



**RAY KUSURLARININ MAKİNE
ÖĞRENMESİ İLE
GERÇEK ZAMANLI TESPİTİ**

Yüksek Lisans Tezi

İbrahim UÇAR

Eskişehir 2024

RAY KUSURLARININ MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI TESPİTİ

İbrahim UÇAR

YÜKSEK LİSANS TEZİ

Raylı Sistemler Mühendisliği Bilim Dalı
Danışman: Dr. Öğr. Üyesi Utku KAYA

Eskişehir
Eskişehir Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
2024

JÜRİ VE ENSTİTÜ ONAYI

İBRAHİM UÇAR'ın "Ray Kusurlarının Makine Öğrenmesi ile Gerçek Zamanlı Tespiti" başlıklı tezi 18/04/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Raylı Sistemler Mühendisliği Bilim dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Üyeleri	Unvanı Adı Soyadı	İmza
Üye (Danışman)	Dr. Öğr. Üyesi Utku KAYA
Üye	Doç. Dr. Ahmet ONAY
Üye	Dr. Öğr. Üyesi Şadiye Meral ÇAKMAK

Prof. Dr. Semra KURAMA
Lisansüstü Eğitim Enstitüsü Müdürü

DANIŐMAN ONAYI

DaniŐmanlıđını yurtttđđm Ykksek Lisans ođrencisi İbrahim UÇAR, ‘Ray Kusurlarının Makine Öğrenmesi ile Gerçek Zamanlı Tespiti’ başlıklı tez çalışmasını tamamlamıştır. Hazırlamış olduđu tez tarafımca incelenmiş ve ođrencinin tez savunma sınavına alınması bilimsel ve etik açıdan uygun görölmüştür.

Tez DaniŐmanı
Dr. Öğr. Üyesi Utku KAYA

ÖZET

RAY KUSURLARININ MAKİNE ÖĞRENMESİ İLE GERÇEK ZAMANLI TESPİTİ

İbrahim UÇAR

Raylı Sistemler Mühendisliği Bilim Dalı

Eskişehir Teknik Üniversitesi LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Danışman: Dr. Öğr. Üyesi Utku KAYA

Bu çalışmada, demir yolları bileşenlerinde meydana gelebilecek kusurların gerçek zamanlı olarak makine öğrenme algoritmalarıyla tespiti araştırılacaktır. Bu araştırma, demiryolu bileşenlerinde meydana gelebilecek kusurları erken tespit ederek kazaları ve kayıpları önceden önlemeyi amaçlamaktadır. Çalışma, demir yolu kırıkları, bağlantı elemanlarının eksikliği, ray sabitleme kelepçesinin eksikliği ve vidaların eksikliği gibi temel parçaların kusurlarını tespit ederek gerçekleştirilmiştir. Uygulamamızda, makine öğrenme algoritmalarını eğitmek için birden fazla görüntü kullanılacaktır. Derin öğrenme ağı tarafından, kusurlu veya kusursuz görüntüler, derin öğrenme ağı tarafından sınıflandırılacaktır. Başka bir deyişle, derin öğrenme ağı, gelen test görüntülerini temas etmeden ve gerçek zamanlı olarak tespit edecektir. Çalışmamızda uygun yöntemler ve başarı metrikleri sunulmuş ve sonuçlar karşılaştırmalı bir şekilde açıklanmıştır.

Anahtar Kelimeler: Makine öğrenmesi, Derin öğrenme, Demiryolu bileşenleri.

ABSTRACT

REAL-TIME DETECTION OF RAIL DEFECTS BY MACHINE LEARNING

İbrahim UÇAR

Department of Rail Systems Engineering

Eskişehir Technical University, Institute of Graduate Programs, 2024

Supervisor: Asst. Prof. Dr. Utku KAYA

In this study, real-time detection of defects that may occur in rail components will be investigated with machine learning algorithms. This research aims to detect the faults that will occur in the railway components early and to prevent accidents and losses in advance. The study was carried out by detecting the faults of basic parts such as rail fractures, lack of fastener, lack of rail fixing clamp, and lack of screws. Multiple images will be used in our application for training machine learning algorithms. Defective or non-defective images will be classified by a deep learning network. In other words, our deep learning network will detect incoming test images contactless and in real-time. In our study, appropriate methods and success metrics are given and the results are explained comparatively.

Keywords: Machine learning, Deep learning, Railway, Rail components.

TEŐEKKÜR

Tez alıőmamın her aőamasında bilgi ve tecrübeleriyle katkıda bulunan beni her konuda yönlendiren danışman hocam Dr. Öğretim Üyesi Utku KAYA'ya;

alıőma sürecimde bana hep destek olan ve yardımlarını esirgemeyen sevgili eőim İrem UAR'a;

Destekleri ile her an yanımda olan anneme, babama ve kardeőime teőekkür ederim.

İbrahim UAR

18.04.2024

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “Bilimsel İntihal Tespit Programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

İbrahim UÇAR

18.04.2024

STATEMENT OF COMPLIANCE WITH ETHICAL PRINCIPLES AND RULES

I hereby truthfully declare that this thesis is an original work prepared by me; that I have behaved in accordance with the scientific ethical principles and rules throughout the stages of preparation, data collection, analysis and presentation of my work; that I have cited the sources of all the data and information that could be obtained within the scope of this study, and included these sources in the references section; and that this study has been scanned for plagiarism with “scientific plagiarism detection program” used by Eskişehir Technical University, and that “it does not have any plagiarism” whatsoever. I also declare that, if a case contrary to my declaration is detected in my work at any time, I hereby express my consent to all the ethical and legal consequences that are involved.

İbrahim UÇAR

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ	XI
SİMGELER VE KISALTMALAR DİZİNİ	XIII
1. GİRİŞ.....	1
1.1. Literatür Taraması.....	3
2. YAPAY ZEKA	5
2.1. Yapay Zekanın Tarihi	7
3. MAKİNE ÖĞRENMESİ.....	9
4. DERİN ÖĞRENME	11
4.1. SqueezeNet.....	13
5. GÖRÜNTÜ İŞLEME KAVRAMI	15
5.1. Görüntü İşleme Teknikleri	16
5.1.1.Histogram eşitleme.....	16
5.1.2.Negatif görüntü	18
5.1.3.Salt and pepper gürültüsü eklenmesi	18
6. YÖNTEM	20
7. BULGULAR.....	26
7.1. Hata Matrisi ile Yorumlama	26
7.2. Orijinal Fotoğraf ile Analiz	27
7.3. Histogram Eşitlenerek Analiz	28
7.4. Referans Fotoğraf ile Histogram Eşitleme Analizi.....	29
7.5. Negatifi Görüntü ile Analiz	30

7.6. Salt and Pepper Gürültüsü Eklerek Analiz	32
7.7. Referans Görüntü ile Histogram Eşitlemesi Yapılıp, Salt and Pepper Gürültüsü Eklerek Analiz.....	33
7.8. Tüm Çalışmanın Analizi.....	35
8. SONUÇ VE ÖNERİLER.....	36

KAYNAKÇA

ÖZGEÇMİŞ



TABLULAR DİZİNİ

	<u>Sayfa</u>
Tablo 7.1. Orijinal Görüntü Matrisi	27
Tablo 7.2. Hata Matrisi	27
Tablo 7.3. Histogram Eşitlenmiş Matris	28
Tablo 7.4. Hata Matrisi	29
Tablo 7.5. Referans Fotoğraf ile Histogram Eşitlenmiş Matris.....	30
Tablo 7.6. Referans Fotoğraf ile Histogram Eşitlenmiş Görüntü Hata Matrisi.....	30
Tablo 7.7. Negatif Görüntü Matris	31
Tablo 7.8. Negatif Görüntü Hata Matrisi	31
Tablo 7.9. Salt and Pepper Gürültüsü Eklenmiş Matris	32
Tablo 7.10. Salt and Pepper Gürültüsü Eklenmiş Hata Matrisi	33
Tablo 7.11. Referans Görüntü ile Histogram Eşitlenmiş ve Salt and Pepper Gürültüsü Eklenmiş Matris	34
Tablo 7.12. Referans Görüntü ile Histogram Eşitlenmiş ve Salt and Pepper Gürültüsü Eklenmiş Hata Matrisi	34
Tablo 7.13. Tüm Verilerin Matrisi.....	35
Tablo 7.14. Tüm Verilerin Hata Matrisi	35

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1. Denetimli Öğrenme	10
Şekil 3.2. Denetimsiz Öğrenme	10
Şekil 4.1. Derin Öğrenmenin Alt Kümeleri	11
Şekil 4.2. Evrişimli Sinir Ağlarının Gösterimi	12
Şekil 4.3. SqueezeNet'in Mimarisi.....	13
Şekil 4.4. SqueezeNet'in Gösterimi	14
Şekil 5.1. RGB Renk Uzayı Koordinat Eksenleri	15
Şekil 5.2. Dijital Görüntülerin Renk Piksel Değeri	16
Şekil 5.3. Bir Histogram Grafiği	17
Şekil 5.4 Gri Tonlamalı Bir Görüntüdeki Histogram Denkleştirme.	17
Şekil 5.5. Negatif Görüntü	18
Şekil 5.6. Salt and Pepper Gürültüsü Eklenmiş Şekil	19
Şekil 6.1. SqueezeNet Sınıflandırma Bilgileri	20
Şekil 6.2. Sınıflandırmaya Göre Eğitim Verileri	21
Şekil 6.3. Evrişim Katmanı.....	21
Şekil 6.4. Sınıflandırma Katmanı	22
Şekil 6.5. Derin Öğrenme Analizi	22
Şekil 6.6. Çalışma Ayarları	23
Şekil 6.7. Eğitim İlerlemesi	25
Şekil 7.1. Hata Matrisi	26
Şekil 7.2. Orijinal Görüntü	27
Şekil 7.3. Histogram Eşitlenmiş Matris.....	28
Şekil 7.4. Referans Fotoğrafla Histogram Eşitlenmiş Matris	30

Şekil 7.5. Negatif Görüntü ile Matris	31
Şekil 7.6. Salt and Pepper Gürültüsü Eklenmiş Matris	33
Şekil 7.7. Referans Fotoğraf ile Histogram Eşitlenmiş ve Salt and Pepper eklenmiş Görüntü	34



SİMGELER VE KISALTMALAR DİZİNİ

RGB	: Red-green-blue
RNN	: Recurrent Neural Networks
CNN	: Convolutional Neural Networks
SGDM	: Stochastic Gradient Descent with Momentum
TP	: True Positive
TN	: True Negative
FN	: False Negative
FP	: False Positive

1.GİRİŞ

Ulaştırma içerisinde havayolu taşımacılığında sonra en emniyetli ulaşım demiryoludur. Ülkeler demiryolu taşımacılığında emniyeti geliştirmek ve sürdürmek için çaba harcamaktadır. Demiryolu yolcu taşımacılığı ile konforlu, güvenli ve hızlı ulaşım sağlarken, yük taşımacılığıyla da ekonomiye kazanım sağlamaktadır. Son zamanlar da yüksek hızlı trenlerinde gelişmesiyle demiryolu ulaşımına ilgi büyük oranda artmıştır (Xu ve ark. ,2016).

Demiryolu ulaşım araçlarının planlı, düzenli bakımlarının yapılması ve oluşabilecek hataların tespiti ve bu hataların onarılması hayati önem taşımaktadır. Demiryolunda farklı sebeplerden dolayı ray yüzeyi çatlakları, kırılma, travers çatlakları vb. problemler meydana gelmektedir. Amerika’da son on yılda demiryolu kazalarının %30’u demiryolu parçalarına bağlı kusurlardan kaynaklanmaktadır (Lasisi ve Attokine, 2018).

Tren raylarındaki kusurlarının geleneksel yöntemler kullanılmaktadır. Ray ve ray bileşenlerinde ulaşım engel olabilecek kusurlar gözle kontrolleri yapılarak tespiti sağlanabilmektedir. Yapılmış olan bu çalışmalarda insan faktörünü de katacak olursak hata yapılabilme olasılığı fazladır. Hatanın tespitinin çok daha verimli, hızlı ve güvenli yapılabilmesi için gelişmiş teknolojilerden faydalanmak gerekmektedir. Görüntü işleme teknolojileri, derin öğrenme ve makine öğrenmesi gibi metotlar ile temassız, hızlı, düşük maliyetli tespitler yapılabilmektedir (Karaköse ve ark., 2021).

Bir araştırma verilerine göre Avrupa Birliği ile Türkiye de meydana gelen ciddi kaza oranları karşılaştırıldığında en dikkat çekici farkın deraymanda olduğu görülmektedir. Türkiye’de özellikle kırık/çatlak ray, yol geometrisinin bozukluğuna yönelik tedbirlerin alınması gerektiği sonucuna ulaşılmıştır (Akbayır, 2016).

Makine öğrenmesi yöntemi bilgisayarların insanlara benzer şekilde öğrenmesi için çeşitli algoritmalar ve tekniklere dayalı bir bilimsel çalışmadır. Makine öğrenmesi bilgisayarların deneyimler yoluyla gelişmesini sağlayan bir alandır (Jordan,M.I., Mitchell, T. M., 2015).

Bu çalışmamızda kullanacağımız yöntem olan makine öğrenmesi yöntemi; girdi verilerini çıktı verileri ile ilişkilendirerek isabetli sonuçlar vermektedir (J. Koehler, 2018).

Sistemin eğitilmesi için tanımlanan veriler algoritma aracılığı ile eğitilip sonrasında algoritma ile işlenerek model tahmini yapabilmektedir (Gültepe, 2016).

Çalışmamızda makine öğrenmesi metodolojisinden faydalanarak rayların sağlık durumları hakkında tespitler yapılabilmektedir. Kestirimci bakım faaliyetine benzer şekilde ray ve ray bileşenlerinde oluşabilecek arızalar önceden tespiti yapılabilecek ve hızlı müdahale etmeyi mümkün kılacaktır.



1.2.Literatür Taraması

Raylı sistemler, yük ve yolcu taşımacılığında önemli bir rol oynamaktadır ve hızlı bir şekilde gelişmektedir. Bu gelişmeyle birlikte, uluslararası normlara uyulması, konforlu ve güvenli seyahatin sağlanması, bakım ve onarım maliyetlerinin düşürülmesi gibi konularda dijitalleşmeye ihtiyaç duyulmaktadır. Raylı sistemlerin dijitalleşmesi demiryolu hatları, yönetim sistemleri ve istasyonlar gibi birçok alanda uygulama alanı vardır.

Makine öğrenmesi, hatasız ve tutarlı bir şekilde hataları tespit etmek için kullanılabilir güçlü bir araçtır. Makine öğrenmesi ile yapılan bazı araştırmalar ele alınmıştır. Bunlar;

Yıldız ve Buldu (2017) çalışmasında kumaş üzerindeki hataları tespit edebilmek için kalite kontrol ünitesinde termal görüntüleme kullanmış ve bu görüntüleri kullanarak k-NN metoduyla hatalı kumaşları bulmuştur. Bir başka çalışmada ise robust regresyon metodu ile yeni ürün geliştirme sürecindeki hata tahminlerini araştırmışlardır. Yeni bilgisayarlarda oluşabilecek hatalı ürün sayısını tahmin etmişler ve ürünler için güvenli gelişim modeli kurmuşlardır (Chu ve Wang, 2014). Orta kalınlıktaki levha gerilim analizinde özellik çıkarımı ve hatalı ürün tahmininde makine öğrenmesi yaklaşımı isimli çalışma da verilerin özellik çıkarımı yapılmıştır. Verilerin özelliklerini analiz ederken ısı haritası, değişken etkileşim analizi ve kümeleme analizi kullanılmıştır (Zhang ve ark., 2017). Veri tabanında hatalı ürün bulma ile ilgili daha çok yazılım üzerindeki hataların tespiti konusunda daha çok çalışma mevcuttur. Mesela Azeem ve Usmani'nin (2011) çalışmasında yazılım hatasının tespiti ve bunun kaliteyle ilişkisi incelenmiştir.

Makine öğrenmesi algoritması günümüzde sağlık, üretim, finans, bankacılık, eğitim gibi birçok alanda karşımıza çıkmaktadır. Yapılan çalışmaların bazıları şu şekildedir;

Arsoy ve Güreşen (2016), Yapraklı ve Erdal (2016) çalışmalarında finansal alanda DVM, yapay sinir ağları gibi makine öğrenme algoritmaları kullanılarak tahminlerde bulunmuş ve performanslar karşılaştırılmıştır. Bueno ve arkadaşları (2017), rüzgar enerjisi alanında yapmış oldukları çalışmada hibrid makine öğrenme tekniklerini kullanarak rüzgar gücünü tahmin etmişlerdir. Atasever (2011) çalışmasında haritacılık alanında uydu görüntüleri sınıflandırılmıştır. Sınıflandırmada DVM, regresyon ağaçları ve rastgele orman yöntemleri kullanılmıştır. Akman (2010), Bilgen (2014), Ayas (2014)

ve Kartal (2015) biyoloji alanında çalışmalar yapmışlardır. Çalışmalarda destek vektör makineleri, karar ağaçları ve rastgele orman gibi makine öğrenme algoritmaları kullanılarak tahmin edilmiş ve performans karşılaştırması yapılmıştır.

Makine öğrenmesi yöntemi ile birçok çalışma ve araştırma gerçekleştirilmiştir bu alanda yapılan bir araştırma da Thilagavathy ve arkadaşlarına aittir. Yapılan araştırma ray üzerinde giden tekerleklerin gürültü ve titreşime neden olup bu titreşim/gürültünün sensörler yardımıyla algılanıp sistemde makine öğrenimi algoritmaları kullanarak kusurlu olup olmadığı tespit etmeyi amaçlanmıştır. Sensör raydaki hatayı otomatik olarak algılayarak sürücüye ve tren istasyonuna bildirimde bulunmaktadır (N.Thilagavathy ve ark., 2020).

Zhang ve arkadaşlarının araştırmalarında ise kırık rayların tahmininde bulunurken; tren yolu hatlarını özelliklerinin, demiryolu profil bilgilerinin, ray döşeme bilgilerinin ve trafikle ilgili verilerin, belirli bir zamanda geçen araba sayılarının, bakım kayıtlarının ve geçmiş ray kusurlarının kayıtlarını içeren makine öğrenmesine dayalı bir algoritma geliştirmişlerdir. Bu tahmin modeli kırık rayların tespitini sağlayıp erken bakım planlamasının yapılmasını sağlamaktadır. (Zhang ve ark., 2020).

Diğer yandan Makine öğrenme algoritmaların üzerine yapılan literatür taramasında söz konusu algoritmaların ürün hatalarının tespit edilmesindeki kullanımıyla ilgili yapılan çok az sayıda çalışmaya rastlanmıştır. Bu çalışmayla literatürdeki bu boşluğun doldurulacağı düşünülmektedir.

2.YAPAY ZEKA

Günümüzde teknolojik gelişmeler birçok iş kolaylığı sağlamaktadır. Teknolojik gelişmeler şirketlerin rekabet avantajlarını ve verimliliklerini arttırmaktadır. Yapay zekanın hızlı gelişimi ile beraber modern dünyaya hızlıca uyum sağlamasıyla yapılan ve yapılması planlanan birçok işte yapay zeka tercih edilmektedir.

Günümüzde yapay zekanın bu denli ileriye gitmesinde birçok bilim adamının katkısı vardır bunların başında da Alan Turing gelmektedir. İngiliz matematikçi ve bilgisayar bilimcisi Alan Turing'in kriptograf alanında çalışmaları vardır. Alan "Bilgisayar Makineleri ve Zeka" adlı makale yayınlamıştır. Bu makale de bir bilgisayarın insan zekasını taklit edebileceği fikrini öne sürmüştür. Bu kavram, "Turing Testi" olarak adlandırılmıştır. Turing Testi, bir bilgisayar programının, gerçek bir insanla yapılan sohbetten ayırt edilemeyecek şekilde insan gibi davranabildiği zaman başarılı olduğunu varsaymaktadır. Bu test, yapay zeka alanında önemli bir dönüm noktası olmuş ve halen yapay zekanın gelişiminde önemli bir kriter olarak kabul edilmektedir (Shieber,1994)

1956 yılında düzenlenen Dortmund Konferansı'nda ilk defa yapay zeka kavramı John McCarthy ve arkadaşlarının öneri mektubunda dile getirilmiştir. Dartmouth Konferansı, yapay zekanın multidisipliner bir alan olarak kabul edilmesine ve bilgisayarların insan düşüncesini ve zekasını taklit etme yeteneğini araştıran bir alan olarak tanımlanmasına öncülük etmiştir. Bu konferans aynı zamanda birçok bilim insanının bir araya geldiği ilk toplu etkinlik olarak kabul edilmektedir (Alpaydın, 2013).

Yapay zekânın başlıca kullanım alanları vardır (Türkiye Cumhuriyeti Cumhurbaşkanlığı Dijital Dönüşüm Ofisi, 2022).

Görüntü işleme alanında yüz ve nesne tanıma, güvenlik ve gözetleme, fotoğraf etiketleme, sentetik görüntü üretimi ve sahte video fotoğraf üretimi uygulamaları gibi alanlarda kullanılmaktadır.

Ses işleme alanında ise, müzik ve ses tanıma, sesli asistanlar, sesli yanıt ve şifre, konuşmadan metne çeviri, metinden konuşmaya çeviri uygulamaları vardır.

Metin işleme alanında çeviri servisleri, çeviri sohbet ve asistanları, kişiye özel metin düzeltme uygulamaları geliştirilmiştir.

Veri işleme alanında öneri sistemleri, veri tasnifleme, ilan önerileri, müzik önerileri, hava durumu, trafik durumu ve rota planlama, işe alım ve performans değerlendirme uygulamaları, oyun motorları uygulamaları, sağlık verilerinin analizi üzerinden tedavi planlaması uygulamaları gibi günümüz sorunlarına cevaplar oluşturmuştur.

Kontrol alanında insansız otonom araçlarda yön kararı verebilme uygulamaları, sigortacılık ve finans alanında hasar yönetimi, sahtekarlık tespiti uygulamaları, tarım ve hayvancılık alanında İHA ile görüntü işleme tabanlı hassas ekim, hayvansal üretim uygulamaları, siber güvenlik alanında siber saldırıları tespit ve önleme, kötü veya zararlı yazılım tespit uygulamaları sıklıkla kullanılmaktadır.

Yapay zekâ alt dallara sınıflandırıldığında karşımıza makine öğrenmesi ve derin öğrenme kavramları çıkmaktadır. Yapay zekâ bu kavramlar tarafından desteklenmektedir.

2.1.Yapay Zekanın Tarihçesi

Yapay zekanın başlangıç yıllarında sembolik yapay zeka kavramı benimsenmiştir ve bu yaklaşım, semboller arasındaki ilişkileri manipüle etmeye dayanmaktadır. Sembolik yapay zeka, insan düşüncesinin mantıksal ve sembolik yönlerini vurgular ve bu düşünce biçimlerini bilgisayar programları aracılığıyla taklit etmektedir. Bu alanda ilk çalışmalar temel matematik teoremleri ve bilgisayar oyunları üzerine olmuştur.

1943 yılında McCulloch ve Pitts ‘Beynin Boolean devre modeli’ni geliştirmiştir. Bu model beyinde nöronların nasıl çalıştığını matematiksel olarak açıklayan bir teoriye sahiptir. 1950 yılında ise Alan Turing’in bu konuda çalışmaları olmuştur. Dartmouth Görüşmesi’nde “Yapay zeka” ismi ortaya atılarak bu sürecin daha bilinir olmasına ve daha hızlı gelişmesini sağlamıştır. 1964-1966 yıllarında ELIZA adındaki program MIT’nin yapay zeka laboratuvarında Newell ve Simon tarafından geliştirilmiştir. Bu programın amacı ise genel bir problem çözücü olmasıdır.

1970 ve 1980 yılları arası yapay zeka krizi olarak nitelendirilmektedir. Bu dönemde, yapay zeka alanında beklenen ilerlemelerin gerçekleşmemesi ve birçok proje ve girişimin hüsrarla sonuçlanmasıyla bir kriz yaşandığı düşünülmüştür. Bu dönemdeki birçok araştırmacı, sembolik yapay zeka yaklaşımının sınırlamalarını daha net bir şekilde fark etmeye başlamıştır. Sembolik yapay zeka, karmaşık ve belirsiz problemlerle başa çıkma konusunda başarısız olmuştur. Gerçek dünya verileriyle çalışmak ve bu verilerden anlamlı sonuçlar çıkarmak sembolik yaklaşımla oldukça zordur. Bu dönem de ki bilgisayarlar, bugünkü kadar güçlü değildir. Bu da karmaşık yapay zeka modellerini eğitmeyi ve çalıştırmayı zorlaştırmıştır (Kılıç, 2023).

İlgi ve finansal desteklerin azalması bu dönemde gelişmelerin yavaşlamasına neden olmuştur. 1970 yılının sonlarına doğru Fukushima, NEOCOGNITRON adında görüntü işleme ve tanımayı esas alan modelini ele almış ve yapay zeka sonuçlarının doğruluğu konusunda güçlü bir model ortaya koymuştur. Bu model esas alınarak mühendislik uygulamalarının daha fazla gelişmesini sağlamıştır. (Keskenler ve Keskenler, 2017).

1980’lerden 1990 yılının sonlarına doğru teknolojik gelişmelerinde artmasıyla beraber çalışmalara yeniden ilgi duyulmaya başlamıştır. Tıp, mühendislik, finans gibi temel alanlarda kullanımı artmıştır. Bu dönemde, makine öğrenimi yaklaşımları daha fazla ilgi görmüştür. Makine öğrenimi, bilgisayar sistemlerinin belirli bir görevi doğrudan

öğrenme veya deneyim yoluyla geliştirme yeteneğini ifade etmiştir. Sınıflandırma, kümeleme ve desen tanıma gibi makine öğrenimi teknikleri geliştirilmiş ve uygulanmıştır. Bu alana olan ilginin artmasıyla birlikte, araştırmalara ve projelere yeniden yatırım yapılmıştır. Birçok üniversite, araştırma enstitüsü ve şirket yapay zeka alanında çalışmalarını hızlandırmıştır.

Kohonen 1982 yılında “Kendi Kendine Öğrenme Nitelik Haritaları” adlı eserimim yayınlarken, gene aynı yılda Hopfield ise yapay sinir ağları kullanılarak, bilgisayar kodlarıyla zaman alan problemlerin daha hızlı çözümlenebileceğini önerisini kanıtlarıyla öne sürmüştür. Rummelhart, yapay zekanın hızlı gelişmesinde çok katmanlı yapay sinir ağlarının temelini atan paralel programlama çalışmalarıyla önemli bir rol oynamıştır. Rummelhart ve McClelland tarafından 1986 yılında geliştirilen geriye yayımlı öğrenme algoritması, filtreleme işlemlerinde yüksek başarılar elde etmiştir. Specht tarafından 1991 yılında "Genel Regrasyon Ağları" ve 1988'de "Probabilistik Ağlar" modellerini ortaya koyarak yapay zeka çalışmalarını daha da ileri taşımıştır. (Keskenler ve Keskenler, 2017).

2000 ve 2010 yılları arasında derin öğrenme, büyük veri ve gelişmiş hesaplama kaynaklarının bir araya gelmesiyle yeniden önem kazanmıştır. Yapay sinir ağları, derin öğrenme ve makine öğrenimi alanlarında büyük ilerlemeler kaydedilmiştir.

Günümüzün dönemi ise yapay zeka dönemidir. Yapay zeka alanında sürekli olarak ilerlemeler kaydedilmektedir. Chatgpt, Gemini gibi doğal dil anlama ve üretme yetenekleri üzerine eğitilmiş modeller bulunmaktadır. Kullanıcılarla doğal bir şekilde etkileşime girebilir, metin tabanlı soruları yanıtlayabilir ve çeşitli konularda sohbet edebilir. Yapılış amacı ise gerçek insan konuşmasına benzer bir şekilde doğal, akıcı ve mantıklı metinler üretmektir.

Bu teknolojiler giderek daha fazla yaşamın içinde ve daha fazla endüstride yer almaktadır. Robotik, otomasyon, risk yönetimi, bakım faaliyetleri gibi endüstri alanında, tıbbi görüntülme, hastalık teşhisi, ilaç geliştirme ve hasta bakımı gibi sağlık alanında, enerji verimliliği, doğal kaynak yönetimi, çevresel izleme gibi sürdürülebilirlik ve çevresel fayda gibi birçok konuda temel taşlarından biri haline gelmiştir (Şahin ve Talu, 2021).

3.MAKİNE ÖĞRENMESİ

Makine öğrenimi bilgisayar sistemlerinin belirli bir görevi programlamasına yarayan yapay zeka dalıdır. Algoritmanın veri üzerinde deneyimler kazanarak örüntüler ve ilişkiler bulmasını ve bu bilgiyi gelecekteki kararlarını vermede, tahminlerini yapmak için kullanır.

Makine öğrenmesinde 7 aşama mevcuttur bunlar; veri toplama, veri hazırlama, model seçimi, model eğitimi, değerlendirme ve yorumlama, parametre ayarlama ve tahmin yapmadır


Verilerin toplanması, modelin eğitilmesi ve test edilmesi için iki aşamalı bir süreç izlenir. İlk aşamada, toplanan veriler belirli bir amaç doğrultusunda gruplanır ve eğitim ile test verileri olarak ayrılır. İkinci aşamada ise, eğitim için kullanılacak model seçilir. Seçilen model, ilk aşamada gruplanan eğitim verileriyle eğitilir.

Eğitim süreci tamamlandıktan sonra, modelin performansını değerlendirmek için ayrılan test veri grubuyla test edilir. Bu değerlendirme sonucunda elde edilen veriler dikkatlice incelenir ve sistemin öğrenme oranı değerlendirilir. Elde edilen sonuçlara göre, modelin parametre ayarları yapılır ve gerekli düzeltmeler yapılır.

Sistem, yeterli bir öğrenme oranına ulaştığında, model tahmin yapmak için hazır hale gelir. Ancak, sistemin performansına ve ihtiyaçlarına bağlı olarak, eğitim ve test süreci gerektiğinde tekrarlanabilir. Bu süreç, sistemin daha iyi performans göstermesi ve güvenilir tahminler yapması için önemlidir.

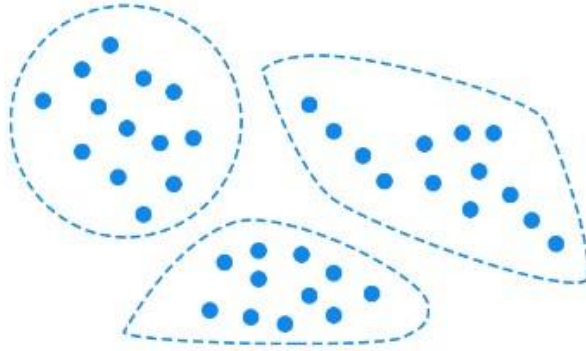
Makine öğrenimi denetimli, denetimsiz ve takviyeli öğrenim olarak üç grupta incelenir.

Denetimli-Gözetimli öğrenme: Bu yaklaşım, giriş verileri ve çıktılar arasındaki ilişkiyi öğrenmeye çalışır. Algoritma, eğitim verisi olarak adlandırılan etiketli veri kümesi üzerinde eğitilir, yani her giriş verisi için doğru çıktılarla birlikte verilir (Kelleher vd., 2015, 39; Mohri vd., 2018). Bu tür makine öğrenimi problemlerine sınıflandırma (classification) ve regresyon (regression) dahildir (Palli ve ark., 2022).



Şekil 3.1. Denetimli öğrenme

Denetimsiz-Gözetimsiz Öğrenme: Bu yöntemde, veri kümesindeki yapıları ve örüntüleri tanımlamak için algoritma etiketsiz veri üzerinde çalışır (Brownlee, 2017, 17; Çelik ve Altunaydin, 2018; Joshi, 2020, 11; Bruce, vd., 2020). Denetimsiz öğrenme, kümelenme (clustering) ve boyut azaltma (dimensionality reduction) gibi görevleri gerçekleştirmek için kullanılır.



Şekil 3.2. Denetimsiz öğrenme

Takviyeli Öğrenme: Bu türde, bir ajan (agent) belirli bir ortamda belirli bir hedefi elde etmeye çalışırken çevreyle etkileşime girer. Ajan, belirli bir davranışı gerçekleştirdiğinde, çevreden geribildirim alır ve bu geribildirime göre davranışını ayarlar. Pekiştirme öğrenme, oyun stratejileri, robotik ve otonom araçlar gibi alanlarda kullanılır (Mohri vd., 2018, 7; Joshi, 2020).

4.DERİN ÖĞRENME

Derin makine öğrenmesi alt dalıdır ve yapay sinir ağlarını kullanarak karmaşık problemleri çözmeyi amaçlar. Derin öğrenme, büyük veri setlerinden yararlanarak bu özellikleri öğrenir ve modelin genelleme yeteneğini artırır. Derin öğrenme yöntemleri, doğal dil işleme, konuşma tanıma, oyun stratejileri ve diğer birçok alanda etkili bir şekilde kullanılmaktadır.



Şekil 4.1. Derin öğrenmenin alt kümeleri

Derin öğrenme yöntemleri arasında yaygın olarak kullanılanlar şunlardır:

Rekurrent Sinir Ağları (Recurrent Neural Networks - RNN): Ardışık verileri işlemek için tasarlanmış sinir ağı modelleridir. Doğal dil işleme, zaman serisi analizi ve metin üretimi gibi alanlarda kullanılırlar.

Derin Doğrulayıcı Öğrenme (Deep Reinforcement Learning): Deneme yanılma yoluyla öğrenen bir yapay zeka öğrenme yöntemidir. Belirli bir hedefi elde etmek için ortamda etkileşimde bulunan ajanlar kullanır.

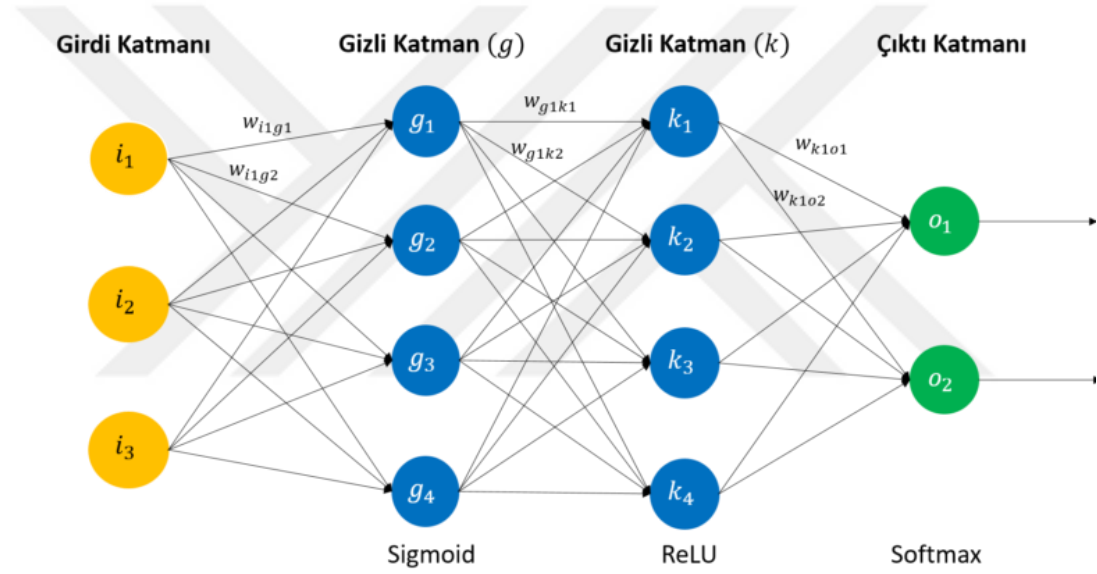
Derin Doğrusal Modeller (Deep Belief Networks): Genellikle unsupervised öğrenme için kullanılan sinir ağı modelleridir. Özellikle boyut azaltma, veri temsili ve olasılık dağılımı tahmini gibi görevlerde kullanılırlar.

Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN): Evrişimli sinir ağı, görüntü işleme ve tanıma gibi alanlarda kullanılan bir derin öğrenme modelidir. Görüntülerdeki özellikleri tanımak için tasarlanmıştır.

Evrişimli sinir ağları, veri içindeki özellikleri belirlemek ve özellikler arasındaki karmaşık ilişkileri öğrenmek için birbirini takip eden katmanlar içerir. Sıralı gelen tabakalardan oluşmaktadır (Lecun ve ark., 1198).

Evrişimli sinir ağları, özellikle evrişim (convolution) katmanları, aktivasyon (activation) katmanları ve havuzlama (pooling) katmanları gibi özel katmanlardan oluşur. Evrişim katmanları, görüntü üzerinde farklı filtrelerin uygulanmasıyla görüntüdeki özelliklerin çıkarılmasına yardımcı olur. Aktivasyon katmanları, evrişim sonucu elde edilen özellik haritalarındaki belirgin özellikleri vurgulamak için kullanılır. Havuzlama katmanları, boyut indirme işlemi yaparak hesaplama karmaşıklığını azaltır ve özelliklerin translasyon, rotasyon gibi çeşitli değişimlere karşı dayanıklılığını artırır.

Evrişimli sinir ağları, özellikle şekil sınıflandırma, nesne tespiti, yüz tanıma gibi birçok görsel tanıma görevinde başarılı sonuçlar vermiştir. Bunun yanı sıra, metin işleme ve ses işleme gibi alanlarda da kullanılmaktadırlar.



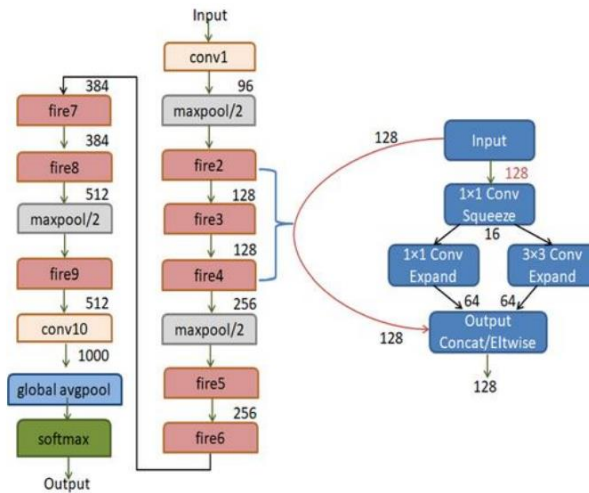
Şekil 4.2. Evrişimli sinir ağlarının gösterimi

4.1. SqueezeNet

2016 yılında SqueezeNet, Iandola ve arkadaşları tarafından sunulmuştur (Iandola ve ark., 2016). Mimari daha az parametreye sahip bir sinir ağı ve özellik olarak veri kümesinde sınıflandırma işlemini başarı ile yapabilmektedir. SqueezeNet, derin öğrenme modeli olan bir tür evrişimli sinir ağı (CNN) mimarisidir. SqueezeNet temelinde model boyunu azaltmak ve ağı mimarisini optimize etmektedir. Bu mimari verimli dağıtılmış katmanlara sahiptir, bu katmanlar sayesinde sinir ağındaki birçok iş yükünü azaltmakta ve daha hızlı çalışabilmektedir (Pathak and El Sharkawy, 2018). Benzer bir derin öğrenme metodu olan AlexNet'den 50 kat daha az parametreye sahip iken onun kadar doğruluk sağlamaktadır (Özyurt ve ark., 2020).

SqueezeNet de bulunan fire modülü giriş katmanını daraltan ve genişleten iki bileşenden oluşmaktadır. Sıkıştırma işlemi kanal sayısını azaltarak hesaplama maliyetini azaltmakta, genişleme adımı ise özellik haritasındaki bilgiyi arttırmaktadır. Ağı oluşturmak için daha az parametreye sahiptir, bellek ve hesaplama işlemlerinde verimi arttırmaktadır. Fire modülü, 1x1 ve 3x3 boyutlarında konvolüsyon katmanlarını birleştirir ve sıkıştırma oranını arttırmak için 1x1 boyutunda bir "sıkıştırma" katmanı ekler. Bu küçük boyutlu filtreler ile daha karmaşık verilerin daha az parametre ile öğrenilmesini sağlar ağıın kapasitesini artırır.

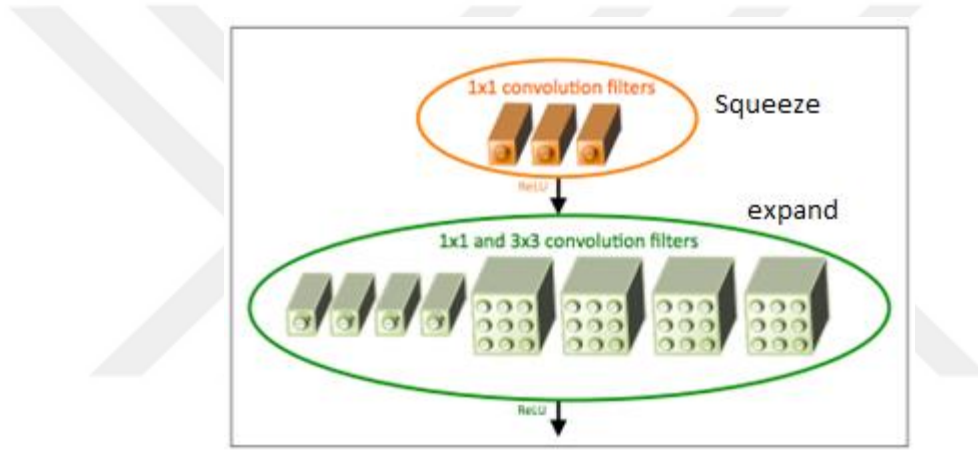
Özellikle mobil cihazlarda ve gömülü sistemlerde gibi kaynak kısıtlı çözümler için popüler yöntemlerden biridir. Küçük boyutu ve hesaplama maliyeti bu tür cihazlarda etkin bir biçimde çalışmasına olanak sağlar.



Şekil 4.3. SqueezeNet'in mimarisi

SqueezeNet'in ana bileşeni Fire modülüdür. Bu modül, daha az parametre kullanarak derinlik ve genişlik arasında denge kurar. Her Fire Modülü, "squeeze" ve "expand" adı verilen iki parçadan oluşur. "Squeeze" adımı, daha az özellik haritasına sahip daha küçük boyutlu bir çıktı oluşturur. "Expand" adımı, bu azaltılmış boyuttaki özellik haritasını daha sonra genişletir ve daha yüksek boyutlu özellik haritası üretir.

Çalışma mantığında giriş katmanı ile veriyi alıp ardından verileri fire modülü aşamasına geçmektedir. Bu modülde sıkılaştırma ve genişleme işlemine uğramaktadır. 1x1 konvolüsyonlarla sıkılaştırılıp 1x1 ve 3x3 konvolüsyonlar ile genişletilmektedir. Giriş özellik haritasında ortalamalar alınarak havuzlama işlemi yapılmaktadır. Sınıf sayısı kadar nörona bağlanan veriler çıkış katmanı ile sınıflandırma sonuçlarını ortaya çıkarır.



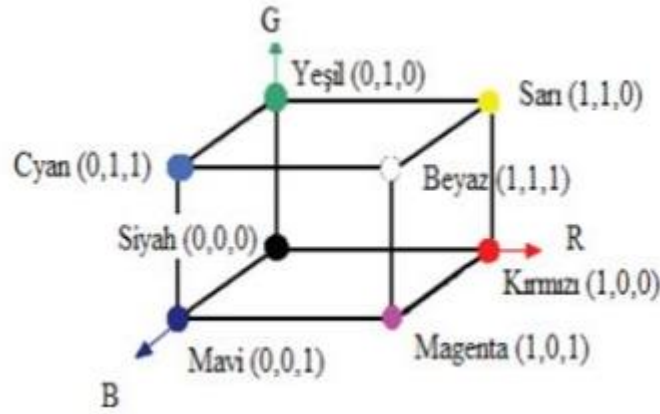
Şekil 4.4. SqueezeNet'in gösterimi

SqueezeNet açık kaynaklıdır ve geniş bir topluluk tarafından desteklenmektedir. Bu da geliştiricilerin ve araştırmacıların modeli kolayca erişebilmesini ve kullanabilmesini sağlar.

5.GÖRÜNTÜ İŞLEME KAVRAMI


Görüntüler bir bütün olarak algılansa da piksel adı verilen parçalardan oluşmaktadır. Görüntüler iki boyutlu piksellerden meydana gelmektedir. Günümüzde video izleme sitelerinin ayar kısımlarında bulunan 720 piksel, 1080 piksel gibi kavramlar ekran boyutundan kaynaklanmaktadır. Kısaca yatay ve dikey uzunluktaki piksel sayısını ifade etmektedir. Görüntü işleme terimine şekilsel bilgilerin analizi denilmektedir. (Sabancı ve Aydın, 2014)

Görüntülerde renk kavramı üç ayrı bileşenden meydana gelmektedir. Kırmızı, yeşil ve mavinin yoğunluklarına göre diğer renkler meydana gelmektedir. Resmi oluşturan her pikselin 0-255 arasında değerleri bulunmaktadır. Kırmızı, yeşil ve mavinin İngilizce baş harflerinden oluşan RGB kelimesi sıklıkla duyulan ifadelerdendir. RGB renk uzayı bir küpün içinde renkleri tanımlayacak şekilde tasarlanmıştır. Bu görüntüler bilgisayar tarafından '0' ve '1' şeklinde anlamlandırılmaktadır.



Şekil 5.1. RGB renk uzayı koordinat eksenleri (Sabancı ve Aydın, 2014)

Görüntü işleme çeşitli kaynaklardan alınan ham görüntünün daha iyi hale getirmek için kullanılan yöntemdir. (Kulkarni ve ark., 2015). Görüntü işleme algılanamayan nesnelerin belirginleşmesinde, keskinleştirme ile daha iyi görüntü elde edilmesini sağlar. Görüntü işleme bir matematiksel ifade gibidir ve dijital görüntüler matrislerden oluşmaktadır.



Şekil 5.2. Dijital görüntülerin renk piksel değeri

Görüntü işleme, günümüzde dijital çağın temel taşlarından biri haline gelmiştir. Bu teknoloji, görsel veriler üzerinde işlemler yaparak yararlı bilgileri ayıklamak veya görüntülerin kalitesini artırmak için algoritmaların kullanılmasını içermektedir. Günlük yaşamda fotoğraf çekmek gibi, tıbbi alanda MR görüntülerini incelemek gibi görüntü işleme yaşamamızın her alanında kullanılmaktadır.

Görüntü işlemenin birçok avantajı bulunmaktadır. Örneğin, görüntü geliştirme, bir fotoğrafın renklerini düzeltebilir veya kontrastını artırabilir; görüntü restorasyonu, eski ve hasarlı fotoğrafları yenileyebilir; görüntü bölümlenme, bir resmi farklı parçalara ayırabilir ve nesne tanıma, görüntülerdeki nesnelere tanımlayabilir ve sınıflandırma işlemini yapabilir.

5.1.Görüntü İşleme Teknikleri

Görüntü işleme teknikleri, genellikle şekilsel bilgilerin geliştirilmesi, depolanması, iletilmesi ve çıkarılması gibi durumlar için kullanılmaktadır. Görüntü işleme, görüntüleri manipüle etme sürecidir, böylece sonuç belirli bir uygulama için orijinalden daha uygun hale getirilmektedir. Görüntü işleme, matematiksel bir temel üzerine kurulmuştur.

5.1.1.Histogram eşitleme

Histogram eşitleme, bir görüntünün kontrastını artırmak ve daha belirgin hale getirmek için kullanılan bir görüntü işleme tekniğidir. Bu teknik, bir görüntünün piksel değerlerinin dağılımını değiştirerek görüntünün parlaklık aralığını genişletir veya sıkıştırır (Young ve ark., 1998).

Bir görüntünün histogramı, görüntüdeki piksellerin parlaklık değerlerinin dağılımını gösteren bir grafikdir. Bu grafiğe bakılarak parlaklık durumu ve renk tonları hakkında bilgi sahibi olunabilir (Jafar ve Ayaing, 2007; Kahraman ve ark., 2005).

X ekseninde orijine doğru ilerledikçe siyah ile belirlen alanlar piksel olarak temsil edilmektedir. Histogram üzerinde orta koyuluktaki gri alanlar ışığın bol olduğu ve beyaz alanları temsil etmektedir.



Şekil 5.3. *Bir histogram grafiği*

Histogram eşitleme işlemi, bu histogramı, belirli bir dağılıma yakın bir şekilde dönüştürmeyi amaçlar. Temelde, bir görüntünün histogramını eşitlediğinizde, görüntüdeki piksel değerlerinin dağılımını daha homojen hale getirilir. Bu, görüntünün kontrastını artırırken detayları daha iyi görmemizi sağlar.



Şekil 5.4. *Gri tonlamalı bir görüntüdeki histogram denkleştirme (Kurka ve Salazar, 2019)*

Histogram eşitleme, özellikle düşük kontrasta sahip görüntülerde veya aydınlatma koşullarının değişken olduğu durumlarda kullanışlıdır. Örneğin, görüntüdeki gölgeli veya aşırı aydınlık alanların daha iyi görünmesini sağlamak için kullanılabilir. Bu işlem, görüntü işleme ve analizinde sıkça kullanılan bir ön işleme tekniğidir.

Histogram eşitlemenin avantajları ise, kontrastı artar, ayrıntılar ve dokular ön plana çıkar, gürültü azalır. Dezavantajları ise renk kayması meydana gelebilir, aşırı kontrast oluşabilir.

5.1.2.Negatif görüntü

Negatif görüntü, bir görüntünün piksel değerlerinin tersine çevrilmiş hali olarak tanımlanır. Bir pikselin orijinal değeri beyaz ise, negatif görüntüde bu piksel siyah olur ve tam tersi şekilde bir pikselin orijinal değeri siyah ise, negatif görüntüde bu piksel beyaz olur.



Şekil 5.5. *Negatif görüntü*

Negatif görüntü oluşturmak için her piksel değeri, 0 (siyah) ile 255 (beyaz) arasındaki maksimum değerden çıkarılır. Bu işlem sonucunda, orijinal görüntünün parlak pikselleri karanlık hale gelirken, karanlık pikselleri ise parlak hale gelir.

Negatif görüntüleme, eski analog fotoğrafçılık dönemlerinden gelir. Orijinal bir fotoğrafın negatif filminden çıkarılması, siyah-beyaz bir fotoğrafın negatifini üretir. Bu negatif film, siyah tonları beyaza, beyaz tonları ise siyaha dönüştürür.

Günümüzde dijital görüntü işleme uygulamalarında negatif görüntüleme belirli özellikleri vurgulamak için kullanılabilir. Örneğin, bir fotoğrafın negatifini almak, bazı detayları ön plana çıkarmak için tercih edilmektedir.

5.1.3.Salt And Pepper gürültüsü eklenmesi

Salt and pepper gürültüsü, bir görüntüde rastgele piksel değerlerinin aniden yüksek veya düşük değerlere sahip olmasıyla karakterize edilen bir türdür. Bu tür gürültü, rastgele piksellerin beyaz veya siyah renklere dönüşmesiyle oluşur, bu da görüntüde beyaz ve siyah noktaların ortaya çıkmasına neden olur. Gürültülü piksel değerlerinin ya 0 ya da 255 olduğu görüntülerdir (Babacan ve Kılıç, 2021).



Şekil 5.6. *Salt and pepper gürültüsü eklenmiş görüntü*

Salt and pepper gürültüsü genellikle bir dijital görüntünün çeşitli nedenlerle bozulduğu veya hasar gördüğü durumlarda ortaya çıkar. Örneğin, iletim hatası, sensör bozulması veya düşük ışık koşulları gibi faktörler bu tür gürültüyü tetikleyebilir.

Gürültü görüntü işleme uygulamalarında karşılaşılan yaygın bir sorundur ve görüntü kalitesini olumsuz yönde etkileyebilir. Bu tür gürültü, nesne algılama, görüntü tanıma ve diğer analiz uygulamaları gibi işlemlerde istenmeyen sonuçlara neden olabilir.

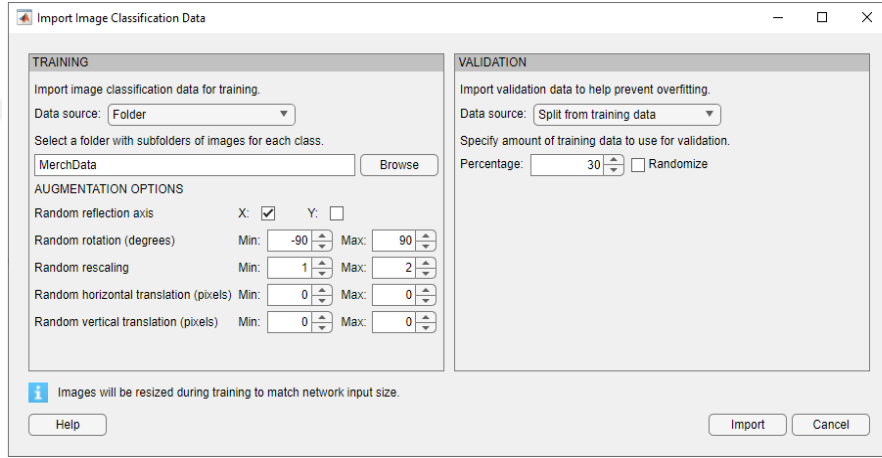
Gürültüsünün azaltılması veya giderilmesi için çeşitli görüntü işleme teknikleri kullanılabilir. Bu teknikler arasında medyan filtreleme, ortalama filtreleme ve morfolojik işlemler gibi yöntemler bulunmaktadır. Bu filtreleme teknikleri, görüntüdeki piksel değerlerini yumuşatarak veya düzelterek gürültüyü azaltmaya çalışır.

6.YÖNTEM

Çalışmamızda kusurlu ve kusursuz adında iki adet veri seti bulunmaktadır. Analizlerimizi yaparken ‘‘Railway Track Fault Detection’’ veri seti kullanılmaktadır (Kaggle). Bu çalışmamızda kusurlu fotoğraf ve kusursuz fotoğraflar ile eğittiğimiz yapay zekanın kararının, başka fotoğrafla karşılaştığında olabildiğince doğru sonuçlar vermesini sağlamaktadır. Çalışmamızda veri setine uygulanacak olan görüntü işleme metotları ile de performans değişiklikleri analiz edilecektir.

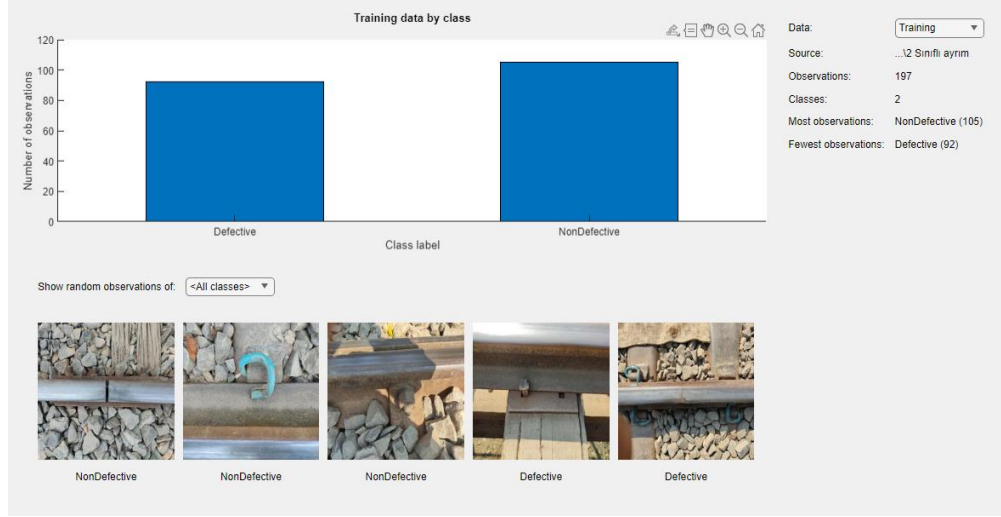
Analiz için derin öğrenme mimarilerinden en hızlı ve hafif olanı SqueezeNet tercih edildi. Çalışmalar Matlab uygulaması üzerinden analiz edilmiştir. SqueezeNet algoritması derin ağ tasarımcısı bölümü çalıştırılır. Bu ağ 18 katman derinliğindeki evrişimli bir sinir ağıdır ve oldukça fazla sayıda görüntü ile eğitilebilmektedir. Ağın görüntü ölçüleri 227 x 227’dir.

Veriler sekmesinden verileri içe aktar bölümü seçilir ve sınıflandırma verileri içe aktara tıklayarak veri kaynağı listesinden daha önce hazırlanmış olunan klasör seçilir.



Şekil 6.1. SqueezeNet sınıflandırma bilgileri

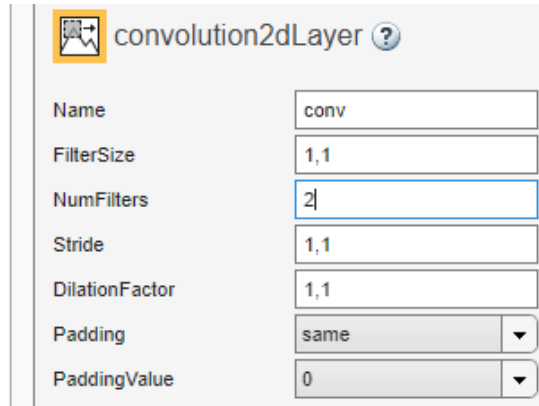
Çalışmaya dahil olan veriler sınırlı olduğundan en iyi sonucu bulabilmek adına şekil yükleme menüsündeki görüntü ayaları kısmından -90 derece ile 90 derece arasında döndürülme ve rastgele boyutlandırma işlemi uygulandı. Tüm çalışma verisindeki fotoğrafların aynı boyutta olması sağlandı. 1-2 aralığında ise rastgele yeniden boyutlandırma işlemine tabii tutuldu. Verilerin %70’i eğitim verisi ve %30’u ise doğrulama verisi olarak seçildi. Bu ayarlar seçildikten sonra içe aktar denilerek verilerin sisteme yüklenmesi sağlandı.



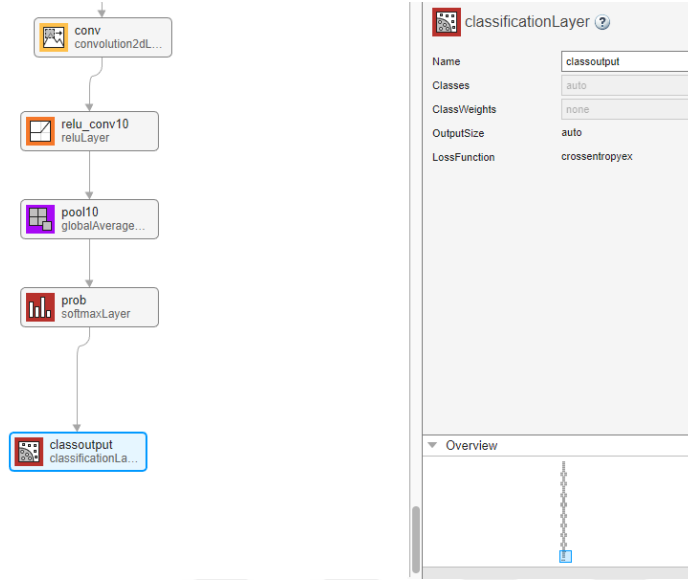
Şekil 6.2. Sınıflandırmaya göre eğitim verileri

Bu kullanılan ağın evrişimli katmanları, son öğretilebilir katmanın ve son sınıflandırma katmanının giriş görüntüsünü sınıflandırmak için görüntü özelliklerini çıkarır. Bu iki katman 'conv10' ve 'ClassificationLayer_predictions' SqueezeNet'te ağın çıkardıkları sınıf olasılıklarını tahmin edilen etiketler halinde nasıl birleştireceğine dair bilgiler içerir.

NumFilters ise sınıflandırma problemleri için sınıf sayısını tanımlar. Çalışmamızda kusurlu ve kusursuz olarak 2 sınıfta tanımlama yapmaktayız. "WeightLearnRateFactor" ve "BiasLearnRateFactor" ayarını yaparak öğrenmenin yeni katmanda aktarılan katmanlara göre daha hızlı olmasını sağlayacak şekilde öğrenme oranlarını 10 olarak ayarlanmıştır.



Şekil 6.3. Evrişim katmanı



Şekil 6.4. Sınıflandırma katmanı

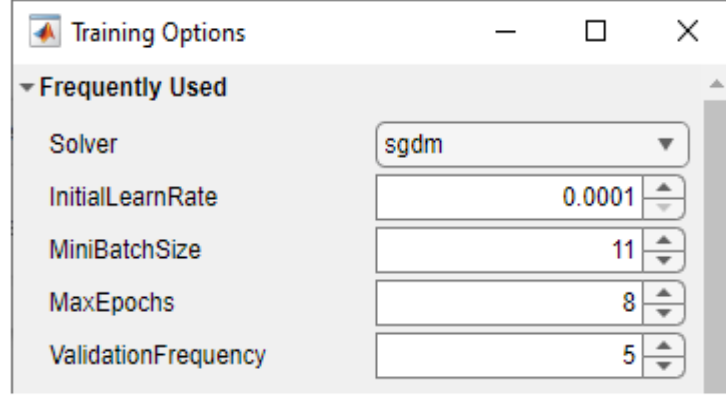
ClassificationLayer bölümünde ise outputsize yani çıktı katmanı otomatik olarak ayarlandığında sınıflarını verilerden otomatik olarak ayarlar.

Hazırlanan ağı eğitime hazır olup olmadığını öğrenmek için analiz et denilerek, derin öğrenme ağı analizcisinin sıfır hata raporunun alması sağlandı. Hata raporunda herhangi bir hataya bulunulmaması çalışmamızın analize hazır olduğunu gösterdi.

Name	Type	Activations	Learnable Proper...	St
1 data 227 x 227 x 3 images with 'zerocenter' nor...	Image Input	227(S) x 227(S) x 3(C) x 1(B)	-	-
2 conv1 64 3x3 convolutions with stride [2 2] a...	2-D Convolution	113(S) x 113(S) x 64(C) x 1(B)	Wegi... 3 x 3 x 3 .. Bias 1 x 1 x 64	-
3 relu_conv1 relu	ReLU	113(S) x 113(S) x 64(C) x 1(B)	-	-
4 pool1 3x3 max pooling with stride [2 2] and pa...	2-D Max Pooling	56(S) x 56(S) x 64(C) x 1(B)	-	-
5 fire2-squeeze1x1 16 1x1x16 convolutions with stride [1 1] ...	2-D Convolution	56(S) x 56(S) x 16(C) x 1(B)	Wegi... 1 x 1 x 64.. Bias 1 x 1 x 16	-
6 fire2-relu_squeeze1x1 relu	ReLU	56(S) x 56(S) x 16(C) x 1(B)	-	-
7 fire2-expand1x1 64 1x1x16 convolutions with stride [1 1] ...	2-D Convolution	56(S) x 56(S) x 64(C) x 1(B)	Wegi... 1 x 1 x 16.. Bias 1 x 1 x 64	-
8 fire2-relu_expand1x1 relu	ReLU	56(S) x 56(S) x 64(C) x 1(B)	-	-
9 fire2-expand3x3 64 3x3x16 convolutions with stride [1 1] ...	2-D Convolution	56(S) x 56(S) x 64(C) x 1(B)	Wegi... 3 x 3 x 16.. Bias 1 x 1 x 64	-
10 fire2-relu_expand3x3 relu	ReLU	56(S) x 56(S) x 64(C) x 1(B)	-	-
11 fire2-concat Depth concatenation of 2 inputs	Depth concatenation	56(S) x 56(S) x 128(C) x 1(B)	-	-
12 fire3-squeeze1x1 16 1x1x128 convolutions with stride [1 1] ...	2-D Convolution	56(S) x 56(S) x 16(C) x 1(B)	Wegi... 1 x 1 x 128.. Bias 1 x 1 x 16	-
13 fire3-relu_squeeze1x1 relu	ReLU	56(S) x 56(S) x 16(C) x 1(B)	-	-

Şekil 6.5. Derin öğrenme analizi

Eđitim seeneklerinden eđitim seenekleri seilerek eđitimde kullanılacak deđerler seilimi yapılır. Aktarılan katmanlardaki đrenmeyi yavařlatmak iin đrenme hızı kk bir deđer seilmektedir.



Őekil 6.6. alıřma ayarları

özmleyici kısmında sgdm seimi yapılmıřtır ve bu da "Stochastic Gradient Descent with Momentum" anlamına gelen bir optimizasyon algoritmasıdır. Bu algoritma, sinir ađlarının eđitimi gibi eřitli makine đrenimi ve derin đrenme problemlerinde kullanılmaktadır. SGDM, momentum terimi ekleyerek gradyan gncellemelerini hızlandırır ve bu sayede daha hızlı ve daha dzgn bir eđitim sađlar. Gradyan gncellemesi ise optimizasyon algoritması olarak kullanılmakta olup maksimumu ve minimumu bulmaya yaramaktadır. Yani en kk karesel hata veya kayıp fonksiyonu gibi bir hatayı minimize etmek iin kullanılan bir sretir. Momentum terimi, gradyan gncellemelerini bir nceki adıma dayalı olarak hesaplar. Bu sayede gradyan gncellemeleri daha tutarlı hale gelir ve minimuma dođru daha hızlı bir ilerleme sađlanır.

İntial Learn Rate: Optimize edici (optimizer) tarafından kullanılan bir parametredir. Bu terim, bir modelin eđitimi sırasında kullanılan đrenme oranının bařlangı deđerini belirtir. đrenme oranı, bir modelin ne kadar hızlı veya yavař đrendiđini belirleyen bir faktördür. Daha yksek bir đrenme oranı, modelin daha hızlı đrenmesine neden olabilir, ancak aynı zamanda ařırđ ařırđ uyum gstermeyi (overfitting) da artırabilir. Daha dřk bir đrenme oranı, modelin daha yavař đrenmesine neden olabilir, ancak daha istikrarlı sonular elde edilmesine yardımcı olabilir. Bu ayar đrenme oranının bařlangı deđeridir ve eđitim sreci ilerledike, bu bařlangı deđerini genellikle ayarlanabilir. rneđin, eđitim

ilerledikçe öğrenme oranı genellikle azaltılarak, modelin daha istikrarlı bir şekilde optimize edilmesi sağlanır.

Mini Batch Size: Eğitim sırasında kullanılan veri kümesinin parçalara bölünmesi gerektiğinde, bu parçaların boyutunu belirten bir parametredir. Genellikle büyük veri kümeleriyle çalışırken, tüm veriyi aynı anda işlemek bellek ve hesaplama açısından zor olmaktadır. Bu nedenle, veri kümesini daha küçük parçalara veya toplu işlemlere (batch) ayırmak yaygın bir uygulamadır. Her bir toplu işleme "mini-batch" denir.

Mini Batch Size parametresi, bir eğitim veri kümesinin bu mini-batch'ler halinde kaç örneğe bölüneceğini belirler. Örneğin, bir miniBatchSize değeri olarak 11 seçilmiştir, eğitim verisi 11'lik küçük parçalara bölünecek ve bu parçalar sırayla modele verilerek eğitim gerçekleştirilecektir.

Bu parametre, eğitim sürecini hızlandırabilir, bellek kullanımını azaltabilir ve daha verimli bir optimizasyon sağlayabilir. Ancak, mini-batch boyutunun seçimi, bir modelin eğitim performansı üzerinde etkili olabilir.

Max Epoch: Bir modelin eğitim döngüsünün kaç kez tamamlanacağını belirten bir parametreyi ifade eder. Her bir eğitim döngüsüne bir "epoch" denir. Bir epoch, modelin tüm eğitim veri kümesini bir kez geçmesini gerektirir. Bir eğitim döngüsü başladığında, model veri kümesindeki tüm örnekleri kullanarak bir tahmin yapar ve ardından bu tahminlerin doğruluğunu değerlendirir. Oluşan sonuçlara göre bir geri yayılım algoritması kullanarak parametrelerini günceller.

Bu parametre eğitim sırasında kaç epoch tamamlanacağını belirler. Bu, bir modelin kaç kez tüm eğitim veri kümesini kullanacağı anlamına gelir. Genellikle, bir modelin eğitim süreci, belirli bir maksimum epoch sayısına ulaştığında veya belirli bir performans ölçütü karşılandığında sonlandırılır. Max epoch parametresi, bir modelin eğitim süresini ve başarı elde etme olasılığını etkileyen önemli bir faktördür. Doğru max epoch değerini seçmek, aşırı uyum sağlamayı önlemek ve istenen performansı elde etmek için önemlidir. Çok düşük bir max epoch değeri, modelin yeterince öğrenme şansını azaltabilirken, çok yüksek bir değer gereksiz hesaplama maliyetine neden olabilir.


Validation Frequency: Eğitim sürecindeki her kaç epoch veya her kaç iterasyon sonra modelin doğrulama veri kümesi üzerinde değerlendirileceğini belirtir. Doğrulama veri kümesi, genellikle eğitim veri kümesinden farklı, modelin daha önce görmediği

verilerden oluşur. Modelin eğitim sırasında doğrulama veri kümesi üzerinde değerlendirilmesi, genelleme yeteneğini kontrol etmek ve aşırı uyumluluğu (overfitting) tespit etmek için önemlidir.

Bu parametre, eğitim sırasında modelin ne sıklıkla doğrulama veri kümesi üzerinde değerlendirileceğini belirler. Validation frequency değeri olarak 5 seçildi, model her 5 epoch'ta bir doğrulama veri kümesi üzerinde değerlendirilir. Bu, modelin eğitim sırasında genelleme yeteneğini düzenli olarak kontrol etmeye yardımcı olur.

Doğrulama verisi kullanarak modelin performansını izlemek, eğitim sürecini yönetmek ve aşırı uyumluluğu tespit etmek için önemlidir. Bu parametrenin uygun bir şekilde ayarlanması, modelin istenen performansı elde etmesine ve aşırı uyumluluğu önlemesine yardımcı olabilir.

Ağı belirlenen seçenekler ile eğitmek için tamam denildikten sonra eğitim başlamış olur.



Şekil 6.7. Eğitim ilerlemesi

Eğitim tamamlandıktan sonra eğitimin kayıtları alınır ve Matlab üzerinde çalışma verilerine uygulanır.

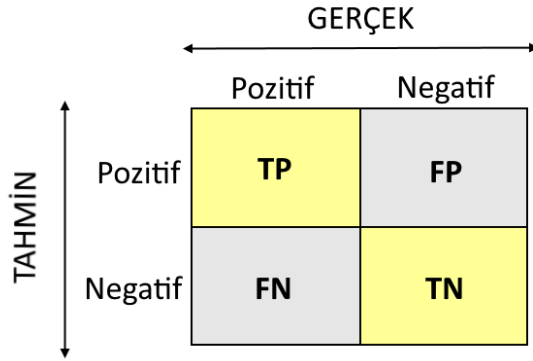
7.BULGULAR

Analizimizde 150 adet kusursuz ve 131 adet kusurlu fotoğraf kullanılmıştır. Fotoğrafların ham halinin analizi ile görüntü işleme tekniği ile oluşturulmuş verilerin analizinin kıyaslaması yapılacaktır.

Analizlerimizin karşılaştırılmasında hata matris kullanılarak duyarlılık, özgüllük ve dengelenmiş doğruluk değerleri incelenecektir.

7.1.Hata Matrisi ile Yorumlama

Hata matrisi özellikle sınıflandırma problemlerinde kullanılan bir değerlendirme metodudur. Makine öğrenimi ve istatistiksel analizlerde kullanılmaktadır. Doğruluk, doğru sınıflandırılan örneklerin toplam örnek sayısına oranıdır. Duyarlılık, belirli bir gerçek sınıfın, model tarafından doğru şekilde tahmin edilen örneklerin oranıdır. Özgüllük, belirli bir gerçek sınıfın, model tarafından yanlış şekilde tahmin edilmeyen örneklerin oranıdır.



Şekil 7.1 Hata matrisi

Duyarlılık pozitif tahminleri pozitif gerçekleşmesidir. Matematiksel gösterimi ise $TP/(TP+FP)$ ' dir. Özgüllük ise Negatif tahminlerin negatif olarak gerçekleşmesidir onunda matematikse gösterimi $TN/(TN+FN)$ 'dir. Doğruluk ise duyarlılık ve özgüllük değerlerinin ortalamasıdır.

7.2. Orijinal Fotoğraf ile Analiz

Veri setimize ilk olarak Matlab uygulaması üzerinden SqueezeNet algoritması uygulanarak aşağıdaki tablodaki sonuçlar elde edilmiştir.

Tablo 7.1. Orijinal görüntü matrisi

	Kusurlu	Kusursuz
Kusurlu	65	66
Kusursuz	13	137

Şekil 7.2. Orijinal görüntü



Kusurlu Görüntü



Kusursuz Görüntü

Tablo 7.2. Hata matrisi

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,49	0,91	0,7

Oluşan tablo neticesinde duyarlılık, özgüllük ve dengelenmiş doğruluk değeri hesaplandığında sırasıyla 0.49, 0.91, 0.7 değerlerini vermektedir. Verilerimize göre özgüllük değeri ise 0.91 olduğu için, kusurlu olmayan örnekleri doğru bir şekilde tanıma oranı daha yüksek olduğu görülmüştür. Analizimizde kusursuz fotoğrafları bulmada

yüksek performans gösterirken kusurlu olanları bulmada aynı performansı gösterememiş ve dengeli doğruluk değeri 0.70 olarak bulunmuştur.

7.3. Histogram Eşitlenerek Analiz

Histogram eşitleme, bir görüntünün kontrastını artırmak ve görüntüdeki renk dağılımını daha dengeli hale getirmek için kullanılmaktadır. Bu görüntü işleme teknik, her bir pikselin yoğunluğunu hesaplayarak, piksel değerlerini değiştirir ve sonuç olarak görüntünün parlaklık dağılımını iyileştirir.

Histogram eşitleme, görüntü üzerinde daha doğru analizler yapılmasını sağlar. Bu, tıbbi görüntüleme, uzaktan algılama veya görüntü tabanlı ölçümler gibi alanlarda önemli bir avantaj sağlamaktadır.

Bu çalışmamızda tüm fotoğraflara histogram eşitlemesi uygulandı ve aşağıdaki tablodaki gibi sonuçlar elde edildi.

Tablo 7.3. Histogram eşitlenmiş matris

	Kusurlu	Kusursuz
Kusurlu	75	56
Kusursuz	19	131

Şekil 7.3. Histogram eşitlenmiş görüntü



Kusurlu Görüntü



Kusursuz Görüntü

Tablo 7.4. *Hata matrisi*

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,57	0,87	0,72

Oluşan tablo neticesinde duyarlılık, özgüllük ve dengelenmiş doğruluk değeri hesaplandığında sırasıyla 0.57, 0.87, 0.72 değerlerini vermektedir. Veri setine histogram eşitlemesi uygulandığında piksel değerlerinin dağılımı değiştiği için sonuçlarınızda önemli değişiklikler görülmektedir. Bu, histogram eşitlemesinin modelin kusurlu görüntüyü tespit etme yeteneğini artırdığını gösterdi. Duyarlılık değeri biraz düşmesine rağmen sistemimiz kararlılığını sürdürdü. Dengeli doğruluk değeri bir öncekine göre bir miktar artmıştır. Bu, modelin genel performansının iyileştiğini gösterir.

7.4. Referans Fotoğraf ile Histogram Eşitleme Analizi

Referans fotoğrafla histogram eşitleme, geleneksel histogram eşitleme yönteminin bir tür değiştirilmiş versiyonudur. Geleneksel histogram eşitleme yöntemi, bir görüntünün piksel değerlerinin dağılımını değiştirerek görüntünün kontrastını artırır. Bu yöntemde, bir görüntünün belirli bir kontrast aralığı seçilerek düzenleme yapılır. Histogram eşitleme işlemi sırasında, eşitlenmiş histogramın referans olarak alınan bir başka görüntünün histogramına yaklaşması sağlanır.

Bu teknik, genellikle bir referans görüntüsünün histogramının önceden belirlenmiş bir özellik taşımasını istediğimiz durumlarda kullanılır. Örneğin, belirli bir aydınlatma seviyesine sahip bir referans görüntüsü kullanarak, diğer görüntülerin bu aydınlatma seviyesine daha yakın olmasını sağlayabiliriz.


Referans fotoğrafla histogram eşitleme yöntemi uygulanmış ray fotoğraflarının analizi yapılırken, sistem tarafından daha iyi tanınması ve veriminin yükseltilmesi planlanmıştır. Bu yöntem, histogram eşitleme yöntemine göre daha kontrol edilebilir bir seçenek sunmuştur.

Bu çalışmamızda tüm fotoğraflara referans bir fotoğraf seçilerek histogram eşitlemesi uygulandı ve aşağıdaki tablodaki gibi sonuçlar elde edildi.

Tablo 7.5. Referans fotoğraf ile histogram eşitlenmiş görüntü matrisi

	Kusurlu	Kusursuz
Kusurlu	97	34
Kusursuz	30	120

Şekil 7.4 Referans fotoğraf ile histogram eşitlenmiş görüntü



Tablo 7.6. Referans fotoğraf ile histogram eşitlenmiş görüntü hata matrisi

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,74	0,80	0,77

Özgüllük değeri ise orijinal fotoğrafa göre referans şekille histogram eşitlendikten sonra sonuçları düşmüştür. Bu analizde, modelin kusursuz sınıfını tanıma yeteneğinde küçük bir düşüş yaşandı. Dengelenmiş doğruluk, referans fotoğraf ile histogram eşitleme sonuçlarında orijinal fotoğrafla analize kıyasla artmıştır.

7.5. Negatifi Görüntü ile Analiz

Bu işlem, her pikselin renk değerlerinin, örneğin, siyah pikselin beyaz, beyaz pikselin siyah olacak şekilde, tersine çevrilmesini sağlar. Bu teknik sayesinde, fotoğraftaki tonlar tersine çevrilir ve böylece görüntünün daha belirgin bir görünüm kazanması sağlanır. Ayrıca, negatif alma işlemi, bazı görüntü işleme uygulamalarında


kontrastı artırmak veya görsel etkiyi güçlendirmek amacıyla da kullanılabilir. Bu analiz kullanılarak raya ait unsurlar ön plana çıkarılarak daha yüksek verim alınması planlanmıştır.

Bu çalışmamızda tüm fotoğraflar negatif hale getirerek aşağıdaki tablodaki gibi sonuçlar elde edildi.

Tablo 7.7. *Negatif görüntü matrisi*

	Kusurlu	Kusursuz
Kusurlu	113	18
Kusursuz	59	91

Şekil 7.5. *Negatifi alınmış görüntü*



Kusurlu Görüntü



Kusursuz Görüntü

Tablo 7.8. *Negatif Görüntü Hata Matrisi*

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,86	0,60	0,73

Oluşan tablo neticesinde duyarlılık, özgüllük ve dengelenmiş doğruluk değeri hesaplandığında sırasıyla 0.86, 0.60, 0.73 değerlerini vermektedir.

Duyarlılık; negatifi ile analiz yapılan görüntünü duyarlılık değeri orijinal veriye göre %49'dan %86'ya yükselmiştir. Bu, modelin kusurlu fotoğrafları daha iyi tanıma yeteneğinde önemli bir iyileşme olduğunu gösterir. Özgüllük değeri, negatifi alındığında

%91'den %60'a düşmüştür. Bu durumda, modelin kusursuz fotoğrafları tanıma yeteneğinde bir düşüş olduğunu gösterir. Dengelenmiş doğruluk, negatifi alındığında %70'ten %73'e yükselmiştir. Bu, iki sınıfın performansının ortalamasının arttığını gösterir.

Sonuç olarak, negatifi alınarak analiz edildiğinde modelin kusurlu fotoğrafları daha iyi tanıma yeteneği artmıştır, ancak kusursuz fotoğrafları tanıma yeteneğinde bir düşüş gözlenmiştir.

7.6.Salt and Pepper Gürültüsü Eklerek Analiz

Salt and pepper gürültüsü, bir görüntüye rastgele beyaz (parlak) ve siyah (karanlık) piksellerin eklenmesiyle oluşan bir tür görüntü gürültüsüdür. Bu tür gürültü, genellikle sensör hataları, veri iletimindeki bozulmalar veya diğer dış etkenler nedeniyle oluşabilir. Sisteme yüklenecek veri her zaman düzgün çekilmiş bir görüntü olmayabilir. Bu gürültü eklenerek sistemin analiz edilmesi, sonuçların daha dayanıklı ve güvenilir olmasını sağlamaktadır. Eğitimi tamamlanan algoritmaya dışarıdan bir fotoğrafın kusurlu veya kusursuz tespitini yapılması istenildiğinde, tespiti istenilen fotoğrafın çekim kalitesine bağlı gürültülü durumda bile iyi sonuçlar vermesi sağlanabilmektedir.

Bu tip gürültüler analiz için aslında istemeyen bir durum oluşturmaktadır. Çalışmamızda ise bu gürültüde kaynaklanan temel anlamda bozuk görüntüler karşısında analizi ve tüm görüntüler içine eklenerek de dışarıdan analizi istenen veri için sistemin yeterli hale getirilmesi amaçlanmıştır.

Tablo 7.9. Salt and pepper gürültüsü eklenmiş matris

	Kusurlu	Kusursuz
Kusurlu	79	52
Kusursuz	20	130

Şekil 7.6. Salt and pepper gürültüsü eklenmiş görüntü



Kusurlu Görüntü



Kusursuz Görüntü

Tablo 7.10. Salt and pepper hata matrisi

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,60	0,86	0,73

Oluşan tablo neticesinde duyarlılık, özgüllük ve dengelenmiş doğruluk değeri hesaplandığında sırasıyla 0.60, 0.86, 0.73 değerlerini vermektedir.

Duyarlılık; ‘‘Salt and pepper’’ gürültüsü eklenmiş şekil sonuçları, orijinal fotoğrafa göre %49'dan %60'a yükseltmiştir.

Bu, modelin kusurlu fotoğraf daha iyi tanıma yeteneğinde bir iyileşme olduğunu gösterir. Özgüllük; değeri salt and pepper gürültüsü eklenmiş veri sonuçlarında %91'den %86'ya düşmüştür. Bu durumda, modelin kusursuz fotoğraf tanıma yeteneğinde bir düşüş olduğunu gösterir. Dengelenmiş doğruluk, salt and pepper gürültüsü eklenmiş görüntü sonuçlarında orijinal fotoğrafa kıyasla neredeyse aynı kalmıştır. Ancak, bu durumda da iki sınıfın performansının ortalamasının arttığını gösterir.


7.7. Referans Görüntü ile Histogram Eşitlemesi Yapılıp, Salt and Pepper Gürültüsü Eklenerek Analiz

Bu çalışmamızda referans görüntüsü ile histogram eşitlemesi yapmış olduğumuz veri setimize salt and pepper gürültüsü de eklenmiştir.

Tablo 7.11. Referans görüntü ile eşitleme yapılarak salt and pepper gürültüsü eklenmiş matris

	Kusurlu	Kusursuz
Kusurlu	78	53
Kusursuz	40	110

Şekil 7.7. Referans fotoğraf ile histogram eşitlenmiş ve salt and pepper eklenmiş görüntü



Tablo 7.12. Referans fotoğraf ile histogram eşitlenmiş ve salt and pepper eklenmiş görüntü hata matrisi

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,59	0,73	0,66

Oluşan tablo neticesinde duyarlılık, özgüllük ve dengelenmiş doğruluk değeri hesaplandığında sırasıyla 0.59, 0.73, 0.66 değerlerini vermektedir. Duyarlılık, orijinal görüntü sonuçlarına göre %49'dan %59'a bir iyileşme gösterir. Bu durum, modelin kusurlu fotoğrafı daha iyi tanıma yeteneğinde bir gelişme olduğunu gösterir. Özgüllük değeri yeni sonuçlarında %91'den %73'e düşmüştür. Bu durumda, modelin kusursuz fotoğrafı tanıma yeteneğinde bir düşüş olduğunu gösterir. Dengelenmiş doğruluk, yeni sonuçlarda orijinal şekil sonuçlarına göre bir düşüş göstermiştir.

7.8. Tüm Çalışmanın Analizi

Bu çalışmada daha önce analizleri yapılan tüm veri setleri toplanarak çalışmanın verimliliği ölçülmüştür. Orijinal, histogram eşitlenmiş, negatifi alınmış ve salt and pepper eklenmiş fotoğraf bir araya getirilerek geniş bir veri seti ile eğitilmiştir.

Tablo 7.13. *Tüm verilerin matrisi*

	Kusurlu	Kusursuz
Kusurlu	391	133
Kusursuz	105	495

Tablo 7.14. *Tüm verilerin hata matrisi*

Duyarlılık	Özgüllük	Dengelenmiş Doğruluk
0,74	0,82	0,78

Tüm fotoğrafların eklemiş olduğu veri seri seti kusurlu fotoğrafları daha iyi tanımaktadır. Hatalı fotoğraflarda ise orijinal fotoğraflar daha başarılı sonuçlar vermektedir. Dengelenmiş doğruluk olarak diğer çalışmalara göre daha fazla yüksek oranda sonuç vermiştir.

8. SONUÇ VE ÖNERİLER

Raylı sistemler endüstrisi, güvenli ve etkin işleyiş için düzenli bakım ve denetim gerektiren bir alandır. Ray kırıklarının tespiti ve bakımı, bu endüstrinin sürdürülebilirliği açısından kritik öneme sahiptir. Geleneksel yöntemlerle, ray kırıklarının tespiti genellikle insan denetimine ve görsel incelemelere dayanmaktadır. Bu yöntemler, hem zaman almakta hem de insan hatalarına açık olabilmektedir. Ayrıca demiryolu ağlarında kapsamlı bir şekilde tarama yapmak oldukça zaman almakta ve büyük iş gücü gerektirmektedir.

Son yıllarda, yapay zeka ve makine öğrenimi tekniklerinin demiryolu bakım süreçlerinde kullanımı artmaktadır. Yapay zeka algoritmaları, büyük miktarda veriyi hızlı bir şekilde işleyebilir ve karmaşık desenleri tanıyabilir. Ray kırığı tespiti için kullanılan yapay zeka algoritmaları, görüntü ve desen tanıma gibi tekniklerden yararlanarak, demiryolu hatlarında potansiyel kırık veya hasar noktalarını belirleyebilmektedir. Yapay zekanın kullanılması geleneksel yöntemlere göre daha hızlı ve hassas sonuçlar alınabilmesine olanak sağlamaktadır. Yapay zeka kullanılarak ray kırığı tespiti yapmak bir dizi kolaylıklar sağlamaktadır.

Yapay zeka algoritmaları kullanılarak büyük veri kümelerini hızlı bir şekilde analiz edilerek, hızlı bir şekilde ortaya sonuçlar ortaya çıkmaktadır. Bu, demiryolu hatlarında potansiyel kırık noktalarının daha hızlı bir şekilde tespit edilmesini sağlar, bunun sonucunda bakım ve onarım süreçleri daha verimli hale gelir. Bu yöntemle insan gözünden kaçabilecek ince detayları yakalanabilir böylece ray kırığı tespitinde daha yüksek doğruluk ve güvenilirlik sağlar. Bu da birçok kazanın önüne geçilmesini sağlar.

Ancak, yapay zeka tabanlı ray kırığı tespiti sistemlerinin bazı dezavantajları da vardır. Yapay zeka algoritmalarının etkili olabilmesi için büyük miktarda etiketli veriye ihtiyaç vardır bu da verilerin toplanması ve işlenmesi zaman gerektirmektedir. Yapay zeka algoritmaları genellikle karmaşık yapılara sahiptir ve uzmanlık gerektirir. Bu, uygulamanın başlatılması ve bakımının yapılması için ek uzmanlık ve kaynak gerektirmektedir. Yapay zeka tabanlı bir sistem, yanlış pozitif veya yanlış negatif sonuçlar üretebilir. Bu durum, güvenilirlik ve güvenlik endişelerine yol açabilir ve gereksiz bakım maliyetlerine veya güvenlik risklerine neden olabilir. Bu algoritmalarının etkin bir şekilde çalışabilmesi için uygun teknolojik altyapıya ihtiyaç vardır. Bu, ek yatırım gerektirebilir ve bazı bölgelerde uygulamanın zorlaşmasına neden olabilir. Böyle bir sistem genellikle

insan onayı ve denetimi gerektirir. Bu, otomasyonun tam anlamıyla gerçekleşmesini engelleyebilir ve işgücü maliyetlerini artırabilir.

Sonuç olarak, yapay zeka tabanlı ray kırığı tespiti, demiryolu bakım süreçlerini önemli ölçüde iyileştirir ve verimliliği artırır. Ancak, uygulama sürecinde dikkate alınması gereken bazı avantajlar ve dezavantajlar bulunmaktadır. Bu nedenle, sistemlerin başarılı bir şekilde uygulanması için titizlikle planlama ve yönetim gerekmektedir.

Çalışmada, orijinal fotoğrafların yanı sıra görüntü işleme tekniklerinin kullanılmasıyla elde edilen sonuçlar karşılaştırılmıştır. Bu karşılaştırma, fotoğrafların kusurlu veya kusursuz olup olmadığını tanımlamak için kullanılmıştır. Görüntü işleme teknikleri, fotoğrafları işleyerek daha net, daha belirgin ve daha analiz edilebilir hale getirmeyi amaçlanmıştır.

Bu teknikler arasında histogram eşitleme, negatifini alma, gürültü ekleme gibi işlemlerde bulunulmuştur. Ardından kusurlu veya kusursuz olup olmadığı belirlenmiş fotoğraflar üzerinde analizler yapılmış ve sonuçlar karşılaştırılmıştır.

Çalışmanın sonuçları, görüntü işleme tekniklerinin kullanılmasıyla kusurlu veya kusursuz fotoğrafları tanıma konusunda belirgin bir artış olduğunu göstermektedir. Bu, görüntü işleme tekniklerinin, fotoğrafların içerdikleri bilgiyi daha iyi ortaya çıkararak tanıma doğruluğunu artırdığını gösterir.

Çalışmanın en iyi sonuçları, tüm çalışma verilerinin toplanarak analiz edilmesiyle elde edilmiştir. Bu, farklı görüntü işleme teknikleri ile elde edilen veriler etkin bir şekilde kullanıldığında daha iyi sonuçlar elde edilmektedir. Bu süreç, kullanılan tekniklerin etkinliğini değerlendirmek ve gelecekteki çalışmalar için rehberlik sağlamak açısından önemlidir.

KAYNAKÇA

- Akbayır Ö. (2016). Dünya’da ve Türkiye’de demiryolu kazaları nedeniyle meydana gelen ölüm oranlarının karşılaştırılması. *ISERSE*.
- Akman, M. (2010). Veri madenciliğine genel bakış ve random forests yönteminin incelenmesi: sağlık alanında bir uygulama. *Ankara Üniversitesi, Sağlık Bilimleri Enstitüsü Yüksek Lisans Tezi*, Ankara.
- Alpaydın, E. (2013). *Yapay öğrenme*. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Arsoy, M.F. ve Güreşen, E. (2016). Nakit temettü tahmininde makine öğrenmesi yaklaşımı: imalat sektörü üzerine bir araştırma. *Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 6 (1), 307-333.
- Atasever, Ü.H. (2011). Uydu görüntülerinin sınıflandırılmasında hızlandırma (boosting), destek vektör makineleri, rastgele orman (random forest) ve regresyon ağaçları yöntemlerinin kullanılması. *Erciyes Üniversitesi, Fen Bilimleri Enstitüsü Yüksek Lisans Tezi*, Kayseri.
- Azeem, N. ve Usmani, S. (2011). Defect prediction leads to high quality product. *Journal of Software Engineering and Applications*, 4(11), 639-645.
- Ayas, S. (2014). Mikroskopik imgelerde tüberküloz bakterisinin rastgele ormanlar yöntemiyle sınıflandırılması. *Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü Yüksek Lisans Tezi*, Trabzon.
- Babacan, Ş. ve Kılıç, İ. (2021). Görüntü işlemede görüntü kalitesinin belirlenmesi için alternatif bir istatistiksel yaklaşım: Bland-Altman Metodu. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi* Cilt 25, Sayı 3, 650-657.
- Bilgen, İ. (2014). İnsan ve hiv-1 proteinleri arasındaki etkileşimlerin rastgele orman yöntemi ve birlikte öğrenme yaklaşımı ile tahmin edilmesi. *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü Yüksek Lisans Tezi*, İstanbul.
- Brownlee, J. (2017). Master machine learning algorithms: discover how they work and implement them from scratch. *Jason Brownlee, v1.12 Edition*
- Bruce, P., Bruce, A. ve Gedeck, P. (2020). Practical statistics for data scientists: 50+ essential concepts using r and python. *Sebastopol: O’Reilly Media, Second Edition*.
- Bueno, L.C., Cuadra, L., Fernández, S.J., Rodríguez, J.A., Prieto, L.ve Sanz, S.S. (2017). Wind power ramp events prediction with hybrid machine 50 learning regression techniques and reanalysis data. *MDPI Open Access Journal*, 10 (11), 1-27.
- Çelik, Ö. Ve Altunaydın, S.S. (2018). A research on machine learning methods and its applications. *Journal of Educational Technology & Online Learning*, 1(3), 25-40.
- Chu, T.P. ve Wang, F.K. (2014). Defect prediction for new products during the development phase, *Journal of Testing and Evaluation*, 42 (4), 989- 995
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, 16, 8- 15.

- Iandola F.N., Han S., Moskewicz M.W., Ashraf K., Dally W.J. ve Keutzer K.(2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *International Conference on Learning Representations. Toulon: ICLR;2016.* pp.1-13.
- Jafar, I. ve Ayaing, H. (2007). A new method for image contrast enhancement based on automatic specification of local histograms. *IJCSNS International Journal of Computer Science and Network Security*, 7(7): 1.
- Joshi, A. V. (2020). Machine Learning and Artificial Intelligence. *Cham: Springer.*
- Kahraman, F., Kurt, B. ve Gokmen, M. (2005). Active appearance model based face recognition. *Signal Processing and Communications Applications Conference*, 483-486.
- Kaggle “Railway Track Fault Detection Resized”
<https://www.kaggle.com/datasets/salmaneunus/railway-track-fault-detection>. Erişim Tarihi: 16.02.2023
- Karadağ B. (2023) Yapay zeka teknolojileri ile mobil uygulamalarda nesne tanıma. *İnönü Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.*
- Kartal, E. (2015). Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama. *İstanbul Üniversitesi, Fen Bilimleri Enstitüsü Doktora Tezi, İstanbul.*
- Keskenler, M.F. ve Keskenler, E.F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*. 5(2): 8-18.
- Kelleher, J.D., Namee, B.M.D. ve Aoife. (2015). Fundamentals of Machine Learning For Predictive Data Analytics. London. *The MIT Press*
- Koehler, J.(2018). Business Process Innovation with Artificial Intelligence: Levering Benefits and Controlling Operational Risks. *European Business and Management*, 4(2), 55-66.
- Kulkarni, P., Naik, A. ve Bhadvankar, A. (2015) Review paper on image processing techniques, *International Journal for Scientific Research & Development*, 3.
- Kutlugün, M.A. (2017). Gözetimli makine öğrenmesi yoluyla türe göre metinden ses sentezleme. *Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi, İstanbul.*
- Lasisi, A. ve Attoh-Okine, N. (2018). Principal components analysis and track quality index: a machine learning approach. *Transp. Res. Part C: Emerg. Technol.*, 91, 230-248.
- Lecun Y., Bottou, L., Bengio Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *proceeding of the IEEE*, cilt 86, no. 11, pp. 2278-2324.
- Mohri, M., Rostamizadeh, A. ve Talwalkar, A. (2018). Foundations of machine learning. London. *The MIT Press, Second Edition.*
- Özyurt F., Sert E. Ve Avcı D. (2020). An expert system for brain tumor detection: Fuzzy C-means with super resolution and convolutional neural network with extreme learning machine, *Medical Hypotheses*, 134,1-8.

- Palli, A.J.M V. ve Medimi, V.S. (2022). Cascade algorithm for helmet and license plate detection of motorcycles (Unpublished Master's Thesis). *Faculty of Computing, Blekinge Institute of Technology*.
- Pathak D. ve El-Sharkawy M. (2018). ReducedSqNet: A shallow architecture for CIFAR-10. *International Conference on Computational Science and Computational Intelligence (CSCI)*, Las Vegas:IEEE,pp. 380-385.
- Sabancı, K., ve Aydın, C. (2014). Görüntü işleme tabanlı hassas ilaçlama robotu. *Tarım Bilimleri Dergisi*, 20, 406-414.
- Shieber, S.M. (1994). Lessons from a restricted Turing test. *Communications of the ACM*, 37(6), 70-78.
- Xu, T., Wang, G., Wang, H., Yuan, T. ve Zhong, Z. (2016), Gap measurement of point machine using adaptive wavelet threshold and mathematical morphology. *Sensors*, 16(12).
- Yapraklı, T.Ş. ve Erdal, H. (2016). Firma başarısızlığı tahminlemesi: makine öğrenmesine dayalı bir uygulama. *Bilişim Teknolojileri Dergisi*, 9 (1), 21-31.
- Yıldız, K. ve Buldu, A. (2017). Kumaş hata tespiti ve sınıflandırmada dalgacık dönüşümü ve temel bileşen analizi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 23 (5), 622-627.
- Young, I., Gerbrands, J., Lucas J., "Fundamentals of Image Processing", *Delf University of Technology*, 5, 6, 17, 18, 29, 32-43, 45, 54, 55, 59, 63, 66, 87, 90 (1998).
- Zhang, H., Zhao, J., Yong, X., Zhang, C. ve Ji, Y. (2017). Machine learning based approaches for medium-thick plate stress analysis feature extraction and product defect prediction. *29th Chinese Control And Decision Conference (CCDC)*, (pp. 7252-7256).

ÖZGEÇMİŞ

ORCID ID : 0009-0003-6829-0374

Adı Soyadı : İBRAHİM UÇAR

Yabancı Dil : İngilizce

Eğitim Geçmişi:

2015, Anadolu Üniversitesi, Açıköğretim Fakültesi, İşletme Yönetimi Bölümü Önlisans Programı.

2016, Karabük Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Bölümü Lisans Programı.

2019, İstanbul Rumeli Üniversitesi, Fen Bilimleri Enstitüsü, İş Sağlığı ve Güvenliği Yüksek Lisans Programı.