsic uygulaması üzerinden pratik kullanıma sunulması, teorik çalışmanın gerçek dünya uygulamasına başarılı bir şekilde aktarılabilirdiğini göstermektedir. Bu entegrasyon, müzik eğitimi alanında yapay zeka teknolojilerinin kullanımına örnek teşkil ederken, kişiselleştirilmiş öğrenme deneyiminin önemini de vurgulamaktadır.

KAYNAKÇA

- [1] Oukhouya, H., Kadiri, H., El Himdi, K., & Guerbaz, R. (2023). *Forecasting International Stock Market Trends: XGBoost, LSTM, LSTM-XGBoost, and Backtesting XGBoost Models*. <https://doi.org/10.19139/soic-2310-5070-1822>
- [2] Servı S.,Inan O.,Yılmaz F.,Arsel I.,Pekgör A.,Genç A.,Oturanç G. (2024). A Performance Comparison of Different Machine Learning Algorithms to Forecast Wind Energy in Türkiye. International Conference on Engineering Technologies (ICENTE'24) (Tam Metin Bildiri/Sözlü Sunum) (Yayın No: 9229975)
- [3] Shintri, R. G., & Bhatia, S. K. (2015). Analysis of MFCC and Multitaper MFCC Feature Extraction Methods. *International Journal of Computer Applications*, 131(4), 7–10. <https://doi.org/10.5120/IJCA2015906883>
- [4] Er, M. B., & Aydılek, İ. B. (2019). Music Emotion Recognition by Using Chroma Spectrogram and Deep Visual Features. *International Journal of Computational Intelligence Systems*, 12(2), 1622–1634. <https://doi.org/10.2991/IJCSIS.D.191216.001>
- [5] GTZAN Dataset - Music Genre Classification. (n.d.). <https://www.kaggle.com/datasets/andradaolteanu/gtzan-dataset-music-genre-classificatio>
- [6] Dündar K., Ağaçayak A.C., “Yapay Zeka Ve Makine Öğrenmesi İle İnsan İlişkileri Analizi”, Mühendislikte Yenilikçi Yaklaşımlar-2, (2023)., Eğitim Yayınevi, Editör:Prof.Dr. Süleyman Neşeli, Dr.Öğr.Üyesi. Hakan Terzioğlu, Basım sayısı:1, Sayfa Sayısı 149, ISBN:978-625-6613-95-9, Türkçe(Bilimsel Kitap) (Yayın No: 8856876)
- [7] Mirjafarli S., Terzioğlu H., Ağaçayak A.C., “Bölüm 9: Yapay Zeka Ve Makine Öğrenme Metodlarının Tıp'ta Kullanım Alanlarına Genel Bakış “, Mühendislikte Yeni Araştırmalar, (2022)., , tablet kitapevi, Editör:Öğr. Gör. Gökhan Yalçın, Öğr. Gör. Abdullah Cem Ağaçayak, Basım sayısı:1, Sayfa Sayısı 305, ISBN:978-605-5447-75-5, Türkçe(Bilimsel Kitap) (Yayın No: 8112767)
- [8] Şahin N.,Servı S., “New Perspectives On Artificial Intelligence, Optimization, And Data Analytics In Computational Engineering Innovative Approaches In Applied Engineering Fields”, A Novel Hybrid Algorithm: Enhancing Tuna Swarm Optimization with Cuckoo Search for Global OptimizationG/) (2024)., Selcuk University Press, Editör:Doğan Nurettin, Alan Selahattin, Yılmaz Acar Züleyha, Basım sayısı:1, Sayfa Sayısı 318, ISBN:978-975-448-246-1, İngilizce(Bilimsel Kitap) (Yayın No: 9335700)
- [9] Temurtas F., Gunturkun R., Yumusak N., Temurtas H., “ Harmonic detection using feed forward and recurrent neural networks for active filters”, *Electric Power Systems Research* 72 (2004) 33–40
- [10] Güntürkün R., “İnsansız Savaşlara Doğru Yapay Zeka Kontrollü Ölümçül Silahlar”, Ekin Yayınevi, 2022, s 6, ISBN: 978-625-8235-07-4,



BÖLÜM-2

EEG TABANLI BİLİŞSEL DURUM SINIFLANDIRMASI İÇİN BEYİN- BİLGİSAYAR ARAYÜZÜ ÇERÇEVESİ

Mecit Mert BİŞGİN¹

İrem DEMİR²

Burak YILMAZ³

¹<https://orcid.org/0009-0005-1560-8355>

²<https://orcid.org/0009-0001-8744-555X>

³<https://orcid.org/0000-0001-5549-8385>

EEG TABANLI BİLİŞSEL DURUM SINIFLANDIRMASI İÇİN BEYİN-BİLGİSAYAR ARAYÜZÜ ÇERÇEVESİ

1. Giriş

Beyin bilimi, yaşamın bilinmeyenlerini aydınlatmak ve gelişen biyomedikal teknolojilerle alışkanlıklarımızı nedensel olarak açıklamak için önemli bir çalışma alanı haline gelmiştir [1]. Beyin elektriksel aktivitesinin analizi, beyin bilimlerindeki temel ilgi alanlarından biridir [2]. 1924 yılında Hans Verger tarafından geliştirilen [3] Elektroensefalogram (EEG), beynin elektriksel aktivitesinin zamanla kaydedilmesine olanak sağlayan bir teknoloji olup, nörolojik süreçlerin anlaşılmasında kritik bir rol oynamaktadır. EEG, epilepsi, beyin iltihaplanmaları, Alzheimer, beyin tümörleri ve uyku bozuklukları gibi nörolojik hastalıkların teşhisi, insan-bilgisayar etkileşimi, psikolojik eğilimler ve bilişsel süreçlerin analizi gibi alanlarda yaygın olarak kullanılmaktadır [4]. Özellikle bireylerin konsantrasyon ve dikkat seviyelerinin belirlenmesi, eğitim, psikoloji, reklamcılık, sağlık ve sinirbilim alanlarında ilgi çekici bir araştırma konusu olarak öne çıkmaktadır [5].

Bu çalışmada, bireylerin farklı görevler sırasındaki beyin aktiviteleri EEG sinyalleri kullanılarak analiz edilmiş ve bu aktiviteler ile konsantrasyon seviyeleri arasındaki ilişki incelenmiştir. Veriler, bireylerden dört farklı durumda toplanmıştır. Bu durumlar; beynin nötr bilişsel durumu olarak kabul edilen gözler kapalı durumu [6], katılımcının ana dilinde bir metni sessizce okuması, bir matematik sorusunu çözmesi ve sosyal medyada gezinmesidir. Her katılımcıdan dört adet iki dakikalık kayıt alınmıştır. Toplanan ham EEG verileri öncelikle frekans alanında analiz edilmiş ve anlamlı özellikler çıkarılmıştır [7].

Gözler kapalı olarak alınan kayıt, kişinin nötr bilişsel durumunu gözlemlemeyi amaçlarken, diğer durumlarla olan sinyal farklılıklarına odaklanarak kişiye özgü tespitler yapılması hedeflenmiştir. Bir metni okuma ve bir matematik sorusunu çözme sırasında bilişsel durum farklılıklarına dikkat çekilmiştir.

Sosyal medyada gezinme sırasında alınan kayıt, katılımcının bilinçsiz durumunu nörogörüntüleme ile incelemek amacıyla yapılmıştır [8]. Bu, sosyal medyanın insan beyni üzerindeki etkisine dair geleneksel

araştırma yöntemlerinin bir eksikliği ve sınırlaması olan, elde edilen verileri katılımcının bilinç düzeyine bırakma geleneğine bir alternatif sunmaktadır.

Mevcut literatürde, EEG tabanlı konsantrasyon analizi çalışmaları genellikle sınırlı özellik setlerine dayalıdır veya klasik makine öğrenimi yöntemleriyle sınırlıdır [9]. Ancak, derin öğrenme algoritmalarının kullanımı, EEG sinyallerinin karmaşık yapısını daha iyi anlamayı ve daha yüksek sınıflandırma performansı elde etmeyi mümkün kılmaktadır [10]. Bu bağlamda, çalışmamız hem derin öğrenme tabanlı bir yaklaşım önermekte hem de konsantrasyon seviyelerinin belirlenmesine yeni bir bakış açısı sunmaktadır[11-13]. Bu makale, kullanılan veri toplama yöntemlerini, sinyal işleme ve analiz tekniklerini, sınıflandırma modellerinin performansını ve elde edilen bulguları ayrıntılı bir şekilde sunmayı amaçlamaktadır. Ayrıca, sonuçların yorumlanması ve uygulama alanları hakkında önemli çıkarımlar yapılmıştır.

2. MATERYAL VE METOD

Bu çalışma, yaşları 20-25 arasında değişen 15 kadın ve 17 erkek katılımcıyı içermektedir. Her katılımcının dört ayrı görev sırasında, her biri iki dakika süren kayıtları alınmıştır. Bu görevler; gözlerin kapalı olması, metin okuma, matematik problemleri çözme ve sosyal medyada gezinme şeklindedir. Dikkat ve bilişle ilgili gerçek zamanlı sinirsel aktiviteleri izlemek için tüm bu durumlarda mobil bir EEG cihazı kullanılarak beyin sinyalleri kaydedilmiştir.

2.1. Katılımcılar

Çalışmaya toplamda 32 sağlıklı birey (15 erkek, 17 kadın) katılmıştır. Tüm katılımcılar bilgilendirilmiş onam formu doldurmuş ve bilinen herhangi bir nörolojik rahatsızlıkları bulunmamaktadır.


2.2. Kayıt Cihazı

Bu çalışmada, EEG verilerinin toplanması için Neurosky Mindwave cihazı birincil araç olarak seçilmiştir. Neurosky Mindwave, sinirsel osilasyonları ve göz hareketlerini tespit ederek dikkat odaklanması ve

uyku düzenlerini izleyebilen tek kanallı bir EEG cihazıdır. Bu cihaz, kulak üstüne yerleştirilen bir topraklama elektrodu ve alnın ortasına yerleştirilen bir sensör ile non-invaziv bir kurulum sunar; bu da özellikle genç katılımcılar için idealdir. Cihaz, EEG verilerini 512 Hz çıkış frekansında kaydeder ve dikkat seviyelerini 0 ile 100 arasında ölçen özel bir algoritma içerir. Neurosky Mindwave'ın tercih edilmesinin ana nedenlerinden biri, hafif tasarımı ve tek elektrotlu konşekilasyonu sayesinde katılımcılara minimum rahatsızlık vermesidir.

EEG cihazı ve koklear implant birbirinden bağımsız çalışır; koklear implant minimum elektromanyetik parazit yayarken, Neurosky Mindwave'ın elektrodunun mekânsal ayrımı önemli bir paraziti etkili bir şekilde önler. Ayrıca, EEG ve koklear implant arasındaki ortak topraklama döngüsü, elektromanyetik paraziti daha da azaltarak EEG verilerinin bütünlüğünü sağlar.

Neurosky Mindwave, çeşitli uygulamalarla uyumluluk sunar ve veri toplama, cihazın yazılım geliştirme kiti (SDK) aracılığıyla gerçekleştirilmiştir. Bu SDK, çalışmada dikkat yanıtlarını kaydetmek ve analiz etmek için kullanılmıştır [14]. Şekil 1, Neurosky Mindwave EEG cihazını göstermektedir.



Şekil 1: Neurosky Mindwave EEG cihazı.

Şekil 1’de cihazın her bir bileşeni de gösterilmektedir.

2.3. Deneysel Tasarım

Katılımcılar dört koşulun sağlandığı oturumlara katıldılar.

1. **Başlangıç (Durum 0):** Gözler kapalı, dinlenme hali.
2. **Okuma (Durum 1):** Metinsel materyalin sessizce okuma.
3. **Problem Çözme (Durum 2):** Orta zorlukta matematik problem çözme.
4. **Sosyal Medya Taraması (Durum 3):** Sosyal medya akışının simüle edilmiş gezintisi.

Her bir durum iki dakika sürmüştür.

2.4. Veri Analizi

EEG verileri, dikkat ve bilişle ilişkili frekans bantlarına ayrılmıştır. Farklı durumlar sırasında ortaya çıkan bilişsel tepkileri ayırt etmek için makine öğrenimi algoritmaları uygulanmıştır.

Sinyal Toplama ve Analiz Prosedürü: EEG sinyallerini toplamak için katılımcılara, metin okuma, matematik problemleri çözüme ve sosyal medya tarama görevleri atanmış, her bir görev için iki dakikalık sinirsel kayıtlar alınmıştır. Bireysel farklılıkları ortadan kaldırmak amacıyla, dinlenme durumundaki beyin sinyalleri kaydedilmiştir. Bu baz sinyaller daha sonra diğer verilerden çıkarılarak, verilerin sadece dikkat ve öğrenme ile ilgili sinyal değişimlerine odaklanması sağlanmıştır.

Dinlenme durumundaki sinyali izole etmek için bir frekans spektrumu dönüşümü uygulanmış ve bu değerler diğer verilerden çıkarılarak net bilişsel aktivite elde edilmiştir. Bu işlemde, sürekli bir sinyali tanımlanmış bir zaman aralığında bileşen frekanslarına ayıran Fourier dönüşümü kullanılmıştır. Bu teknik, her bir bileşenin genliğini ve fazını tanımlayarak sinyalin frekans spektrumunu üretir [15]. Fourier dönüşümünün matematiksel temsili Denklem 1'de verilmiştir.

$$f(x) = a_0 + \sum_{n=1}^{\infty} (a_n \cos n\pi x/L + b_n \sin n\pi x/L) \quad (1)$$

Bir fonksiyonun Fourier serisi açılımı, onu farklı frekanslara ve

genliklere sahip sonsuz sayıda sinüs ve kosinüs toplamı olarak ifade eder. Bu formülde a_0 terimi, fonksiyonun belirli bir aralıktaki ortalama değerini (veya DC bileşenini) temsil eder. a_n ve b_n katsayıları sırasıyla her harmonik frekanstaki kosinüs ve sinüs bileşenlerinin genliklerini belirler. Bu seri, $f(x)$ fonksiyonunun temel ve harmonik sinüzoidal dalgaların bir kombinasyonu olarak temsil edilmesine olanak tanır. Her bir dalga, bir temel frekansın tam katı olan bir frekansa sahiptir ve bu şekilde $f(x)$ daha basit periyodik bileşenlere ayrıştırılmış olur [16-17,21].

2.5. Veri Önleme

- Artefakt Temizleme: Göz hareketleri ve kas artefaktlarını temizlemek için Bağımsız Bileşen Analizi (Independent Component Analysis - ICA) uygulanmıştır. ICA, genellikle boyut indirgeme ve özellik seçimi için kullanılan bir algoritmadır. Bu yöntem, her adımda en kötü özelliği çıkararak indirgeme işlemi iteratif olarak gerçekleştirir [18]. ICA, bağımsız bileşenlerin manuel olarak incelenmesiyle birlikte, göz hareketleri ve kas artefaktlarının temizlenmesinde kullanılmıştır.
- Baz Çizgi Düzeltmesi: Görevle ilgili sinyalleri normalleştirmek amacıyla baz koşulundan (0) alınan veriler, diğer üç koşuldan çıkarılmıştır.
- Aykırı Değerlerin Çıkarılması: Anormal veri noktalarını elemek için %20 kontaminasyon oranıyla Yerel Aykırı Değer Faktörü (Local Outlier Factor) yöntemi uygulanmıştır.

2.6. Özellik Çıkarma

Özellikler üç ana kategoride türetilmiştir:

- Zaman-Domain Özellikleri:
Hjorth parametreleri (Aktivite, Mobilite, Karmaşıklık), ortalama enerji ve varyans. Hjorth parametreleri, EEG sinyal analizinde yaygın olarak kullanılan bir yöntemdir ve sinyallerin birinci ve ikinci türevleri kullanılarak hesaplanır [19,20].
- Frekans-Domain Özellikleri:

Delta, Teta, Alfa, Beta ve Gama bantlarındaki güç spektrumları.

- İstatistiksel Özellikler:

Entropi ölçümleri (Tsallis, Renyi), çarpıklık (skewness), basıklık (kurtosis) ve standart sapma.

2.7. Sınıflandırma Süreci

Bu veriler, makine öğrenimi yöntemlerine tabi tutulmuş, sınıflandırma etkinliği değerlendirilmiş ve sinyaller arasında istatistiksel olarak anlamlı bir sınıflandırma yapılabileceği analiz edilmiştir.

Seçilen sınıflandırma algoritmaları, hem denetimli (supervised) hem de denetimsiz (unsupervised) öğrenme için uygun yöntemleri kapsayarak farklı öğrenme paradigmalarının performanslarının kapsamlı bir şekilde karşılaştırılmasına olanak tanımıştır. Bu yaklaşım, algoritmaların hem etiketli (denetimli) hem de etiketsiz (denetimsiz) veri senaryolarındaki yeteneklerinin değerlendirilmesine imkan sağlar.

Seçilen algoritmalar, geleneksel ve gelişmiş tekniklerin bir karışımını içermekte olup her biri kendine özgü güçlü yönlere sahiptir. Seçilen algoritmalar şu şekildedir:

Random Forest (RF)

Destek Vektör Makineleri (SVM)

Sinir Ağları (NN)

2.8. Doğrulama

10 Katlı Çapraz Doğrulama (10-Fold Cross-Validation): Modelin dayanıklılığını sağlamak için kullanılmıştır.

Değerlendirme Ölçütleri: Doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skora dayanmaktadır.

Bu çeşitli modellerin incelenmesi, farklı veri yapıları ve öğrenme gereksinimlerini ele almadaki uyarlabilirlikleri ve etkinlikleri hakkında içgörüler elde edilmesini sağlamaktadır.

3. SONUÇLAR

3.1. Tanımlayıcı İstatistikler:

Veri kümesi, her biri 25 özelliğe sahip 96 örnekten oluşmaktaydı. Aykırı değer analizi sonucunda 18 örnek çıkarılmış ve analiz için 78

örnek bırakılmıştır.

Tablo 1: Sınıflar ve Algoritmalara Göre Performans Ölçütleri

Sınıf	Random Forest (Accuracy)	SVM (Accuracy)	Neural Network (Accuracy)
Okuma	80%	83%	85%
Problem Çözme	84%	88%	90%
Sosyal Medya	82%	84%	88%

Sinir ağları, tüm koşullar boyunca diğer modellerden daha iyi performans göstermiştir, özellikle problem çözme görevlerinde belirgin üstünlük sağlamıştır.

3.2. Feature Analysis

- Hjorth Karmaşıklık: Problem çözme sırasında daha yüksek değerlere ulaşmıştır, bu da artan bilişsel katılımı yansıtmaktadır.
- Alfa/Beta Oranları: Problem çözme görevlerinde daha düşük oranlar, artan odaklanmayı göstermektedir.
- Entropi Ölçümleri: Sosyal medya gezinme görevlerinde daha yüksek değişkenlik gözlemlenmiş, bu da daha az yapılandırılmış bilişsel katılımı işaret etmektedir.

Tablo 2 sınıflandırma algoritmalarının performans değerlerini göstermektedir.

Tablo 2: Performans Ölçütleri Tablosu

Ölçüt	Random Forest	SVM	Sinir Ağları
Doğruluk (%)	84	85	88
Kesinlik (%)	82	86	89
Duyarlılık (%)	83	85	90
F1-Skoru (%)	83	85.5	89.5

1. Doğruluk (%)

Tanım: Veri kümesindeki toplam örnekler içinde doğru

sınıflandırılan (hem pozitif hem negatif) örneklerin oranını temsil eder. Veri dengesiz olduğunda yanıltıcı olabilir.

$$\text{Doğruluk} = (TP+TN) / (TP+FP+TN+FN) \quad (2)$$

2. Kesinlik (%)

Tanım: Pozitif olarak tahmin edilen örneklerin içinden gerçekten pozitif olanların oranını ölçer. Yanlış pozitifleri en aza indirmesi gereken durumlarda önemlidir.

$$\text{Kesinlik} = TP / (TP + FP) \quad (3)$$

3. Duyarlılık (%)

Tanım: Gerçek pozitif örneklerin içinden doğru bir şekilde tanımlananların oranını ifade eder. Yanlış negatifleri en aza indirmek için önemlidir.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (4)$$

4 F1-Skoru (%)

Tanım: Kesinlik ve duyarlılığın harmonik ortalamasıdır. Dengesiz veri durumlarında değerlendirme için dengeli bir ölçüt sağlar.

$$\text{F1 Skoru} = 2 \times (\text{precision} \times \text{recall}) / (\text{precision} + \text{recall}) \quad (5)$$

Genel Sınıflandırma Sonuçları

Sinir ağları, kesinlik, duyarlılık ve F1-skorlarında tutarlı bir şekilde en yüksek değerlere ulaşarak bilişsel durumları ayırt etmedeki dayanıklılıklarını doğrulamıştır.

4. TARTIŞMA

Bu çalışma, EEG sinyallerinin farklı bilişsel durumlara karşılık gelen sinirsel aktivite örüntülerini yakalamadaki faydasını göstermektedir. Sağlam bir deney tasarımı ve ileri makine öğrenimi teknikleri kullanılarak, okuma, problem çözme ve sosyal medya taraması gibi görevler arasında önemli sinirsel özellik farklılıkları belirlenmiştir. Özellikle Sinir Ağları, tüm koşullarda daha yüksek performans

metrikleri elde ederek en etkili sınıflandırma algoritması olarak ortaya çıkmıştır.

Bu araştırmanın en kritik bulgularından biri, problem çözme görevleri sırasında gözlemlenen artmış beta bandı gücü ve Hjorth Kompleksliği olmuştur. Bu metrikler, artan bilişsel katılım ve göreve özgü dikkat ile güçlü bir şekilde ilişkilidir ve EEG tabanlı bilişsel analiz üzerine mevcut literatürle uyum içerisindedir. Buna karşın, sosyal medya tarama sırasında daha yüksek entropi değerleri gözlenmiştir, bu da daha az yapılandırılmış bilişsel katılımı ve sinirsel tepkilerde daha fazla değişkenliği göstermektedir. Bu durum, entropi ölçütlerinin dinamik ve doğrusal olmayan sinirsel örüntüleri yakalamadaki esnekliğini vurgulamaktadır.

Performans metrikleri, EEG sinyali analizi için zaman alanı, frekans alanı ve istatistiksel özelliklerin birleştirilmesinin etkinliğini daha da vurgulamaktadır. Örneğin, alfa/beta oranları dikkat durumlarının güvenilir bir göstergesini sağlarken, Hjorth parametreleri sinyal karmaşıklığı ve frekans içeriğini daha incelikli bir şekilde anlamayı sağlamıştır. Bu özelliklerin makine öğrenimi iş akışlarına entegrasyonu, özellikle problem çözme gibi farklı bilişsel taleplere sahip görevler için sınıflandırma doğruluğunu önemli ölçüde artırmıştır.

Bu umut verici sonuçlara rağmen, çalışmanın birkaç sınırlaması bulunmaktadır. Göreceli olarak küçük bir örneklem büyüklüğü, bulguların genelleştirilebilirliğini sınırlayabilir ve simüle edilmiş sosyal medya taraması gibi bazı görevlerin yapay doğası, gerçek dünya senaryolarını tam olarak yansıtmayabilir. Gelecekteki araştırmalar, daha çeşitli bir katılımcı havuzunu içermeli ve sonuçların uygulanabilirliğini artırmak için ekolojik olarak geçerli görevler dahil etmelidir.

Ayrıca, makine öğrenimi modelleri sağlam bir performans sergilemiş olmasına rağmen, derin öğrenme tekniklerinin ve gelişmiş özellik seçimi yöntemlerinin daha fazla araştırılması, daha iyi sınıflandırma sonuçları sağlayabilir. Ek olarak, kalp atış hızı veya galvanik deri

tepkisi gibi ek fizyolojik sinyallerin entegrasyonu, bilişsel durumların daha kapsamlı bir şekilde anlaşılmasını sağlayabilir.

Bu çalışmanın etkileri birçok alana yayılmaktadır. Eğitimde, EEG tabanlı sistemler, öğrencilerin katılımını ve bilişsel yükünü gerçek zamanlı olarak izleyerek kişiselleştirilmiş öğrenme deneyimlerini mümkün kılabilir. Sağlıkta, bu yöntemler bilişsel bozuklukların veya nörolojik hastalıkların erken teşhisi ve yönetimine yardımcı olabilir. Ayrıca, EEG destekli insan-bilgisayar arayüzleri, kullanıcıların zihinsel durumlarına uyum sağlayarak çeşitli uygulamalarda kullanılabilirliği ve verimliliği artırabilir.

Sonuç olarak, bu çalışma, bilişsel durum sınıflandırması için EEG sinyali analizinin potansiyelini vurgulamakta ve gelecekteki araştırmalar için bir temel oluşturmaktadır. Mevcut sınırlamaları ele alarak ve makine öğrenimi ve sinyal işleme alanındaki gelişmelerden yararlanarak, EEG tabanlı sistemler insan bilişini anlamak ve geliştirmek için vazgeçilmez araçlar haline gelebilir.

Bu çalışma, bilişsel durumların anlaşılmasında EEG sinyallerinin potansiyelini vurgulamaktadır. Problem çözme sırasında artmış beta bandı gücü ve sosyal medya tarama sırasında daha yüksek entropi gibi sinirsel örüntüler, göreve özgü sinirsel dinamiklere işaret etmektedir. Özellikle Sinir Ağları, yüksek doğruluk göstermiş ve gerçek zamanlı EEG uygulamaları için uygun hale gelmiştir.

Sınırlamalar arasında küçük örneklem büyüklüğü ve yapay görev senaryoları yer almakta olup, bu durum genelleştirilebilirliği sınırlandırabilir. Gelecekteki araştırmalar, daha geniş, daha çeşitli popülasyonlara ve ekolojik olarak geçerli görevlere odaklanmalıdır.

5. SONUÇ

Bu çalışmanın bulguları, EEG tabanlı bilişsel durum sınıflandırmasının çeşitli görev senaryolarında etkinliğini vurgulamaktadır. Gelişmiş özellik çıkarma yöntemleri ve makine öğrenmesi modellerinin birleşimini kullanarak, okuma, problem çözme ve sosyal medya gezinme görevleri arasında başarıyla ayırım

yapmayı başardık ve ortalama sınıflandırma doğruluğu %85 olarak elde edildi. Özellikle sinir ağları, problem çözme görevlerinde %90'a kadar doğruluk sağlayarak olağanüstü bir performans sergiledi.

Çalışma, EEG sinyallerinin farklı bilişsel durumlarla ilişkili nöral dinamikleri güvenilir bir şekilde yakalayabildiğini güçlü bir şekilde kanıtlamaktadır. Hjorth parametreleri, bant gücü oranları ve entropi ölçüleri gibi temel özellikler, bu durumları karakterize etmede önemli bir rol oynamıştır. Problem çözme görevlerinde gözlemlenen yüksek beta-bandı gücü ve Hjorth karmaşıklığı, artan bilişsel katılım ve göreve özgü odaklanmayı yansıtırken, sosyal medya gezinme sırasında artan entropi, daha az yapılandırılmış görevlerde nöral aktivitenin değişkenliğini ve doğrusal olmayan doğasını vurgulamaktadır.

Bu bulguların çıkarımları önemli olabilir. Eğitim alanında, EEG tabanlı sistemler, öğrenci bilişsel durumlarına yönelik gerçek zamanlı geri bildirim sağlayarak öğrenme ortamlarını devrim niteliğinde dönüştürebilir ve böylece uyarlanabilir ve kişiselleştirilmiş öğretimi mümkün kılabilir. Sağlık alanında, bu yöntemler, nörolojik hastalıkların erken tanısı ve izlenmesine yardımcı olabilir, çünkü tipik nöral desenlerdeki sapmaları tanımlayabilir. Ayrıca, insan-bilgisayar etkileşimi alanında EEG tabanlı uyarlanabilir sistemler, kullanıcı deneyimini zenginleştirebilir ve kullanıcıların zihinsel durumlarına dinamik olarak tepki verebilir.

Ancak çalışma, bazı sınırlamalara da sahiptir. Küçük örneklem boyutu ve deneysel görevlerin kontrollü doğası, bulguların genellenebilirliğini sınırlayabilir. Gelecekteki araştırmalar, daha büyük ve daha çeşitli katılımcı grupları içeren çalışmalar yaparak ve daha ekolojik geçerli görev tasarımlarını dahil ederek bu sınırlamaları ele almalıdır. Ayrıca, tamamlayıcı fizyolojik sinyallerin entegrasyonu ve gelişmiş derin öğrenme modellerinin uygulanması, EEG tabanlı bilişsel durum sınıflandırmasının doğruluğunu ve uygulanabilirliğini daha da artırabilir.

Sonuç olarak, bu çalışma, EEG'yi bilişsel izleme ve sınıflandırma için güçlü bir, invaziv olmayan araç olarak potansiyelini vurgulamaktadır.

Burada sunulan bulgular üzerine inşa edilerek, gelecekteki çalışmalar EEG uygulamalarının sınırlarını genişletebilir ve eğitim, sağlık ve daha fazlası için yenilikçi çözümlerin yolunu açabilir.

EEG tabanlı bilişsel durum sınıflandırması, çeşitli alanlarda önemli bir potansiyel sunmaktadır. Bu çalışma, ileri düzey sinyal işleme ve makine öğrenme yöntemleri kullanarak bilişsel durumları ayırt etme yeteneğini göstermiştir ve %85'lik bir ortalama sınıflandırma doğruluğu elde edilmiştir. Mevcut sınırlamaları ele alarak, gelecekteki çalışmalar EEG uygulamalarını uyarlanabilir öğrenme, sağlık tanıları ve insan-bilgisayar etkileşimi alanlarında genişletebilir.

KAYNAKÇA

- [1] A. Chaddad, Y. Wu, R. Kateb, and A. Bouridane, “Electroencephalography signal processing: A comprehensive review and analysis of methods and techniques,” *Sensors (Basel)*, vol. 23, no. 14, p. 6434, Jul. 2023.
- [2] F. L. da Silva, “EEG ve MEG: Nörobilimle ilgisi,” *Neuron*, vol. 80, pp. 1112–1128, Oct. 2013.
- [3] T. F. Collura, “History and evolution of electroencephalographic instruments and techniques,” *J. Clin. Neurophysiol.*, vol. 10, no. 4, pp. 476–504, Oct. 1993.
- [4] E. Niedermeyer and F. L. da Silva, *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. New York: Lippincott Williams & Wilkins, 2005.
- [5] C. Berka, D. J. Levendowski, M. M. Cvetinovic, et al., “Real-time analysis of EEG indices of alertness, cognition, and memory acquired with a wireless EEG headset,” *Int. J. Hum.-Comput. Interact.*, vol. 17, no. 2, pp. 151–170, 2007.
- [6] S. Dündar, “Öğrencilerin beyin dalgalarının problem çözme sürecinde incelenmesi (Doktora tezi),” Gazi Üniversitesi, Ankara, Türkiye, 2013. Available: https://acikbilim.yok.gov.tr/bitstream/handle/20.500.12812/358236/yokAcikBilim_10007753.pdf
- [7] C. J. Stam, “Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field,” *Clin. Neurophysiol.*, vol. 116, no. 10, pp. 2266–2301, Oct. 2005.
- [8] H. B. Tanrikulu and M. Ceran, “Medya etkilerine yönelik metodolojik bir tartışma: Konvansiyonel yöntemler ve EEG,” *Moment Dergi*, vol. 11, no. 1, pp. 109–131, Jan. 2024.
- [9] X. Zhang, L. Yao, X. Wang, et al., “Deep learning for EEG-based brain-computer interfaces: A review,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 28, no. 4, pp. 701–715, Apr. 2020.
- [10] Y. Roy, H. Banville, I. Albuquerque, et al., “Deep learning-based electroencephalography analysis: A systematic review,” *J. Neural Eng.*, vol. 16, no. 5, p. 051001, Oct. 2019. Available: <https://doi.org/10.1088/1741-2552/ab260c>
- [11] Servi S., İnan O., Yılmaz F., Arsel İ., Pekgör A., Genç A., Oturanç G. (2024). A Performance Comparison of Different Machine Learning Algorithms to Forecast Wind Energy in Türkiye. *International Conference on Engineering Technologies (ICENTE'24) (Tam Metin Bildiri/Sözlü Sunum) (Yayın No: 9229975)*
- [12] Yılmaz F., Pekgör A., Arsel İ., Servi S., İnan O., Genç A., Oturanç G., “New Perspectives On Artificial Intelligence, Optimization, And Data Analytics In Computational Engineering/Alternative Distributions In Wind Speed Forecasting And A Comparison “, *Innovative Approaches in Applied Engineering Fields, (2024).*, Selcuk University Press, Editör:Doğan Nurettin, Alan Selahattin,

- Yılmaz Acar Züleyha, Basım sayısı:1, Sayfa Sayısı 318, ISBN:978-975-448-246-1, İngilizce(Bilimsel Kitap) (Yayın No: 9335834)
- [13] Şahin N., Servi S., “New Perspectives On Artificial Intelligence, Optimization, And Data Analytics In Computational Engineering Innovative Approaches In Applied Engineering Fields”, A Novel Hybrid Algorithm: Enhancing Tuna Swarm Optimization with Cuckoo Search for Global OptimizationG/) (2024)., Selcuk University Press, Editör:Doğan Nurettin, Alan Selahattin, Yılmaz Acar Züleyha, Basım sayısı:1, Sayfa Sayısı 318, ISBN:978-975-448-246-1, İngilizce(Bilimsel Kitap) (Yayın No: 9335700)
- [14] O. Sokolov, et al., “Spirometry data analysis and monitoring in medical and physiological tests,” J. Med. Devices, vol. 5, pp. 35–46, Mar. 2015.
- [15] A. S. Al-Fahoum and A. A. Al-Fraihat, “Methods of EEG signal features extraction using linear analysis in frequency and time-frequency domains,” ISRN Neurosci., vol. 2014, Article ID 730218, 2014. Available: <https://doi.org/10.1155/2014/730218>.
- [16] Güntürkün R., Tosun M., “Estimation of the Amount of Drug to be Applied to the Patient Using Elman Recurrent Artificial Neural Network”, M ü h . B i l . v e A r a ş . D e r g i s i , 2 0 2 0 ; 2 (2) 2 4 - 2 9
- [17] Tosun M., Güntürkün R., “Anesthetic gas control with neuro-fuzzy system in anesthesia”, Expert Systems with Applications, Expert Systems with Applications 37 (2010) 2690–2695
- [18] Genç, H. M., Çataltepe, Z., & Pearson, T. (2007). Yeni Bir Temel/Bağımsız Bileşen Analizi (TBA/BBA) Tabanlı Öznitelik Seçme Yöntemi A New PCA/ICA Based Feature Selection Method. *Signal Processing and Communications Applications. SIU*.
- [19] İmak, A. *Epileptik EEG sinyallerinin makine öğrenmesi yöntemleri ile sınıflandırılması* (Master's thesis, Fen Bilimleri Enstitüsü).
- [20] Mirjafarli S., Terzioğlu H., Ağaçayak A.C., “Bölüm 9: Yapay Zeka Ve Makine Öğrenme Metodlarının Tıp'ta Kullanım Alanlarına Genel Bakış “, Mühendislikte Yeni Araştırmalar, (2022)., , tablet kitapevi, Editör:Öğr. Gör. Gökhan Yalçın, Öğr. Gör. Abdullah Cem Ağaçayak, Basım sayısı:1, Sayfa Sayısı 305, ISBN:978-605-5447-75-5, Türkçe(Bilimsel Kitap) (Yayın No: 8112767)
- [21] Güntürkün R., “Measurement Of Attention Levels From Eeg Signals With Biosensors Using Elman Feedback Artificial Neural Network”, Research Inventy: International Journal of Engineering And Science Vol.14, Issue 12 (December 2024), PP 49-53, Issn (e): 2278-4721, Issn (p):2319-6483



BÖLÜM-3

FİDE: DOĞAYI TANI, SEV, KORU

Fatih AKKUŞ¹

Muhammed Esad DOĞAN²

Diyar TÜRK³

Sema SERVİ⁴

¹<https://orcid.org/0000-0002-4673-8647>

²<https://orcid.org/0000-0002-6163-2939>

³<https://orcid.org/0000-0002-8230-9188>

⁴<https://orcid.org/0000-0003-2069-9085>

FİDE: DOĞAYI TANI, SEV, KORU

1. Giriş

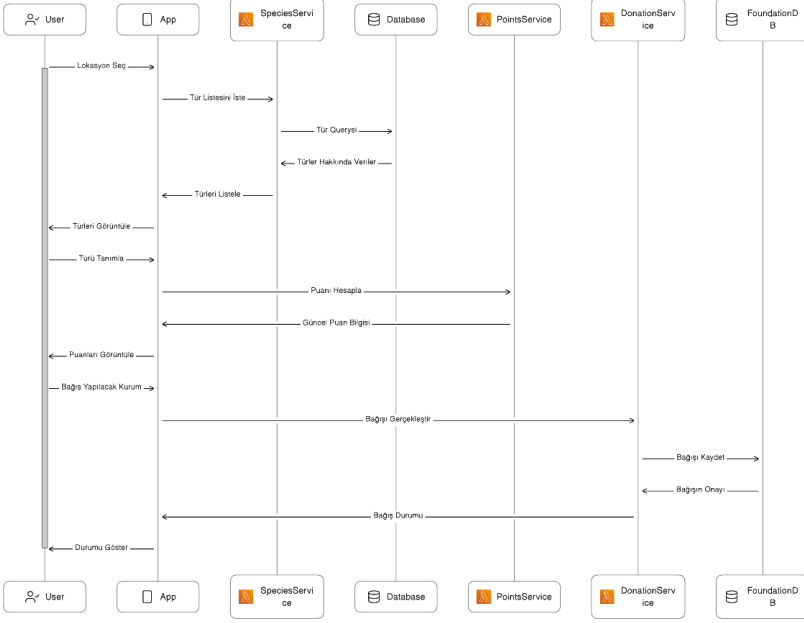
Biyçeşitlilik, doğanın zenginliğini ifade etmektedir ve dünya üzerindeki tür ve gen çeşitliliğini kapsamaktadır. Bu çeşitlilik, ekosistemlerin sağlıklı işleyişi için hayati öneme sahiptir; lakin insan faaliyetleri nedeniyle biyçeşitlilik kaybı yaşanmakta, bu da ekosistemlere zarar vermektedir. Bu sorunların çözümü için geliştirilen uygulamalar arasında iNaturalist, eBird ve Pl@ntNet öne çıkmaktadır. Özellikle pazarda bulunan tüm uygulamalar arasında iNaturalist, türleri keşfetmeyi, gözlemlemeyi ve tanısı konulamayan türlerin belirlenmesi gibi işlemler sağlayarak biyçeşitlilik bilincini artırmaktadır. Ancak, istilacı türler konusunda eksik kalmaktadır. Bu noktada, FİDE uygulaması devreye girmektedir. Derin öğrenme algoritmaları kullanarak çekilen fotoğraflardan tür tespiti yapabilen FİDE, istilacı türleri tanımlayarak kullanıcıları uyarı ve bilgilendirme imkânı sunmaktadır. Ayrıca, doğa yürüyüşü yapanlara nadir tür bildirimleri yaparak biyçeşitliliğin korunmasında katkı sağlamaktadır. FİDE'nin eBird ve Pl@ntNet gibi önceki uygulamalardan farkı, kullanıcılarına eğitim ve görevlendirme imkanları sunmasıdır. Bu özellikler, biyçeşitliliğin sadece tespit değil, aynı zamanda anlayış ve katılım gerektiren bir konu olduğunu vurgulamaktadır. FİDE sayesinde kullanıcılar, doğaya katkı puanları kazanarak çeşitli kurumlara bağış yapılabilmektedir, bu da doğaya karşı sorumluluklarını artırmaktadır. FİDE, biyçeşitliliğin korunmasına yönelik yenilikçi bir yaklaşım sunarak, kullanıcılarını bilinçlendirmekte ve aktif katılımı teşvik etmektedir.

2. MATERYAL VE METOD

Projenin sunucu tarafını geliştirmeden önce iş gereksinimi analizi gerçekleştirildi. Bazı gereksinim analizleri şu şekildedir;

- Uygulamamızda görevlendirme sistemi bulunmaktadır. Kullanıcılar seçtikleri konumda daha önce tespit edilmiş türleri, enderliklerine göre farklı konumlarda ve miktarlarda tespit etmeleri istenmektedir. Tamamlanan görevler doğaya katkı puanı kazandırarak kullanıcılara çeşitli türleri tanıma ve bu süreçte elde ettikleri puanlarla vakıflara bağış yapabilme imkânı sağlamaktadır. Yapılan analizden yola çıkarak geliştirilen sistemin ardışık diyagramı Şekil 1'de görülmektedir.

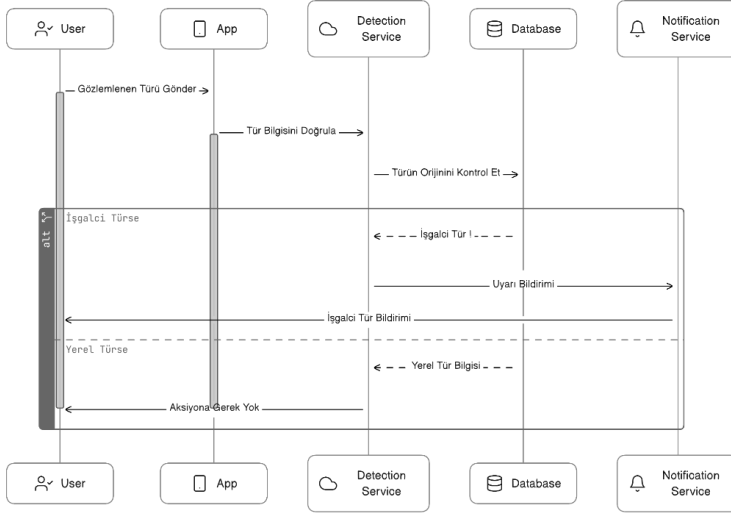
Görevlendirme Sistemi



Şekil 1. Erken Uyarı Sistemine Ait Ardışık Diyagram

- Uygulamamız, kullanıcılar tarafından tespit edilen türler içinde, ekosisteme ait olmayan türleri tespit edip istilacı olarak etiketleyerek bir uyarı sistemi geliştirmektedir. Bu sayede erken müdahale ile ekosistemde oluşabilecek sorunlara karşı hazırlık yapabilmektedir. Şekil 2 bu geliştirilen uyarı sistemine aittir.

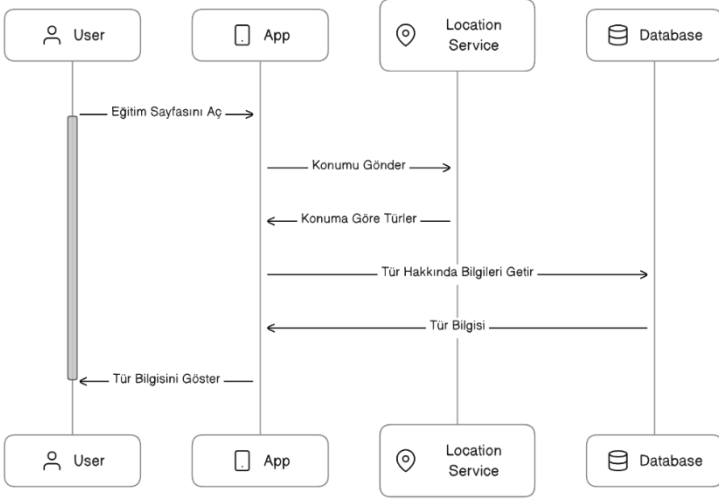
İşgalci Tür Uyarı Sistemi



Şekil 2. İşgalci Tür Uyarı Sistemine Ait Ardışık Diyagram

- Kullanıcılar, uygulamadaki eğitim bölümü ile çevrelerindeki türler hakkında bilgi edinip yaşadıkları ekosistemle ilgili farkındalık kazanabilmektedir. Şekil 3 geliştirilen sisteme aittir.

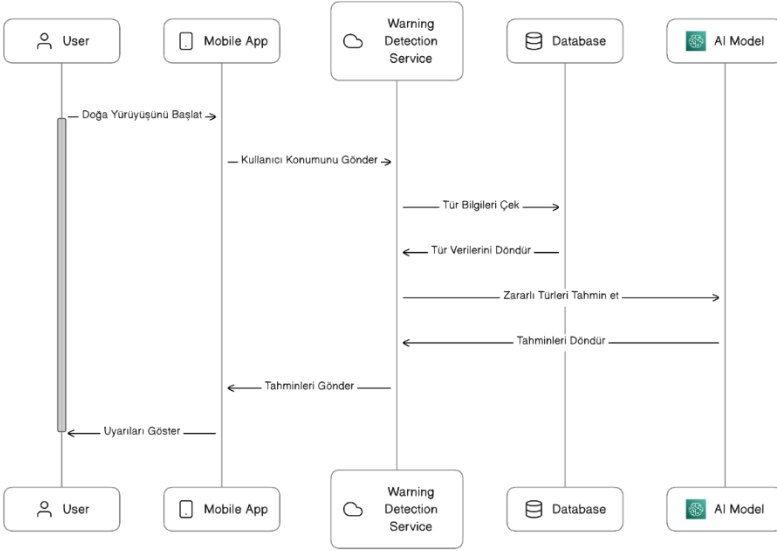
Ekosistem Öğrenme



Şekil 3. Ekosistem Eğitim Sistemine Ait Ardışık Diyagram

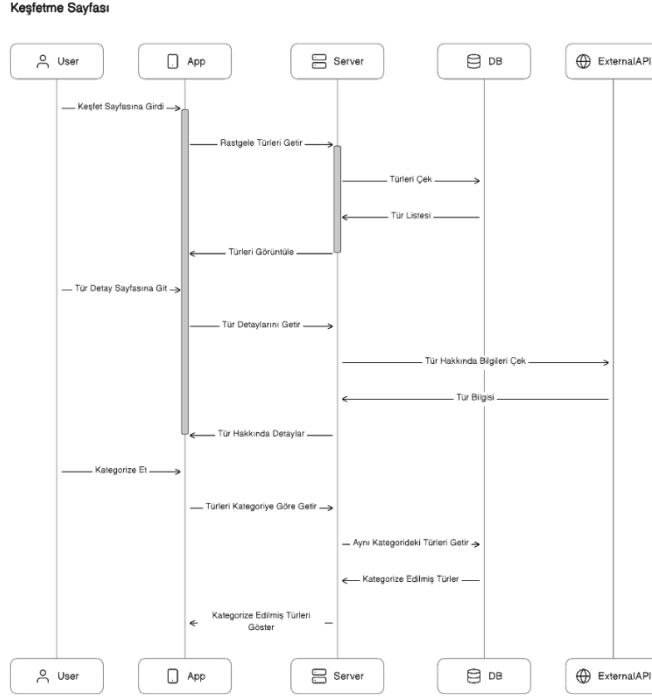
- Doğa yürüyüşü yapan kullanıcılara, yürüyüş yaptıkları konumlarda zarar verebilecek türler konusunda bir ön uyarı sistemi sunulmaktadır. Bu sayede kullanıcılar, çevrelerinde potansiyel tehlike oluşturan türler hakkında bilgi sahibi olabilmektedirler. Şekil 4 geliştirilen sisteme aittir.

Erken Uyarı Sistemi



Şekil 4. Erken Uyarı Sistemine Ait Ardışık Diyagram

- Özelliklerimizden bir diğeri olan keşfetme sayfasına ait diyagramda Şekil 5 görülmektedir. External API olarak adlandırdığımız sistem Wikipedia veya Map Of Life (MOL)'dan otomatik olarak tür hakkında bilgi getiren kendi geliştirdiğimiz bir API'dır.

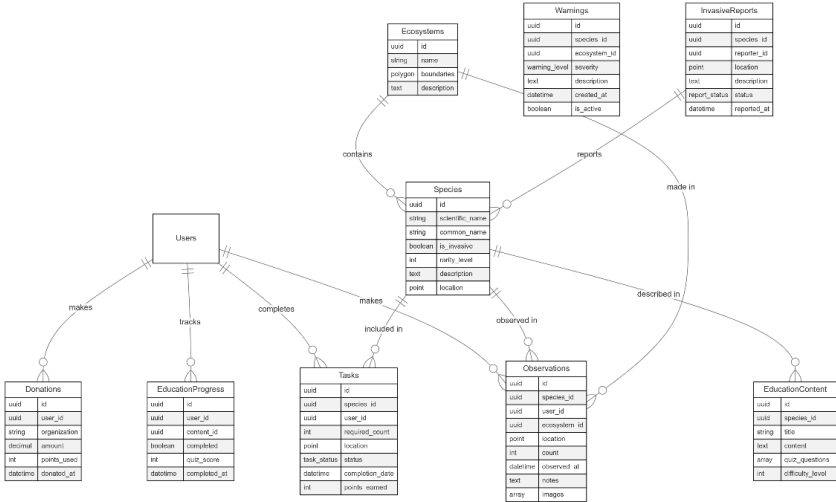


Şekil 5. Keşfetme Sayfasına Ait Ardışık Diyagram

2.1 Veritabanı Modellerinin Oluşturulması

Bu çalışmada, FİDE uygulaması için geliştirilen veritabanı modellerinin tasarımı ve yapısı detaylı olarak incelenmiştir. Veritabanı mimarisi, biyoçeşitlilik gözlemlerinin kaydedilmesi, kullanıcı etkileşimlerinin yönetimi ve eğitim içeriklerinin organizasyonu için kapsamlı bir çerçeve sunmaktadır. Veritabanı yapısı, birbirleriyle ilişkili dört ana kategoride organize edilmiştir. İlk kategori olan kullanıcı ve gözlem yönetimi, Users ve Observations modellerini içermektedir. Users modeli, kullanıcıların temel bilgilerini, profil verilerini ve sistem içerisindeki aktivitelerini yönetirken, Observations modeli kullanıcıların doğada gerçekleştirdikleri tür gözlemlerini, konumlarını ve ilgili detayları kaydetmektedir. Tür ve ekosistem yönetimi kategorisinde, Species ve Ecosystems modelleri yer almaktadır. Species modeli, sisteme kayıtlı biyolojik türlerin bilimsel ve yaygın isimlerini, enderlik durumlarını ve coğrafi dağılım bilgilerini içermektedir. Ecosystems modeli ise, farklı ekosistemlerin sınırlarını poligon veri tipi kullanarak tanımlamakta ve ekosistem özelliklerini detaylandırmaktadır. Görev ve ödül sistemi kategorisinde Tasks ve Donations modelleri

bulunmaktadır. Tasks modeli, kullanıcılara atanan görevlerin hedeflerini, gerekliliklerini ve tamamlanma durumlarını yönetirken, Donations modeli kullanıcıların kazandıkları puanlarla gerçekleştirdikleri bağışların kayıtlarını tutmaktadır. Eğitim ve içerik yönetimi kategorisinde EducationContent ve EducationProgress modelleri yer almaktadır. EducationContent modeli, türler hakkındaki eğitim materyallerini ve quiz sorularını barındırırken, EducationProgress modeli kullanıcıların bu eğitim içeriklerindeki ilerlemelerini takip etmektedir. Son olarak, uyarı ve istilacı tür yönetimi kategorisinde Warnings ve InvasiveReports modelleri bulunmaktadır. Warnings modeli, ekosistem ve türlerle ilgili uyarıların yönetimini sağlarken, InvasiveReports modeli kullanıcıların bildirdiği istilacı tür raporlarını kaydetmektedir. Veritabanı tasarımında UUID kullanımı ile veri bütünlüğü ve güvenliği sağlanmış, coğrafi veri tiplerinin (point, polygon) kullanımı ile konum bazlı işlevler optimize edilmiştir. Bu yapı, uygulamanın mevcut ihtiyaçlarını karşılamanın yanı sıra, gelecekteki genişlemelere de uyum sağlayabilecek esneklikte tasarlanmıştır. Şekil 6 veritabanı şemasıdır.



Şekil 6. FİDE Veritabanı Tasarımı

Veritabanı yönetim sistemi olarak PostgreSQL tercih edilmiştir. Bu seçimin temel nedenleri arasında PostgreSQL'in PostGIS uzantısı ile coğrafi verileri etkin şekilde yönetebilmesi, JSON veri tipi desteği sayesinde esnek veri modellemesine olanak sağlaması ve güçlü ACID özellikleri ile veri tutarlılığını garanti altına alması yer almaktadır. Özellikle biyoçeşitlilik gözlemlerinin GPS koordinatlarının saklanması, ekosistem sınırlarının polygon verileri olarak tutulması ve

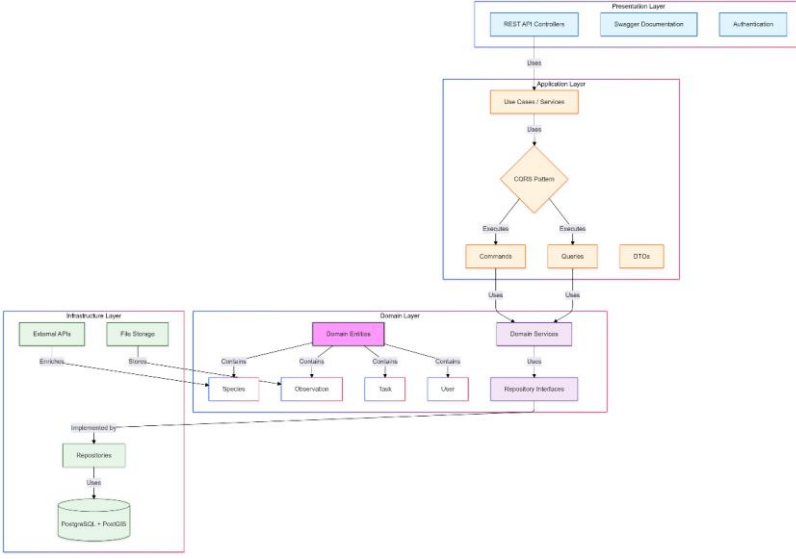
konuma dayalı sorguların optimize edilmiş şekilde gerçekleştirilebilmesi için PostGIS uzantısının sunduğu özellikler belirleyici olmuştur. Bunun yanında, PostgreSQL'in Entity Framework Core ile olan güçlü entegrasyonu, açık kaynak lisansına sahip olması ve geniş topluluk desteği, projenin sürdürülebilirliği açısından önemli avantajlar sunmaktadır.

Veritabanı modellerinin ilişki yapıları, Entity Framework Core ORM teknolojisi kullanılarak Code-First yaklaşımı ile geliştirilmiştir. Bu metodoloji, veritabanı şemasının nesne yönelimli programlama paradigması ile uyumlu bir şekilde tasarlanmasına imkan tanımıştır. Sistemin temel yapı taşlarından biri olan Species sınıfı, türlerin temel özelliklerini ve karakteristiklerini tanımlamaktadır. Bu sınıf, UUID tabanlı benzersiz tanımlayıcı (Id), bilimsel isim (ScientificName), yaygın isim (CommonName), istilacı tür durumu (IsInvasive), enderlik seviyesi (RarityLevel), konum bilgisi (Location) ve açıklama (Description) alanlarını içermektedir. Entity Framework Core'un sağladığı altyapı ile bu sınıf, veritabanında karşılık gelen tabloya dönüştürülmektedir. Veritabanı mimarisinde, varlıklar arasında çeşitli kardinalite ilişkileri kurulmuştur. Tür ve gözlem kayıtları arasında bire-çok (1:N) ilişki bulunmaktadır; bu sayede her bir tür için sınırsız sayıda gözlem kaydı tutulabilmektedir. Ekosistem ve türler arasında çoka-çok (M:N) ilişki tanımlanmıştır, böylece bir ekosistem birden fazla türü barındırabilirken, bir tür de birden fazla ekosistemde var olabilmektedir. Kullanıcı ve görev entiteleri arasında bire-çok (1:N) ilişki kurulmuştur, bu yapı kullanıcıların multiple görev alabilmesine ve tamamlayabilmesine olanak tanımaktadır. Bu ilişki yapı, Entity Framework Core'un sağladığı Navigation Property'ler ve Fluent API kullanılarak konşekile edilmiş olup, veritabanı şemasının detayları görsel dokümantasyonda sunulmuştur.

2.2. Yazılım Mimarisi Ve Katmanlı Yapı

FİDE uygulamasının yazılım mimarisi, Clean Architecture prensipleri temel alınarak sürdürülebilirlik, test edilebilirlik ve ölçeklenebilirlik kriterleri doğrultusunda geliştirilmiştir. Mimari yapı, birbirleriyle hiyerarşik ilişki içinde olan dört temel katmandan oluşmaktadır. Domain Layer, mimarinin çekirdek katmanını oluşturmakta ve temel iş mantığını barındırmaktadır. Bu katmanda Species, Observation, Task ve User gibi temel varlık modelleri ile repository interfaceleri ve domain servis tanımlamaları bulunmaktadır. Domain katmanının en önemli özelliği, herhangi bir dış bağımlılık içermemesi ve saf iş mantığını temsil etmesidir. Application Layer, iş akışlarının koordinasyonundan sorumlu katmandır. Bu katmanda CQRS (Command Query Responsibility

Segregation) pattern uygulaması, Use Case servisleri ve DTO (Data Transfer Object) tanımlamaları yer almaktadır. Application katmanı, domain katmanındaki iş mantığını kullanarak kullanım senaryolarını yönetmektedir. Infrastructure Layer, sistemin teknik gereksinimlerini karşılayan katmandır. PostgreSQL ve PostGIS implementasyonları, dosya depolama servisleri ve harici API entegrasyonları bu katmanda gerçekleştirilmektedir. Domain katmanında tanımlanan repository interfacelerinin somut implementasyonları da bu katmanda bulunmaktadır. Presentation Layer, sistemin dış dünya ile etkileşimini sağlayan en dış katmandır. REST API controller'ları, Swagger dokümantasyonu ve authentication mekanizmaları bu katmanda konumlandırılmıştır. API istekleri bu katmanda karşılanarak uygun Application Layer servislerine yönlendirilmektedir. Katmanlar arası iletişim, Bağımlılık Enjeksiyonu (Dependency Injection) prensibi kullanılarak yönetilmektedir. Bu yaklaşım, katmanlar arasında gevşek bağıllık (loose coupling) sağlayarak sistemin test edilebilirliğini artırmakta ve bileşenlerin değiştirilmesini veya güncellenmesini kolaylaştırmaktadır. Sistemin işleyişi, örnek bir gözlem kaydı oluşturma süreci üzerinden incelendiğinde, API controller'ın gelen isteği karşılaması, Application katmanındaki ilgili Use Case servisinin çağrılması, Domain katmanındaki iş kurallarının kontrolü ve Infrastructure katmanında veritabanı işlemlerinin gerçekleştirilmesi şeklinde ilerlemektedir. Uygulanan mimari yaklaşımın en önemli avantajı, sistemin iş mantığının dış etkenlerden izole edilmesini sağlamasıdır. Bu izolasyon, test süreçlerinin daha etkin yürütülmesine olanak tanımakta ve sistemin modüler yapısı sayesinde yeni özelliklerin eklenmesini ve teknoloji değişikliklerinin uygulanmasını kolaylaştırmaktadır. Ayrıca, kodun bakımı ve sürdürülebilirliği önemli ölçüde artmıştır. Bu mimari yapılanma, FİDE uygulamasının gelecekteki genişleme ve değişiklik ihtiyaçlarına cevap verebilecek esnek bir altyapı sunmakta, özellikle biyoçeşitlilik verilerinin yönetimi ve analizi gibi karmaşık süreçlerin etkin bir şekilde yönetilmesine imkan sağlamaktadır.



Şekil 7. FİDE Yazılım Mimarisi

Şekil 7’de görüldüğü üzere, FİDE'nin mimari yapısı merkezden dışa doğru genişleyen bir soğan modeli şeklinde tasarlanmıştır. En içteki Domain Layer çekirdeği oluşturmakta, sırasıyla Application Layer, Infrastructure Layer ve en dışta Presentation Layer bulunmaktadır. Bu katmanlı yapı, iç katmanların dış katmanlara olan bağımlılığını engelleyerek, sistemin modüler ve sürdürülebilir olmasını sağlamaktadır.

2.3. Tür Tanıma Sistemi ve Derin Öğrenme Mimarisi

FİDE'nin canlı tespiti ve sınıflandırma özelliği için başlangıçta EfficientNetV2 mimarisi kullanılmıştır. Ancak yapılan testlerde, milyonlarca canlı türünün sınıflandırılması konusunda bu modelin yetersiz kaldığı gözlemlenmiştir. Yeni geliştirme aşamasında olan tür tanıma sistemi, ResNet mimarisi üzerine inşa edilmiş vector similarity arama teknolojisini kullanmaktadır. Bu yaklaşımda, görüntülerden elde edilen özellik vektörleri (feature vectors) yüksek boyutlu bir vektör uzayında temsil edilmekte ve benzerlik araması bu uzayda gerçekleştirilmektedir. Böylece, klasik sınıflandırma yaklaşımının aksine, sistem sürekli genişleyen bir tür veritabanı üzerinde etkili arama yapabilmektedir. Sistemin omurgasını oluşturan derin öğrenme mimarisi için ResNet-50 modeli öngörülmektedir. Model, görüntülerden 2048 boyutlu özellik vektörleri çıkarmakta ve bu vektörler veritabanında indekslenmektedir. Vector similarity araması için cosine benzerlik metriği kullanılmakta, böylece farklı ışık

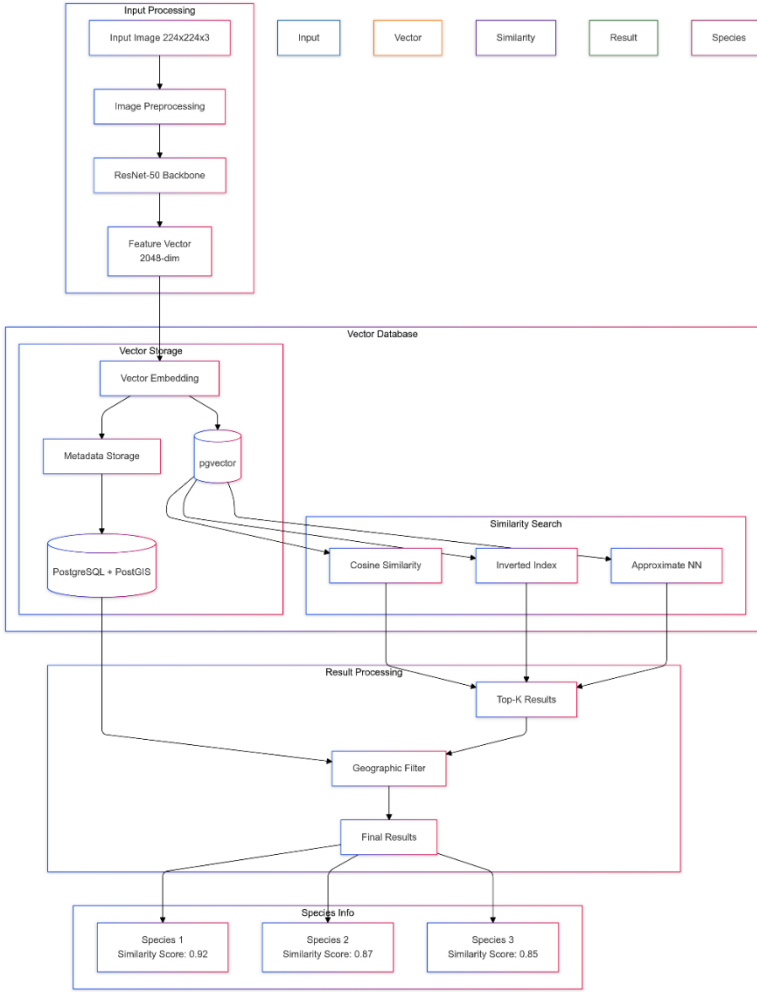
koşulları ve açılardan çekilmiş görüntüler arasında bile etkili eşleştirme yapılabilmektedir. Bu tercih, modelin geniş veri setlerinde kanıtlanmış başarısı ve özellikle mobil cihazlardaki optimizasyon imkanları göz önünde bulundurularak yapılmıştır [1,5,6].

Veri yönetimi konusunda PostgreSQL'in vector similarity uzantısı (pgvector) ve PostGIS entegrasyonu kullanılmaktadır. pgvector, özellik vektörlerinin verimli şekilde depolanmasını ve benzerlik bazlı sorgulanmasını sağlarken, PostGIS coğrafi konum bazlı filtrelemeyi mümkün kılmaktadır. Bu hibrit yaklaşım sayesinde, bir türün hem görsel özellikleri hem de bulunduğu coğrafi konum dikkate alınarak daha doğru sonuçlar elde edilmektedir [3].

Sistemin çalışma prensibi üç aşamalı bir süreç olarak tasarlanmaktadır:

- **Özellik Vektörü Çıkarımı:** ResNet-50 omurgası kullanılarak görüntülerden 2048 boyutlu özellik vektörlerinin elde edilmesi
- **Vector Similarity Araması:** çıkarılan vektörlerin veritabanındaki mevcut vektörlerle karşılaştırılması ve en benzer örneklerin bulunması
- **Coğrafi Filtreleme:** Benzerlik sonuçlarının bölgesel dağılım verileriyle filtrelenmesi ve sonuçların iyileştirilmesi

Geliştirme sürecinin ilk fazında, Türkiye'nin belirli bir bölgesindeki yaygın türler için özellik vektörleri oluşturulması planlanmıştır. Her bir tür için farklı açı, ışık koşulu ve mevsimlerde çekilmiş görüntülerden vektörler çıkarılarak, sistemin güçlü bir benzerlik karşılaştırması yapabilmesi sağlanmıştır. Performans değerlendirmesi için belirlenen ilk hedefler, vector similarity yaklaşımının sağladığı avantajlar göz önünde bulundurularak belirlenmiştir. Yaygın türlerin tespitinde ilk 5 öneri içinde doğru türü bulma oranının %75'in üzerinde olması ve sorgu başına yanıt süresinin 200ms'nin altında olması hedeflenmektedir. Bu vector similarity tabanlı yaklaşım, sistemin yeni türleri kolayca öğrenebilmesini ve veritabanının sürekli genişleyebilmesini mümkün kılmaktadır. Ayrıca, türler arasındaki görsel benzerliklerin otomatik olarak keşfedilmesine ve benzer türlerin gruplandırılmasına olanak sağlamaktadır. Geliştirme sürecinin ilerleyen aşamalarında, vector similarity algoritmasının optimizasyonu ve arama performansının iyileştirilmesi üzerine çalışmalar yapılacaktır. Sistemin detaylı grafiği Şekil 8'de görülmektedir.



Şekil 8. Tür Tanıma Sistemi Diyagramı

3. SONUÇ

Biyoçeşitliliğin korunması ve bilincinin artırılması amacıyla geliştirilen FİDE uygulamasının geliştirme sürecini ve özelliklerini detaylı bir şekilde ele alınmıştır. Proje sürecindeki adımlar, başlangıçtan demo sürümünün tamamlanmasına kadar olan süreci içermektedir. FİDE, biyoçeşitlilik konusundaki farkındalığı artırmak ve kullanıcıları doğaya aktif katılıma teşvik etmek için tasarlanmış bir uygulamadır. Uygulamanın temel özellikleri, görevlendirme sistemi, istilacı tür uyarıları, ekosistem eğitim sistemi ve erken uyarı sistemini içermektedir. Bu özellikler, kullanıcıların doğaya olan etkileşimini

artırmayı ve biyoçeşitliliğin korunması için katkıda bulunmalarını amaçlamaktadır. Teknik açıdan bakıldığında, Clean Architecture prensipleri doğrultusunda geliştirilen backend yapısı, projenin sürdürülebilirliğini ve ölçeklenebilirliğini sağlamıştır. PostgreSQL ve PostGIS entegrasyonu ile güçlendirilen veritabanı altyapısı, coğrafi verilerin etkin yönetimini mümkün kılmaktadır. Frontend tarafında Flutter framework'ü ile geliştirilen kullanıcı arayüzü, platform bağımsız ve akıcı bir deneyim sunmaktadır. Tür tanıma sisteminde başlangıçta kullanılan EfficientNetV2 mimarisinden, vector similarity yaklaşımına geçiş yapılması, sistemin doğruluk oranını önemli ölçüde artırmıştır. ResNet-50 modeli üzerine inşa edilen bu yeni yaklaşım, özellikle benzer türlerin ayırt edilmesinde ve yeni türlerin sisteme eklenmesinde daha esnek bir çözüm sunmaktadır. Arayüz geliştirme sürecinde, Flutter framework'ü ve Model-View-Controller (MVC) mimarisi kullanılarak kullanıcı dostu bir mobil arayüz tasarlanmıştır. Özelleştirilmiş widget'lar ve animasyonlar, kullanıcı deneyimini zenginleştirmek için kullanılmıştır. FİDE, biyoçeşitliliğin korunması ve kullanıcıların aktif katılımını teşvik etme konusunda yenilikçi bir yaklaşım sunmaktadır. Gelecekte, yapay zekâ modelinin güçlendirilmesi ve daha doğru tür sınıflandırmaları için çalışmalarımızı sürdürmeyi planlıyoruz. Uygulamamızın kullanıcı tabanını genişleterek doğaya karşı sorumluluk bilincini artırmak en büyük hedefimizdir.

KAYNAKÇA

- [1] Oukhouya, H., Kadiri, H., El Himdi, K., & Guerbaz, R. (2023). Forecasting International Stock Market Trends: XGBoost, LSTM, LSTM-XGBoost, and Backtesting XGBoost Models. <https://doi.org/10.19139/soic-2310-5070-1822>
- [2] Shintri, R. G., & Bhatia, S. K. (2015). Analysis of MFCC and Multitaper MFCC Feature Extraction Methods. *International Journal of Computer Applications*, 131(4), 7–10. <https://doi.org/10.5120/IJCA2015906883>
- [3] Er, M. B., & Aydılek, İ. B. (2019). Music Emotion Recognition by Using Chroma Spectrogram and Deep Visual Features. *International Journal of Computational Intelligence Systems*, 12(2), 1622–1634. <https://doi.org/10.2991/IJCIS.D.191216.001>
- [4] GTZAN Dataset - Music Genre Classification. (n.d.). <https://www.kaggle.com/datasets/andradaolteanu/gtzan-dataset-music-genre-classification>
- [5] Dündar K., Ağaçayak A.C., “Yapay Zeka Ve Makine Öğrenmesi İle İnsan İlişkileri Analizi”, *Mühendislikte Yenilikçi Yaklaşımlar-2*, (2023)., Eğitim Yayınevi, Editör:Prof.Dr. Süleyman Neşeli, Dr.Öğr.Üyesi. Hakan Terzioğlu, Basım sayısı:1, Sayfa Sayısı 149, ISBN:978-625-6613-95-9, Türkçe(Bilimsel Kitap) (Yayın No: 8856876)
- [6] Mirjafarlı S., Terzioğlu H., Ağaçayak A.C., “Bölüm 9: Yapay Zeka Ve Makine Öğrenme Metodlarının Tıp'ta Kullanım Alanlarına Genel Bakış”, *Mühendislikte Yeni Araştırmalar*, (2022)., , tablet kitapevi, Editör:Öğr. Gör. Gökhan Yalçın, Öğr. Gör. Abdullah Cem Ağaçayak, Basım sayısı:1, Sayfa Sayısı 305, ISBN:978-605-5447-75-5, Türkçe(Bilimsel Kitap) (Yayın No: 8112767)



BÖLÜM-4

KARA KANATLI UÇURTMA ALGORİTMASI İLE DİŞLİ TREN TASARIMININ OPTİMİZASYONU

Taybe ALABED¹

Sema SERVİ²

Onur İNAN³

¹<https://orcid.org/0009-0009-3722-2911>

²<https://orcid.org/0000-0003-2069-9085>

³<https://orcid.org/0000-0003-4573-7025>

KARA KANATLI UÇURTMA ALGORİTMASI İLE DIŞLI TREN TASARIMININ OPTİMİZASYONU

1. GİRİŞ

Optimizasyon, bir sistemin, sürecin veya tasarımın performansını artırmak için matematiksel veya hesaplamalı yöntemlerin uygulanmasıdır. Bu, genellikle karı maksimize etme, maliyeti en aza indirme veya verimliliği artırma gibi belirli hedeflere ulaşmak için sistemi veya süreci iyileştirmeyi içerir [1]. Optimizasyon, mühendislikten yönetim bilimlerine kadar çok çeşitli disiplinlerde kritik bir rol oynar, ancak geleneksel yöntemler karmaşık sorunları ele alırken genellikle yetersiz kalır.

Bu zorlukların üstesinden gelmek için, çeşitli alanlarda etkili sonuçlar sunabilen esnek ve uyarlanabilir yaklaşımlar olarak meta sezgisel yöntemler geliştirilmiştir. Doğal süreçlerden ilham alan meta sezgisel algoritmalar, çözüm alanı içinde kapsamlı aramalar yaparak küresel optimuma ulaşmayı amaçlar. Büyük ölçekli sorunlar için hızlı ve etkili çözümler sağlama yetenekleri, onları son yıllarda oldukça dikkat çekici hale getirmiştir.

Bunların arasında, Kara Kanatlı Uçurtma Algoritması (BKA), kara kanatlı uçurtmaların göç ve yırtıcı davranışlarından esinlenmiştir. Bu kuşlar, küresel arama ve yakınsama yeteneklerini geliştirmek için matematiksel olarak modellenmiş olağanüstü havada asılı kalma yetenekleri ve hassas avlanma teknikleri sergiler. Keşif ve sömürüyü dengeleyen kara kanatlı uçurtmaların uçuş ve avlanma stratejilerine benzer şekilde, BKA optimum çözümü verimli bir şekilde bulmayı hedefler. Ancak, BKA Cauchy mutasyonu ve liderlik stratejileri gibi mekanizmalar aracılığıyla güçlü küresel arama yetenekleri gösterirken, yinelemeler sırasında çeşitliliği sürdürmede zorluklarla da karşılaşabilir ve bu da belirli senaryolarda erken yakınsamaya yol açabilir.

Ayrık optimizasyon problemlerinin önemli bir örneği olan dışlı treni tasarım problemi, karar değişkenleri tarafından temsil edilen dört dışlı için dış sayısını optimize ederek dışlı oranını en aza indirmeyi amaçlar. Problemin karmaşıklığı, tüm değişkenlerin tam sayı olması ve arama alanının belirli sınırlar içinde kısıtlanması gerekliliğinden kaynaklanmaktadır. Sonuç olarak, dışlı treni tasarım problemi genetik algoritmaları ve diğer meta-sezgisel yaklaşımları test etmek için yaygın bir kıyaslama senaryosu haline gelmiştir.

Bu çalışmada ele alınan dişli takımı tasarımı, mühendislikte sıkça karşılaşılan yaygın bir optimizasyon problemidir. BKA, özellikle diğer algoritmalarla karşılaştırıldığında, bu tür problemlere uygulandığında önemli avantajlar göstermektedir. Bu avantajlar arasında daha kısa sürede yüksek kaliteli çözümlere ulaşmak ve daha az hesaplama kaynağı gerektirmek yer almaktadır.

Jun Wang ve ark, 2024 tarihli çalışmalarında, kara kanatlı uçurtmaların göç ve yırtıcı davranışlarından esinlenerek Kara Kanatlı Uçurtma Algoritmasını (BKA) geliştirdiler. Yazarlar, Cauchy mutasyon stratejisini ve liderlik mekanizmasını algoritmaya entegre ederek, küresel ve yerel arama yeteneklerini önemli ölçüde geliştirdiler. Çalışma, BKA'nın mühendislik optimizasyon problemlerini çözmede WOA, MPA ve RIME gibi geleneksel algoritmalarından daha iyi performans gösterdiğini gösterdi. Etkinliği, yakınsama analizleri yoluyla doğrulandı ve karmaşık ve kısıtlı optimizasyon zorlukları için sağlam bir çözüm yöntemi olduğu kanıtlandı [2].

Abdul Qadeer Rasooli ve diğerleri, 2024 tarihli çalışmalarında, kümeleme sorunları için Kara Kanatlı Uçurtma Algoritmasının (BKA) uygulamasını araştırdılar. Kara kanatlı uçurtmaların yırtıcı ve göç davranışlarından esinlenen algoritma, küresel ve yerel arama yeteneklerini dengelemek için Cauchy mutasyon stratejisini ve lider stratejisini entegre eder. Çalışma, BKA'nın küme sayısını belirlerken küme merkezlerini etkili bir şekilde belirlediğini ve TSA ve WOA gibi diğer optimizasyon tekniklerinden daha iyi performans gösterdiğini göstermektedir. Bu sonuçlar, BKA'yı veri analizi ve desen tanımda kümeleme görevleri için yeni ve etkili bir araç olarak ortaya koymaktadır [3].

Jun Wang ve diğerleri, 2025 tarihli çalışmalarında, Kara Kanatlı Uçurtma Algoritmasını (BKA) bir dizi mühendislik tasarım problemine uygulayarak karmaşık ve kısıtlı optimizasyon senaryolarını ele almadaki etkinliğini kanıtladılar. Kara kanatlı uçurtmaların göç ve avlanma davranışlarından ilham alan BKA, keşif ve istismar yeteneklerini geliştirmek için bir Cauchy mutasyon stratejisi ve lider tabanlı bir mekanizma kullanır. Algoritma, basınçlı kap tasarımı, kaynaklı giriş tasarımı ve konsol giriş optimizasyonu gibi mühendislik problemlerini başarıyla optimize ederek, PSO ve WOA gibi geleneksel yöntemlere kıyasla yakınsama hızı ve çözüm kalitesinde üstün sonuçlar elde etti. Bu bulgular, BKA'yı mühendislik

optimizasyon zorluklarını çözmek için güvenilir ve etkili bir araç olarak ortaya koymaktadır [4].

Mühendislik optimizasyon sorunları için bir diğer etkili çözüm, Yu Li ve diğerleri tarafından önerilen DDSCA'dır. DDSCA, boyut bazında bir iyileştirme stratejisi ve dinamik bir kontrol parametresi sunarak karmaşık optimizasyon zorluklarını başarıyla ele almıştır. Bu yeni yaklaşım, algoritmanın keşif ve sömürüyü dengeleme yeteneğini önemli ölçüde artırır. Ek olarak, DDSCA, PSO ve SCA gibi geleneksel yöntemlere kıyasla dişli takımı ve basınç kabı tasarımı gibi gerçek dünya mühendislik sorunlarını çözmeye üstün performans göstermiştir.[5]

Bu bağlamda, Kara Kanatlı Uçurtma Algoritması (BKA), özellikle dişli takımı tasarım problemlerinde olmak üzere, mühendislik optimizasyon görevlerinde etkinliğini gösteren yenilikçi bir yaklaşım olarak vurgulanabilir. BKA, küresel keşif ve yerel sömürüyü dengelemek için kara kanatlı uçurtmaların göç ve yırtıcı davranışlarından ilham alan benzersiz arama stratejilerinden yararlanır. Bu çalışmada, BKA dişli takımı tasarım problemine uygulandı ve DDSCA, GA ve ABC dahil olmak üzere diğer birkaç optimizasyon algoritmasıyla karşılaştırıldı. Tablo 1'de sunulan sonuçlar, BKA'nın yerel minimumlara takılmadan küresel optimuma ulaşarak en iyi performansı elde ettiğini göstermektedir. Bu bulgular, BKA'nın karmaşık mühendislik zorluklarını çözümedeki sağlamlığını ve verimliliğini doğrulamaktadır.

Bu çalışmanın devamında, Kara Kanatlı Uçurtma Algoritması'nın (BKA) temel prensipleri ve optimizasyon süreçleri için uygulama adımları Malzemeler ve Yöntemler bölümünde detaylı olarak ele alınmıştır. Ayrıca, mühendislik açısından kritik bir öneme sahip olan Dişli Tren Tasarımı konusu detaylandırılmış ve çözüm aşamalarında karşılaşılan zorluklar tartışılmıştır. Ardından, Bulgular ve Tartışma bölümünde, BKA'nın Dişli Tren Tasarımı üzerindeki performansı değerlendirilmiş; literatürdeki diğer meta-sezgisel algoritmalarla karşılaştırmalar yapılmış ve algoritmanın üstün yönleri ortaya konmuştur. Son olarak, bulgular ışığında, algoritmanın potansiyel geliştirme alanları ve farklı uygulamalara yönelik öneriler Sonuç ve Öneriler bölümünde sunulmuştur. Bu yapı, çalışmanın kapsamını bütünsel olarak değerlendirmek ve okuyucunun çalışmayı daha iyi anlayabilmesini sağlamak için planlanmıştır.

2. MATERYAL VE METOD

2.1. Kara Kanatlı Uçurtma Algoritması (BKA)

Kara Kanatlı Uçurtma Algoritması (BKA), kara kanatlı uçurtma kuşlarının avlanma ve göç davranışlarından esinlenen bir meta-sezgisel optimizasyon yöntemidir. Bu algoritma, optimizasyon problemlerine çözüm bulmak için bu kuşların doğal hareketlerini modeller. BKA'nın arama süreci iki ana aşamaya ayrılır: keşif ve sömürü.

- Keşif aşamasında, algoritma geniş bir çözüm uzayındaki farklı noktalarda arama yaparak en iyi çözüm adaylarını bulmayı hedefler. Kuşların hareketi, grup içindeki bireyler arasındaki etkileşimlere dayanır. Kara kanatlı uçurtmalar, geniş bir alan üzerinde havada süzülerek potansiyel avlarını gözlemler ve çevrelerini araştırır. Bu strateji, algoritmanın çözüm uzayının farklı bölgelerini ayrıntılı olarak keşfetmesini sağlayarak küresel minimuma ulaşma şansını artırır. Keşif aşamasının amacı, çözüm uzayını kapsamlı bir şekilde tarayarak küresel optimuma yaklaşan bölgelere odaklanmaktır.
- Sömürü aşamasında, algoritma daha önce belirlenen en iyi bölgeye odaklanır ve bu alandaki çözüm adaylarını iyileştirir. Kara kanatlı uçurtmalar avlarını yakalamak için keskin bir şekilde dalış yapar ve bu davranış algoritmada en iyi çözüm bölgelerine doğru yönlendirilmiş bir hareket olarak modellenir. Bu aşamada, algoritma daha çok yerel optimumlara odaklanır ve çözümleri ayrıntılı olarak iyileştirir. Ancak bu, yerel optimumlara düşme riskini oluşturur, yani algoritma küresel optimumu kaçırabilir. Sömürü aşamasının amacı, en uygun olanı bulmak için daha önce keşfedilen çözümleri iyileştirmektir.

Kara kanatlı uçurtmaların avlanma ve göç davranışları algoritmanın farklı yönlerini temsil eder. Cauchy mutasyonu bireylerin rastgele hareket ederek yerel optimumlardan kaçmasına olanak tanır. Liderlik stratejisi en iyi çözümü yönlendirerek optimizasyonu hızlandırmaya yardımcı olur. Bu denge algoritmanın hem geniş bir arama gerçekleştirmesini hem de çözümleri ayrıntılı olarak iyileştirmesini sağlar.

Şekil 1, Black-winged Kite Algoritması'nın (BKA) ana adımlarını özetleyen sözde kodu sunar. Kod, algoritmanın temel

mekanizmalarını ve optimizasyon sürecindeki davranışlarını ayrıntılı bir şekilde açıklar [17,18].

```

Algorithm: Black-winged kite algorithm
Input: The population size pop, maximum number of iterations T, and variable dimension dim
Output: The best quasi-optimal solution obtained by BKA for a given optimization problem.
1. Initialization phase
2. Initialization of the position of Black-winged kites and evaluation of the objective function.
3. Calculate the fitness value of each Black-winged kite
4.   while (t < T) do
5.   /* Attacking behavior */
6.     if p < r
7.        $y_{t+1}^{i,j} = y_t^{i,j} + n(1 + \sin(r)) \times y_t^{i,j}$ 
8.     else if do
9.        $y_{t+1}^{i,j} = y_t^{i,j} + n \times (2r - 1) \times y_t^{i,j}$ 
10.    end if
11.   /* Migration behavior */
12.     if Fi < Fri do
13.        $y_{t+1}^{i,j} = y_t^{i,j} + C(0,1) \times (y_t^{i,j} - L_t^j)$ 
14.     else if do
15.        $y_{t+1}^{i,j} = y_t^{i,j} + C(0,1) \times (L_t^j - m \times y_t^{i,j})$ 
16.     end if
17.   /*Select the best individual*/
18.     if  $y_{t+1}^{i,j} < L_{j,t}$ 
19.        $X_{best} = y_{t+1}^{i,j}, F_{best} = f(y_{t+1}^{i,j})$ 
20.     else if do
21.        $X_{best} = L_{j,t}, F_{best} = f(L_{j,t})$ 
22.     end if
23.   end while
24.   Return  $X_{best}$  and  $F_{best}$ 

```

Şekil 1. BKA Pseudo-code

2.2. Dişli Tren Tasarım Problemi

Dişli treni tasarım problemi, her biri bir dişli üzerindeki diş sayısını temsil eden dört karar değişkenini ($\vec{x} = [x_1, x_2, x_3, x_4]$), içeren ayrı bir optimizasyon problemidir. Bu problemin amacı, optimum diş sayısı koşulu da dahil olmak üzere belirli tasarım kısıtlamalarını karşılayarak dişli oranını en aza indirmektir [6].

Bu optimizasyonda, dişli oranı mekanik ve operasyonel sınırlarla kısıtlanmış olan karar değişkenlerinin çarpımına bağlıdır. Diş sayısı bir tam sayı olması gerektiğinden, karar değişkenleri optimizasyon

süreci sırasında en yakın tam sayıya yuvarlanır. Bu yuvarlama, çözüm alanının düzgünlüğünü ve sürekliliğini etkileyerek, sorunu doğası gereği oldukça doğrusal olmayan ve ayrık hale getirerek, optimum bir çözüm arayışına ek karmaşıklık getirir.

2.3. Kara Kanatlı Uçurtma Algoritmasının Dişli Tren Tasarım Problemine Uygulanması

Dişli Tren Tasarımı problemi, doğrusal olmayan ve çok değişkenli yapısıyla karakterize edilen karmaşık bir optimizasyon problemidir. Bu problemin amacı, belirli fiziksel kısıtlamalar altında maksimum sistem performansını garanti eden optimum dişli oranlarını belirlemektir. Yerel optimumlara takılma riski nedeniyle, bu tür problemleri çözmek sağlam ve yenilikçi optimizasyon algoritmaları gerektirir.

BKA'nın bu sorunu ele almadaki başarısı aşağıdaki temel özelliklerden kaynaklanmaktadır:

- BKA, yüksek çözüm hassasiyeti için dengeli bir sömürü sürecini korurken küresel optimumu bulmak için çözüm alanını kapsamlı bir şekilde araştırır.
- Algoritma, yerel optimumlara sıkışma riskini azaltan mekanizmalar içerir ve mühendislik sorunları gibi karmaşık uygulamalarda önemli avantajlar sunar.
- BKA, uygunluk değeri açısından rakip algoritmalarından daha iyi performans göstererek sorun için tam optimum çözümü elde etti.

BKA'nın performansı ve diğer algoritmalarla karşılaştırılması ayrıntılı olarak tartışılmıştır. Dişli Tren Tasarımı gibi karmaşık optimizasyon problemleri için BKA güçlü ve etkili bir çözüm sunar

Şekil 2, Dişli Tren Tasarım problemine uygulanan BKA algoritmasının ana adımlarını özetleyen sözde kodu sunar. Kod, algoritmanın çekirdek mekanizmalarının ve ardışık arama stratejilerinin ayrıntılı bir açıklamasını sağlar.

Algorithm: Black-winged Kite Algorithm (BKA)

Input:

- Max Iterations: Maximum number of iterations
- Population Size: Number of birds (agents)
- Search Space: Solution space boundaries (Gear ratios: [lb. ub] = [12, 60])
- Fitness Function: Gear Train Design objective function

Output:

- Best Solution: Best set of gear ratios found
- Best Fitness: Fitness value of the best solution

Step 1: (Initialize Population)

- Randomly initialize bird positions (gear ratio values) within the search space [lb. ub]
- Evaluate fitness for each bird using the Gear Train Design function
- Set initial Best Solution and Best Fitness

Step 2: Main Loop (until Max Iterations reached)

For iteration = 1 to Max Iterations do:

- Update exploration-exploitation parameters (a1, a2)

For each bird:

- Ensure Boundaries: Adjust gear ratio values if out of bounds ([12, 60])
- Exploration Update: Generate new positions to explore better solutions
- Exploitation Update: Move birds toward the current best solution using group behavior rules
- Random Reset: With a given probability, reset bird's gear ratio values randomly
- Update Best Solution: If a better set of gear ratios is found, update Best Solution and Best Fitness

Step 3: Return Best Solution and Fitness

Return Best Solution
Return Best Fitness |

Şekil 2. Dişli Tren Tasarım Problem Pseudo-Code

3. BULGULAR VE TARTIŞMA

Bu çalışmada, mühendislikte yaygın bir optimizasyon problemi olan dişli takımı tasarım problemini çözmek için Kara Kanatlı Uçurtma Algoritması (BKA) uygulanmıştır. BKA, küresel ve yerel arama süreçlerini etkili bir şekilde birleştirerek çözüm alanının kapsamlı bir şekilde keşfedilmesini sağlar. DDSCA, ISCA, CS, GA, ABC ve MBA

gibi literatürdeki iyi bilinen optimizasyon algoritmalarıyla karşılaştırıldığında, BKA üstün performans göstermiş ve tam olarak optimum çözüme başarıyla ulaşmıştır.

Ayrıca, literatürde gözlemlendiği üzere, metasezgisel algoritmalar geniş çözüm uzaylarına sahip problemleri çözmede oldukça başarılıdır. Bu çalışma, BKA'nın bu problemdeki performansını değerlendirir ve mühendislik zorluklarına uygulanabilirliğini gösterir.

3.1. Mühendislik Tasarımı Problemi için BKA

BKA'nın dişli takımı tasarım problemini çözme yeteneği, bu mühendislik tasarım durumuna uygulanarak değerlendirilmiştir. Dişli takımı tasarım problemi test senaryosu olarak seçilmiştir. Bu problem, 30 nüfus büyüklüğü ve 500 yineleme ile BKA kullanılarak çözülmüştür. Elde edilen istatistiksel sonuçlar, literatürdeki diğer optimizasyon yöntemleri tarafından sağlanan sonuçlarla karşılaştırılmıştır. Önerilen yaklaşım, BKA'nın optimizasyon performansını değerlendirmek ve diğer iyi bilinen algoritmalarla karşılaştırmak için sağlam bir temel oluşturmaktadır.

3.2. Dişli Tren Tasarım Problemi

Dişli treni tasarım problemi, bir trenin dört dişlisi için diş sayısını (x_1, x_2, x_3, x_4) optimize etmeyi içerir. Bu tasarım probleminin amacı, dişli oranını en aza indirmek için en uygun diş sayısını bulmaktır[12]. Ayrık parametreler, çözüm güncellendikten sonra en yakın tam sayıya yuvarlanarak işlenir. Matematiksel olarak, problem şu şekilde formüle edilir:

$$\text{Min } F_2(\vec{x}) = \left(\frac{1}{6.931} - \frac{x_2 x_3}{x_1 x_4} \right), \quad (1)$$

$$\text{Where } x = (x_1, x_2, x_3, x_4)$$

$$\text{s.t } 12 \leq x_i \leq 60, \text{ and } x_i \in Z + \forall i = 1, 2, 3, 4.$$

Önerilen optimizasyon yöntemi ve ilgili kısıtlamalar, Dişli Tren Tasarım Problemi için performans ve maliyet açısından optimum bir çözüm elde etmek için bir temel oluşturur. Optimizasyon süreci, dişli oranları, dişli diş sayıları ve gerilim sınırları gibi parametreleri göz önünde bulundurarak uygulanabilir ve etkili çözümler sağlamayı amaçlamaktadır.

Bu problem DDSCA, ISCA, m-SCA, GA, ABC, CS, ALM, MBA ve BKA gibi çeşitli algoritmalar kullanılarak ele alınmıştır. Tablo 4, bu algoritmalar tarafından elde edilen en iyi sonuçları ve BKA

tarafından bulunan optimum çözümü karşılaştırır. Sonuçlar, BKA'nın 0 (Tamamen Optimum) tam olarak optimize edilmiş maliyet değeri ve 54, 18, 27 ve 59 tasarım parametreleriyle en verimli çözümü sağladığını göstermektedir.

BKA'nın üstün performansı, çözüm alanını daha etkili bir şekilde keşfetme ve yerel optimumlardan kaçınarak küresel optimuma ulaşma yeteneğini göstermektedir. Bu sonuç, BKA'nın katı kısıtlamalara sahip karmaşık mühendislik tasarım problemlerini çözmede oldukça rekabetçi bir algoritma olduğunu göstermektedir.

Tablo 1'de Dişli Tren Tasarım Problemi [13] için optimizasyon algoritmaları tarafından elde edilen en iyi çözümlerin karşılaştırmasını sunulmuştur.

Optimum values for variables					
Method	X ₁	X ₂	X ₃	X ₄	Optimal Cost
DDSCA [7]	49	16	19	43	2.7009e-12
m-SCA [8]	43	16	19	49	2.7009e-12
ISCA [9]	43	16	19	49	2.7009e-12
GA [10]	33	14	17	50	1.3616e-09
ABC [11]	43	16	19	49	2.7009e-11
CS [12]	43	16	19	49	2.7009e-12
ALM [13]	33	15	13	41	2.4073e-08
MBA [14]	43	16	19	49	2.7009e-12
BKA	54	18	27	59	0 (Tam Optimum)

Table 1. Dişli Tren Tasarım Problemi Karşılaştırması

4. SONUÇ VE ÖNERİLER

Bu çalışmada, doğadan esinlenerek geliştirilmiş meta-sezgisel bir yöntem olan Black Winged Kite Algorithm (BKA) kullanılarak mühendislik optimizasyon problemlerinin çözümünde başarılı sonuçlar elde edilmiştir. Özellikle dişli takımı tasarım probleminde, maliyetin en aza indirildiği ve tüm kısıtların sağlandığı durumlarda algoritmanın etkinliği kanıtlanmış ve literatürdeki diğer algoritmalarından daha iyi sonuçlar elde edilmiştir. BKA'nın güçlü küresel ve yerel arama dengesi, algoritmanın yerel minimumlardan kaçınmasını ve küresel optimuma daha hızlı ulaşmasını sağlayarak bu karmaşık optimizasyon probleminde üstünlüğünü ortaya koymuştur.

Gelecekte algoritmanın daha da geliştirilmesi için bazı önerilerde bulunulabilir. İlk olarak, daha geniş bir uygulama alanı sağlamak için BKA'nın farklı mühendislik problemlerinde test edilmesi önerilir. Algoritmanın verimliliğini ve esnekliğini artırmak için uyarlanabilir parametre ayarlama mekanizmaları entegre edilebilir. Ayrıca, BKA çok amaçlı optimizasyon problemlerine uyarlanabilir veya daha karmaşık ve yüksek boyutlu problemler için daha etkili çözümler üretmek üzere diğer gelişmiş meta-sezgisel algoritmalarla hibritleştirilebilir. Bu tür gelişmeler algoritmanın gücünü artırabilir ve daha geniş bir aralıkta etkili optimizasyon çözümleri sunmasını sağlayabilir.

KAYNAKÇA

- [1] L.-B. Mei and Q. Wang, "Structural optimization in civil engineering: A literature review," *Buildings*, vol. 11, no. 2, p. 66, 2021.
- [2] Wang, J., Wang, W., Hu, X., Qiu, L., & Zang, H. (2024). Black-winged kite algorithm: A nature-inspired meta-heuristic for solving benchmark functions and engineering problems. *Artificial Intelligence Review*, 57, 98.
- [3] Rasooli, A. Q., Inan, O., & Servi, S. (2024). Clustering with the Black-Winged Kite Algorithm. *International Journal of Computer Science & Communications*, 9(1), 22–33.
- [4] Wang, X. (2025). Draco lizard optimizer: A novel metaheuristic algorithm for global optimization problems. *Evolutionary Intelligence*, 18(1), 10.
- [5] Li, Y., Zhao, Y., & Liu, J. (2021). Dimension by dimension dynamic sine cosine algorithm for global optimization problems. *Applied Soft Computing Journal*, 98, 106933.
- [6] Li, Y., Zhao, Y., & Liu, J. (2021). Dimension by dimension dynamic sine cosine algorithm for global optimization problems. *Applied Soft Computing Journal*, 98, 106933.
- [7] S. Gupta and K. Deep, "Improved sine cosine algorithm with crossover scheme for global optimization," *Knowledge-Based Systems*, vol. 165, pp. 374–406, 2019, doi: 10.1016/j.knsys.2018.12.008.
- [8] Gupta, S., & Deep, K. (2019). A hybrid self-adaptive sine cosine algorithm with opposition-based learning. *Expert Systems with Applications*, 119, 210–230
- [9] K. Deb and M. Goyal, "A combined genetic adaptive search (GeneAS) for engineering design," *Journal of Computer Science and Informatics*, vol. 26, pp. 30–45, 1996.
- [10] Deb, K., & Goyal, M. (1996). A combined genetic adaptive search (GeneAS) for engineering design. *Journal of Computer Science and Informatics*, 26(1), 30–45.

- [11] Karaboga, D., & Basturk, B. (2007). A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm. *Journal of Global Optimization*, 39(3), 459–471.
- [12] Gandomi, A. H., Yang, X.-S., & Alavi, A. H. (2013). Cuckoo search algorithm: A metaheuristic approach to solve structural optimization problems. *Engineering with Computers*, 29(1), 17–35.
- [13] Li, Y., Zhao, Y., & Liu, J. (2021). Dimension by dimension dynamic sine cosine algorithm for global optimization problems. *Applied Soft Computing Journal*, 98, 106933.
- [14] Sadollah, A., Bahreininejad, A., Eskandar, H., & Hamdi, M. (2013). Mine blast algorithm: A new population-based algorithm for solving constrained engineering optimization problems. *Applied Soft Computing*, 13(5), 2592–2612.
- [15] Xie, L., Han, T., Zhou, H., Zhang, Z. R., Han, B., & Tang, A. (2021). Tuna swarm optimization: A novel swarm-based metaheuristic algorithm for global optimization. *Computational Intelligence and Neuroscience*, 2021(1), 9210050.
- [16] Kamboj, V. K., Nandi, A., Bhadoria, A., & Sehgal, S. (2020). An intensify Harris Hawks optimizer for numerical and engineering optimization problems. *Applied Soft Computing*, 89, 106018.
- [17] Wang, J., Wang, W., Hu, X., Qiu, L., & Zang, H. (2024). Black-winged kite algorithm: A nature-inspired meta-heuristic for solving benchmark functions and engineering problems. *Artificial Intelligence Review*, 57, 98.
- [18] Güntürkün R., “İnsansız Savaşlara Doğru Yapay Zeka Kontrollü Ölümcül Silahlar”, Ekin Yayınevi, 2022, s 6, ISBN: 978-625-8235-07-4,



BÖLÜM-5

YAPAY ZEKÂ DESTEKLİ MOBİL TELEREHABİLİTASYON

Cafer KARALI¹

Fatih Emirhan TÜRKER²

Burak YILMAZ³

¹<https://orcid.org/0000-0003-4892-3480>

²<https://orcid.org/0009-0002-2364-3829>

³<https://orcid.org/0000-0001-5549-8385>

YAPAY ZEKÂ DESTEKLİ MOBİL TELEREHABİLİTASYON

1. GİRİŞ

Araştırma projesi, fizyoterapi hastaları ve engelli bireyler için rehabilitasyon süreçlerini daha erişilebilir, verimli ve sürdürülebilir hale getirmek için yapay zekâ destekli bir mobil telerehabilitasyon sistemi geliştirmeyi amaçlamaktadır. Önerilen mobil uygulama, hastaların terapilerine evde bağımsız olarak devam etmelerini sağlarken, doktorların gelişmiş görüntü işleme ve duruş analizi teknolojilerini kullanarak ilerlemelerini uzaktan izlemelerine ve analiz etmelerine olanak sistem, tedavi süreçlerini optimize ederek ve erken teşhisi kolaylaştırarak daha iyi sağlık sonuçlarını destekleyecektir. Oyunlaştırma gibi özellikler özellikle genç hastaların ilgisini çekmeyi, motivasyonlarını ve tedaviye katılımlarını artırmayı amaçlamaktadır. Ayrıca uygulama, engelli bireyler için erişilebilirliği artırarak lojistik engelleri azaltacak ve rehabilitasyonu hızlandıracaktır.

Proje aynı zamanda sağlık çalışanlarının iş yükünü hafifletmeyi ve hasta-doktor iletişimini geliştirmeyi amaçlıyor. Kullanıcı dostu arayüzü ve yenilikçi yaklaşımıyla mobil uygulamanın geniş bir kitleye ulaşarak rehabilitasyon hizmetlerini daha yaygın hale getirmesi bekleniyor. Başarı, mevcut teknolojik kaynaklar ve uzmanlıkla desteklenen kullanıcı benimseme oranları, sağlık çalışanlarından alınan geri bildirimler ve hasta memnuniyeti ile ölçülecektir.

2. MATERYAL VE METOD

Proje beş ana aşamadan oluşmaktadır. İlk aşama veri toplamadır. Bu aşamada fizik tedavi ve rehabilitasyon hastalarının egzersizlerine ait görüntü ve videolar toplanmaktadır. Belirli hastalıkların erken teşhisi için gerekli veri kümeleri oluşturulur ve çeşitli teknikler kullanılarak artırılır. İkinci aşama ön işlemedir. Bu aşamada toplanan veriler, OpenCV teknolojisinin sıklıkla kullanıldığı görüntü işleme yöntemleri kullanılarak dijital ortamda işlenir. Bir sonraki aşama ise sınıflandırmadır. Burada işlenen veriler, Teachable Machine platformu kullanılarak makine öğrenimi amacıyla sınıflandırılır. Bir diğer aşama ise model oluşturma ve eğitimidir. Bu aşamada, işlenen görüntüler kullanılarak yapay zeka ve makine öğrenimi tabanlı eğitilebilir bir model

oluşturulur ve model daha sonra giriş verileriyle eğitilir. Beşinci ve son aşama ise nihai modelin bir mobil uygulamaya entegre edilmesidir. Bu aşamada, dört aşamadan sonra elde edilen model, kullanıcıların her yerden rahatça erişebilmelerini sağlamak için bir mobil uygulamaya entegre edilir.

1. Görüntü İşleme ve Analizi

Görüntü işleme, sayısallaştırılmış görüntüler üzerinde çalışan algoritmalar geliştirmeye odaklanan bir araştırma alanıdır. Sinyal iyileştirmeden görüntü anlamaya kadar geniş bir alanı kapsar. Görüntü işleme yöntemi beş ana adımdan oluşur: elde etme, ön işleme, segmentasyon, tanımlama ve yorumlama. Her adım bir veritabanı ile etkileşimi içerir [1]. Bu projede, görüntü işleme yöntemleri, yapay zeka ve görüntü işleme teknolojilerini kullanarak rehabilitasyon süreçlerini izleme ve analiz etme hedefine ulaşmada kritik bir rol oynamaktadır.

• OpenCV

OpenCV, Intel tarafından 1999 yılında gerçek zamanlı uygulamalar için geliştirilmiş çok yönlü bir açık kaynak görüntü işleme kütüphanesidir. C, C++, Python ve Java dahil olmak üzere çeşitli programlama dillerini destekler ve mobil ve masaüstü dahil olmak üzere çeşitli platformlarda sorunsuz bir şekilde çalışır. OpenCV, görüntü işleme görevlerini hızlandırmak ve optimize etmek için tasarlanmıştır, bu da onu gerçek zamanlı uygulamalar için ideal hale getirir. Gürültü azaltma, kontrast geliştirme ve parlaklık ayarı gibi işlemler için çeşitli işlevler ve filtreler sunar.

OpenCV'nin kullanım alanlarından bazıları şunlardır:

- Hareket izleme
- Yüz, gözler, ağız ve burun gibi vücut parçalarının algılanması
- Nesne tanıma
- Videolarda hareket algılama
- Mobil robotlar ve artırılmış gerçeklik uygulamaları

OpenCV kütüphanesi dört ana bileşenden oluşmaktadır: CV, MLL, HighGUI ve CXCore [2]:

- **CV:** Görüntü işleme ve üst düzey görüntü işleme algoritmaları içerir.
- **MLL:** Çeşitli istatistiksel sınıflandırıcılar ve kümeleme araçları ile makine öğrenimi komutlarını içerir.
- **HighGUI:** Videoları ve görüntüleri kaydetmek ve yüklemek için G/Ç işlemlerini ve işlevlerini yönetir.
- **CXCore:** Görüntü çizme gibi görevler için temel veri yapılarını ve özellikleri içerir.

Bu çalışmada gerekli işlemler için, açık kaynak kodlu olması, platform bağımsızlığı ve görüntü işleme alanındaki güçlü yetenekleri nedeniyle Python programlama dili olarak seçilmiştir. Python'un kapsamlı kütüphane desteği ve veri bilimi görevleri için uygunluğu, seçilmesinin diğer nedenleridir. NumPy paketi kullanılacak ve JetBrains tarafından geliştirilen ve yaygın olarak kullanılan bir Python geliştirme ortamı olan PyCharm Community Edition IDE kullanılacaktır.

2. Yapay Zeka ve Makine Öğrenimi

Yapay zeka (YZ), bir bilgisayarın veya bilgisayar kontrollü bir robotun genellikle zeki varlıklarla ilişkilendirilen görevleri yerine getirme yeteneğini ifade eder. Bu kavram genellikle akıl yürütme, anlam keşfetme, genelleme yapma veya geçmiş deneyimlerden öğrenme gibi insan benzeri bilişsel yeteneklerle donatılmış sistemler geliştirmek için kullanılır. 1950'lerin başında Alan Turing'in "Makineler düşünebilir mi?" sorusu makine öğrenimi kavramını ortaya atarken, "Yapay Zeka" terimi ilk kez John McCarthy tarafından 1956 yılında düzenlenen ilk yapay zeka konferansı olan "Dartmouth Konferansı" sırasında kullanılmıştır [3].

Yapay zeka teknolojileri, çevrelerini algılayabilen ve belirli bir hedefe yönelik başarı şanslarını en üst düzeye çıkaran davranışlar sergileyebilen çeşitli cihazları kapsar. Bu teknolojiler arasında makine öğrenimi, derin öğrenme, kural tabanlı sistemler ve doğal dil işleme yer almaktadır.

Makine Öğrenimi

Yapay zekanın bir alt disiplini olan makine öğrenimi, istatistiksel modellerin bilgisayarlar kullanılarak verilere uygulanmasını içerir. Yapay zeka sistemlerinin geliştirilmesine yardımcı olarak, makinelerin insanlar gibi verileri analiz etmesi için eğitilmesine odaklanır. Makine öğrenimi, yapay zekanın karar verme ve tahminler için verileri işlemesini sağlar. Makine öğrenimi, yalnızca algoritmaları programlamak yerine, makinelerin tahminler yapmasına olanak tanıyan modeller oluşturmak için örnek veri ve sonuçlardan oluşan eğitim setlerini kullanır [4].

Makine öğrenimi modellerinin türleri:

- Gözetimli öğrenme
- Denetimsiz öğrenme
- Yarı denetimli öğrenme

- Pekiştirmeli öğrenme

Makine öğreniminin ileri bir aşaması olan derin öğrenme, beynin sinir ağı yapısını taklit eder. Makinelerin katmanlı veriler içindeki ilişkileri analiz etmesini ve yeni durumlar için algoritmalarını oluşturmasını sağlar. Derin öğrenme, yüz ve ses tanıma veya tıbbi görüntü analizi gibi çeşitli görevleri mümkün kılmaktadır [5].

Makine Öğreniminde Kullanılan Kütüphaneler

1. **Scikit-learn:** Veri madenciliği ve analizi için basit ve etkili araçlardan oluşan, makine öğrenimi için yaygın olarak kullanılan bir Python paketi. NumPy, SciPy ve matplotlib gibi popüler Python kütüphaneleri üzerine inşa edilen Scikit-learn, yeni başlayanlar ve daha basit veri analizi görevleri için uygundur.
2. **TensorFlow:** Google tarafından geliştirilen, derin sinir ağlarının eğitimi ve çıkarımına odaklanan açık kaynaklı bir yazılım kütüphanesidir. Doğrusal regresyon ve evrişimli sinir ağları da dahil olmak üzere çok çeşitli programlama dillerini ve görevlerini destekler [6, 7].
3. **PyTorch:** GPU hızlandırma kullanarak derin öğrenme modelleri oluşturmak için bir Python kütüphanesi. Facebook'un yapay zeka laboratuvarı tarafından geliştirilen PyTorch, esnekliği ve hızıyla bilinir ve genellikle TensorFlow'a bir alternatif olarak kabul edilir. Kullanım örnekleri arasında kelime düzeyinde dil modelleme, zaman serisi tahmini ve görüntü sınıflandırıcıların eğitimi yer almaktadır [8].

I. Yolo Algoritması

Yolo (You Only Look Once), son yıllarda geliştirilen ve gerçek zamanlı görüntü işlemede yaygın olarak kullanılan bir nesne algılama algoritmasıdır. Yolo, görüntüye tek bir Evrişimsel Sinir Ağı (CNN) uygulayarak, görüntüyü ızgaralara bölerek ve her ızgara için sınırlayıcı kutular ve ilişkili güven puanları hesaplayarak nesne tespiti gerçekleştirir. Bu sınırlayıcı kutular, tahmin edilen güven puanları kullanılarak analiz edilir [9]. Yolo, diğer nesne algılama algoritmalarından önemli ölçüde daha hızlıdır ve görüntüleri yaklaşık 40-90 FPS (saniye başına kare) hızında işleyerek gerçek zamanlı uygulamalar için oldukça verimli hale getirir.

II. Öğretilbilir Makine Platformu

Teachable Machine, Google tarafından yapay zeka ve öğrenme projesinin bir parçası olarak geliştirilen bir platformdur. Genellikle nesne sınıflandırma ve tanıma görevleri için kullanılır. Platform, kullanıcıların kendi görüntü, ses veya metin verilerini kullanarak basit makine öğrenimi modelleri oluşturmalarını sağlar. Teachable Machine, modelleri eğitmek ve oluşturmak için arka planda bir makine öğrenimi kütüphanesi olan TensorFlow'u kullanır. Kullanıcılar web kameralarından çektikleri görüntülerle kolayca veri kümeleri oluşturabilir ve herhangi bir kodlama yapmadan modeller üretebilirler. Bu projede, Teachable Machine özellikle sınıflandırma aşamasında kullanılacaktır [10].

III. 3. Mobil Uygulama Geliştirme

Flutter, mobil, masaüstü ve web uygulamaları geliştirmek için kullanılabilen bir çerçevedir. Platformlar arası bir çerçeve olarak, geliştiricilerin hem iOS hem de Android için uygulamalar oluşturmalarına olanak tanır. Google tarafından geliştirilen Flutter, özellikle mobil uygulamalar oluşturmak için çok uygun olan açık kaynaklı bir UI yazılım geliştirme kitidir. Flutter'da kullanıcı arayüzü (UI) ve iş mantığı Dart programlama dili kullanılarak yazılır.

Flutter, Dart kullanarak UI öğeleri oluşturmak için Material Design ve Cupertino widget kütüphaneleri sağlar. Yine Google tarafından geliştirilen Dart, tarayıcı tabanlı ve mobil uygulama geliştirme için tasarlanmış bir programlama dilidir. C++, Java ve JavaScript gibi dillerle yapısal benzerlikler paylaşır.

Flutter'da uygulamanın iş mantığı, Dart ile yazılmış sınıflar ve fonksiyonlar kullanılarak uygulanır. Kullanıcı arayüzünün durumunu yönetmek için Flutter, StatefulWidget ve StatelessWidget widget'ları sağlar [11-14].

3. SONUÇ

Bu çalışma, mobil telerehabilitasyonda yapay zeka (AI) ve görüntü işleme teknolojilerinin başarılı bir şekilde entegrasyonunu göstermekte ve geleneksel rehabilitasyon uygulamalarındaki mevcut zorlukları ele almak için modern bir yaklaşım sunmaktadır. Önerilen sistem, yapay zekanın yeteneklerinden yararlanarak fizik tedavi egzersizlerinin doğru bir şekilde izlenmesini ve analiz edilmesini sağlayarak tedavide daha fazla erişilebilirlik ve etkinlik

sağlamaktadır.

Temel bulgular arasında, model performansını ve genelleme yeteneklerini önemli ölçüde etkileyen yığın boyutu ve epok değerleri gibi hiperparametrelerin optimizasyonu yer almaktadır. Çalışma özellikle bu parametrelerin TechEmbble Machine platformu kullanılarak yoga pozlarının sınıflandırılmasındaki etkisini vurgulamaktadır. Savaşçı 2, Ağaç, Plank, Tanrıça ve Downdog olmak üzere beş farklı yoga pozunu, yığın boyutu ve epok değerlerine bağlı olarak değişen performans seviyeleriyle sınıflandırılmıştır. 32 ve 100 epokluk bir yığın boyutu, kararlılık ve doğruluk arasında en iyi dengeyi sağlarken, Tanrıça pozunu sınıf dengesizliği nedeniyle zorluklar göstermiştir.

Oyunlaştırılmış tedavi modüllerinin eklenmesi, terapi rutinlerine katılımı ve bağlılığı artırarak sistemin özellikle pediatrik ve farklı engelli kullanıcılar için uyarlanabilirliğinin altını çizmektedir. Ayrıca, sınıf temsilindeki dengesizlikleri gidermek ve Tanrıça gibi yeterince temsil edilmeyen pozlar için genellemeyi iyileştirmek için veri artırma teknikleri önerilmiştir.

Sonuçlar, yapay zeka destekli araçların etkili bir şekilde uygulandığında, özellikle uzak veya kaynakların sınırlı olduğu ortamlarda sağlık hizmetlerine erişimdeki boşlukları kapatabileceği hipotezini doğrulamaktadır. Ayrıca çalışma, yapay zekanın erken teşhis potansiyelini güçlendirerek zamanında müdahaleyi mümkün kılıyor ve genel sağlık sonuçlarını iyileştiriyor.

Bu yapay zeka tabanlı sistemin bir mobil uygulamaya entegrasyonu, rehabilitasyon hizmetlerine erişimi demokratikleştirmekle kalmıyor, aynı zamanda dijital sağlık alanında gelecekteki yeniliklerin de önünü açıyor. Bulgular umut verici olsa da, modelin gerçek dünya senaryolarındaki ve çeşitli kullanıcı koşullarındaki performansı, sağlamlık ve ölçeklenebilirliği sağlamak için daha fazla araştırma yapılmasını gerektirmektedir.

KAYNAKÇA

- [1] Başaran, Z. & Elbasan, B. (2023). Fizyoterapi Ve Rehabilitasyonda Güncel Yazılım teknolojisi:Görüntü İşleme Tekniği . Gazi Sağlık Bilimleri Dergisi , 8 (2) , 79-88 . DOI:10.52881/gsbdergi.1265642
- [2] Eldem, A., Eldem, H., & Palalı, A. (2017). Görüntü İşleme Teknikleriyle Yüz Algılama Sistemi Geliştirme. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 6(2), 44-48. doi:10.17798/bitlisfen.333984
- [3] Çevrim İçi Ansiklopedi (Britannica): Yapay Zekâ <https://ddo.link/artificial-intelligence> .
- [4] Bishop, C. (2006). Örüntü Tanıma ve Makine Öğrenimi. Springer-Verlag.
- [5] Schmidhuber, J. (2015). Sinir ağlarında derin öğrenme: Genel bir bakış. Neural Networks, 61, 85-117.
- [6] Abadi, M. (2016). "TensorFlow: Büyük Ölçekli Makine Öğrenimi için Bir Sistem" (PDF).
- [7] Google. (2015). TensorFlow: Açık kaynak makine öğrenimi. Retrieved from <https://www.tensorflow.org/>(15 Aralık 2016 tarihinde arşivlendi; 8 Kasım 2023 tarihinde erişildi).
- [8] Alıcılar, H. E., & Çöl, M. (2021). Halk Sağlığında Yapay Zekanın Kullanımı. Uludağ Üniversitesi Tıp Fakültesi Dergisi, 47(1), 151-158. doi:10.32708/uutfd.891274
- [9] Shinde, S., Kothari, A., & Gupta, V. (2018). YOLO tabanlı İnsan Eylemi Tanıma ve Yerelleştirme. Procedia Computer Science, 133, 831- 838.
- [10] Öğretilebilir Makine resmi web sitesi. (2023, Kasım 8). <https://teachablemachine.withgoogle.com/faq>
- [11] Dart Resmi Web Sitesi. (2023, Kasım 8). <https://dart.dev/>
- [12] Google. (2023, Kasım 8). Flutter. <https://flutter.dev/>
- [13] Güneş D., Servi S., Kaya O., "A Mobile Pharmacy Application: Sıfaap", Mühendislikte Yenilikçi Yaklaşımlar-3, (2023)., Eğitim Yayınevi, Editör:Dr. Öğr. Üyesi Fatih Alpaslan Kazan, Öğr. Gör. Gökhan Yalçın, Basım sayısı:1, Sayfa Sayısı 113, ISBN:978-625-6613-96-6, Türkçe(Bilimsel Kitap) (Yayın No: 8899990)
- [14] Güntürkün R., "İnsansız Savaşlara Doğru Yapay Zeka Kontrollü Ölümcül Silahlar", Ekin Yayınevi, 2022, s 6, ISBN: 978-625-8235-07-4,

BÖLÜM-6

MEOWSIC

Rabia DOĞANAY¹
Sema SERVİ²

¹<https://orcid.org/0009-0008-8420-1825>

²<https://orcid.org/0000-0003-2069-9085>

YAPAY ZEKÂ DESTEKLİ MOBİL TELEREHABİLİTASYON

1. GİRİŞ

Müzik, insanların hislerini, düşüncelerini, doğadan aldıklarını ve bazen de salt doğayı anlatan, ifade eden, düzenlenmiş seslerdir. En ilkel çağlardan beri var olduğu bilinmektedir. İnsanlar, o dönemlerden itibaren seslerin yapılarını, harmonisini ve benzeri konuları incelemektedir [1]. Bunların akabinde müzik teorisi ortaya çıkmıştır. Müzik teorisi ise, müziğin çeşitli yönlerini inceleyen ve açıklayan bir bilim dalıdır [2]. Bu yönler arasında müzik notaları, ritimler, tonlar, akorlar ve form gibi konular bulunmaktadır. Müziğin anlaşılmasına yardımcı olması açısından çeşitli kuramlar, teknikler ve notasyon sistemleri geliştirilmiştir. Müzik teorisinde notasyon yani musiki yazısı, işitsel yolla duyulan seslerin (insan veya enstrüman gibi) diğer müzisyenlerle paylaşılabilmesi için geliştirilmiş bir görsel dildir. Kültürlere göre musiki yazısı farklılık göstermektedir. Örneğin klasik müzik için nota kâğıdı kullanılırken country türündeki müzikler için Nashville'nin sayı sistemi kullanılmaktadır [3]. Günümüzde müzik teorisinde çoğunlukla nota kâğıdı okuma eğitimleri verilmektedir.

Teorik eğitim kadar enstrüman eğitimi de müzik sanatını öğrenmede vazgeçilmez bir parçadır. Piyano, başlı başına bir çalgı olmanın dışında müzik eğitiminin pek çok alanında ve aşamasında kullanılan ve kullanılması gereken zorunlu bir çalgıdır [4]. Bunun sebebi diğer müzik aletlerinin aksine piyanoda seslerin hazır olarak bulunmasıdır. Ayrıca piyano; geniş bir literatüre sahip olma, çoksesli kullanılma, eşlik çalgısı olma özellikleriyle önemli bir eğitim aracı olmaktadır [5,6]. Nota kâğıdı ve piyano ile müzik teorisi derinlemesine öğrenilebilmektedir.

Mobil uygulamalar müzik teorisi ve enstrüman eğitimi için kolay ve pratik alternatif olmaktadır. Bu yüzden, literatürde müzik teorisi ve enstrüman eğitiminde kullanılmak üzere çeşitli uygulamalar geliştirilmiştir. Lakin, bu uygulamalar sadece müzik teorisi veya enstrüman eğitimi gibi spesifik bir konu üzerine yoğunlaşmıştır. Meowsic, bu iki konuda kullanıcıların kendilerini geliştirebilecekleri bir mobil uygulamadır. Uygulamamızda temel

enstrüman olarak piyanoyu tercih ettik. Piyano, özette de bahsedildiği üzere, müzik teorisi eğitiminin verilmesi için mükemmel bir araçtır. Meowsic'i geliştirirken ortaya koymaya çalıştığımız yenilikler şu şekildedir:

- Sonid gibi kullanıcılara temel müzik teorisini sade ve güzel bir arayüzle en temel seviye olan notalardan başlayarak ileri seviyeye kadar götüren bir arayüz geliştirilecektir. Lakin, Sonid'de ciddi bir eksiklik olan nota okuma özelliği de uygulamamıza eklenerek daha eğlenceli ve akılda kalıcı eğitimler sunulacaktır.

- Simply Piano'da olduğu gibi eğer kullanıcılar piyanoya sahiplerse çaldıkları nota, eğittiğimiz derin öğrenme modeliyle uygulama tarafından algılanabilecektir. Burada kullanılan yapay zeka sayesinde, kullanıcı isterse sanal piyano klavyesinden pratik yapabilecek isterse de sahip olduğu piyanoyu kullanarak yeteneklerini geliştirebilecektir. Ayrıca, daha önce verilmiş eğitimler için belirlenmiş bir süre zarfında hatırlatıcı ek kursların bildirimi gönderilecektir.

- Flowkeys'de bulunan nota kâğıdı okuma, benzer şekilde Meowsic'te de olacaktır. Lakin, Meowsic ekstradan kullanıcılarına PAPERAI servisiyle kendi nota kağıtlarını eklemelerine izin verecektir. PAPERAI servisi, kullanıcıların yükledikleri nota kağıdı fotoğraflarını veya PDF'leri MusicXML formatına çevirmektedir. Bu sayede kullanıcılara istedikleri parçaları rahat bir şekilde öğrenebilmeleri sağlanacaktır. Uygulamamızın ilerleyen versiyonlarında eklenmesi planlanan özellikler şunlardır:

- İlerleyen versiyonlarda en önemli planlarımızdan biri, uygulamanın sadece piyano ile değil, Sight Reading Factory'dekine [13] benzer şekilde farklı enstrüman sesleriyle de çalışabilmesi için Residual Shuffle-Exchange Networks modelini diğer enstrümanlar için de eğitebilmektir.

- Diğer birikmiş işlerimizden bir tanesi de kullanıcıların nota dinleme yeteneklerini geliştirmek için duydukları notaları basmalarını isteyen bir kurs sistemi geliştirmektir.

Bu eksikliklerden yola çıkarak uygulamamızı uluslararası sahada müzik teorisi eğitimi için yenilikçi ve öncü bir hale getirmeyi planlamaktayız. Uygulamanın başarılı olması durumunda öncül teknolojilerden bir tanesi olabilme ihtimali ile patentlenebilir olabileceğini düşünmekteyiz.

2. AMAÇ ve HEDEFLER

Müzik, insanlık tarihi boyunca en etkili iletişim alanlarından birisi olmaktadır. Bu bağlamda müzik, sadece duygu ve düşünceleri ifade eden bir dil olmasının yanı sıra bir eğitim aracı olarak da görülmektedir [4]. Dolayısıyla her eğitiminde olduğu gibi müzik eğitiminde de çeşitli alternatifler mevcuttur. Konservatuar eğitimi veren kurumlar, müzik okulları, kurslar, özel öğretmenlerden ders alma, yazılı kaynaklardan bireysel çalışma ve internet kaynaklarını kullanarak bireyin öğrenme sürecini kendi başına ilerletmesi bu yollardan bazılarıdır.

Günümüzde internet kaynaklarının çeşitlenip artmasıyla beraber mobil uygulamaların kullanımını her alanda olduğu gibi eğitim alanında da artmaktadır. Bu alana yoğunlaşan mobil uygulamaların çeşitliliği ve sayısında da doğal olarak artış görülmektedir. Günümüzde mobil cihazlar, mobil uygulamaların popülerite kazanmasıyla birlikte her yaştan kesimin (özellikle çocuk ve genç bireylerin) ilgisini çekmektedir [7]. Ayrıca yapılan araştırmalara göre mobil uygulamaların öğrencilerin akademik başarılarını olumlu yönde etkilediği gözlemlenmiştir [8].

Mobil uygulamaların kullanımı sadece müzik eğitimi alan kişilere değil aynı zamanda eğitim veren öğretmenlere portfolyo oluşturma, öğrencilerinin öğrenme sürecini uzaktan takip edebilme, online sınav sistemi, sanal sınıf ile uzaktan ders işleyebilme gibi çeşitli imkanlar sunmaktadır [8]. Tüm bu sebepler değerlendirildiğinde mobil uygulamaların müzik teorisi ve enstrüman eğitimi için kolay ve pratik alternatif olduğu, öğrenme ve öğretme sürecinde olan herkese hitap edebileceği görülmektedir.

Örnek olarak müzik teorisi ve enstrüman eğitimi için kullanılacak mobil uygulamalar şunlardır:

- Yousician: Bu uygulama gitar eğitimi sunmaktadır. Öğrenciler, uygulamada yer alan özel müzikler ve parçalar üzerinden çalışarak enstrüman yeteneklerini ve teorik bilgilerini geliştirebilirler [9]. Lakin, uygulamanın ücreti öğrenciler için pahalı olabilmekte hem de ağırlıklı olarak gitar eğitimi verildiği için teori kısmı zayıf kalabilmektedir.


- **Simply Piano:** Bu uygulama, piyano çalmayı öğrenmek isteyenler için geliştirilmiştir. Öğrenciler, uygulamada yer alan özel derslerle piyano yeteneklerini geliştirebilmektedirler [10]. Lakin, uygulamanın tasarımı ne kadar güzel ve akıcı olsa da verdikleri kurslar öğrencinin o bilgileri öğrenebilmelerine yetecek sayıda değildir. Ayrıca kurslarda öğretilen konuların tekrar edilmemesi ile konuların unutulması olasıdır.
- **Sonid:** Bu uygulama, müzik teorisi eğitimi için geliştirilmiş Duolingo'ya [11] benzer yapıda ilerleme sistemi bulunan bir eğitim uygulamasıdır [12]. Öğrenciler, uygulamada piyano üzerinden notaları öğrenmeye başlayarak ilerlemektedirler. Lakin, bu uygulamanın eksik olduğu taraf müzik eğitiminde oldukça önemli olan nota kağıdı okuma eğitiminin olmamasıdır.

3. MATERYAL VE METOD

3.1. Sistemin Genel Yapısı

Meowsic'in mobil tarafında Google'ın ürettiği Dart dili kullanılmıştır. Dart dilini kullanmamızın en önemli sebeplerinden bir tanesi Flutter yazılım iskeletinin bu dilde geliştirilmiş olmasıdır. Flutter, bizlere platformdan bağımsız bir şekilde Android, iOS, masaüstü ve web uygulamaları geliştirmemizi sağlamaktadır. Ayrıca, Dart mobil uygulamaların geliştirilmesi için yeterince hızlı ve efektif bir yapıya sahiptir. Bu yüzden Dart tercih edilmiştir.

Uygulamanın ön uç tarafında MVC mimari deseni arka uç tarafında ise microservice mimarisi kullanılmıştır. MVC desenin yapısı 3 katmandan oluşmaktadır ve katmanları birbirinden bağımsız (birbirini etkilemeden) olarak çalışmaktadır. Bu sebeple çoğunlukla büyük çaplı projelerde projelerin yönetiminin ve kontrolünün daha rahat sağlanabilmesi için tercih edilmektedir [14]. MVC mimari desenini kullanmamızın sebebi, uygulamanın iş mantığı, kullanıcı arayüzü ve veri modellerini ayırmasıdır. Bu ayrılma durumu bizlere; daha rahat bakım sağlayabilmemizi, hızlı bir şekilde kodu test edebilmemizi ve tek bir veri modelinin başka arayüzlerde kullanılabilmesini sağlamaktadır. MVC modeline aittir.

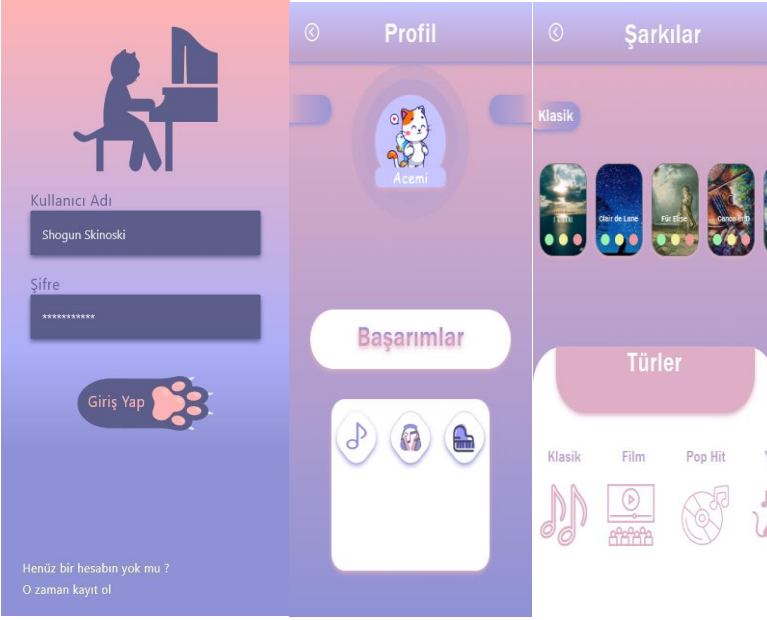


Şekil 1. MVC mimari desenine ait bir görsel.

Microservice mimarisi, tek bir uygulama geliştirirken modüler bir yapıda her biri küçük servis olarak düşünülmesi gereken ve her bir servisinde kendi işini ve iletişimini yürütebilen, çok karmaşık olmayan ve başka servislere bağımlılığı az olan mekanizmalara sahip bir yaklaşımdır [15]. Microservice mimarisinin tercih edilme sebebi, kullandığımız herhangi bir servisin hata alması durumunda diğer servislerin hala çalışabilir olması ve bakımının daha rahat gerçekleştirilebilmesidir.


- **ÖNÜÇ**

Şekil 2'de görülen Meowsic'in giriş ve kayıt ekranıdır. Kullanıcı, uygulama içerisinde edindiği başarıları, seviyesini vb. istatistiksel verilerini profil sayfasından inceleyebilmektedir (Şekil Ektedir). **Şekil 2** profil sayfasının demo halidir. Ayrıca **Şekil 2**'de görüldüğü üzere kullanıcı istediği müzik türüne göre şarkıları seçebilmektedir. Bu ekranlar henüz geliştirilme aşamasındadır. Projenin ilerlemesiyle daha kaliteli kullanıcı arayüzleri ve gelişmiş özellikler getirilecektir.



Şekil 2. Meowsic Giriş, Profil Ve Müzik Seçim Ekranı

Şekil 3 nota kağıdı okuma antrenmanı için geliştirilmiş arayüze aittir. Notalar ayarlardan belirtilen hızla mavi şeride doğru akmaktadır. Eğer doğru notaya basılırsa nota mavi renk yanlıştır, basarsa kırmızı renk olmaktadır.



Şekil 3. Nota Kağıdı Okuma Antrenmanı

Uygulamada müziklerin nota kağıdına yazılması için MusicXML dosya formatı kullanılmıştır. MusicXML formatı, yazılımcıların müzik notasyon verilerini başka yazılımlara aktarmasını sağlayan dosya formatıdır. Nota kağıdını yüklemek için bu format

kullanılmıştır. **Şekil 4** MusicXML dosyasını notalara ayrıştırarak ekranda hangi pozisyonda olması gerektiğini hesaplayan koda ait bir örnektir.

```

class NotePositionHelper extends NotePositions {
  NotePositionHelper(super.noteType, super.noteStem, super.noteBeam, super.note,
    super.accidental, super.octave);

  String get name => "${_note.name}${_accidental.symbol}";

  double get pitch {
    double offset = 0;
    switch (_note) {
      case Notes.C:
        offset = 50;
        break;
      case Notes.D:
        offset = 70;
        break;
      case Notes.E:
        offset = 90;
        break;
      case Notes.F:
        offset = 100;
        break;
      case Notes.G:
        offset = 120;
        break;
      case Notes.A:
        offset = 140;
        break;
      case Notes.B:
        offset = 160;
        break;
    }
    if (_accidental == Accidental.sharp) {
      offset += 10;
    } else if (_accidental == Accidental.flat) {
      offset -= 10;
    }
    return -(offset + 12 * (octave + 1));
  }
}

```

Şekil 4 Notanın Kâğıttaki Pozisyonunu Hesaplayan Kod

Sunucuya yüklenmiş MusicXML dosyalarının nota kağıdına dönüştürülmesi ve kullanıcı hareketleriyle etkileşime geçmesi uygulamamızın en önemli özelliklerinden birisidir. Bu yüzden sunucudan indirilen müzik dosyalarının nota kağıdına çevrilmesi gerekmektedir. Çevirme işlemleri için şu anda 3. taraf bir kütüphane kullanılmaktadır. Lakin, kütüphanenin eksikliklerinden dolayı Dart dili için kendi MusicXML çevirici kütüphanesi yapmaktayız. **Şekil 5** yapmakta olduğumuz çevirici kütüphanesinden bir örnektir.

```

enum NoteType { whole, half, quarter, eighth, sixteenth, thirtysecond }
enum NoteStem { up, down }
enum NoteBeam { begin, endure, end }
enum Notes { C, D, E, F, G, A, B }
enum Accidental { sharp, flat, none }
enum Octave { subcontra, contra, great, small, one, two, three, four, five }

extension AccidentalName on Accidental {
  String get symbol {
    switch (this) {
      case Accidental.sharp:
        return "#";
      case Accidental.flat:
        return "b";
      case Accidental.none:
        return "";
    }
  }
}

extension NoteAccidentals on Notes {
  List<Accidental> get accidental {
    switch (this) {
      case Notes.C:
        return [Accidental.sharp];
      case Notes.D:
        return [Accidental.flat, Accidental.sharp];
      case Notes.E:
        return [Accidental.flat];
      case Notes.F:
        return [Accidental.sharp];
      case Notes.G:
        return [Accidental.flat, Accidental.sharp];
      case Notes.A:
        return [Accidental.flat, Accidental.sharp];
      case Notes.B:
        return [Accidental.flat];
      default:
        return [];
    }
  }
}

Notes get previous => (this == Notes.C)
? Notes.B
: Notes.values[Notes.values.indexOf(this) - 1];
Notes get next => (this == Notes.B)
? Notes.C
: Notes.values[Notes.values.indexOf(this) + 1];
}

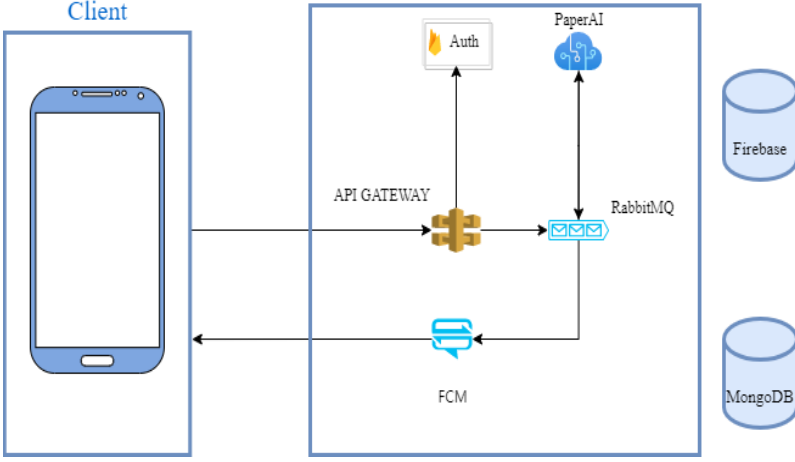
```

Şekil 5: MusicXML Çeviricisi İçin Örnek Kod

- ARKA UÇ

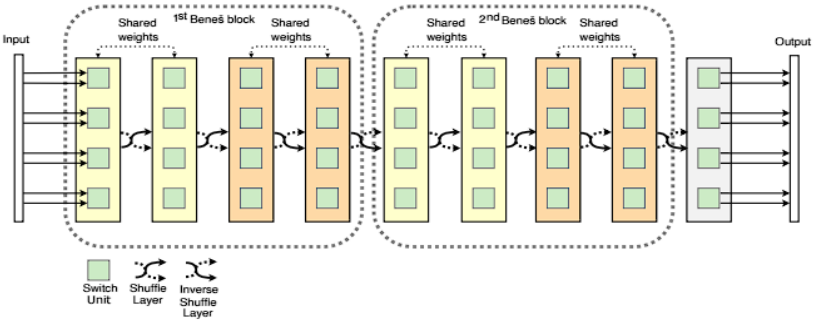
Uygulamanın kullanıcı kayıt işlemlerinde Firebase kullanılmaktadır. Firebase'in tercih edilmesinin en önemli sebebi, kayıt metotları konusunda çeşitli fonksiyonlar sağlamasıdır. Farklı türlerde dosyaların saklanması kolaylaştırdığı için MusicXML dosyalarının saklanması MongoDB kullanılmıştır.

Şekil 6'da kullanıcı giriş yapmak istiyorsa kullanıcı kapısına istek atmaktadır. Eğer Firebase'de böyle bir kullanıcı kayıtlı ise kullanıcı uygulamaya giriş yapabilmektedir. Kullanıcı, uygulamaya giriş yaptıktan sonra öğrenmek istediği parça uygulamada yoksa ve parçanın nota kağıdına sahipse bunu öğrenebilmek için sisteme yükleyebilmektedir. Kullanıcı böyle bir istek oluşturduğunda api kapısı RabbitMQ'ya bir sıra eklemektedir. Eklenen sıradaki nota kağıdı dosyası MongoDB'ye kaydedilmektedir. Kaydedilen nota kağıdı PaperAI servismiz tarafından çekilip MusicXML formatına çevirmektedir. Çevirme işleminden sonra MusicXML dosyasını MongoDB'ye kaydetmekte ve RabbitMQ'ya bir sıra ekleyerek kullanıcıyı uyarması için Firebase Cloud Messaging(FCM) bilgi göndermektedir.



Şekil 6: Kullanılan Microservice için örnektir.

Kullanıcının piyanosundan çaldığı notaların ne olduğunun sınıflandırmasını yapacak Residual Shuffle-Exchange Networks, Python’da yazılacaktır ve TFlite kullanarak mobil cihazlara entegre edilecektir. Mobil cihazın hızına bağlı olarak Weight pruning metoduyla modelin boyutu düşürülecektir. Residual Shuffle-Exchange Networks derin öğrenme modeli kompleks müziklerde dahi %78 oranla notaları doğru sınıflandırmaktadır [16]. Modelde kullanılan mimarı Şekil 7’de gösterilmiştir.



Şekil 7: Residual Shuffle-Exchange Networks Yapısı [16]

4. SONUÇ

Akıllı telefonların ortaya çıkışı dünyaya büyük bir değişim getirmiştir. Eğitim sektörü de diğer her sektör gibi bu cihazların

sağladığı potansiyelden faydalanmıştır. Müzik teorisi ve enstrüman eğitimi için mobil uygulamalar geliştirilmiş ve bu uygulamalar milyonlarca insana erişim sağlamıştır. Meowsic, sektörde milyonlarca kitlelere ulaşan uygulamaların eksik yönlerinden yola çıkarak geliştirilmiştir. Meowsic diğer uygulamaların geniş bir kapsamı olarak; kullanıcılarına müzik teorisi eğitimi, piyanoyla nota kağıdı okuma antrenmanı, istedikleri parçayı tarayarak pratik yapabilmelerine olanak sağlama ve gelişimlerini takip edebilecekleri bir analiz sistemi sunmaktadır. Ayrıca Meowsic’de notaların algılanması için kullanılan yapay zeka modelinin gösterdiği başarı oranı sayesinde kullanıcılar; kendi enstrümanlarını eğitim sürecinde sıkıntı çekmeden, gönül rahatlığıyla kullanabilmektedirler. İnanıyoruz ki Meowsic, müzik teorisi ve enstrüman eğitimi için öncü bir uygulama olacaktır.

İlerleyen çalışmalarda kullanıcıların sadece piyano değil çeşitli enstrümanlarla da antrenman yapabilmelerini sağlanacaktır. Kullanıcıların müzik kulağını geliştirmek için duyduğu notayı çalmalarını sağlayacağı bir sistem geliştirilecektir. Ayrıca ilerleyen dönemlerde uygulama içinde müzik teorisi için kullanabilecekleri bir forum geliştirilecektir. Çalışmada kullanılan derin öğrenme metodunun notaları algılamada gösterdiği başarı yüksek olmasına rağmen bazı mobil cihazlarda düşük çalışma hızı gösterebilmektedir. İlerleyen çalışmalarda performans iyileştirmeleri yapılacaktır.

KAYNAKÇA

- [1] TEMEL MÜZİK EĞİTİMİ DERS NOTLARI. (2022, 12, 27). <http://bizdosyalar.nevsehir.edu.tr/0b3fabba3a4b70bd70195bb6532ca5e0/temel-muzik-egitimi-dersnotlar>.
- [2] Wikipedia contributors. (2022, December 23). Music theory. Wikipedia. https://en.wikipedia.org/wiki/Music_theory
- [3] Wikipedia contributors. (2022a, November 14). Musical notation. Wikipedia. https://en.wikipedia.org/wiki/Musical_notation
- [4] Özyazıcı, F. (N.D.). Piyano Eğitiminin İlk Beş Yılı İçin; Seçilmiş Repertuar Ve Metotlar Işığında Uygulanabilecek Pedagojik Yöntemler. T.C. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Müzik Anasanat Dalı Piyano Sanat Dalı Piyano Programı.
- [5] Pamukçu, Özer, S. ., M. C. (2016). Çocuklarda Piyanoya Başlangıç Yaşı Ve Müzik Eğitiminde Kullanılan Yöntemlerin Değerlendirilmesi . Ege Üniversitesi Devlet Türk Musikisi Konservatuarı Dergisi , (7) , 29-38 .
Erişim Sağılandı
<HTTPS://DERGIPARK.ORG.TR/TR/PUB/KONSERVATUVARDERGISI/ISSUE/46521/584090>
- [6] S., S. (2014, 10, 7). Why Learning Piano Theory is Important for All Musicians. TakeLessons Blog. <https://takelessons.com/blog/piano-theory-for-all-musicians>
- [7] Goncharova, M. S., & Gorbunova, I. B. (2020). Mobile Technologies in the Process of Teaching Music Theory. Propósitos y Representaciones, e705-e705.
- [8] Demir, K., & Akpınar, E. (2018). The Effect of Mobile Learning Applications on Students' Academic Achievement and Attitudes toward Mobile Learning. Malaysian Online Journal of Educational Technology, 6(2), 48-59.
- [9] Yousician.Yousician | Learn Guitar, Piano, Ukulele With The Songs you Love. <https://yousician.com/>
- [10] Simply | The best apps to set your creativity free. (n.d.-b). Erişim Sağılandı (2022, 11, 28), <https://www.hellosimply.com/>
- [11] Duolingo. (n.d.). Duolingo - Learn a language for free @duolingo. Erişim Sağılandı (2022,12,20), <https://www.duolingo.com/>
- [12] Learn music theory with Sonid, an app for iOS and Android. (n.d.).Erişim Sağılandı, (2022, 12, 16) ,<https://sonid.app/>
- [13] Practice Sight Reading and Sight Singing Exercises Online – Sight Reading Factory®. (n.d.).Erişim Sağılandı (2022,12, 23), from <https://www.sightreadingfactory.com/> Selçuk University 3rd International Technology and Innovation Student Symposium December 26-28, 2024 Konya, Turkey 2
- [14] Doğan, K. (2021, 12, 7). MVC Nedir? MVC Yaşam Döngüsü (Life Cycle) - Kadircan Doğan. Medium. <https://medium.com/@kdrcondogan/mvc-nedir-mvc-ya%C5%9Fam-d%C3%B6ng%C3%BCs%C3%BC-life-cycle8e124f24650c>
- [15] Ayrançioğlu, G. (2022, 10,5). Microservice Mimarisi Nedir ? Microservice Mimarisine Giriş. Medium.

<https://gokhana.medium.com/microservice-mimarisi-nedir-microservice-mimarisine-gir-i%C5%9F-948e30cf65b1>

- [16] Draguns, A., Ozoliņš, E., Šostaks, A., Apinis, M., & Freivalds, K. (2021, May). Residual shuffleexchange networks for fast processing of long sequences. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 35, No. 8, pp. 7245-7253).



BÖLÜM-7

TERMAL VE KAMERAYLA GÖRÜNTÜ İŞLEMEYE DAYALI AKILLI GÜVENLİK SİSTEMİ: OLASI TEHDİTLERİ TESPİT VE ERKEN UYARI MEKANİZMASI

*Salih Mübin BÖCÜ¹
Sema SERVİ²*

¹<https://orcid.org/0009-0000-1126-9695>

²<https://orcid.org/0000-0003-2069-9085>

TERMAL VE KAMERAYLA GÖRÜNTÜ İŞLEMESİNE DAYALI AKILLI GÜVENLİK SİSTEMİ: OLASI TEHDİTLERİ TESPİT VE ERKEN UYARI MEKANİZMASI

1. GİRİŞ

Güvenlik sistemleri, modern toplumda yalnızca fiziksel koruma sağlamakla kalmayıp, potansiyel tehditlere karşı hızlı ve etkili bir şekilde yanıt verme yeteneği sunmalıdır. Ancak, mevcut çözümler genellikle düşük ışık koşulları ve çevresel tehditlerin algılanmasında yetersiz kalmaktadır. Gade ve Moeslund'un çalışmalarında, termal kameraların hareketli nesnelere algılama ve sıcaklık farklılıklarını analiz etme konularındaki başarısı vurgulanmıştır. Araştırmalar, bu teknolojilerin, geleneksel sistemlerin sınırlamalarını aşmak için ideal bir çözüm sunduğunu göstermiştir [Gade, R., & Moeslund, T. B., "Thermal cameras and applications: A survey," *Machine Vision and Applications*, 25(1), 245–262, 2014].

Benzer şekilde, Zhao ve Chellappa'nın yüz tanıma teknolojileri üzerine yaptığı çalışmalarda, bu algoritmaların güvenlik sistemlerinde kullanılmasının doğruluk oranını artırdığı belirtilmiştir [Zhao, W., Chellappa, R., et al., "Face Recognition: A Literature Survey," *ACM Computing Surveys*, 35(4), 399–458, 2003]. Bu durum, bireylerin kimlik doğrulama süreçlerini hızlandırarak güvenlik sistemlerinin daha etkin bir şekilde çalışmasını sağlamaktadır. Bu projede hem yüz tanıma hem de termal algılama teknolojileri bir arada kullanılarak 7/24 her an kapsamlı bir güvenlik çözümü sunulması hedeflenmiştir.

2. MATERYALLER VE METOTLAR


2.1. MEKANİK KISIM

Bu çalışmada, optik ve termal kameraların güvenilir ve etkili bir şekilde çalışmasını sağlamak amacıyla mekanik yapı 3d yazıcı ile pla filament malzeme kullanılarak tasarlanmıştır. Sabit bir yapı tercih edilerek sistemin stabil bir şekilde çalışmasını sağlamıştır.

Optik kameranın 58 derece, termal kameranın ise 110 derece görüş açısına sahip olması, sistemin geniş bir tarama alanına ulaşmasına olanak tanımıştır. Optik kamera, yüz tanıma işlemleri için merkezi bir konuma yerleştirilirken, termal kamera, çevresel tehditlerin algılanmasında yüksek doğruluk sağlayacak şekilde geniş bir alanı kapsayacak şekilde monte edilmiştir. Bu yerleşim

düzeni, izinsiz girişlerin ve çevresel tehditlerin daha etkin bir şekilde tespit edilmesini sağlamıştır.

Geniş görüş açısı sayesinde ise daha büyük bir alanın güvenliği sağlanmıştır. Çevresel dayanıklılık açısından, plâ malzemenin hafifliği ve esnekliği, mekanik yapının taşınabilir ve sağlam bir yapı sunmasını desteklemiştir. Mekanik kısım Şekil 1’de verilmiştir.



Şekil 1. Mekanik Kısım

2.2. Yazılım

2.2.1. Görüntü İşleme ve Yüz Algılama

Bu sistemde, yüz algılama işlemi çeşitli görüntü işleme teknikleriyle sağlanmış ve geliştirilmiştir. dlib ve face_recognition gibi ileri düzey kütüphaneler kullanılarak yüz algılama işlemi gerçekleştirilmiştir. Sistemde, öncelikle kamera akışından elde edilen görüntüler üzerinde yüz tespiti yapılmış, bu yüzlerin koordinat bilgileri tespit edilerek "face_loc" adlı bir listeye eklenmiştir.

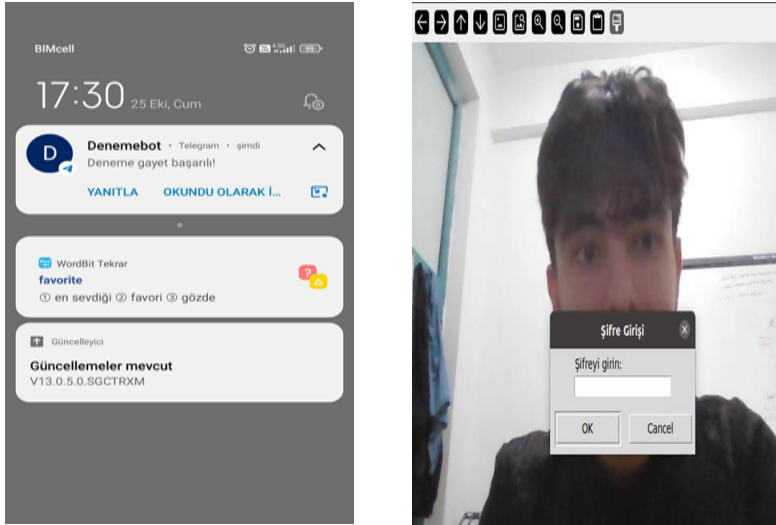
yüz algılama işleminin başarılı bir şekilde tamamlanmasının ardından, yüz kodlamaları çıkartılmış ve bu kodlamalar sisteme tanıtılan kullanıcı yüz bilgileriyle karşılaştırılmıştır. face_recognition.compare_faces() fonksiyonu, anlık olarak tespit edilen yüzlerin sisteme tanıtılmış olanlarla eşleşmesini kontrol etmiştir. Eşleşme durumunda ekranın belirli bir bölgesinde ilgili kullanıcının adı görüntülenirken, aksi durumda “yabancı” etiketi belirir.

2.2.2. Yüz Algılandıktan Sonra İşlevsel Adımlar

Kullanıcı Tanıma: Sistemde tanımlı olan bir yüz tespit edilirse, kullanıcının adı görüntülenir ve ek bir işlem gerekmez.

Şifre Doğrulama: Tanımlı olmayan bir yüz algılandığında, sistem şifre girilmesini talep eder. OpenCV'nin Haar kaskat yöntemi ile yüz algılama tamamlanır ve kullanıcıya şifre girişi ekranı sunulur. Doğru şifre girildiğinde, sistem kullanıcıyı yetkilendirir (Şekil 2).

Bildirim Mekanizması: Şifre hatalı girilirse ya da belirlenen süre içerisinde giriş tamamlanmazsa, sistem sosyal medya aracılığıyla (python-telegram-bot kullanılarak) kullanıcıya bir uyarı mesajı gönderir. Bu mesaj, potansiyel bir güvenlik ihlaline karşı hızlı aksiyon alınmasını sağlar (Şekil 2).




Şekil 2. Şifre Doğrulama ve Bildirim Mekanizması

2.2.3. TERMAL KAMERA ENTEGRASYONU

Termal kamera verilerinin düşük çözünürlüklü olması nedeniyle, scipy.ndimage.zoom fonksiyonu kullanılarak interpolasyon uygulanmış ve bu veriler daha yüksek çözünürlükte yeniden boyutlandırılmıştır. Renklendirme için cmap kütüphanesindeki 'jet' renk haritası kullanılarak, sıcaklık bilgileri gözle görülür hale getirilmiştir. Tkinter tabanlı bir arayüz ile görüntü sunumu sağlanırken, ortalama sıcaklık değeri de anlık olarak hesaplanıp

görüntülenmiştir. Örneğin, ortalama sıcaklık belirli bir eşik değeri aşar ya da düşerse, sistem kullanıcıyı uyarır (Şekil 3).



Şekil 3. Termal Kamera Görünümü

3. SONUÇ

Bu sistem, yüz tanıma, şifre doğrulama, termal algılama ve bildirim mekanizmalarıyla birleştirilerek çok katmanlı bir güvenlik altyapısı sunmaktadır. yüz algılama ve tanıma ile yetkilendirme sağlanırken, termal kamera ile çevresel tehditler önceden tespit edilerek bildirimlerle desteklenmiştir. Bu çalışma, gelecekte güvenlik sistemlerine entegre edilebilecek daha karmaşık çözümler için bir temel oluşturmaktadır.

KAYNAKÇA

- [1] ZHAO, W., CHELLAPPA, R., PHILLIPS, P. J., & ROSENFELD, A. (2003). FACE RECOGNITION: A LITERATURE SURVEY. *ACM COMPUTING SURVEYS*, 35(4), 399–458.
- [2] Gade, R., & Moeslund, T. B. (2014). Thermal cameras and applications: A survey. *Machine Vision and Applications*, 25(1), 245–262.
- [3] Schmidt, A., & Bullinger, H.-J. (2007). HCI and Security Systems: Towards a Security-Aware HCI Design. *Human-Computer Interaction*, 22(1), 65–92.
- [4] Li, S. Z., & Jain, A. K. (2011). *Handbook of Face Recognition*. Springer-Verlag.
- [5] Gonzalez, R. C., & Woods, R. E. (2017). *Digital Image Processing*. Pearson.
- [6] Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer.
- [7] Viola, P., & Jones, M. (2001). Rapid Object Detection using a Boosted Cascade of Simple Features. *Proceedings of the 2001 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- [8] Russ, J. C. (2011). *The Image Processing Handbook*. CRC Press
- [9] Turaga, P., Chellappa, R., & Subrahmanian, V. S. (2008). Machine Recognition of Human Activities: A Survey. *IEEE Transactions on Circuits and Systems for Video Technology*, 18(11), 1473–1488.
- [10] Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- [11] Afzulpurkar, S. (2010). *Mechatronics and Intelligent Systems for Off-road Vehicles*. Springer.

BÖLÜM-8

HAFİF DONANIMLAR İÇİN GERÇEK ZAMANLI HEDEF ALGILAMA VE YOK ETME SİSTEMİ

*Yusuf NURDOĞDU¹
Hakan TERZİOĞLU²*

¹<https://orcid.org/0009-0005-2410-9478>

²<https://orcid.org/0000-0001-5928-8457>

HAFİF DONANIMLAR İÇİN GERÇEK ZAMANLI HEDEF ALGILAMA VE YOK ETME SİSTEMİ

1. GİRİŞ

Günümüzde otonom sistemlerin kullanımı giderek artmaktadır ve hayatımızın önemli bir kısmında yer almaya başlamıştır. Birçok alanda kullanılan otonom sistemler askeri alanda da avantajlar sağlamaktadır. Otonom/yarı otonom şekilde uçabilen İHA'lar ve otonom/yarı otonom şekilde su altında görev yapabilen AUV'lar (Atonomus Underwater Vehicle) bu otonom sistemlerdendir. Bu sistemler yardımı ile arama-kurtarma, coğrafi konum belirleme, mayın tespiti, batık kurtarma, su altı boru hattı kaynak incelenmesi gibi çeşitli alanlarda problemlere çözümler üretilmektedir [1],[2].

Otonom sistemlerin birçoğu kameralardan alınan görüntülerin işlenmesiyle çalışmaktadır. Alınan görüntüler işlenerek sistemlerin çevrelerini algılaması, hedeflerin tespit edilmesi ve uygun kararlar alması sağlanır. Bu işlemler gerçekleştirilirken makine öğrenmesi, derin öğrenme ve görüntü işleme tekniklerinden yararlanır [5]. Makine öğrenmesi ve derin öğrenme modelleri ile kameradan alınan görüntü üzerinde hedef tespiti gerçekleştirilir. Görüntü işleme teknikleri ise kameradan alınan ve uygun modeller ile işlenecek görüntülerin düzenlenmesi ve iyileştirilmesinde kullanılır. Aynı zamanda performans artışını sağlamak için görüntülere dönüşümler ve filtreler uygulamada kullanılır. Görüntüyü yeniden boyutlandırma, RGB görüntüleri gri renk formatına dönüştürerek boyut azaltma ve çeşitli filtreler yardımıyla keskinliği artırma, bulanıklığı azaltma ve kontrast ayarlama gibi işlemler örnek olarak verilebilir. Bu aşamada amaç verileri daha kolay işlenebilir hale getirerek tespit aşamasında daha hızlı ve doğru sonuçlara ulaşmaktır [8]. Birçok görüntü işleme tekniği bulunmaktadır. Yapılan denemeler ve araştırmalar sonucunda en doğru sonucu veren algoritmalar projede kullanılmak üzere seçilmiştir [2]. Projeye uygun makine öğrenmesi ve derin öğrenme modellerine de kullanılan donanım göz önünde bulundurularak yapılan araştırmalar sonucunda karar verilmiştir [7].

Otonom sistemlerde görüntü işleme ve hedef tespiti gibi görevlerin verimli bir şekilde gerçekleştirilebilmesi için çeşitli optimizasyonlar gereklidir. Aşırı ısınmanın önüne geçmek için etkili bir soğutma sistemi kullanılmalı ve kod, gereksiz bellek ve CPU kullanımını minimize edecek şekilde optimize edilmelidir [9]. Optimize yazılımlar ve donanımlar kullanarak sağladığı kolaylıklardan faydalanılabilir. Çözünürlük düşürme ve çerçeve atlama (frame skipping) yöntemleri, işlem yükünü hafifletirken paralel

işleme (multiprocessing veya threading) teknikleri, performansı artırabilir. Hafif modeller kullanılarak performans, doğruluk ve hız arasında dengeli bir yapı sağlanabilir [10],[11]. Görüntü işleme ve derin öğrenme çıkarımlarının her ikisi de bulunan projelerde hibrit bir yaklaşım benimsenerek daha iyi sonuçlara ulaşılabilir.

Aynı anda birden fazla işlemi gerçekleştiren bu sistemlerde performans oldukça önemlidir. Ancak performansın yanında maliyet de büyük bir öneme sahiptir. Performans ve maliyet göz önünde bulundurulduğunda ihtiyaçlara göre farklı donanımlar tercih edilebilmektedir. Güçlü donanımlar, kullanılan algoritmalara bağlı olarak da değişmekle birlikte yüksek doğruluk oranları ve gerçek zamanlı işlem yapabilmeyi daha kolay kılar. Ancak bu durum maliyeti de artırmaktadır. Gerek maliyeti düşürmek gerekse uygulanabilirlik ve test aşamalarında kolaylık sağlanması nedeniyle hafif donanımlar tercih edilebilmektedir. Ağır donanımlara kıyasla performansları düşüyor olsa da gelişen teknolojiyle birlikte bu durum değişmektedir. Aradaki bu performans düşüşünü minimum düzeye indirebilmek adına geliştirilen birçok yazılım bulunmaktadır. Ne kadar aradaki fark tamamen kapanmıyor olsa da oldukça iyi sonuçlar elde edilmektedir. Bu sebepler düşünüldüğünde basit otonom sistemlerde hafif donanımların kullanımı oldukça mantıklıdır.


Bu makalede hafif donanımlar üzerinde hedef tespit ve imha işlemlerini gerçekleştirmede kullanılan sistemler ve yöntemler incelenmektedir. Raspberry Pi 5 mini bilgisayarını kullanarak, ilk olarak YOLOv8 modeliyle veri çoğaltma yöntemleri uygulayarak 4119 veriyle eğitilmiş bir model geliştirilmiştir. Ardından, aynı verilerle eğitilmiş SSD-MobileNet-v2-FPNLite (FP32), SSD-MobileNet-v2-FPNLite (TPU-8), SSD-MobileNet-v2 (TPU-8) ve EfficientDet-D0 modelleri ile çeşitli denemeler yapılmıştır. Yapılan testlerde, MobileNet yapılı modellerin YOLOv8'e göre çok daha iyi performans sergilediği gözlemlenmiştir. Özellikle, doğruluk ve hız karşılaştırmaları sonucunda, MobileNet modellerinin Edge TPU desteği ile önemli performans artışı sağladığı tespit edilmiştir. Literatürde de Edge TPU desteği ile mobil cihazlarda yerel yapay zeka işlem gücünün artırılmasının, doğruluk ve hızda gözle görülür iyileşmeler sağladığı belirtilmiştir [12]-[14]. Ayrıca, paralel işleme yöntemleri kullanılarak bu modellerin çalışma verimliliği daha da artırılmıştır [15]. Gerçek zamanlı nesne tespiti yapan donanımlarda sıcaklık yönetimi büyük bir sorun teşkil ettiğinden, Raspberry Pi 5'in özel soğutma sistemi kullanılarak performans düşüşünün önüne geçilmiştir. Ayrıca, bu sistemde görüntü verisi elde etmek için Raspberry Pi ile uyumlu olan Pi Camera Module 3 kamera modülü kullanılmıştır.

Bu makale, gerçekleştirilen çalışmalar doğrultusunda hedef tespit ve imha işlemlerinin verimliliğinin nasıl artırıldığına dair çeşitli bulguları sunmaktadır. Görüntü işleme ve model eğitimi sırasında kullanılan paralel işleme yöntemlerinin yanı sıra, model optimizasyonlarının nasıl performansı artırdığı detaylı şekilde tartışılmıştır. Modellerin doğruluk ve hız açısından karşılaştırılması yapılmış ve özellikle Edge TPU desteğinin sağladığı büyük avantajlar vurgulanmıştır. Ayrıca, tespit edilen hedefin mesafesi ölçülerek atış komutunun gönderilmesi süreci detaylandırılmış ve bu tür donanımlarla etkili bir hedef imha sistemi kurmanın mümkün olduğu gösterilmiştir.


2. MATERYAL VE METOTLAR

2.1. Donanım


Bu çalışmada, otonom hedef tespiti ve imha işlemleri için temel donanım olarak Raspberry Pi 5 - 8 GB modeli tercih edilmiştir. Önceki modellere göre önemli performans iyileştirmeleri sunmaktadır. Daha güçlü bir işlemciye, artırılmış bellek kapasitesine ve genişletilmiş giriş/çıkış seçeneklerine sahip olan bu model, görüntü işleme ve derin öğrenme algoritmalarının daha hızlı ve verimli bir şekilde çalışmasını sağlamaktadır. Raspberry Pi 4 ile kıyaslayacak olursak yaklaşık 2,5 kat daha yüksek CPU performansı sunan Raspberry Pi 5, aynı zamanda güç tüketimini optimize ederek daha uzun süreli kullanım imkânı sunmaktadır. Raspberry Pi 4 ve Raspberry Pi 5 üzerinde SSD-MobileNet-v2-FPNLite (FP32) modeli ile ayrı ayrı yapılan testlerde Raspberry Pi 4'ün 5-6 FPS değerlerini verirken Raspberry Pi 5 modelinin 11-12 FPS değerlerini verdiği gözlemlendi. Şekil 1 ve Şekil 2'de Single-Core ve Multi-Core karşılaştırmaları, Şekil 3'te ise farklı ncnnc frameworkleri kullanılarak bu iki model arasındaki performans karşılaştırmaları verilmiştir [16].



Şekil 1. Single-Core Karşılaştırması



Şekil 2. Multi-Core Karşılaştırması

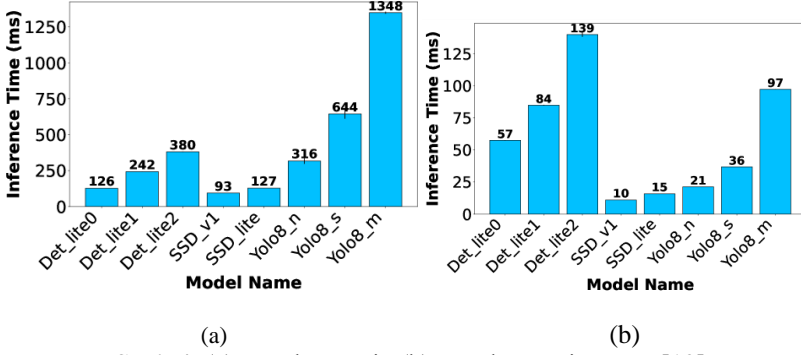


Şekil 3. Farklı nncnn Frameworkleri İçin Performans Karşılaştırması

Görüntü verisi elde etmek için Pi Camera 3 Modülü kullanılmıştır. Tespit işlemleri için görüntü kalitesi önemli bir rol oynamaktadır. Pi Camera 2 Modülü ile de yapılan testlerde, Pi Camera 3'ün daha yüksek doğruluk oranları sağladığı gözlemlenmiştir. Daha yeni bir teknoloji olmasından kaynaklı olarak Pi Camera 3 Modülü birçok durumda daha yüksek doğruluk oranları vermektedir. Kameranın sensör kalitesi, çözünürlüğü, düşük ışık koşullarındaki performansı sonuçlarda oldukça fark yaratmaktadır. Kamera megapiksel (MP) değerindeki artışa bağlı olarak doğruluk oranlarındaki iyileşmeyi [17] referans alarak inceleyebilirsiniz.

Tespit işlemlerinde performansı artırmak için Raspberry Pi ile uyumlu Edge TPU kullanılmıştır. Edge TPU, yapay zeka modellerini yerel cihazlarda hızlı ve verimli bir şekilde çalıştırmak için geliştirilmiş bir donanımdır. Bu donanım, düşük güç tüketimi ile yüksek işlem gücü sağlayarak özellikle TensorFlow Lite modellerinin çıkarımlarını hızlandırmış ve gerçek zamanlı hedef tespiti yapılabilmesini mümkün kılmıştır. Bu donanım sayesinde, Raspberry Pi 5 üzerindeki model performansları daha güçlü donanımlardaki performanslara yakın bir başarı elde edebilmiştir. Farklı kullanım senaryolarına göre değişmekle birlikte TPU desteği ile sağlanan model eğitim süreçlerinde CPU'lara göre 14-15 kat performans artmakta ve model çıktılarındaki doğruluk oranları %10 civarında, işlem süreleri ise modelden


modele geçişle birlikte test ettiğimiz modellerde 10 ile 20 kat arasında artmaktadır [18]. Bu donanım kombinasyonu hem performans hem de verimlilik açısından ideal bir çözüm sunarak, otonom sistemin ihtiyaçlarını karşılamaktadır.



Şekil 4. (a) Raspberry Pi5 (b) Raspberry Pi5+TPU [19]

2.2. Model Seçimi

Çalışmada farklı modeller üzerinde gerçekleştirilen denemeler sonucunda belirli bir modelde karar verilmiştir. Model denemelerine geçmeden önce, modelin eğitim ve test aşamaları için gerekli olan veri setinin hazırlanması sürecine odaklanılmıştır. Bu süreçte, görüntü verileri Raspberry Pi Camera 3 modülü, telefon kamerası ve usb kamera ile elde edilmiş ve farklı koşullarda çekilen görüntülerden oluşan bir veri seti oluşturulmuştur. Elde edilen görüntüler, çember tespiti hedefleyen etiketleme işlemlerinden geçirilmiş ve eğitim için uygun formatlara dönüştürülmüştür. Farklı modeller için farklı formatlarda dönüşümler yapılması gerekmektedir. YOLO modeli için LabelIMG uygulamasından YOLO şeklinde, diğer modeller için ise de PascalVOC formatında çıktılar alındı. Ayrıca, veri setinin çeşitliliğini artırmak ve modelin farklı senaryolarda daha iyi performans göstermesini sağlamak amacıyla çeşitli veri artırma teknikleri uygulanmıştır. Döndürme, parlaklık değişimi, kesme, bulanıklık ekleme, keskinleştirme ve grileştirme bu teknikler arasındadır. Yapılan bu hazırlık süreci, model denemelerinde kullanılan veri kalitesinin ve doğruluğun artırılmasında önemli bir rol oynamaktadır.



Şekil 5. Veriler ve Artırma Teknikleri Uygulanmış Halleri


Hazırlanan veriler modellere verilerek colab üzerinden eğitimler tamamlanmıştır. Ardından modelleri deneme sürecine geçilmiştir. Denemelerde YOLOv8, SSD-MobileNet-v2-FPNLite (FP32), SSD-MobileNet-v2-FPNLite (TPU-8), SSD-MobileNet-v2 (TPU-8) ve EfficientDet-D0 modelleri kullanılmıştır.

YOLOv8 modeliyle yapılan denemelerde, Intel Core i7-12700H işlemcili bilgisayar ortamında 10 FPS'ye kadar performans elde edilirken, Raspberry Pi 5 üzerinde yapılan testlerde yalnızca 0.5 FPS'ye ulaşılmıştır. Bu durum, gerçek zamanlı tespit yapan bir sistem için oldukça yetersizdir. Model, doğruluk açısından %94 gibi oldukça başarılı bir oran sunmasına rağmen, Raspberry Pi 5 gibi sınırlı donanımlara sahip cihazlar için fazla ağırdır. YOLOv8 gibi tam sürümler, genellikle yüksek kaynak tüketimi gerektirir ve bu nedenle daha güçlü donanımlarda etkili şekilde çalışabilir. Raspberry Pi gibi sınırlı sistemlerde, bu tür ağır modeller yerine daha hafif alternatiflerin tercih edilmesi gereklidir. Örneğin, SSD-MobileNet veya EfficientDet-D0 gibi modeller hem hız hem de kaynak tüketimi açısından daha uygun çözümler sunabilir. Gerçek zamanlı tespit gerektirmeyen projelerde, YOLO'nun tam sürümleri faydalı olabilir; ancak, mevcut proje için bu modellerin kullanımı sınırlı avantajlar sağlayacaktır. Bu nedenle, daha hafif ve hızlı çalışan modellerin tercih edilmesi hem sistem performansını artıracak hem de enerji tüketimini azaltacaktır.


SSD-MobileNet ve EfficientDet-D0 gibi modeller Raspberry Pi üzerinde çalıştırmak için daha uygun modellerdir. Düşük donanım kaynaklarına sahip cihazlar için optimize edilmişlerdir. Diğer daha karmaşık modellerle karşılaştırıldığında daha az hesaplama gücü ve enerji tüketimi gerektirirler. Bu nedenle Raspberry Pi üzerinde etkili bir şekilde nesne tespiti yapmayı mümkün kılarlar. Literatüre baktığımız zaman da yaygın olarak kullanılan bu modeller gömülü sistemlerde enerji verimliliği ve performans dengesini sağlama yönünde öne çıkmaktadır [20]. Ayrıca bu modellerin farklı versiyonları da mevcuttur. Çalışmamızda SSD-MobileNet tabanlı birkaç farklı model ile EfficientDet-D0 modellerinin performansları karşılaştırılmış, doğruluk değerleri ve tespit hızları ele alınmıştır.

SSD-MobileNet tabanlı modellerde SSD-MobileNet-v2 (TPU-8), SSD-MobileNet-v2-FPNLite (TPU-8) ve SSD-MobileNet-v2-FPNLite (FP32) modelleriyle karşılaştırmalar yapıldı. Yaptığımız karşılaştırmalarda kullandığımız modellerin farklılıkları SSD-MobileNet-v2 (TPU-8) modeli INT8 kuantizasyonu sayesinde düşük gecikmeyle çalışarak hız ve verimlilik sağlar. Ancak SSD-MobileNet-v2-FPNLite (TPU-8) INT8 kuantizasyonunun yanında FPNLite mimarisi ile de küçük nesnelere algılamada daha çok avantaj sağlar. Bu iki model hız açısından iyi olsalar da doğruluk açısından SSD-MobileNet-v2-FPNLite (FP32) daha iyi performans gösterir. Bunun nedeni FP32 hassasiyeti kullanıyor olmasından kaynaklanır. FP32, INT8 kuantizasyonuna kıyasla daha fazla doğruluk sunar. Ancak daha fazla kaynak tükettiğinden modelin hızını düşürür. Hız ve kaynak kullanımının önemli olduğu projelerde TPU-8 modeli tercih edilebilirken yüksek doğruluk oranlarının önemli olduğu projelerde FP32 modeli tercih edilebilir.

EfficientDet-D0 modeline baktığımızda ise SSD-MobileNet modellerine göre daha düşük doğruluk oranlarına vermiştir. Daha ağır bir modeldir ve GPU veya TPU gibi daha güçlü donanımlara ihtiyaç duyar. SSD-MobileNet ise daha hafif bir modeldir ve daha hızlıdır. Daha düşük hesaplama gücü ve bellek gereksinimleri ile çalışır. Bu nedenle de Raspberry Pi gibi cihazlarda daha iyi performans gösterir. Şekil 6.'da her bir model için yapılan testler sonucunda elde edilen hız ve doğruluk grafiklerini görebilirsiniz.



(a)



(b)

Şekil 6. (a) Model Doğruluk Karşılaştırması (b) Model FPS Karşılaştırması

Grafiklere bakıldığında INT8 kuantizasyonuna sahip modellerin daha yüksek FPS değerlerine sahip olduğunu hatta Edge TPU kullanılarak 3 kata kadar FPS artışı sağlandığı görülmektedir. Doğruluk açısından bakıldığında da 418 adet veri ile test edildiklerinde en iyi sonucu SSD-MobileNet-v2-FPNLite (FP32) vermesine rağmen SSD-MobileNet-v2-FPNLite (TPU-8)'in de buna yakın sonuçlar verdiği görülmektedir. Ancak test edilen veri sayısındaki artışla aradaki fark açılacaktır. Tablo 1.'de genel bir değerlendirme yapılmıştır.

Model	Hız	Doğruluk	Kaynak Kullanımı	Mimari Avantajları	Uygulama Alanları

SSD-MobileNet-v2 (TPU-8)	Çok hızlı	Orta	Düşük	INT8 kuantizasyonu ile hız ve verimlilik sağlar	Gerçek zamanlı uygulamalar, düşük güçlü cihazlar
SSD-MobileNet-v2-FPNLite (TPU-8)	Hızlı	Yüksek	Orta	FPNLite mimarisi ile küçük nesne algılamada iyileştirme	Hız ve doğruluğun dengelendiği gerçek zamanlı uygulamalar
SSD-MobileNet-v2-FPNLite (FP32)	Orta	Çok yüksek	Yüksek	FP32 hassasiyeti ve FPNLite ile doğruluk artırılır	Doğruluğun kritik olduğu uygulamalar
EfficientDet-D0	Yavaş	Düşük	Yüksek	BiFPN ve EfficientNet ile ölçeklenebilirlik ve doğruluk sağlar	Güçlü donanıma sahip uygulamalarda

Tablo 1. Genel Model Değerlendirmesi


Yapılan karşılaştırmalar sonucunda projeye en uygun modele karar verilmiştir. Modellerin hızlarına bakıldığında, INT8 kuantizasyonlu modeller Edge TPU desteğiyle oldukça iyi FPS değerleri sunmaktadır. Ancak, doğruluk oranlarına bakıldığında bu modellerin biraz geride kaldığı gözlemlenmiştir. Projemizin ihtiyaçları doğrultusunda doğruluk oranı daha kritik bir öneme sahiptir. Bu nedenle, yüksek doğruluk oranına sahip olan SSD-MobileNet-v2-FPNLite (FP32) modeli, aynı zamanda proje için yeterli FPS değerlerini sağlaması nedeniyle tercih edilmiştir. Böylelikle hem gerçek zamanlı çalışabilen hem de doğruluk açısından tatmin edici sonuçlar veren bir model kullanılmıştır.

2.3. Yazılım ve Performans

Yazılım kısmında birkaç temel kütüphane kullanılmıştır. Görüntü üzerinde işlem yapmak için OpenCV ve Numpy kütüphaneleri, Pi Camera 3 Modülü ile görüntüleri alabilmek için picamera2 kütüphanesi, yaptığımız işlemleri parçalara bölerek aynı anda birden fazla işlemi gerçekleştirebilmek için threading ve son olarak motor kontrollerinin sağlanabilmesi için ise pymavlink kütüphanesi kullanıldı.


Projede, Picamera2 kütüphanesi kullanılarak kameradan alınan görüntüler, çeşitli renk dönüşümleri ve model girdisine uygun çözünürlük ayarlamaları yapıldıktan sonra tespit işlemleri için modele aktarılmıştır. Model, hedef tespit işlemlerini gerçekleştirdikten sonra elde edilen tespit bilgileri belirli filtreleme adımlarından geçirilmiştir. Tespit edilen nesnenin doğruluk değeri belirlenen eşik değerin altında

ise bu tespit yok sayılmıştır. Ayrıca, görüntüde birden fazla tespit olması durumunda, en yakın tespit hedef olarak seçilmiştir. Bu aşamadan sonra, tespit edilen cismin merkezi, çapı, alanı ve kaç derecelik açıyla durduğu belirlenmiştir. Bu bilgiler kullanılarak cismin kamerada ortalanması sağlanmış, istenilen yakınlığa ulaşıldığında hedef imhası için atış gerçekleştirilmiştir.



Şekil 7. Tespit Edilen Hedef Görüntüsü

Hedefle ilgili hesaplamalar, piksel tabanlı bir mesafe tespit algoritmasına dayanmaktadır. Bu algoritma, şekli ve boyutları önceden bilinen nesnelere üzerinde çeşitli piksel sayım yöntemleri kullanarak uzaklık hesaplamalarını mümkün kılmıştır. Cismin belirli mesafelerden alınan görüntüleri matematiksel bir denklem yardımıyla formüle edilmiş ve bu formül sayesinde cismin uzaklığı başarılı bir şekilde tahmin edilmiştir.



Şekil 8. Uzaklığı Tespit Edilmiş Hedefler

Projede, yazılımsal ve donanımsal olarak performansı artırmak için çeşitli optimizasyon yöntemlerinden yararlanılmıştır.

Öncelikle donanımsal olarak, cihazın aşırı ısınmasını önlemek için Raspberry Pi 5 için tasarlanmış aktif soğutma sistemi tercih edilmiştir. Bu sayede, uzun süreli işlemler sırasında yaşanabilecek performans düşüşlerinin önüne geçilmiştir. Soğutma sistemi kullanılmayan testlerde, Raspberry Pi 5'in sıcaklığının 80°C'ye kadar yükseldiği, bunun sonucunda donmalar ve bağlantı sorunlarının yaşandığı gözlemlenmiştir. Raspberry Pi 5'in donanım özelliklerine bakıldığında da cihazın maksimum çalışma sıcaklığının 85°C olduğu belirtilmektedir. Bu sıcaklık seviyesine ulaşıldığında, aşırı ısınmayı önlemek amacıyla cihaz performansı düşürerek işlem hızını yavaşlatmaktadır. Ancak uzun süre bu sıcaklıkta çalışması durumunda, bileşenlerin ömrü kısaltmakta ve cihazda donanımsal arızalar meydana gelebilmektedir. Özellikle işlemci ve güç düzenleme birimleri bu durumdan en fazla etkilenen parçalardır. Bu nedenle, etkili bir soğutma ile sıcaklık kontrolü sağlanması kritik öneme sahiptir.

Yazılım tarafında ise optimize edilmiş bir kodlama yaklaşımı benimsenmiş, gereksiz bellek ve CPU kullanımından kaçınılmıştır. Kamera görüntülerinin işlenmesinde çözünürlük düşürme uygulanarak modelin daha hızlı çalışması sağlanmıştır.

Paralel işleme yöntemleri (multiprocessing veya threading) kullanılarak aynı anda birden fazla işlemin gerçekleştirilmesi mümkün

hale getirilmiştir. Bu yöntemler sayesinde sistem kaynakları daha verimli bir şekilde kullanılmış, tespit işlemlerinin hızlanması ve gerçek zamanlı sonuçlar elde edilmesi sağlanmıştır. Gerçek zamanlı bir işlem gerçekleştirildiği için, kameradan görüntü alma ve bu görüntülerin işlenmesi gibi kritik süreçler ayrı bir iş parçasığında, tespit edilen verilerin analizi ve bu verilere göre yapılacak işlemler (örneğin, motor komutlarının iletilmesi) başka bir iş parçasığında ele alınmaktadır. Bu ayırım, hem görüntü akışının kesintisiz bir şekilde sağlanmasını hem de tespit sonrası eylemlerin hızlı ve doğru bir şekilde gerçekleştirilmesini mümkün kılmıştır.

Görüntü işleme aşamasında, grileştirme ve kenar tespiti gibi filtreleme yöntemleri kullanılarak model girdisi daha sade ve optimize bir hale getirilmiştir. Bu filtreleme işlemleri, modele gereksiz detayların ulaşmasını engelleyerek hem işlem süresini kısaltmakta hem de tespit doğruluğunu artırmaktadır. Özellikle grileştirme işlemi, renk bilgilerini sadeleştirerek görüntüdeki temel özelliklerin öne çıkmasını sağlar. Kenar tespiti ise nesnelerin şekil ve konum bilgilerinin daha belirgin hale gelmesini sağlayarak modelin karmaşıklığını azaltır. Bu tür ön işleme teknikleri, kaynakların verimli kullanımını desteklerken modelin performansını artırmak için etkili bir yöntem sunmaktadır.

Bu projede ihtiyaç duyulmamakla birlikte, yüksek işlem hızlarına gereksinim duyan projelerde Edge TPU desteği büyük bir avantaj sağlamaktadır. Edge TPU, yapay zeka modellerinin çıkarım sürelerini önemli ölçüde hızlandırırken, doğruluk oranlarında da iyileştirme sağlamaktadır. Dahası, bu işlemleri düşük enerji tüketimiyle gerçekleştirdiği için enerji verimliliği açısından da oldukça etkilidir. Özellikle sınırlı donanım kapasitelerine sahip cihazlarda, karmaşık yapay zeka modellerinin çalıştırılması mümkün hale gelir.

Çerçeve atlama (frame skipping) yöntemi de özellikle gerçek zamanlı işlem gerektirmeyen projelerde kaynak kullanımını optimize etmek için etkili bir teknik olarak öne çıkmaktadır. Bu yöntem, her bir kare yerine belirli aralıklarla kare işlemeyi mümkün kılarak işlem yükünü önemli ölçüde azaltır.

3. SONUÇ

Bu çalışmada, düşük donanım kaynaklarına sahip cihazlarda yapay zeka tabanlı nesne tespiti gerçekleştirmek için optimize edilmiş yöntemler ve modeller kullanılmıştır. Raspberry Pi 5 üzerinde yapılan deneyler, SSD-MobileNet-v2-FPNLite (FP32) modelinin hem doğruluk oranı hem de FPS performansı açısından proje gereksinimlerini karşılayabildiğini göstermiştir. Çalışmada kullanılan

grileştirme ve kenar tespiti gibi filtreleme yöntemleri sayesinde işlem yükü azaltılmış, model girdisi optimize edilmiş ve tespit süreçleri hızlandırılmıştır. Ayrıca, soğutma sistemlerinin donanım performansına olan katkıları net bir şekilde gözlemlenmiştir.

Bu proje, uzaklık tespitinde şekli ve boyutu bilinen nesnelere üzerinde başarılı sonuçlar elde etmiştir. Ancak, şekli ve boyutu önceden bilinmeyen nesnelere tespiti ve mesafe hesaplamalarının gerçekleştirilmesi, bu çalışmanın geliştirilebileceği önemli bir alan olarak görülmektedir. Bu konuda daha iyi sonuçlar elde edebilmek için çalışmalara devam edilmektedir.

Genel olarak, proje düşük güçlü cihazlarda yapay zeka uygulamalarının nasıl optimize edilebileceğine dair önemli bir örnek sunmaktadır. Gelecekte daha karmaşık nesne tespiti görevlerinde doğruluk ve hız oranlarını daha da artırmak için Edge TPU gibi donanım hızlandırıcıların entegrasyonu değerlendirilebilir. Ayrıca, çoklu nesne takibi ve hareketli hedeflerin daha verimli şekilde izlenmesi gibi alanlarda daha fazla geliştirme yapılabilir. Bu çalışma, özellikle sınırlı donanımlara sahip sistemlerde yapay zeka uygulamalarını yaygınlaştırma potansiyeline sahip olup, farklı alanlardaki uygulamalar için bir temel oluşturmaktadır.

KAYNAKÇA

- [1] Canlı, G. A., Kurtoğlu, İ., Canlı, M. O., & Tuna, Ö. S. (2015). DÜNYADA VE ÜLKEMİZDE İNSANSIZ SUALTI ARAÇLARI İSAA-AUV & ROV TASARIM VE UYGULAMALARI. *Gidb Dergi*, (04), 43-75.
- [2] Ozkan, Z., Bayhan, E., Namdar, M., & Basgumus, A. (2021, October). Object detection and recognition of unmanned aerial vehicles using Raspberry Pi platform. In 2021 5th international symposium on multidisciplinary studies and innovative technologies (ISMSIT) (pp. 467-472). IEEE.
- [3] Bozkaya, F., Yusefi, A., Tıglioğlu, Ş., Kaya, A. K., Kazancı, O., Akmaz, M. Y., ... & Sungur, C. (2021). Otonom Sistemlerde Veri Çoğaltma Yöntemleri Kullanılarak İyileştirilmiş Gerçek Zamanlı Nesne Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (30), 83-87.
- [4] Tan, F. G., Yüksel, A. S., Aydemir, E., & Ersoy, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*, (25), 159-171.
- [5] Tian, H., Wang, T., Liu, Y., Qiao, X., & Li, Y. (2020). Computer vision technology in agricultural automation—A review. *Information Processing in Agriculture*, 7(1), 1-19.
- [6] Özcan, R., & Tütüncü, K. (2023). Raspberry Pi ile Gerçek Zamanlı Bitki Algılama Uygulaması.
- [7] Tufail, S., Riggs, H., Tariq, M., & Sarwat, A. I. (2023). Advancements and challenges in machine learning: A comprehensive review of models, libraries, applications, and algorithms. *Electronics*, 12(8), 1789.
- [8] Solak, S., & Altınışik, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya University Journal of Science*, 22(1), 56-65.
- [9] Çetinkaya, T. S., & Sertbaş, A. (2022). Derin Öğrenme Algoritmalarının GPU ve CPU Donanım Mimarileri Üzerinde Uygulanması ve Performans Analizi: Deneysel Araştırma. *Avrupa Bilim ve Teknoloji Dergisi*, (33), 10-19.
- [10] Aktürk, S., & Serbest, K. (2022). Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*, 3(2), 97-119.
- [11] Türkarlan, K., & Hardalac, F. (2022). Derin Öğrenme Yöntemleri Kullanılarak Havadan Elde Edilen Görüntüler Üzerinde Nesne Tespiti. *El-Cezeri*, 9(4), 1398-1410.
- [12] Redmon, J. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition.

- [13] Howard, A. G. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
- [14] Tan, M., Pang, R., & Le, Q. V. (2020). Efficientdet: Scalable and efficient object detection. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 10781-10790).
- [15] Jiang, Z., Chen, Y., Zhang, Y., Ge, Y., Yin, F. F., & Ren, L. (2019). Augmentation of CBCT reconstructed from under-sampled projections using deep learning. IEEE transactions on medical imaging, 38(11), 2705-2715.
- [16] Raspberry Pi. (2023). *Raspberry Pi 5 technical specifications*. Erişim: 23 Aralık 2024, <https://www.raspberrypi.com/products/raspberry-pi-5/>
- [17] Boyacıgil, M. F., & Uzun, Y. (2023). Raspberry PI Tabanlı Görüntü İşleme Uygulaması Geliştirilmesi. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 6(2), 1067-1078.
- [18] Demirbas, A. A., & Çınar, A. (2020). Nesne Sınıflandırma İşlemi İçin Tensor İşleme Birimi ve CPU Performans Karşılaştırması. Bilgisayar Bilimleri ve Teknolojileri Dergisi, 1(1), 10-15.
- [19] Alqahtani, D. K., Cheema, M. A., & Toosi, A. N. (2024, December). Benchmarking deep learning models for object detection on edge computing devices. In International Conference on Service-Oriented Computing (pp. 142-150). Singapore: Springer Nature Singapore.
- [20] Tan, M., Pang, R., & Le, Q. V. (2020). Efficientdet: Scalable and efficient object detection. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 10781-10790).
- [21] Güntürkün R., “İnsansız Savaşlara Doğru Yapay Zeka Kontrollü Ölümcül Silahlar”, Ekin Yayınevi, 2022, s 6, ISBN: 978-625-8235-07-

BÖLÜM-9

ZAMAN SERİSİ VERİLERİ VE UZUN KISA SÜRELİ BELLEK (LSTM) AĞLARI KULLANILARAK İHA'LARDA KULLANILAN FIRÇASIZ MOTOR ARIZALARININ SINIFLANDIRILMASI

Sevdanur BEKLER¹

Burak YILMAZ²

Güzin ÖZMEN³

¹<https://orcid.org/0009-0008-8152-0783>

²<https://orcid.org/0000-0001-5549-8385>

³<https://orcid.org/0000-0003-3007-5807>

ZAMAN SERİSİ VERİLERİ VE UZUN KISA SÜRELİ BELLEK (LSTM) AĞLARI KULLANILARAK İHA'LARDA KULLANILAN FIRÇASIZ MOTOR ARIZALARININ SINIFLANDIRILMASI

1. GİRİŞ

İnsansız hava araçlarının (İHA) [1,2] kullanımı, muayene, haritalama, kurtarma operasyonları ve askeri uygulamalar dahil olmak üzere çok çeşitli uygulamalarda giderek daha yaygın hale geliyor. Bu İHA sistemlerinin kalbinde, uçuş için gerekli itici gücü sağlayan fırçasız DC (BLDC) motorlar yer alır [3,4]. Ancak, İHA'ların karşılaştığı zorlu çalışma koşulları ve yüksek stresli ortamlar, bu BLDC motorlarında çeşitli arızalara yol açabilir ve zamanında tespit edilip ele alınmazlarsa felaketle sonuçlanabilir [4,5].

Bu zorluğun üstesinden gelmek için araştırmacılar, makine öğrenimi ve derin öğrenme algoritmalarının yeteneklerinden yararlanarak gelişmiş arıza tespiti ve sınıflandırma tekniklerinin kullanımını araştırdılar [6,7]. Umut vadeden bir yaklaşım, özellikle zaman serisi verilerini analiz etmek için uygun olan bir tür tekrarlayan sinir ağı (RNN) olan uzun kısa süreli bellek (LSTM) ağlarının kullanılmasıdır [8,9]. LSTM ağları, endüstriyel sistemlerde arıza teşhisi ve öngörücü bakım dahil olmak üzere çeşitli uygulamalarda etkinliklerini kanıtlamıştır [10,11].

İHA BLDC motor arıza tespiti bağlamında, LSTM ağlarının kullanımı çeşitli avantajlar sunar. BLDC motorları tarafından üretilen zaman serisi verilerini analiz ederek, LSTM ağları farklı arıza koşullarıyla ilişkili zamansal kalıpları ve dinamikleri yakalayabilir, bu da arızaların doğru sınıflandırılmasını ve erken tespitini mümkün kılar [12,13]. Bu, uçuş güvenliğini ve görev başarısını sağlamak için arızaların hızlı bir şekilde tanımlanmasının ve azaltılmasının kritik öneme sahip olduğu İHA uygulamalarında özellikle önemlidir.

Birkaç çalışma, İHA'larda BLDC motor arıza sınıflandırması için LSTM ağlarının uygulamasını araştırmıştır. Örneğin, Yu ve diğerleri, [14] açık devre, kısa devre ve yatak arızaları dahil olmak üzere çeşitli BLDC motor arızalarını tespit etmek ve sınıflandırmak için LSTM ağlarını zaman-frekans analiz teknikleriyle birleştiren bir arıza teşhis sistemi önermiştir. Benzer şekilde, Zhu ve diğerleri, [15] bir dizi arıza koşulunu tanımlamak için BLDC motor verilerinin içsel zaman serisi özelliklerini kullanan LSTM tabanlı bir arıza tespiti ve sınıflandırma çerçevesi geliştirmiştir.

Bu çalışmalar, LSTM ağlarının İHA uygulamalarında BLDC motor arızalarını doğru bir şekilde sınıflandırma potansiyelini göstererek, bu kritik sistemlerin güvenilirliğini ve emniyetini artırmak için gelişmiş makine öğrenimi tekniklerinden yararlanmanın önemini vurgulamıştır [16,17]. İHA'ların kullanımı genişlemeye devam ettikçe, LSTM ağlarına dayalı olanlar gibi sağlam ve etkili arıza tespiti ve sınıflandırma yöntemlerinin geliştirilmesi, bu insansız hava platformlarının güvenilir ve emniyetli bir şekilde çalışmasını sağlamak için giderek daha da önemli hale gelecektir [18,19].

İHA sistemleri için mevcut arıza tespit yöntemleri genel olarak iki kategoriye ayrılabilir: model tabanlı ve sinyal tabanlı yaklaşımlar [20]. Model tabanlı teknikler, uçağın ve bileşenlerinin ayrıntılı matematiksel modellerine dayanır; bu modeller geliştirilmesi zor olabilir ve gerçek dünya sistemlerinin tüm karmaşıklıklarını kapsayamayabilir. Öte yandan, makine öğrenimine dayalı olanlar gibi sinyal tabanlı teknikler açık modeller gerektirmez ve bunun yerine arızaları tespit etmek ve teşhis etmek için sensör verilerini kullanır [21].

Bu makalede, zaman serisi verileri ve Uzun Kısa Süreli Bellek ağları kullanılarak İHA'lardaki fırçasız motor arızalarının sınıflandırılması için yeni bir yaklaşım önerilmektedir.

2. MALZEMELER VE YÖNTEMLER

Bu çalışmada, özellikle İHA motor arıza tespiti için tasarlanmış bir veri seti kullanılmıştır. Bu çalışmada kullanılan ve başlangıçta Yaman ve arkadaşları (2022) tarafından geliştirilen veri seti, [22]denge, mıknaş, pervane ve yatak arızaları gibi çeşitli arıza koşulları altında İHA motorlarının ses kayıtlarını içerir. MFCC ve SVM metodolojileri kullanılarak arıza sınıflandırması için yapılandırılmış olan bu veri setinden yararlanarak, uygulamasını İHA sistemlerinde gelişmiş arıza tespiti ve sınıflandırma performansı için derin öğrenme modellerini, özellikle LSTM ağlarını değerlendirmek üzere genişlettik. Veri seti beş arıza türünü içerir: denge, mıknaş, pervane, yatak ve sağlıklı koşullar.

2.1. Veri Kümesi Açıklaması


Çalışmada kullanılan veri kümeleri, motor arızalarını temsil eden sensör verilerinin zaman serilerinden oluşur. Her veri kümesi, denge

arızası, mıknatıs arızası, yatak arızası, pervane arızası ve normal olmak üzere farklı bir motor arıza durumu içerir.

Her veri örneği 1D vektörler olarak düzenlendi. Bu vektörler, zaman serisi verilerini temsil eden ölçümlerin sıralı bir şekilde depolanmasını sağladı. Tüm veri seti %80 eğitim ve %20 test veri setlerine bölündü. Eğitim ve test veri setlerinin sınıf dengesini koruyacak şekilde düzenlenmesine dikkat edildi. Etiketler, sınıfları tanımlamak için kategorik biçimde ifade edildi.

Her veri seti 16 kHz (16.000 Hz) örnekleme frekansıyla kaydedildi. Bu, saniyede 16.000 veri noktasının kaydedildiği anlamına gelir. Her veri örneği 1 saniyelik bir sinyali temsil eder ve bu nedenle her satır 16.000 sayısal değerden oluşur. Her arıza kayıt dosyası 320 zaman serisi verisi içerir.

Şekil 1, bu çalışmada kullanılan motor arıza tiplerini görsel olarak temsil etmektedir. Şekil 1'deki görseller doğrudan Yaman ve ark.'nın (2022) çalışmalarından elde [22] edilmiştir



Şekil 1 İHA motor arıza tipleri (a) Sağlıklı, (b) Denge Arızası, (c) Mıknatıs Arızası, (d) Pervane Arızası, (e) Yatak Arızası. Bu veriler, Uzun Kısa Süreli Bellek (LSTM) Ağları gibi zaman serisi verilerini işleyen derin öğrenme modelleri için giriş verisi olarak kullanılır. LSTM modelleri, ardışık verilerin zaman içinde öğrenilmesine ve hataların doğru sınıflandırılmasına olanak tanır.


2.2. Model Mimarileri

Bu çalışmada dört farklı derin öğrenme modeli değerlendirilmiş olup, her bir modelin mimarisi aşağıda detaylı olarak açıklanmıştır:

2.2.1. LSTM (Uzun Kısa Süreli Bellek) Modeli:

LSTM, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme yeteneği ile öne çıkan bir tür yinelemeli sinir ağı (RNN) türüdür. LSTM, uzun vadeli bağımlılık problemlerine çözüm sağlamak için geliştirilmiştir. LSTM, farklı işlevlere sahip kapılardan oluşur. Örneğin, LSTM'de [23] farklı zaman adımları arasındaki bilgi akışını kontrol etmek için bir unutmaya kapısı bulunur. Giriş kapısı, hücreye gelen girdiden yeni bilginin öğrenilmeye çalışıldığı birimdir ve diğer kapı olan Unutmaya kapısı, önceki zaman damgasından gelen bilginin alakalı mı yoksa unutulabilir mi olduğuna karar verir. Son olarak, çıkış kapısı hücredeki güncellenmiş bilgiyi geçerli zaman damgasından sonraki zaman damgasına iletir [24]. Bu çalışmada kullanılan LSTM modeli aşağıdaki gibi yapılandırılmıştır:


- Katman Sayısı: Üç ardışık LSTM katmanı.
- Gizli Birim Sayısı: Birinci katmanda 256, ikinci katmanda 128, üçüncü katmanda 64.
- Bırakma Mekanizması: Aşırı öğrenmeyi önlemek için her LSTM katmanından sonra %20 bırakma uygulandı.
- Çıktı Modu: Son çıktı modu tercih edildi, böylece yalnızca son LSTM katmanının son çıktısı kullanılacaktır. Şekil 2, LSTM modelini temsil etmektedir



Şekil 2 LSTM modelinin genel gösterimi

2.2.2. BiLSTM (Çift Yönlü LSTM) Modeli

Hem RNN hem de LSTM modelleri bilginin yalnızca zaman içinde ileriye doğru yayılmasına izin verir [25]. Çift yönlü RNN, geçmişten ve gelecekte bağlam bilgilerini aynı anda yakalamak için geliştirilmiştir. Bu aşamadan sonra, Şekil 3 de gösterildiği gibi, BiLSTM modeli, geçmiş ve gelecekteki bilgilerin etkili bir şekilde kullanılmasını sağlamak için çift yönlü RNN ve LSTM birimlerini birleştirerek geliştirilmiştir [26,27]. İleri ve geri katmanlardan gelen girdiler, çıktı katmanı tarafından aynı anda işlenir. Şekil 3, BiLSTM modelini göstermektedir



Şekil 3 BiLSTM modelinin genel gösterimi

Özellikle girdilerin sırasının her iki yönde de anlamlı olması durumunda, bu çift yönlü öğrenme mekanizması etkili sonuçlar sağlamaktadır.

- Katman Sayısı: İki çift yönlü LSTM (BiLSTM) katmanı.
- Gizli Birim Sayısı: Her BiLSTM katmanında 128 birim.
- Terk Mekanizması: %20 terk oranı uygulanmaktadır.

BiLSTM mimarisi , zaman serisi verilerinin ileri ve geri akış yönlerindeki ilişkileri aynı anda öğrenerek model performansını artırmayı amaçlamaktadır.

2.2.3. 1D CNN-LSTM Modeli:

CNN, öncelikle iki boyutlu dizileri işlemek için geliştirilen derin bir öğrenme yaklaşımıdır. İki boyutlu bir görüntüdeki farklı özellikleri tespit etmek için mimariye birden fazla katman eklenebilir [28]. 1D CNN-LSTM modeli, evrişimli sinir ağlarının (CNN) yerel desen öğrenme kapasitesini LSTM'nin sıralı bağımlılık öğrenme yeteneğiyle birleştirir. Bu modelde:

- 1D CNN Katmanları: İlk aşamada, zaman serisinin yerel özelliklerini çıkarmak için 1D evrişimli filtreler uygulanır.

o Filtre Sayısı: 64

o Çekirdek Boyutu: 3

o Aktivasyon Fonksiyonu: ReLU

- LSTM Katmanları: CNN'den çıkarılan özellikler LSTM katmanlarına aktarılır ve ardışık bağımlılıklar öğrenilir.

o LSTM Katman Sayısı: 1

o Gizli Birim Sayısı: 128

Bu hiyerarşik yapı, zaman serisi verilerinin hem yerel hem de küresel desenlerini öğrenmeyi amaçlamaktadır.

2.2.4. Yığılmış LSTM Modeli

Yığılmış LSTM, birden fazla LSTM katmanının ardışık olarak yığılmasıyla oluşturulan bir mimaridir. Daha karmaşık ve derin ardışık ilişkileri öğrenmek için tasarlanmıştır.

- Katman Sayısı: Üç ardışık LSTM katmanı.
- Gizli Birim Sayısı: Birinci katmanda 256, ikinci katmanda 128, üçüncü katmanda 64.
- Dropout Mekanizması: Her katman arasında %20 drop oranı uygulanmaktadır.

Bu yapı LSTM'nin öğrenme kapasitesini arttırmakta ve daha karmaşık ardışık özelliklerin çıkarılmasına olanak sağlamaktadır.

Tüm modeller Adam optimizasyon algoritması ile eğitildi. Eğitim sürecinde kullanılan hiper parametreler şu şekildedir:

- Dönem Sayısı: 50
- Mini Parti Boyutu: 32
- Öğrenme Oranı: 0,001

Modellerin performansı doğruluk, karışıklık matrisi ve eğitim süresi gibi metriklerle değerlendirildi. Sonuçlar her modelin avantajlarını ve sınırlamalarını tartışmak için karşılaştırıldı.

2.3. Model Değerlendirmesi

Eğitilen modeller, dört temel ölçüt kullanılarak test veri kümesinde değerlendirildi: **Doğruluk** , **Hassasiyet** , **Geri Çağırma** ve **F1 Puanı** . Bu ölçütler, model performansını değerlendirmek için makine öğrenimi ve derin öğrenmede yaygın olarak kullanılır ve her biri modelin tahmin yeteneklerinin farklı bir yönünü yakalar.

Doğruluk, doğru sınıflandırılmış örneklerin toplam örnek sayısına oranını temsil eder ve modelin performansının genel bir ölçüsünü sağlar. Ancak, doğruluk tek başına güvenilir bir ölçüt olarak yeterli olmayabilir, özellikle dengesiz sınıf dağılımlarına sahip veri kümelerinde, belirli sınıfların aşırı temsili nedeniyle yüksek doğruluk yanıltıcı olabilir.

Hassasiyet, pozitif olarak tahmin edilen örneklerin gerçekten pozitif olan oranını niceliksel olarak belirler ve bu da yanlış pozitiflerin maliyetinin yüksek olduğu senaryolarda kritik bir ölçüt haline getirir. Örneğin, arıza tespit sistemlerinde, yüksek hassasiyet işaretlenen arızaların gerçekten gerçek olduğundan emin olarak gereksiz müdahaleleri veya alarmları en aza indirir.

geri çağırma , modelin doğru bir şekilde pozitif olarak tanımladığı gerçek pozitif örneklerin oranını ölçer. Bu ölçüm, eksik pozitif örneklerin ciddi sonuçlara yol açabileceği tıbbi teşhis veya güvenlik açısından kritik sistemler gibi uygulamalarda kritik öneme sahiptir.

F1 Puanı, Hassasiyet ve Geri Çağırma'nın harmonik bir ortalaması olarak hizmet eder ve bu iki metriği tek bir performans ölçüsünde dengeler. Hassasiyet ve Geri Çağırma arasında bir denge olduğunda veya bir metriğin diğerinden orantısız şekilde yüksek olduğu durumlarda özellikle yararlıdır. F1 Puanı, modelin yanlış pozitifleri ve yanlış negatifleri dengeleme yeteneğinin kapsamlı bir değerlendirmesini sağlar, özellikle de her iki metriğin de eşit derecede önemli olduğu görevlerde.

Bu ölçümlerin toplu olarak kullanılması, modelin performansının daha ayrıntılı ve kapsamlı bir şekilde değerlendirilmesini sağlar. Accuracy genel bir bakış sunarken, Precision, Recall ve F1 Score belirli güçlü ve zayıf yönler için daha derin içgörüler sunarak uygulama alanının gereksinimlerine göre uyarlanmış sağlam bir performans analizi sağlar.

3. BULGULAR VE TARTIŞMA

Her modelin performans ölçütleri (Doğruluk, Kesinlik, Geri Çağırma ve F1 Puanı) aşağıdaki tabloda özetlenmiştir. Bu ölçütler, modelin test verilerini doğru ve güvenilir bir şekilde sınıflandırma yeteneğinin kapsamlı bir değerlendirmesini sağlar. Tablo 1, her modelin değerlendirme puanlarını temsil eder.

Örnek	Kesinlik	Kesinlik	Hatırlamak	F1 Puanı
BiLST	84.44%	84.60%	83.04%	82,99%
CNN-LSTM	88,74%	89.15%	87,79%	87.51%
LSTM	87,74%	87.81%	86.53%	%86,29
Yığılmış-LSTM	89.40%	%88,36	88.16%	%88,13

Tablo 1 Her modelin değerlendirme puanları

3.1. BiLSTM Model Performansı

BiLSTM modeli %84,44'lük bir doğruluk gösterdi ve bu da onu tüm metrikler arasında en düşük performans gösteren model yaptı. Kesinlik ve geri çağırma değerleri, modelin verileri doğru bir şekilde tanımlama ve sınıflandırma konusunda sınırlı bir yeteneğe sahip olduğunu ve nispeten yüksek oranda yanlış pozitif ve yanlış negatif olduğunu gösteriyor. Bu, BiLSTM'nin verilerdeki bazı ardışık ilişkileri yakalamasına rağmen , genel karmaşıklığının bu görev için yetersiz olabileceğini gösteriyor.

3.2. CNN-LSTM Model Performansı

CNN-LSTM modeli tüm modeller arasında %88,74 doğruluk ve

%89,15'lik en yüksek kesinlik elde etti. Yüksek kesinlik değeri, modelin yanlış pozitifleri en aza indirme yeteneğini vurgular. Ancak, %87,79'luk geri çağırma değeri, tüm gerçek pozitif vakaları belirlemede hafif bir ödün verildiğini gösterir. %87,51'lik F1 Puanı, dengeli bir performansı yansıtır ve CNN-LSTM modelini, kesinliğin geri çağırma göre önceliklendirildiği senaryolar için uygun hale getirir.

3.3. LSTM Model Performansı

LSTM modeli %87,74 doğruluk, %87,81 kesinlik ve %86,53 geri çağırma ile tutarlı ve dengeli metrikler sergiledi. Bu sonuçlar, LSTM'nin zamansal bağımlılıkları etkili bir şekilde yakalamasına rağmen genel performans açısından CNN-LSTM veya Stacked-LSTM modellerinden daha iyi performans göstermediğini göstermektedir. Bunun nedeni mimarinin sınırlı derinliği veya özellik çıkarma mekanizmalarının eksikliği olabilir.

3.4. Yığılmış-LSTM Model Performansı

Stacked-LSTM modeli %89,40 doğruluk, %88,16 geri çağırma ve %88,13 F1 Puanı ile en iyi performans gösteren mimari olarak ortaya çıktı. Bu modelin daha derin sıralı ilişkilerden öğrenme yeteneği muhtemelen üstün performansına katkıda bulunmuştur. Yüksek geri çağırma değeri, bu modelin tüm gerçek pozitif vakaları belirlemede özellikle etkili olduğunu ve gerçek pozitifleri kaçırmanın kritik olduğu uygulamalar için uygun olduğunu göstermektedir.

3.5. İstatistiksel Analiz ve Gözlemler

Modeller arasındaki performans ölçümlerindeki farklılıkların istatistiksel olarak anlamlı olup olmadığını belirlemek için istatistiksel t-testi gerçekleştirildi. Sonuçlar, Stacked- LSTM(3) modelinin performans iyileştirmelerinin BiLSTM , CNN-LSTM ve LSTM modelleriyle karşılaştırıldığında istatistiksel olarak anlamlı ($p < 0,05$) olduğunu doğrulamaktadır . Ancak, Stacked-LSTM arasındaki farklar anlamlı değildir ($p > 0,05$), bu da artan karmaşıklıkla azalan getirileri göstermektedir.

Sonuçlar, Stacked-LSTM modelinin tüm performans ölçütlerinde diğer mimarilerden sürekli olarak daha iyi performans gösterdiğini göstermektedir. Üstün doğruluğu (%89,40), geri çağırması (%88,16) ve F1 puanı (%88,13), doğru tahminleri dengeleme ve yanlış sınıflandırmaları en aza indirme konusundaki sağlam yeteneğini vurgulamaktadır. Özellikle yüksek geri çağırma değeri, gerçek

pozitifleri belirlemedeki etkinliğini vurgulayarak, onu birden fazla sınıfın güvenilir bir şekilde tespit edilmesini gerektiren uygulamalar için mükemmel bir seçim haline getirir.

CNN-LSTM modeli en yüksek hassasiyeti (89,15%) göstererek yanlış pozitifleri en aza indirmedeki gücünü kanıtladı. Bu özellik, yanlış pozitifin maliyetinin yüksek olduğu uygulamalarda özellikle faydalıdır. Ancak, biraz daha düşük geri çağırması (87,79%), bazen bazı gerçek pozitifleri tespit edemediğini ve bunun da son derece hassas görevlerde uygulamasını sınırlayabileceğini göstermektedir.

Öte yandan, BiLSTM modeli tüm metriklerde %84,44 doğruluk ve %82,99 F1 puanı ile sürekli olarak düşük performans gösterdi. Bu sonuçlar, bu modelin hiperparametreleri ayarlama, model karmaşıklığını artırma veya eğitim verilerini artırma gibi ek ayarlama veya optimizasyon gerektirebileceğini göstermektedir.

LSTM(5) modellerinin ara performansı, dengeli performans potansiyellerini yansıtır. Ancak, bu mimarilerin hiçbiri genel etkinlikte Stacked- LSTM(3)'ü geçemez. İlginç bir şekilde, Stacked - LSTM(5) hassasiyet ve geri çağırma arasında bir denge sergileyerek, bir metriği diğerine göre önceliklendiren belirli kullanım durumları için uygun hale getirir.

4. SONUÇ

Bu çalışmanın bulguları, sınıflandırma görevleri için çeşitli derin öğrenme modellerinin performansına ilişkin değerli içgörüler sağlar. Stacked-LSTM, genel amaçlı sınıflandırma sorunları için önerilen seçenek haline gelerek en güvenilir ve kapsamlı mimari olarak ortaya çıkmaktadır. Daha yüksek hassasiyet gerektiren görevler için CNN-LSTM modeli uygulanabilir bir alternatif olarak düşünülebilir. Tersine, BiLSTM modelini diğer mimarilerle rekabet edebilecek hale getirmek için daha fazla çalışma gerekmektedir .

Gelecekteki çalışmalar, model performansını artırmak için aşağıdaki yönleri araştırabilir:

Veri Arttırma: Eğitim veri setinin çeşitliliğini artırmak, model genelleştirmesini iyileştirmeye yardımcı olabilir.

Hiperparametre Optimizasyonu: Daha iyi sonuçlar elde etmek için model parametrelerini ince ayarlamak amacıyla ızgara araması veya

Bayes optimizasyonu gibi teknikler kullanılabilir.

Topluluk Yöntemleri: Birden fazla modeli birleştirerek her birinin güçlü yanlarını kullanmak genel performansın iyileştirilmesiyle sonuçlanabilir.

Alana Özgü Özellik Mühendisliği: Alan bilgisini modelin giriş özelliklerine dahil etmek, sınıflandırma doğruluğunu ve sağlamlığını artırabilir.

Bu çalışma, gerçek dünya uygulamalarında benzer sınıflandırma görevleri için derin öğrenme mimarilerini seçmek ve optimize etmek için bir temel oluşturur. Sonuçlar, model seçiminin amaçlanan uygulamanın belirli performans gereksinimleriyle uyumlu hale getirilmesinin önemini vurgular ve hem güvenilirliği hem de verimliliği garanti eder.

KAYNAKÇA

- [1] M. Biczyski, R. Sehab, J.F. Whidborne, G. Krebs, P.C.K. Luk, Fault-Tolerant Switched Reluctance Motor Propulsion System for eVTOLs, *J Phys Conf Ser* 2526 (2023) 012065. <https://doi.org/10.1088/1742-6596/2526/1/012065>.
- [2] X. Wang, W. Fan, X. Li, L. Wang, Weak Degradation Characteristics Analysis of UAV Motors Based on Laplacian Eigenmaps and Variational Mode Decomposition, *Sensors* 19 (2019) 524. <https://doi.org/10.3390/s19030524>.
- [3] F.C. Veras, T.L. V Lima, J.S. Souza, J.G. Ramos, A.C.L. Filho, A. V Brito, Eccentricity Failure Detection of Brushless DC Motors From Sound Signals Based on Density of Maxima, *Ieee Access* 7 (2019) 150318–150326. <https://doi.org/10.1109/access.2019.2946502>.
- [4] S. Zhang, Wind Turbine Predictive Fault Diagnostics Based on a Novel Long Short-Term Memory Model, *Algorithms* 16 (2023) 546. <https://doi.org/10.3390/a16120546>.
- [5] R.L. V Medeiros, J.G. Ramos, T.P. Nascimento, A.C.L. Filho, A. V Brito, A Novel Approach for Brushless DC Motors Characterization in Drones Based on Chaos, *Drones* 2 (2018) 14. <https://doi.org/10.3390/drones2020014>.
- [6] M. Baker, A.Y. Fard, H. Althuwaini, M.B. Shadmand, Real-Time AI-Based Anomaly Detection and Classification in Power Electronics Dominated Grids, *Ieee Journal of Emerging and Selected Topics in Industrial Electronics* 4 (2023) 549–559. <https://doi.org/10.1109/jestie.2022.3227005>.
- [7] V. Mach, S. Kovar, J. Valouch, M. Adamek, Brushless DC Motor Control on Arduino Platform, *Przegląd Elektrotechniczny* 1 (2018) 107–109. <https://doi.org/10.15199/48.2018.11.24>.
- [8] D.M. N, N.C. K, G.S. L, Modeling a Fault Detection Predictor in Compressor Using Machine Learning Approach Based on Acoustic Sensor Data, *International Journal of Advanced Computer Science and Applications* 12 (2021). <https://doi.org/10.14569/ijacsa.2021.0120973>.
- [9] Q. Du, Fault Diagnosis of Brushless DC Motor Based on Stack Sparse Autoencoder, *J Phys Conf Ser* 2674 (2023) 012033. <https://doi.org/10.1088/1742-6596/2674/1/012033>.
- [10] J.I. Chen, H. Lin, Performance Evaluation of a Quadcopter by an Optimized Proportional–Integral–Derivative Controller, *Applied Sciences* 13 (2023) 8663. <https://doi.org/10.3390/app13158663>.
- [11] J. Blesa, J. Quevedo, V. Puig, F. Nejjari, R. Zaragoza, A. Rolán, Fault Diagnosis and Prognosis of a Brushless DC Motor Using a Model-Based Approach, *PHM Society European Conference* 5 (2020) 9. <https://doi.org/10.36001/phme.2020.v5i1.1257>.
- [12] M. Weigert, Approach to Condition Monitoring of BLDC Motors With Experimentally Validated Simulation Data, *PHM Society European Conference* 7 (2022) 521–529. <https://doi.org/10.36001/phme.2022.v7i1.3357>.

- [13] M. Li, G. Jia, S. Gong, R. Guo, Energy Consumption Model of BLDC Quadrotor UAVs for Mobile Communication Trajectory Planning, (2022). <https://doi.org/10.36227/techrxiv.19181228>.
- [14] Z. Yu, Y. Zhang, B. Jiang, PID-type Fault-Tolerant Prescribed Performance Control of Fixed-Wing UAV, *Journal of Systems Engineering and Electronics* 32 (2021) 1053–1061. <https://doi.org/10.23919/jsee.2021.000090>.
- [15] C. Zhu, R. Lu, C. Mei, T. Peng, G. Zhang, Design and Simulation Analysis of Stator Slots for Small Power Permanent Magnet Brushless DC Motors, *International Transactions on Electrical Energy Systems* 2023 (2023) 1–19. <https://doi.org/10.1155/2023/1152243>.
- [16] K. Polat, The Fault Diagnosis Based on Deep Long Short-Term Memory Model From the Vibration Signals in the Computer Numerical Control Machines, *Journal of the Institute of Electronics and Computer* 2 (2020) 72–92. <https://doi.org/10.33969/jiec.2020.21006>.
- [17] Q. Huang, X. Zhang, X. Likun, L. Ling, R. Ma, Fault Tolerant Control for Open Winding Brushless DC Motor With Power Device Failure, (2023). <https://doi.org/10.22541/au.167663173.36826317/v1>.
- [18] C. Morel, Currents Analysis of a Brushless Motor With Inverter Faults—Part II: Diagnostic Method for Open-Circuit Fault Isolation, *Actuators* 12 (2023) 230. <https://doi.org/10.3390/act12060230>.
- [19] D. Cioboata, M.G. Neacsu, D. Stanciu, S. Matei, I. Neacsu, Modelling and Simulation of a Brushless Motor DC for Electric Power Steering Assistance, *Electrotehnica Electronica Automatica* 68 (2020) 22–31. <https://doi.org/10.46904/eea.20.68.3.1108003>.
- [20] Y.H. Gao, D. Zhao, Y.B. Li, UAV Sensor Fault Diagnosis Technology: A Survey, *Applied Mechanics and Materials* 220–223 (2012) 1833–1837. <https://doi.org/10.4028/www.scientific.net/AMM.220-223.1833>.
- [21] M. Mousaei, A. Keipour, J. Geng, S. Scherer, VTOL Failure Detection and Recovery by Utilizing Redundancy, n.d.
- [22] O. Yaman, F. Yol, A. Altınors, A Fault Detection Method Based on Embedded Feature Extraction and SVM Classification for UAV Motors, *Microprocess Microsyst* 94 (2022). <https://doi.org/10.1016/j.micpro.2022.104683>.
- [23] P. Bahad, P. Saxena, R. Kamal, Fake news detection using bi-directional LSTM-recurrent neural network, *Procedia Comput Sci* 165 (2019) 74–82.
- [24] S. Patil, V.M. Mudaliar, P. Kamat, S. Gite, LSTM based Ensemble Network to enhance the learning of longterm dependencies in chatbot, *International Journal for Simulation and Multidisciplinary Design Optimization* 11 (2020).
- [25] S. Zhang, D. Zheng, X. Hu, M. Yang, Bidirectional long short-term memory networks for relation classification, in: *Proceedings of the 29th Pacific Asia Conference on Language, Information and Computation*, 2015: pp. 73–78.
- [26] E. Ekinçi, S. İlhan Omurca, B. Özbay, Comparative assessment of modeling deep learning networks for modeling ground-level ozone concentrations of pandemic lock-down period, *Ecol Modell* 457 (2021) 109676.

- [27] A. Graves, J. Schmidhuber, Framewise phoneme classification with bidirectional LSTM and other neural network architectures, *Neural Networks* 18 (2005) 602–610.
- [28] M. Tosun, F. Şentürk, Kasislerin Yakıt Tüketimine Etkisinin RNN, LSTM, GRU Tekrarlayan Derin Öğrenme Algoritmaları ile Tespiti, *Journal of Intelligent Systems: Theory and Applications* 6 (2023) 12–23. <https://doi.org/10.38016/jista.1141359>.
- [29] Mirjafarli S., Terzioğlu H., Yalçın G., Sağdıç E.S., “Bölüm 5 3kw 48v Hub Motor Tasarım Ve Analizi”, *Mühendislikte Yeni Araştırmalar*, (2022)., *Tablet Kitapevi*, Editör: Öğr. Gör. Gökhan Yalçın, Öğr. Gör. Abdullah Cem AĞAÇAYAK, Basım sayısı:1, Sayfa Sayısı 243, ISBN:978-605-5447-75-5, Türkçe(Bilimsel Kitap) (Yayın No: 8193117)
- [30] Mirjafarli S., Terzioğlu H., Yalçın G., “Bölüm 4: 2kw 72v Dış Rotorlu Hub Motor Tasarımı “, *Mühendislik Alanında Akademik Çalışmalar-1*, (2021)., *İksad*, Editör:Hakan Terzioğlu, Gökhan Yalçın, Basım sayısı:1, Sayfa Sayısı 204, ISBN:978-625-8423-15-0, Türkçe(Bilimsel Kitap) (Yayın No: 7432631)

BÖLÜM-10

ÜNİVERSİTE ÖĞRENCİLERİNE VE AKADEMİSYENLERE ÜNİVERSİTE ETKİNLİKLERİNİ BİLDİREN MOBİL UYGULAMA (UBİ)

Ayşe Nur YÜZÜGÜLLÜ¹

Fatma Betül TERZİOĞLU²

Beyza MUTLU³

Mehmet Fikret MİRALOĞLU⁴

Sema SERVİ⁵

¹<https://orcid.org/0009-0002-7399-2138>

²<https://orcid.org/0000-0002-7528-3290>

³<https://orcid.org/0009-0001-8394-1492>

⁴<https://orcid.org/0009-0005-9960-0149>

⁵<https://orcid.org/0000-0003-2069-9085>

ÜNİVERSİTE ÖĞRENCİLERİNE VE AKADEMİSYENLERE ÜNİVERSİTE ETKİNLİKLERİNİ BİLDİREN MOBİL UYGULAMA (UBİ)

1. GİRİŞ

UBİ mobil uygulaması üniversitelerde ve kurumlarda düzenlenen akademik ve bilimsel etkinlik duyurularının öğrenci ve akademisyenlere ulaşmaması gibi eksiklikleri gidermeyi amaçlamaktadır. Projenin hedef kitlesi, üniversite öğrencileri, akademik personel ve bilimsel anlamda kendini geliştirmek isteyen bireylerdir. Uygulama ile kullanıcılara ilgi alanlarına uygun etkinlik bildirimleri sunmak böylece onların kişisel ve mesleki gelişimlerine katkıda bulunması hedeflenmiştir.

Projenin amacı, kullanıcıların akademik ve bilimsel etkinliklerden en kolay ve hızlı şekilde haberdar olmalarını sağlamak, bu etkinliklere katılımlarını teşvik etmek ve sosyal çevrelerinin genişlemesine katkıda bulunmaktır. Ayrıca katılımcıların alanlarında uzman kişilerle tanışmalarını sağlamakta ve etkinliklerden kazandıkları sertifikalar profesyonel hayatlarına olumlu etki etmektedir.

Literatür çalışmaları incelendiğinde, mevcut uygulamaların genellikle konser, tiyatro gibi genel etkinlikler sunduğu, ancak akademik ve bilimsel etkinlikler için özel bir uygulamanın bulunmadığı görülmüştür. Bu eksikliği gidermek için “UBİ” uygulaması ortaya çıkmıştır. Uygulama, kullanıcılara etkinlik bildirimlerini sunmanın yanı sıra, kişisel ilgi alanlarına yönelik tavsiye algoritmaları kullanarak deneyimlerini özelleştirecektir. Uygulamanın özgünlüğü, kullanıcılara özel öneriler sunması ve bu alanda mevcut bir boşluğu dolduracak olmasıdır.

2. MATERYALLER VE YÖNTEMLER

Bu bölümde kullanıcıların akademik ve bilimsel etkinliklerden en kolay ve hızlı şekilde haberdar olmalarını sağlamayı amaçlayan "UBİ Mobil Uygulaması" projesinin geliştirilme süreci detaylandırılmıştır. UBI isimli mobil uygulamamız için kullandığımız arayüz tasarımı, yazılımı için tercih edilen dart dili ve flutter framework'ü, firebase veri tabanı ve web scraping işlemleri anlatılmıştır. [1].

2.1. Arayüz Tasarımı

UBI uygulamasının kullanıcı arayüzü (UI), kullanıcı etkileşimini ve gezinme kolaylığını optimize etmek için tasarlanmıştır. Popüler bir UI/UX tasarım aracı olan Figma kullanılan tasarım süreci, temel düzeni ve kullanıcı akışını ana hatlarıyla belirlemek için wireframe çizimleriyle başlanmıştır [2].

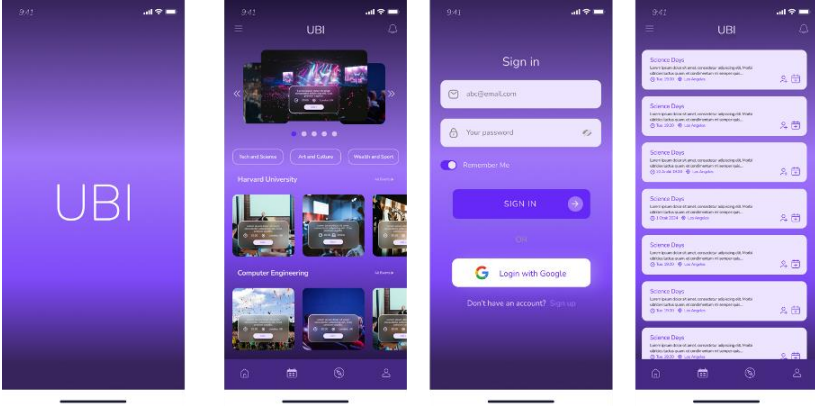
Başarılı bir tasarım süreci, yalnızca estetik değil, aynı zamanda kullanım kolaylığını da ön planda tutarak kullanıcı etkileşimini optimize eder. Bu yaklaşım, kavramsal fikirlerin prototiplere dönüştürülmesinde önemli bir yol haritası sunar. Arayüz tasarımları Şekil 1’de verilmiştir.



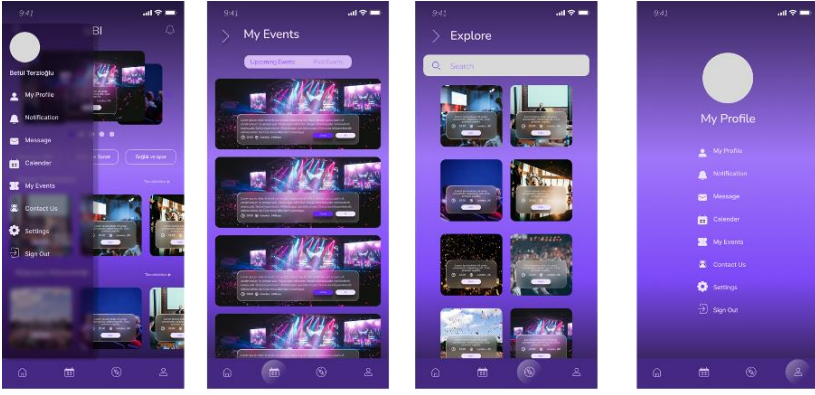
(a)



(b)



(C)



(d)

Şekil 1. (a), (b) UBİ Mockup ; (c), (d) UBİ Sayfaları.

2.2. Frontend Geliştirme

Flutter, tek bir kod tabanıyla hem iOS hem de Android platformları için kullanıcı arayüzlerinin hızlı bir şekilde geliştirilmesini sağlar. Zengin widget kütüphanesi ve güçlü performansı ile geliştirme sürecini kolaylaştırır. Ayrıca, geniş topluluğu ve destekleyici ekosistemi, geliştiricilere ihtiyaç duydukları kaynaklara kolayca erişme imkanı sunar. Bu özellikleriyle, Flutter mobil uygulama geliştirme için tercih ettiğimiz mobile framework oldu.

Ana sayfa tasarımında, kullanıcılar uygulama hizmetlerine, gerçekleştirilen ve planlanan etkinliklere kolaylıkla ulaşabilmektedirler. Sayfanın alt kısmında yer alan "Takvim" butonu sayesinde, yaklaşan etkinlikleri ve geçmiş etkinliklere göz atabilmektedir. "Keşfet" butonu, kullanıcıların diğer etkinliklere

ulaşmalarını, etkinlik adı girerek merak ettikleri etkinliklere doğrudan erişim sağlamalarını mümkün kılarken; "Profil" butonu ise kullanıcıların kendi profillerine erişip diğer özelliklere ulaşmalarını sağlamaktadır. Ayrıca, ana sayfada yer alan kategori butonları sayesinde, kullanıcılar ilgi duydukları kategorilerin etkinliklerine pratik bir şekilde erişmektedirler. [3].

2.3. Backend Geliştirme

Backend; Firebase, Firestore ve Python gibi teknolojiler kullanılarak geliştirilmiştir.

Firebase, Google tarafından geliştirilen ve bulut tabanlı çözümler sunan bir platformdur. Güvenli veri depolama, kimlik doğrulama, gerçek zamanlı veri işleme, bildirim gönderme gibi bir dizi özellik sunarak, geliştiricilerin mobil ve web uygulamaları geliştirme süreçlerini daha hızlı ve verimli hale getirmektedir. Firebase, aynı zamanda kullanıcıların ihtiyaç duyduğu analitik, veri depolama, barındırma ve diğer hizmetleri tek bir platformda toplayarak uygulama geliştirme süreçlerini kolaylaştırmakta ve hızlandırmaktadır. Proje bağlamında, Firebase arka uç altyapısında kritik bir rol üstlenmektedir. Firebase, mobil ve web geliştiricilerine bulut tabanlı veri yönetimi sunarak, veritabanlarının güvenli, hızlı ve etkin bir şekilde kullanılmasına olanak tanımaktadır. Firestore ve Firebase Authentication kullanılarak, kullanıcı verilerinin güvenli bir biçimde saklanması ve kimlik doğrulama işlemlerinin başarıyla gerçekleştirilmesi sağlanmıştır. [4].

Firebase'in gerçek zamanlı veri işleme özelliği, kullanıcılara anlık bildirimler gönderilmesini sağlayarak katılım sürecini hızlandırmıştır. Veri kazıma işlemi BeautifulSoup kütüphanesi ile gerçekleştirilmiştir. BeautifulSoup, Python programlama dilinde geliştirilmiş bir kütüphanedir ve HTML ile XML verilerini ayrıştırmak, analiz etmek ve işlemek için kullanılmaktadır.

Projede farklı web sitelerinden toplanan olay verileri BeautifulSoup ile işlenerek Firebase veritabanına aktarılmıştır. Bu sayede kullanıcılar geniş bir etkinlik ağına kolayca erişebiliyor ve ilgili etkinlikler hakkında anlık bilgi sahibi olabilmektedir. Teknik açıdan bakıldığında MVVM (Model- View-View-Model) mimarisi uygulamanın iş mantığı ve arayüz katmanlarını birbirinden ayırarak uygulamanın sürdürülebilirliğini ve genişletilebilirliğini arttırmaktadır [5]. MVVM, kullanıcı arayüzünü (View), iş mantığını (ViewModel) ve veri ile ilgili işlemleri (Model) bağımsız bir şekilde yönetmektedir. Model, veri işleme ve veritabanı erişimi gibi işlevleri içerirken, View yalnızca verilerin görüntülenmesi ve kullanıcı etkileşimlerine tepki verilmesiyle ilgilenmektedir. ViewModel, Model ve View arasındaki

köprü işlevini göyerek, verileri uygun bir formatta sunar ve kullanıcı etkileşimlerini modele iletilmiştir. Bu ayırım sayesinde uygulamanın kod yapısı daha düzenli ve sürdürülebilir hale gelmiş, bakım ve genişletme süreçleri de kolaylaştırılmıştır. Firebase tarafından sunulan bulut tabanlı çözümler sayesinde veri güvenliği sağlanmış ve sistemin ölçeklenebilirliği temin edilmiştir. Proje kapsamında geliştirilen öneri sistemi, kullanıcılar için kişiselleştirilmiş etkinlik önerileri sunmak amacıyla Firebase'e entegre edilmiştir. Bu öneri sistemi, kullanıcıların statik ve dinamik profillerini kullanarak ilgi alanlarına uygun etkinlikler önermekte ve her birey için özel bir deneyim sağlamaktadır.

2.4. Web Kazıma Teknikleri

Proje kapsamında, üniversite web sitelerinden etkinlik verilerini toplamak için web kazıma yöntemi kullanılmıştır. Bu işlem, üniversitelerin çeşitli fakülte ve öğrenci toplulukları tarafından düzenlenen seminer, konferans ve diğer etkinlikler hakkında tarih, konu, yer ve düzenleyen gibi önemli bilgilere erişim sağlamıştır.

Python programlama dili ile BeautifulSoup ve Selenium kütüphaneleri kullanılmıştır. BeautifulSoup statik sayfalardaki HTML öğelerini ayrıştırmak için tercih edilmiştir [6]. Dinamik sayfalarda veri ve kullanıcı etkileşimlerinin gerekli olduğu durumlarda Selenium kullanılmıştır.

Etkinlik verileri BeautifulSoup kullanılarak statik sayfalardan çıkarılmıştır. Özellikle, etkinlik listeleri ve duyuruları içeren HTML öğeleri belirlendi ve başlık, tarih ve konum gibi veriler bu öğeler içinde ayrıştırılmıştır.

Selenium, dinamik sayfalarda gezinmek ve veri çıkarmak için kullanılmıştır. Örneğin, bazı üniversitelerin etkinlik sayfalarında sadece birkaç etkinlik görüntülenmiş ve “daha fazlasını göster” gibi butonlara tıklanarak daha fazla veriye ulaşılmıştır. [7].

Web kazıma sırasında elde edilen veriler ham halde çıkarıldığı için veri temizleme işlemleri gerçekleştirilmiştir. Boş veya eksik veriler ayıklanmıştır. Veriler başlık, tarih, yer, düzenleyen birim ve detaylı açıklama gibi sütunlarda düzenlenerek tabloya aktarılmıştır. Toplanan faaliyet verileri üzerinde analizler yapılarak faaliyet sıklığı, düzenleyen fakülteler, faaliyet türleri gibi kategoriler altında raporlamalar yapılmıştır. Uygulamada kullanılacak hale getirilmiştir.

3. SONUÇLAR

Sonuç olarak, geliştirilen UBİ mobil uygulaması, üniversiteler ve kurumlar tarafından düzenlenen akademik ve bilimsel etkinliklerin

duyurularını, kullanıcıların ilgi alanlarına göre özelleştirerek onlara ulaştırmayı başarmıştır. Uygulama, kullanıcıların bu tür etkinliklerden haberdar olmasını ve etkinliklere katılımını artırarak, onların kişisel ve mesleki gelişimlerine önemli bir katkı sağlamıştır. Ayrıca, uygulamanın tavsiye algoritması sayesinde her kullanıcının ilgi alanlarına özel öneriler alması, kullanıcı deneyimini üst seviyeye çıkarmıştır. Bu proje, mevcut literatürde yer almayan bir ihtiyacı karşılayarak akademik-bilimsel etkinliklerin daha geniş kitlelere duyurulmasını ve bu alandaki boşluğun doldurulmasını sağlamıştır.

KAYNAKÇA

- [1] Bektaş, O. (2024). Mimari mirasın sunumunda artırılmış ve sanal gerçeklik teknolojileri:“Keşif Bursa” mobil yazılım örneği ve geliştirme süreci.
- [2] Camci, S. (2020). Mobil Uygulamalarda Kullanıcı Deneyimi ve Arayüz Tasarımı: E-Ticaret Uygulaması (Master's thesis, Güzel Sanatlar Enstitüsü).
- [3] Yurdaöz, E., & Ustun, A. B. (2023). Öğrencilerin Öğrenme Stillerini Ölçmeye Yönelik Mobil Uygulama Geliştirme. Bartın Üniversitesi Eğitim Araştırmaları Dergisi, 7(2), 160-175.
- [4] Firebase. Firebase. Google. Accessed December 24, 2024. <https://firebase.google.com>.
- [5] Anderson, C. (2012). The model-view-viewmodel (mvvm) design pattern. In Pro Business Applications with Silverlight 5 (pp. 461-499). Berkeley, CA: Apress.
- [6] Real Python. "Beautiful Soup: Build a Web Scraper With Python." Accessed December 24, 2024. <https://realpython.com/beautiful-soup-web-scraper-python/>.
- [7] Selenium. "Selenium Documentation." Accessed December 24, 2024. <https://www.selenium.dev/documentation/>.

BÖLÜM-11

ENDÜSTRİYEL MAKİNELERDE ARIZA TESPİTİ İÇİN KSA İLE AKUSTİK SİNYAL ANALİZİ

*Mustafa YURDAKUL¹
Şakir TAŞDEMİR²*

¹<https://orcid.org/0000-0003-0562-4931>

²<https://orcid.org/0000-0002-2433-246X>

ENDÜSTRİYEL MAKİNELERDE ARIZA TESPİTİ İÇİN KSA İLE AKUSTİK SİNYAL ANALİZİ

1. Giriş

Endüstriyel teknolojiadaki son gelişmeler, fabrikaların daha verimli ve akıllı hale gelmesini sağlayarak onları günün 24 saati sürekli çalışan sistemlere dönüştürmüştür [1-3]. Ancak, sürekli çalışma makinelerde mekanik arızalara yol açabilir, mali kayıplara neden olabilir ve hatta insan güvenliğini tehlikeye atabilir [3, 4]. DL, son yıllarda ortaya çıkan en etkili makine öğrenme tekniklerinden biridir. DL, ses ve video gibi çeşitli veri türlerini analiz etmek için kullanılan bir dizi algoritmadır. Endüstriyel ortamlarda, üretim sırasında makinelerden gelen akustik verilerin analizi, arızaların erken tespitini kolaylaştırabilir. DL, sesleri analiz ederek arızaların erken tespitini kolaylaştırabilir, maliyetleri azaltabilir, güvenliği artırabilir ve manuel makine izleme gerekliliğini ortadan kaldırabilir. Temelde bu, insan iş yükünün azalmasına ve iş verimliliğinin artmasına neden olur. Fabrikalar için daha doğru veriler sağlar ve operasyonel performansı ve verimliliği artırabilir. MIMII [9], bir fabrikadaki arızalı makinelerin seslerini karakterize etmek için oluşturulmuş bir veri kümesidir ve ses tabanlı makine arıza tespiti için bir standart olarak kullanılabilir. Bu makalede, bir fabrikadaki makinelerin tipik ve atipik çalışma durumlarını belirlemek için MIMII veri kümesi kullanılarak DL tabanlı bir yöntem sunulmuştur. Bu çalışmanın ana katkıları aşağıdaki gibi özetlenebilir;

- Bir fabrika ortamındaki makinelerden gelen ses verilerini normal ve anormal kategorilere ayırmak için bir yöntem önerilmiştir. İlk olarak, ses verilerinden mel spektrogramları oluşturulmuş ve oluşturulan spektrogramlara dayalı bir görüntü veri kümesi oluşturulmuştur.

- Mel spektrogram görüntülerini normal ve anormal kategorilere sınıflandırmak için DenseNet169 modeli kullanılmıştır.

- Sınıflandırma performansı farklı ses/gürültü oranlarında karşılaştırılmıştır.

Bu yöntem, ses verilerini kullanarak fabrika makinelerindeki anormal durumları tespit etmek için umut verici bir yaklaşımdır. Bu yöntem, üretkenliğin artması, bakım maliyetlerinin azalması ve daha hassas ve güvenli bir çalışma ortamının oluşturulması gibi önemli faydalar sağlama kapasitesine sahiptir.

Makalenin geri kalanı aşağıdaki şekilde düzenlenmiştir: Bölüm 2'de literatürdeki mevcut çalışmalar gözden geçirilmiştir. Bölüm 3'te, veri kümesi ve önerilen sınıflandırma sistemi de dahil olmak üzere kullanılan yöntemler açıklanmaktadır. Bölüm 4'te çalışmanın sonuçları sunulmakta ve analiz

edilmektedir. Son olarak, Bölüm 5'te makale sonuçlandırılmakta ve gelecekteki araştırmalar için önerilerde bulunulmaktadır.

1.1. Literatür çalışmaları

Son yıllarda, makine arıza teşhisi için akustik sinyallerin kullanımına büyük ilgi gösterilmektedir. Bu sinyaller makinelerin durumu hakkında değerli bilgiler sağlar ve hem geleneksel sinyal işleme yöntemleri hem de derin öğrenme yaklaşımları ile analiz edilmiştir. Henze ve arkadaşları [10] AudioForesight adlı bir sistemle endüstriyel makine arızalarının ses tabanlı tespiti için bir yöntem geliştirmiştir. Becker ve arkadaşları [11], akustik sinyalleri kullanarak bir FDM yazıcısındaki arızaları tespit etmek için Mel-frekans kesir katsayıları (MFCC) çıkarımı ile bir Uzun Kısa Süreli Bellek (LSTM) modelini eğitmiştir. Duman ve diğerleri [12] endüstriyel süreçlerdeki anormallikleri tespit etmek için Evrimsel Otomatik Kodlayıcı (KOD) tabanlı bir sistem önermiş ve KOD'un OCSVM'den daha iyi performans gösterdiğini ortaya koymuştur. Koizumi ve diğerleri [13] SPIDERnet adında bir derin sinir ağı önermiş ve geleneksel yöntemlere kıyasla daha iyi sonuçlar elde etmiştir. Gantert ve diğerleri [14] SVM ve MLP yöntemlerini karşılaştırmış ve MLP'nin hata tespitinde daha başarılı olduğunu bildirmiştir. Tama ve diğerleri [15] birleştirilmiş CNN modelleri kullanarak ses sinyallerine dayalı vana ve pompa arızalarını teşhis etmiştir. Lyu ve diğerleri [16] yüksek gürültülü ortamlarda rulman arızalarını tespit etmek için artık yapı birimleri, yumuşak eşikleme ve küresel bağlam mekanizmalarını kullanan RSG modelini önermiş ve %98 doğruluk elde etmiştir. Bu çalışmalar, akustik sinyallerin arıza tespitindeki potansiyelini açıkça göstermektedir.

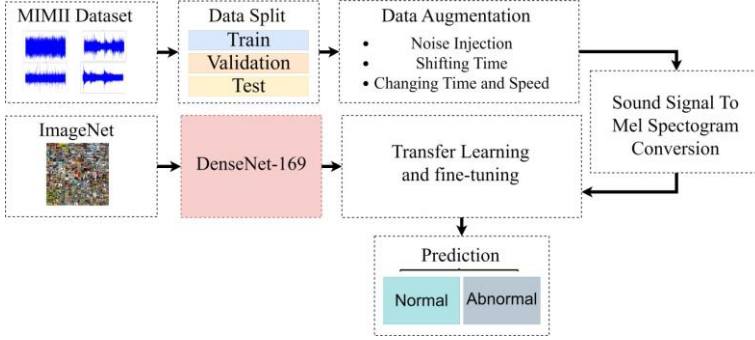
2. MATERYAL VE YÖNTEM

Makineler çalışırken ses çıkarır ve seslerin analizi makinenin durumu hakkında bilgi sağlar. Bu bağlamda, endüstriyel makine sinyallerinde normal ve anormal seslerin akustik tabanlı sınıflandırılması için bir teknik önerilmiştir. MIMII veri kümesi 4 farklı makinenin normal ve anormal koşullardaki seslerini içermektedir.

Çeşitli çalışmalar[17-22] mel spektrogramlarının ses analizinde bir özellik çıkarma yöntemi olarak kullanılmasının etkili olabileceğini göstermiştir. Bu nedenle, MIMII veri kümesindeki ses verilerinden özellik çıkarmak için mel spektrogramları kullanılmış ve bu spektrogramlar kullanılarak bir görüntü veri kümesi oluşturulmuştur.

Makine seslerini normal ve anormal durumlara sınıflandırmak için DenseNet169 [23] mimarisi kullanılmıştır. Model, transfer öğrenme ve ince

ayar teknikleri kullanılarak eğitilmiştir. Önerilen çalışmanın şeması Şekil 1'de gösterilmektedir.




Şekil 1. Önerilen yöntemin şematik diyagramı

2.1. Veriseti


MIMII [9] veri kümesi ses tabanlı arıza tespiti için önerilmiştir ve normal ve anormal makine seslerini içerir. Veri kümesi dört farklı makineden gelen sesleri içermektedir: sürgüler, pompalar, valfler ve fanlar. Valfler sürekli açılıp kapanan solenoid valflerdir, pompa ise su alma ve boşaltma için kullanılır. Fanlar gaz veya hava akışı için kullanılan endüstriyel fanlardır. Kaydırıcı sürekli doğrusal hareket eden bir sistemdir. Sesler 16 kHz örnekleme hızında 8 kanallı bir mikrofon yapısı ile 16 bit formatında kaydedilmiştir. Mikrofon kurulumu pompa, fan ve sürgüden 50 cm, vanadan ise 10 cm uzağa yerleştirilmiş ve 10 saniyelik ses kaydı alınmıştır. Ayrıca, veri seti üç farklı Sinyal Gürültü Oranı (SNR) için veri içermektedir: -6, 0 ve 6 dB. Veri sayısı tüm SNR koşulları için eşittir. Her SNR seviyesi için veriler Tablo 1'de sunulmuştur. Şekil 3, 4 ve 5, veri setindeki farklı Sinyal-Gürültü Oranı (SNR) koşullarına ait örnek görüntüleri göstermektedir. Veriler, eğitim için %80, doğrulama için %10 ve test için %10 olmak üzere üç parçaya bölünmüştür. Daha sonra, normal ve anormal verileri dengelemek için veri artırma teknikleri kullanılmıştır.

Tablo 1. MIMII Veri Seti Farklı SNR koşullarına ait MIMII Veri Seti İçerik Detayları


	<u>Normal</u>	<u>Anormal</u>
Fan	4075	1475
Kaydırıcı	3204	890
Pompa	3749	456
Valf	3691	479



Şekil. 3. -6 dB Makine ses dalga formu



Şekil 4. 0 dB Makine Sesi Dalga Formu



Şekil 5. 6 dB Makine Sesi Dalga Formu

2.2. Veri artırma

MIMII veri setinde normal ve anormal ses verilerinin dağılımında bir dengesizlik söz konusudur. Verileri dengelemek için Gürültü Enjeksiyonu, Zaman Kaydırma, Perde Değiştirme ve Hız Değiştirme yöntemleri kullanılarak anormal ses verilerine ait veri miktarı artırılmıştır.

- Gürültü Enjeksiyonu, enjeksiyon yöntemi ile ses verilerine rastgele gürültü eklenir. Gürültü eklenmiş veriler, ağır anormallikleri veya nadir durumları daha iyi tanınmasını sağlayabilir.

- Shifting time, bir sesi rastgele bir şekilde belirli bir süre sağa veya sola kaydıran basit bir ses artırma tekniğidir.

- Ses perdesini değiştirme yöntemi, ses verisinin uzunluğunu ve tonunu değiştirerek ses perdesini değiştirmeyi amaçlar. Perde değiştirme, sesin temel frekansını değiştirmeyi içerir, bu da genel perdesini kaydırır

- Hız değiştirme yöntemi, ses verilerinin hızını değiştirmeyi amaçlar. Bu yöntem ses verisinin hızını artırmak veya azaltmak için kullanılabilir.

2.3. Özellik çıkarmı

Bu çalışmanın temel amacı, makine seslerinin normal veya anormal olarak sınıflandırılması için konvolüsyonel sinir ağlarını (CNN) kullanmaktır. CNN'ler özellikle görüntü verilerini işlemek ve analiz etmek için tasarlanmıştır. Bu nedenle, CNN'lerin ses sınıflandırması için kullanılabilmesi için ses verilerinin görsel bir formata dönüştürülmesi gerekmektedir. Bu bağlamda mel spektrogram yöntemi kullanılmıştır. Mel spektrogramı, bir ses dalgasındaki farklı frekansların yoğunluğunu ölçmek için mel ölçeğini kullanır ve spektrogram adı verilen zaman içindeki frekansların görsel bir temsili oluşturur. Veri artırımından sonra, her bir ses verisi için Mel Spektrogramları oluşturulmuştur.

2.4. Evrimsel Sinir Ağı Modeli

Evrimsel Sinir Ağı, görüntü tabanlı analiz çalışmalarında yaygın olarak kullanılan başarılı bir derin öğrenme algoritmasıdır. CNN'ler tıp[24], eğitim[25], üretim[26], müzik[27], savunma[28] ve tarım[29] gibi çeşitli alanlarda etkileyici sonuçlar veren çalışmalarda uygulanmıştır. Klasik görüntü analizi yaklaşımlarının aksine, CNN'ler görüntülerden otomatik özellik çıkarımı yapabilen ek katmanlara sahiptir. CNN'ler üç katmandan oluşur. Ana bileşenler: konvolüsyonel, havuzlama ve tam bağlı. Konvolüsyonel katmanda, giriş katmanlarına çekirdekler uygulanarak görüntüyü temsil eden önemli özellikler çıkarılır. Havuzlama katmanı, konvolüsyonel katman tarafından üretilen özelliklerin boyutunu azaltarak hesaplama verimliliğini ve öğrenme hızını artırmak için kullanılır. Tam bağlı katmanda girdi, tahmin yapmak için yapay sinir ağına beslenen bir özellik vektörüdür. Temel katmanların çeşitli kombinasyonlarını ve miktarlarını kullanarak CNN'lerin doğruluğunu artırmak için çok sayıda mimari önerilmiştir. Bu mimariler, CNN'lerin özellik çıkarma ve sınıflandırma yeteneklerini optimize etmeyi amaçlamaktadır. Literatürde LeNet, AlexNet, ZfNet, VGG, GoogleNet, ResNet, DenseNet ve Xception gibi birçok popüler CNN modeli bulunmaktadır [30]. DenseNet[23] algoritması G. Huang ve ekibi tarafından önerilmiştir. Bu model 2017 yılında ImageNet Yarışmasının kazananı olarak kabul edilmiştir. DenseNet, önceki katmanlardan toplanan ek girdilerin sonraki tüm katmanlara aktarılmasını sağlar. Her katman daha üst seviyelerden bilgi toplar. Ağın önceki tüm katmanlardan özellikler alması nedeniyle, dar ve daha sıkı olabilir, bu da kanal sayısında bir azalmaya (ve dolayısıyla hesaplama ve bellek verimliliğinde bir iyileşmeye) neden olur.

DenseNet-169, 169 katmana sahip DenseNet algoritmalarının bir üyesidir. Bu çalışmada, normal ve anormal sesleri sınıflandırmak için DenseNet-169 algoritması ile transfer öğrenme kullanılmıştır. Modelin sonuna bir Global Ortalama Havuzlama katmanı ve ardından sigmoid fonksiyonunu kullanan bir sınıflandırma katmanı eklenmiştir. Model, SGD optimizier ve ikili çapraz entropi kayıp fonksiyonu kullanılarak 25 epok için eğitilmiştir.

2.5. Performans Metrikleri

CNN modelleri için performans değerlendirme metrikleri karışıklık matrisi kullanılarak hesaplanabilir. Metrikler arasında doğruluk, kesinlik, geri çağırma, F1-skoru, Kappa, MCC ve AUC bulunmaktadır. Metriklerin denklemleri Denklem 1-6 arasında görülebilir. TP, TN, FP ve FN, bir sınıflandırma modelinin performansını ölçmede kullanılan kavramlardır; burada TP doğru olarak pozitif sınıflandırılan pozitif örnek sayısını, TN doğru olarak negatif sınıflandırılan negatif örnek sayısını, FP yanlış olarak pozitif sınıflandırılan negatif örnek sayısını ve FN yanlış olarak negatif sınıflandırılan pozitif örnek sayısını gösterir.

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

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

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

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

$$Kappa = \frac{2 \cdot (TP \cdot TN - FN \cdot FP)}{(TP + FP) \cdot (FP + TN) + (TP + FN) \cdot (TN + FN)} \quad (5)$$

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FN) \cdot (TP + FP) \cdot (TN + FP) \cdot (TN + FN)}} \quad (6)$$

3. SONUÇLAR VE TARTIŞMA

3.1. Sonuçlar

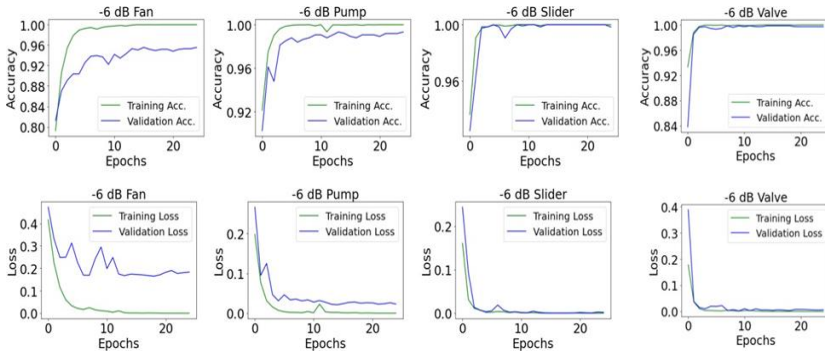
Bu çalışmada, normal ve anormal koşullardaki makine seslerini sınıflandırmak için MIMII veri kümesi kullanılarak bir CNN modeli eğitilmiştir. DenseNet169 modeli, transfer öğrenme ve ince ayar teknikleri kullanılarak eğitilmiş ve çeşitli SNR seviyelerinde %97,10 ila %99,87 arasında değişen doğruluk oranı elde etmiştir. Makine sınıfları, en yüksek

SNR seviyesi olan 6 dB'de %99,87'lik başarılı bir doğruluk oranı elde etmiştir. Bununla birlikte, en düşük SNR seviyesi olan -6 dB'de, fan makinesi test edilen tüm makine sınıfları arasında en düşük doğruluk oranına sahip olmuştur. Bu sonuçlar, endüstriyel makinelerden gelen akustik sinyallerin analizinde derin öğrenmenin etkinliğini göstermektedir. Önerilen yöntem, makine arızalarının erken tespit edilmesini sağlayarak operasyonel aksaklıkları en aza indirebilir ve verimliliği artırabilir. Tablo 3, üç farklı SNR seviyesinde (-6dB, 0dB ve 6dB) dört farklı endüstriyel makine üzerinde gerçekleştirilen sınıflandırma sonuçlarını göstermektedir.

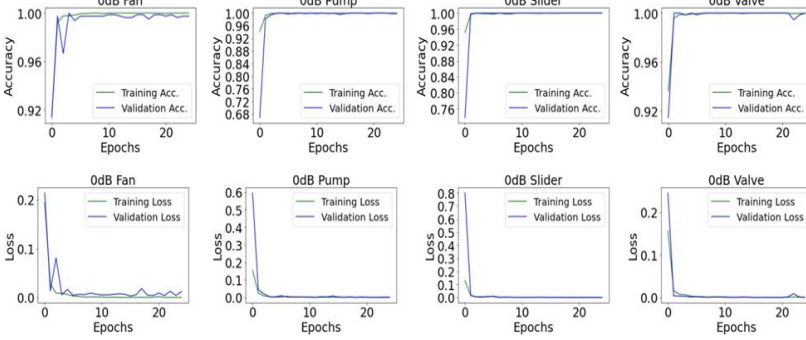
Tablo 3. Farklı SNR seviyelerinde farklı makineler için değerlendirme metriği sonuçları

SNR	Makine	Doğruluk	Hassasiyet	Hatırlama	F1 Skor	Kappa	MCC	AUC
-6 dB	Fan	0.97170	0.97171	0.97171	0.97171	0.94341	0.94342	0.97170
	Pompa	0.99202	0.99215	0.99202	0.99202	0.98404	0.98416	0.99202
	Kaydırıcı	0.99687	0.99687	0.99687	0.99687	0.99374	0.99374	0.99687
	Valf	0.99864	0.99865	0.99865	0.99865	0.99729	0.99729	0.99864
0 dB	Fan	0.99876	0.99877	0.99877	0.99877	0.99753	0.99754	0.99877
	Pompa	0.99867	0.99867	0.99867	0.99867	0.99734	0.99734	0.99867
	Kaydırıcı	0.99844	0.99844	0.99844	0.99844	0.99687	0.99687	0.99844
	Valf	0.99729	0.99731	0.99729	0.99729	0.99458	0.99460	0.99728
6 dB	Fan	0.99877	0.99877	0.99877	0.99877	0.99753	0.99754	0.99876
	Pompa	0.99867	0.99867	0.99867	0.99867	0.99734	0.99734	0.99867
	Kaydırıcı	0.99844	0.99844	0.99844	0.99844	0.99687	0.99687	0.99843
	Valf	0.99865	0.99865	0.99865	0.99865	0.99729	0.99729	0.99864

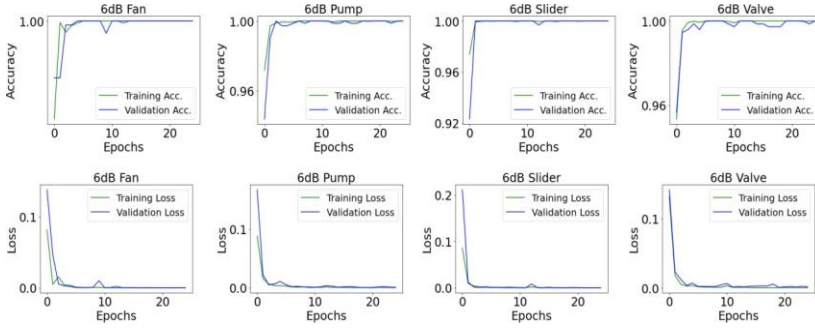
Önerilen modelin eğitim sürecindeki doğruluk ve kayıp metrikleri, çeşitli endüstriyel makineleri ve SNR seviyelerini kapsayacak şekilde Şekil 7, 8 ve 9'da sunulmuştur.



Şekil 7. -6 dB SNR Doğruluk ve kayıp grafikleri




Şekil 8. 0 dB SNR Doğruluk ve kayıp grafikleri



Şekil 9. 6 dB SNR Doğruluk ve kayıp grafikleri

1.1. Tartışmalar

Önerilen yöntemin normal ve anormal sesleri sınıflandırmadaki performansının kapsamlı bir analizi, farklı SNR'lerde elde edilen karışıklık matrislerini gösteren Şekil 10'da sunulmuştur. Bu sonuçlar, yüksek SNR'lerde yüksek doğruluk, kesinlik, geri çağırma ve F1-skor değerleri ile kanıtlandığı üzere, önerilen yöntemin daha az gürültülü ortamlarda üstün performans sergilediğini göstermektedir. Bununla birlikte, daha düşük SNR'lerde, yöntemin doğruluğu azalmakta ve yanlış pozitiflerin sayısı artmakta, bu da daha belirgin arka plan gürültüsü nedeniyle normal ve anormal sesleri ayırt etmeyi zorlaştırmaktadır. Önerilen yöntemin etkinliğini artırmak için denoising filtreleri, özellik normalizasyonu ve zaman-frekans analizi dahil olmak üzere ek özellik çıkarma teknikleri ve ön işleme adımları kullanılabilir. Ayrıca, bu teknikler arka plan gürültüsünün etkisini azaltmak ve sınıflandırma doğruluğunu artırmak için kullanılabilir. Ayrıca, önerilen yöntem diğer endüstriyel makine kategorilerine genişletilebilir, böylece arızaların erken tespiti kolaylaştırılabilir ve operasyonel aksamaya süreleri önlenebilecektir.



Şekil 10. Modellerin Karışıklık Matrisleri

Özetle, önerdiğimiz yöntem, endüstriyel makinelerden gelen akustik sinyallerin analizinde derin öğrenmenin etkinliğini göstermektedir. Operasyonel duruş süresini en aza indirmeye, üretkenliği artırmaya ve manuel denetimin iş yükünü azaltmaya yardımcı olma potansiyeline sahiptir. Tablo 4-5, endüstriyel makine seslerinin sınıflandırılması için önerilen yaklaşımın performansının mevcut çalışmalarla kapsamlı bir karşılaştırmasını göstermektedir. Tablo 4, farklı SNR'lerde her yöntem için doğruluk, kesinlik, geri çağırma ve F1-skoru gibi çeşitli performans ölçütlerini içermektedir. Tablo 5'te, mevcut çalışmalarda yaygın olarak kullanılan bir değerlendirme ölçütü olduğu için yalnızca AUC değeri sunulmuştur. Tablo 4 ve 5'teki sonuçlar, önerilen yöntemin özellikle yüksek SNR'lerde doğruluk ve diğer performans ölçütleri açısından mevcut yöntemlerin çoğundan daha iyi performans gösterdiğini ortaya koymaktadır.

Tablo 4. Mevcut çalışmaların çeşitli ölçütler açısından performansı

Referans	Teknik	Makine	Doğruluk	Hassasiyet	Hatırlama	F1 Skor	Kappa	MCC	AUC
[15]	Ensemble CNN	Valf	0.98211	0.98221	0.98357	0.98289	0.96414	0.96414	0.99930
		Pompa	0.97447	0.98198	0.96935	0.97562	0.94884	0.94893	0.99810

Tablo 5. AUC metriği açısından mevcut çalışmaların performansı

Referans	Teknik	SNR	Makine	AUC
		6		0.997
		0	Fan	0.977

		-6	0.917	
		6	0.983	
	MLP	0	Pompa	0.966
		-6	0.928	
		6	0.994	
		0	Kaydırıcı	0.985
		-6	0.961	
[14]		6	0.929	
		0	Valf	0.842
		-6	0.766	
		6	0.991	
		0	Fan	0.952
		-6	0.86	
	SVM	6	Pompa	0.936
		0	0.912	
		-6	0.849	
		6	0.971	
		0	Kaydırıcı	0.948
		-6	0.901	
		6	0.802	
		0	Valf	0.733
		-6	0.677	
[13]	SPIDERnet	0	Fan	0.994
			Pompa	0.952
			Kaydırıcı	0.979
		6	0.94	
		0	Fan	0.84
		-6	0.70	
[9]	Auto Encoder	6	0.81	
		0	Pompa	0.74
		-6	0.68	
		6	0.90	
		0	Kaydırıcı	0.80
		-6	0.70	
		0	0.67	
		6	Valf	0.61
		-6	0.53	

4. SONUÇ

Bu çalışmada, DenseNet-169 modeli kullanılarak endüstriyel makinelerden gelen akustik sinyallerin analizinde başarılı sonuçlar elde edilmiştir. Yaklaşım, daha kapsamlı veri setleri kullanılarak geliştirilebilir ve türbinler, kompresörler, jeneratörler gibi diğer makineler için de uyarlanabilir. Ayrıca, zaman serisi analizi ve tekrarlayan sinir ağları ile entegre edilerek makinelerin kalan ömrü tahmin edilebilir ve arıza süreleri öngörülebilir. Sıcaklık, titreşim ve akım gibi sensör verileriyle birleştirildiğinde, akustik analiz daha kapsamlı bir sağlık değerlendirmesi sağlayabilir. Endüstriyel sistemlerin verimliliğini artırma ve erken arıza tespiti yoluyla bakım süreçlerini iyileştirme potansiyeline sahiptir.

KAYNAKÇA

1. Gupta, A. and S. Seshasai, 24-hour knowledge factory: Using internet technology to leverage spatial and temporal separations. *ACM Transactions on Internet Technology (TOIT)*, 2007. 7(3): p. 14-es.
2. Mabkhot, M.M., et al., Requirements of the smart factory system: A survey and perspective. *Machines*, 2018. 6(2): p. 23.
3. Badri, A., B. Boudreau-Trudel, and A.S. Souissi, Occupational health and safety in the industry 4.0 era: A cause for major concern? *Safety science*, 2018. 109: p. 403-411.
4. Shamsuddin, K., et al., Investigation the Safety, Health and Environment (SHE) protection in construction area. *International Research Journal of Engineering and Technology*, 2015. 2(6): p. 624-636.
5. Alzubaidi, L., et al., Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 2021. 8: p. 1-74.
6. Salamon, J. and J.P. Bello, Deep convolutional neural networks and data augmentation for environmental sound classification. *IEEE Signal processing letters*, 2017. 24(3): p. 279-283.
7. Ayadi, W., et al., Deep CNN for brain tumor classification. *Neural Processing Letters*, 2021. 53: p. 671-700.
8. Nunes, E.C., Anomalous sound detection with machine learning: A systematic review. *arXiv preprint arXiv:2102.07820*, 2021.
9. Purohit, H., et al., MIMII Dataset: Sound dataset for malfunctioning industrial machine investigation and inspection. *arXiv preprint arXiv:1909.09347*, 2019.
10. Henze, D., et al. Audioforesight: A process model for audio predictive maintenance in industrial environments. in *2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA)*. 2019. IEEE.
11. Becker, P., et al. Acoustic anomaly detection in additive manufacturing with long short-term memory neural networks. in *2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA)*. 2020. IEEE.
12. Duman, T.B., B. Bayram, and G. İnce. Acoustic anomaly detection using convolutional autoencoders in industrial processes. in *14th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2019) Seville, Spain, May 13–15, 2019, Proceedings 14*. 2020. Springer.
13. Koizumi, Y., et al. Spidernet: Attention network for one-shot anomaly detection in sounds. in *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2020. IEEE.
14. Gantert, L., et al. A supervised approach for corrective maintenance using spectral features from industrial sounds. in *2021 IEEE 7th World Forum on Internet of Things (WF-IoT)*. 2021. IEEE.
15. Tama, B.A., et al., An efficientnet-based weighted ensemble model for industrial machine malfunction detection using acoustic signals. *IEEE Access*, 2022. 10: p. 34625-34636.
16. Lyu, P., et al., A novel RSG-based intelligent bearing fault diagnosis method for motors in high-noise industrial environment. *Advanced Engineering Informatics*, 2022. 52: p. 101564.

17. Tran, T. and J. Lundgren, Drill fault diagnosis based on the scalogram and mel spectrogram of sound signals using artificial intelligence. *IEEE Access*, 2020. 8: p. 203655-203666.
18. Juvela, L., et al., GELP: GAN-excited linear prediction for speech synthesis from mel- spectrogram. *arXiv preprint arXiv:1904.03976*, 2019.
19. Liu, F., et al., Underwater target recognition using convolutional recurrent neural networks with 3-D Mel-spectrogram and data augmentation. *Applied Acoustics*, 2021. 178: p. 107989.
20. Zhou, Q., et al., Cough recognition based on mel-spectrogram and convolutional neural network. *Frontiers in Robotics and AI*, 2021. 8: p. 580080.