

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

TARİHİ YIĞMA YAPILARIN DERİN ÖĞRENMEYE DAYALI OTOMATİK
HASAR TESPİTİ

YÜKSEK LİSANS TEZİ

Tuğba ABDİOĞLU

MART 2023
TRABZON



**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**TARİHİ YIĞMA YAPILARIN DERİN ÖĞRENMEYE DAYALI OTOMATİK
HASAR TESPİTİ**

Tuğba ABDİOĞLU

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
“İNŞAAT YÜKSEK MÜHENDİSİ”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 31/01/2023
Tezin Savunma Tarihi : 24/03/2023**

Tez Danışmanı : Prof. Dr. Kemal HACİEFENDİOĞLU

Trabzon 2023

ÖNSÖZ

“Tarihi Yığma Yapılarda Derin Öğrenme ile Otomatik Hasar Tespiti” adlı bu çalışma, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak hazırlanmıştır.

Bu çalışmayı bana öneren, çalışmamın her aşamasında benimle yakından ilgilenen, çalışmam boyunca bilgi ve tecrübelerinden her daim yararlandığım değerli hocam Prof. Dr. Kemal HACİEFENDİOĞLU’na sonsuz teşekkürlerimi sunmaktan büyük gurur ve mutluluk duyarım.

Öğrenim hayatımın her aşamasında maddi ve manevi desteklerini hiçbir zaman eksik etmeyen çok kıymetli aileme ve bu süreçte her türlü desteği benden esirgemeyen arkadaşlarıma müteşekkir olduğumu belirtip, bu çalışmanın ülkeme faydalı olmasını temenni ederim.

Tuğba ABDİOĞLU
Trabzon, 2023

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Tarihi Yığma Yapılarda Derin Öğrenme ile Otomatik Hasar Tespiti” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Kemal HACİEFENDİOĞLU’nun sorumluluğunda tamamladığımı, verileri kendim topladığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 24/03/2023

Tuğba ABDİOĞLU

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ	XII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. İnşaat Mühendisliği’nde Derin Öğrenme Uygulamaları	1
1.3. Derin Öğrenme ile Tarihi Yığma Yapılarda Hasar Tespiti için Yapılan Bazı Çalışmalar.....	8
1.4. Çalışmanın Amacı ve Kapsamı	9
1.5. Yapay Zeka.....	9
1.6. Makine Öğrenimi	10
1.7. Yapay Sinir Ağlarına Temel Giriş.....	11
1.7.1. Tek Katmanlı Yapay Sinir Ağları	13
1.7.3. İleri Beslemeli Yapay Sinir Ağları.....	14
1.7.4. Geri Beslemeli Yapay Sinir Ağları	14
1.8. Aktivasyon Fonksiyonları	15
1.8.1. Sigmoid Aktivasyon Fonksiyonu	15
1.8.2. Hiperbolik Tanjant Aktivasyon Fonksiyonu	16
1.8.3. ReLU Aktivasyon Fonksiyonu.....	16
1.8.4. Sızdıran ReLU Aktivasyon Fonksiyonu.....	16
1.8.5. Softmax Aktivasyon Fonksiyonu	17
1.9. Derin Öğrenme	17
1.9.1. Evrişimli Sinir Ağı (CNN)	19
1.9.1.1. Evrişim Katmanı.....	21
1.9.1.2. Havuzlama Katmanı	22
1.9.2. Öğrenme Aktarımı.....	23

1. 9. 3.	ResNet-50 Modeli	23
1.9.4.	VGG-16 Modeli	25
1.9.5.	VGG-19 Modeli	26
1.9.6.	Xception Modeli.....	26
1.9.7.	Inception-V3 Modeli	27
1.9.8.	Sınıf Aktivasyon Haritası Yaklaşımı (Grad-CAM).....	28
1.10.	Ölçüm Metrikleri	29
2.	YAPILAN ÇALIŞMALAR	31
2.1.	Giriş	31
2.2.	Ön Hazırlık Çalışmaları.....	31
2.3.	Veri Kümesinin Oluşturulması.....	31
2.4.	ResNet-50 Modeli ile Analiz Sonuçları	33
2.5.	VGG-16 Modeli ile Analiz Sonuçları	38
2.6.	VGG-19 Modeli ile Analiz Sonuçları	43
2.7.	Xception Modeli ile Analiz Sonuçları.....	48
2.8.	Inception-V3 Modeli ile Analiz Sonuçları	53
3.	BULGULAR VE İRDELEMELER	59
3.1.	Görselleştirme Tekniklerinin Karşılaştırılması	61
4.	SONUÇLAR VE ÖNERİLER	62
5.	KAYNAKLAR.....	63
ÖZGEÇMİŞ		

Yüksek Lisans Tezi

ÖZET

TARİHİ YIĞMA YAPILARDA DERİN ÖĞRENME İLE OTOMATİK HASAR TESPİTİ

Tuğba ABDİÖĞLU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Kemal HACİEFENDİOĞLU
2023, 71 Sayfa

Tarihi yığma yapıların yüzeylerinde meydana gelen hasarları incelemek zahmetli, maliyetli ve zaman alıcıdır. Bu çalışmada, bu sorunların üstesinden gelebilmek amacıyla tarihi yığma yapılarda meydana gelen çatlakları tespit etmek için derin öğrenme tabanlı ResNet-50, VVG-16, VGG-19, Xception ve Inception-V3 önceden eğitilmiş modeller kullanılarak otomatik hasar tespiti önerilmiştir. Bunun yanı sıra tarihi yığma yapılarda çatlakların yerini tespit etmek amacıyla derin öğrenme tekniklerini görüntü tabanlı veriler üzerinde daha açıklanabilir düzeye getirmek için sınıf aktivasyon haritası yaklaşımı (Grad-CAM, Grad-CAM++, Score-CAM) kullanılmıştır. Önceden eğitilmiş hazır modellerin eğitilmesinde Gümüşhane kent merkezine yaklaşık 82 kilometre uzaklıkta, Yağmurdere Bucağı Dumanlı Köyü sınırlarında yer alan ve tarihi yapı olarak koruma altına alınan Santa Harabeleri'nden elde edilen 502 çatlak ve 502 çatlak içermeyen görüntüler kullanılmıştır. Önerilen derin öğrenme mimarilerinden ResNet-50 modeli ve tüm görselleştirme stratejilerinin, çatlak bölgelerinin lokalize edilmesi açısından en iyi performansı gösterdiği anlaşılmıştır. Sonuç olarak, önerilen yöntem tarihi yığma yapılarının hasar tespiti için hızlı, verimli ve güvenilir bir yöntemdir ve bu yöntemlerin otomatik olarak uygulanması mümkündür. Bu, tarihi yığma yapılarının korunması ve gelecekte de kullanılabilir hale getirilmesine yardımcı olacaktır.

Anahtar Kelimeler: Derin Öğrenme Yöntemi, Sınıf Aktivasyon Haritası, Çatlak Tespiti, Tarihi Yığma Yapılar

Master Thesis

SUMMARY

AUTOMATIC DAMAGE DETECTION IN HISTORICAL MASONRY STRUCTURES

Tuğba ABDİOĞLU

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Civil Engineering Graduate Program
Supervisor: Prof. Dr. Kemal HACİEFENDİOĞLU
2023, 71 Pages

Examining the damages on the surfaces of historical masonry structures is laborious, costly and time consuming. In this study, automatic damage detection is proposed using deep learning based ResNet-50, VVG-16, VGG-19, Xception and Inception-V3 pretrained models to detect cracks in historical masonry structures in order to overcome these problems. In addition, class activation map approach (Grad-CAM, Grad-CAM++, Score-CAM) was used to make deep learning techniques more explainable on image-based data in order to detect the location of cracks in historical masonry structures. In the training of pre-trained ready-made models, 502 cracked and 502 crack-free images obtained from the Santa Ruins, which is located in the Dumanlı Village of Yağmurdere Sub-district, approximately 82 kilometers away from Gümüşhane city center, and which is under protection as a historical structure, were used. Among the proposed deep learning architectures, the ResNet-50 model and all visualization strategies were found to have the best performance in terms of localizing crack regions. As a result, the proposed method is a fast, efficient and reliable method for damage detection of historical masonry structures and it is possible to apply these methods automatically. This will help preserve historic masonry structures and make them usable in the future.

Key Words: Deep Learning Method, Class Activation Map, Crack Detection, Historical Masonry Buildings

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.	Yapay zekanın tarihsel gelişim süreci 10
Şekil 2.	Temel makine öğrenmesi süreci 11
Şekil 3.	Tek katmanlı yapay sinir ağı modeli 13
Şekil 4.	Çok katmanlı yapay sinir ağı modeli 13
Şekil 5.	İleri beslemeli yapay sinir ağı modeli 14
Şekil 6.	Geri beslemeli yapay sinir ağı modeli 14
Şekil 7.	Aktivasyon fonksiyonunun çalışma prensibi 15
Şekil 8.	LeNet ağıının mimarisi 20
Şekil 9.	Örnek evrişimli sinir ağı yapısı 20
Şekil 10.	Evrişim katmanında kullanılacak örnek bir filtre 21
Şekil 11.	Evrişim katmanında gerçekleşen matris işlemleri 21
Şekil 12.	4x4'lük giriş görüntüsüne 2x2 filtre ile bir ve iki adım kaymalı maksimum havuzlama işleminin uygulanması 22
Şekil 13.	Çatlak tespiti için öğrenme aktarımı 23
Şekil 14.	Artık blok örneği 24
Şekil 15.	ResNet-50 mimarisi 25
Şekil 16.	VGG-16 mimarisi 25
Şekil 17.	VGG-19 mimarisi 26
Şekil 18.	Xception mimarisi 27
Şekil 19.	InceptionV3 mimarisi 28
Şekil 20.	Karışıklık matrisi 30
Şekil 21.	Çatlak içeren görüntü örnekleri 32
Şekil 22.	Çatlak içermeyen görüntü örnekleri 33
Şekil 23.	ResNet-50 modelinin eğitim ve doğrulama kayıp değerlerinin grafiği 34
Şekil 24.	ResNet-50 modelinin eğitim ve doğrulama doğruluk değerlerinin grafiği 34
Şekil 25.	ResNet-50 modelinin karışıklık matrisi 35
Şekil 26.	ResNet-50 modelinin değerlendirme metrikleri 36
Şekil 27.	ResNet-50 modelinin ROC eğrisi 36
Şekil 28.	ResNet-50 modelinde çatlak sınıfı için CAM çıktıları 37
Şekil 29.	ResNet-50 modelinde çatlak olmayan sınıf için CAM çıktıları 38
Şekil 30.	VGG-16 modelinin eğitim ve doğrulama kayıp değerlerinin grafiği 39

Şekil 31.	VGG-16 modelinin eğitim ve doğrulama doğruluk değerlerinin grafiği	39
Şekil 32.	VGG-16 modelinin karışıklık matrisi	40
Şekil 33.	VGG-16 modelinin değerlendirme metrikleri	41
Şekil 34.	VGG-16 modelinin ROC eğrisi	41
Şekil 35.	VGG-16 modelinde çatlak sınıfı için CAM çıktıları	42
Şekil 36.	VGG-16 modelinde çatlak olmayan sınıf için CAM çıktıları	43
Şekil 37.	VGG-19 modelinin eğitim ve doğrulama kayıp değerlerinin grafiği	44
Şekil 38.	VGG-19 modelinin eğitim ve doğrulama doğruluk değerlerinin grafiği	44
Şekil 39.	VGG-19 modelinin karışıklık matrisi	45
Şekil 40.	VGG-19 modelinin değerlendirme metrikleri	46
Şekil 41.	VGG-19 modelinin ROC eğrisi	46
Şekil 42.	VGG-19 modelinde çatlak sınıfı için CAM çıktıları	47
Şekil 43.	VGG-19 modelinde çatlak olmayan sınıf için CAM çıktıları	48
Şekil 44.	Xception modelinin eğitim ve doğrulama kayıp değerlerinin grafiği	49
Şekil 45.	Xception modelinin eğitim ve doğrulama doğruluk değerlerinin grafiği	49
Şekil 46.	Xception modelinin karışıklık matrisi	50
Şekil 47.	Xception modelinin değerlendirme metrikleri	51
Şekil 48.	Xception modelinin ROC grafiği	51
Şekil 49.	Xception modelinde çatlak sınıfı için CAM çıktıları	52
Şekil 50.	Xception modelinde çatlak olmayan sınıf için CAM çıktıları	53
Şekil 51.	Inception- V3 modelinin eğitim ve doğrulama kayıp değerlerinin grafiği	54
Şekil 52.	Inception-V3 modelinin eğitim ve doğrulama doğruluk değerlerinin grafiği	54
Şekil 53.	Inception-V3 modelinin karışıklık matrisi	55
Şekil 54.	Inception-V3 modelinin değerlendirme metrikleri	56
Şekil 55.	Inception-V3 modelinin ROC eğrisi	56
Şekil 56.	Inception-V3 modelinde çatlak sınıfı için CAM çıktıları	57
Şekil 57.	Inception-V3 modelinde çatlak olamayan sınıf için CAM çıktıları	58

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Literatür çalışmalarının inşaat mühendisliği anabilim dallarına göre derlenmesi	6
Tablo 2. Derin öğrenme modelleri tarafından elde edilen performans değerleri	59



SEMBOLLER DİZİNİ

AUC	: Area Under The Curve
CAM	: Class Activation Mapping
CNN	: Convolutional Neural Networks
e	: Euler sayısı
e^{zi}	: Girdi Vektörünün Her Ögesine Uygulanan Eksponansiyel Fonksiyon
FN	: False Negative
FP	: False Positive
$f(x)$	: Aktivasyon Fonksiyonu
GPU	: Graphics Processing Unit
Grad-CAM	: Gradient-Weighted Class Activation Mapping
Grad-CAM++	: Gradient-Weighted Class Activation Mapping++
IFaster R-CNN	: Improved Faster Convolutional Neural Networks
K	: Çoklu Sınıflayıcılardaki Sınıf Sayısı
LSTM	: Long Short-Term Memory
MATLAB	: Matrix Laboratory
$R(z)$	: ReLU Aktivasyon Fonksiyonu
ReLU	: Rectified Linear Unit
ResNet-50	: Residual Network- 50
ROC	: Receiver Operator Characteristic
Score-CAM	: Score-Weighted Class Activation Mapping
SVM	: Support Vector Machine
$\tanh(x)$	: Hiperbolik Tanjant Aktivasyon Fonksiyon
TN	: True Negative
TP	: True Positive
VGG-16	: Visual Geometry Group- 16
VGG-19	: Visual Geometry Group -19
YSA	: Yapay Sinir Ağları
$\vec{z}$	: Softmax Fonksiyonunun Girdi Vektörü
z_i	: Girdi Vektörünün Girdi Değerleri
W	: Ağırlık
x	: Girdi Verisi
$\sigma(x)$	: Sigmoid Aktivasyon Fonksiyonu

$\sum_{j=1}^K e^{z_i}$: Normalizasyon



1. GENEL BİLGİLER

1.1. Giriş

Bünyesinde kolon, kiriş, perde duvar gibi taşıyıcı sistem barındırmayan, bunun yerine duvarlarının taşıyıcı olduğu, tuğla, taş vb. elemanların üst üste konularak ve harçla bağlanarak, elemanların düşey yükleri birbirine aktarması esasına dayalı çalışan yapısal sistemlere yığma yapı denir. Yığma yapılarda kâgir, doğal taş, tuğla, ahşap gibi elemanların harç veya harçsız üst üste konulup örülmesi ile duvarlar oluşturulur. Böylelikle binanın maruz kaldığı yükler taşıyıcı duvarlar vasıtasıyla yukarıdan aşağıya doğru zemine aktarılır.

Çok eski zamanlardan günümüze kadar tarihi yapıların inşasında yığma yapı tekniği kullanılmıştır. Türkiye’de de yapıların büyük bir oranını, yığma yapılar oluşturmaktadır (Kara, 2009). Yığma tipi yapılar, Anadolu’daki köylerde ve küçük kentlerdeki yapıların çoğunu oluştururlar. Hatta büyük kentlerde de yığma yapılara rastlamak mümkündür ve birçok tarihi yapılarımız yığma yapı olarak inşa edilmiştir. Zaman içerisinde doğal ve yapay etkenlere maruz kalan tarihi yığma yapılar hasara uğramış fakat inşa edildikleri dönemdeki yapım ustalığı sayesinde ayakta kalmayı başarmıştır. Bu yapıların mevcut durumlarının incelenmesi, hasarlarının tespiti, onarımı ve güçlendirilmesi için en uygun tekniğin seçilmesi ve gereken müdahalenin zamanında yapılması oldukça önemlidir. Çünkü tarihi yığma yapılar kültürel mirasın sonraki kuşaklara aktarılmasını sağlamada önemli bir görev üstlenmektedir. Ayrıca tarihi yerlerin turistik çekiciliği göz önünde bulundurulursa tarihi yığma yapıların korunmasının ülkemize pozitif etkiler sunacağı sonucuna varılabilmektedir. Bu tez çalışmasında, tarihi yığma yapılarda geleneksel hasar tespitine alternatif olarak derin öğrenmeye dayalı bir yöntem araştırması yapılacaktır.

1.2. İnşaat Mühendisliği’nde Derin Öğrenme Uygulamaları

Teknolojinin ilerlemesiyle gelişimi oldukça hız kazanan derin öğrenme yöntemi birçok alanda kendinden söz ettirmeyi başarmıştır. Derin öğrenmenin diğer sektörlerde aktif kullanımı ve meydana gelen olumlu gelişmelerden yola çıkarak inşaat sektöründe de

kullanımı yaygın hale gelmiştir. Bu bölümde, inşaat mühendisliğinde derin öğrenme uygulamaları incelenerek literatürde yer alan çalışmalardan kısaca bahsedilecektir.

- İnce (2004), çalışmasında, yapay zekanın bir alt dalı olarak literatürde yer alan yapay sinir ağlarını kullanarak çimento esaslı malzemelerin kırılmasındaki parametrelerin tahmin edilmesini sağlamıştır.
- Topçu ve Sarıdemir (2008), çalışmalarında, yüksek ve düşük kireç içeren uçucu küller ile hazırlanmış betonların basınç dayanımlarını yapay zekanın bir alt dalı olan yapay sinir ağları ve bulanık mantık yöntemleri ile tahmini üzerine çalışmışlardır.
- Başyigit vd. (2012), yaptıkları çalışmada, farklı radyasyon değerlerinde olan betonların radyasyon soğurması için gerekli olan kalınlıkları yapay sinir ağları ve çoklu regresyon yöntemleri ile tahmin etmişlerdir. Çalışmanın sonucunda, yapay sinir ağları kullanılarak geliştirilen modeller sonucu elde edilen çıktı sonuçlarının veriler ile uyumlu olduğu ve radyasyona zırlama hesaplarında alternatif bir çözüm yolu olarak kullanılabileceği görülmüştür.
- Choudhary ve Dey (2012), çalışmalarında beton yüzeylerindeki çatlak tespitini görüntü işleme, bulanık mantık ve yapay sinir ağları yöntemlerini kullanarak gerçekleştirmişlerdir. Modeller, 205 adet görüntü üzerinde test edilmiş olup beş performans ölçütü temelinde değerlendirilmiştir. Yapay sinir ağlarının tüm modelin performans ölçümlerinde oldukça iyi bir performans gösterdiği sonucuna ulaşılmıştır.
- Dalkılıç ve Okkan (2012), çalışmalarında yapay sinir ağlarına dayalı bir yöntem kullanarak büyük Menderes Havzası'nda bulunan Kemer Barajı Havzası'na ait aylık akışı derin öğrenme yöntemiyle tahmin etmeye çalışmışlardır.
- Golafshani vd. (2012), betonda bulunan çelik çubukların bağlanma mukavemetlerini belirlemek için yapay zekanın bir alt dalı olan yapay sinir ağlarından yararlanmışlardır.
- Nishikawa vd. (2012), çalışmalarında, beton yapıların yüzey görüntülerindeki çatlakları tespit etmek için görüntü işleme yöntemlerini kullanmışlardır.
- Çankaya vd. (2013), yaptıkları çalışmada, yapay zeka tabanlı görüntü işleme tekniklerini ve yapay sinir ağlarını kullanmışlardır. Bu kapsamda, görüntü işleme tekniğinin betonun basınç dayanımının belirlenmesindeki performansını incelemişlerdir.

- Lee vd. (2013), betonun yüzeyinde bulunan yüzey çatlaklarını tespit ve analiz etmek için görüntü işleme tekniği kullanarak yapay sinir ağlarından yararlanmışlardır.
- Marco vd. (2013), yapmış oldukları çalışmada, yapay sinir ağları yöntemlerinden biri olan bulanık mantık yöntemini kullanarak kil tuğla ve çimentodan oluşan bir duvar yapısının basınç dayanımını belirlemişlerdir.
- Büyükyıldız vd. (2014), yapmış oldukları çalışmada, Beyşehir Gölü'ndeki aylık su seviyesi değişimini tahmin etmek için parçacık sürüsü optimizasyonuna dayalı birde fazla katman içeren yapay sinir ağı kullanmışlardır.
- Arslan vd. (2015), betonarme binaların deprem performanslarının yapay sinir ağı modeli ile tahmini üzerine bir çalışma gerçekleştirmişlerdir.
- Chun vd. (2015), köprülerdeki hasarlı bölgelerin yerlerinin ve derecelerinin tahmin edilebildiği yapay sinir ağı tabanlı bir sistem geliştirmişlerdir.
- Hakim vd. (2015), yapmış oldukları çalışmada, kirişlerde oluşan hasar tespiti için yapay sinir ağlarını kullanarak bir model geliştirmişlerdir. Hasarın derecesi ve yerini belirlemek için oluşturdukları modele girdiler vermişlerdir. İlk olarak, hasarın derecesinin ve yerinin belirlenmesi için mod 1 ile mod 5'e karşılık gelen beş ayrı sinir ağı ele almışlardır. İkinci olarak, geleneksel sinir ağlarının sonuçlarını birleştirmek için topluluk sinir ağına dayalı bir yöntem önermişlerdir.
- Sünbül vd. (2015), 1999 yılında gerçekleşen Marmara depremi sonrası Adapazarı şehir merkezinde üniversite ve özel firmalar tarafından yapılan zemin etüt verilerini kullanarak, zeminin sıvılaşma potansiyelini yapay sinir ağları yöntemlerinden biri olan Bulanık Mantık yöntemi ile analiz etmişlerdir. Çalışma sonucunda Bulanık Mantık yöntemiyle elde edilen sonuçlar, depreme dayanıklı zemin parametreleri arasındaki ilişkiyi hızlı ve doğru bir şekilde tahmin edebileceğini ortaya koymuştur.
- Yurtcu ve Özocak (2016), ince daneli zeminlerin sıkışma indeksinin yapay zekâ yöntemleri ve istatistiksel yöntemler ile belirlenmesine dayalı bir çalışma yapmışlardır.
- Abdeljaber vd. (2017), çalışmalarında, dolgu kirişleri ortalama kirişlere bağlayan cıvatalarda varolan hasarları tespit etmek ve hasarlı eklemlerin yerini doğru bir şekilde belirlemek için evrişimli sinir ağı tabanlı bir algoritma kullanmışlardır. Kullandıkları algoritmada öncelikle, ivmeölçerlerle donatılmış 30 bağlantının her biri için benzersiz bir evrişimli sinir ağını tasarlayarak eğitmişlerdir. Evrişimli sinir

ağlarının eğitimi için her bir bağlantı için bir dizi hasarlı ve hasarsız hızlanma sinyalinin oluşan bir veri seti oluşturmuşlardır. Veri setini gruplamak, çerçevelere bölmek, dengelemek ve normalleştirmek için bir Matlab yazılımı kullanmışlardır.

- Cha vd. (2017), çalışmalarında birden fazla hasar türünün (beton çatlağı, çelik korozyonu, cıvata korozyonu ve çelik delaminasyonu) tespiti için derin öğrenmeden yararlanarak yapısal görsel inceleme gerçekleştirmişlerdir. Birden çok hasar çeşidinin eş zamanlı tespitini yapmak için evrişimli sinir ağlarını kullanmışlardır. Tasarlamış oldukları evrişimli sinir ağları, 256×256 piksel çözünürlükteki veri seti üzerinde eğitilerek yaklaşık %98 doğrulukla sonuç elde etmişlerdir. Önerilen yaklaşımın sağlamlığı ve uygulanabilirliği, çeşitli koşullar altında (örneğin, güçlü ışık noktası, gölgeler ve çok ince çatlaklar) eğitim ve doğrulama işlemleri için kullanılmayan farklı bir yapıdan alınan 55 adet görüntü üzerinde test edilmiştir. Geleneksel Canny ve Sobel kenar algılama yöntemlerini kullanarak önerilen evrişimli sinir ağlarının iyi performans gösterdiği ve gerçekçi durumlarda beton çatlaklarını bulabildiği gösterilmiştir.
- Atha ve Jahanshahi (2018), çalışmalarında, korozyonlu ve korozyonsuz görüntü bölgelerini sınıflandırmak için evrişimli sinir ağı yöntemine dayanan VGG-16 ve ZF-Net modellerini kullanmışlardır. Veri setini oluşturmak için farklı dijital kameralar kullanarak 926 görüntü toplamışlardır. Bu görüntüler daha sonra tamamen korozyon içeren ve korozyon içermeyen bölgelere göre tekrar boyutlandırılmıştır. Görüntüler 128×128 boyutunda görüntülere bölünerek 33039 adet korozyon içeren görüntü ve 34148 korozyon içermeyen görüntü elde edilmiştir. Son olarak eğitilmiş oldukları VGG-16 ve ZF-Net model performansları karşılaştırılmıştır.
- Akçay ve Manisalı (2018), inşaat işlerinde yüklenici seçmek için yapay sinir ağı yöntemlerinden biri olan bulanık mantığı kullanmışlardır.
- Fang vd. (2018), şantiyelerde güvenliği ve üretkenliği artırmak amacıyla işçi, ekipman ve malzemelerin varlığını tespit etmekte bilgisayarlı görü tabanlı bir çalışma gerçekleştirmişlerdir. Şantiyelerdeki nesneleri doğru bir şekilde tespit etmek ve farklı veri kümelerine genelleme yapabilmek için nesnelerin varlığını gerçek zamanlı olarak otomatik olarak algılayacak evrişimli sinir ağı özelliklerine sahip İyileştirilmiş Daha Hızlı Bölgeler (IFaster R-CNN) yöntemini kullanmışlardır. Çalışmalarında sırasıyla; evrişimli sinir ağlarını eğitmek için işçi ve ağır teçhizatın kuruluş veri seti, derin öğrenme yöntemini kullanarak

görüntülerden özellik haritalarının çıkarılması, özellik haritalarından bir bölge önerisinin çıkarılması ve nesne tanıma aşamalarını uygulamışlardır. Elde ettikleri sonuçlar neticesinde İyileştirilmiş Daha Hızlı Bölgeler (IFaster R-CNN) modeli nesnelerin varlığını yüksek bir doğruluk düzeyinde (%91 ve %95) tespit edebildiğini ortaya koyulmuştur.

- Mohanaselvi ve Hemapriya (2018), yapmış oldukları çalışmada, depremde oluşan hasar tahminlerini belirlemek amacıyla yapay sinir ağı yöntemlerinden biri olan bulanık mantık yönteminden yararlanmışlardır. Binaları az, orta ve çok hasar seviyelerine göre üç gruba ayırarak yeni bir veri seti modeli eğittikten sonra yöntemin performansını değerlendirmişlerdir.
- Mangalathu ve Burton (2019), yapmış oldukları çalışmada, depremde etkilenen binaları derin öğrenmeye dayalı bir yöntemle sınıflandırmışlardır. Çalışmalarında, 2014 yılında gerçekleşen Kaliforniya depremi sonucu 3423 adet binada meydana gelen hasarlardan oluşan veri setini kullanmışlardır. Bu binaları az, orta ve çok hasarlı olmak üzere sırasıyla yeşil, sarı ve kırmızı renklerle etiketleyerek rastgele eğitim ve test alt kümelerine ayırmışlardır. Eğitim setini kullanarak tahmine dayalı bir model kurmuşlardır. Bu modelde, binalarda oluşan hasarların şiddetini belirlemek için de Uzun Kısa Vadeli Bellek (LSTM) derin öğrenme mimarisini kullanmışlardır. Modelin performansını test etmek için test veri setini kullanarak %86 tahmin başarısı elde etmişlerdir.
- Özbayrak (2019), yaptığı bir çalışmada, yapay sinir ağlarını kullanarak deprem etkisi altında olan betonarme kirişsiz plakların eğilme momentlerini %98'lik bir performans ile elde etmiştir.
- Wang vd. (2019), yapmış oldukları çalışmada, tarihi yığma yapıların yüzeyinde meydana gelen çiçeklenme ve dökülme hasar türlerini tespit etmek ve sınıflandırmak için evrişimli sinir ağları, daha hızlı evrişimli sinir ağları ve ResNet101 modelini kullanmışlardır.
- Arslan vd.(2020), Keban Baraj Gölü'ndeki su seviyesinin tahmini için makine öğrenimi algoritmalarından biri olan Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi algoritmasını kullanarak tahmin edilmesi ile ilgili bir çalışma ortaya koymuşlardır.
- Çakıroğlu ve Süzen (2020), betonarme binaların deprem performanslarının yapay sinir ağı modeli ile tahmini üzerine bir çalışma yapmışlardır.

- Kaçın ve Aydın (2020), kirişlerde yükleme sonucu oluşan çatlakların tespit edilmesi, kiriş yüzey gerilmelerinin zamana bağlı değişiminin görselleştirilmesi ve kirişlerin yüzeyinde oluşacak olası çatlakların çatlama olmadan önce belirlenmesi amacı ile yapay sinir ağı tabanlı görüntü işleme tekniğini kullanmışlardır.
- Hou vd. (2021), yapmış oldukları çalışmada, yol yüzey kaplamalarının izlenmesi ve analizlerinde görüntü işleme teknikleri ile makine öğrenmesi yöntemlerinden destek vektör makinesi, yapay sinir ağları ve evrişimli sinir ağları yöntemlerini kullanarak hasar tespiti yapmışlardır.
- Hu vd. (2021), ulaşım alt yapısında çatlakların yeri ve kapsamına karşılık gelen şiddet seviyelerinin sınıflandırılması için derin öğrenmenin nesne algılama, görüntü sınıflandırma ve piksel bölütleme gibi parametrelerinden yararlanmışlardır.
- Hacıfendioğlu vd. (2022), yapmış oldukları çalışmada beton yollardaki çatlakları tespit etmek için önceden eğitilmiş derin öğrenme tabanlı daha hızlı R-CNN yöntemi kullanmışlardır. Çalışmalarında hava koşulları ve aydınlatma seviyesinin etkilerini de incelemişlerdir. Çalışmalarının sonucunda, aydınlatmanın çatlakların tespiti üzerindeki etkisinin oldukça yüksek olduğu anlaşılmıştır. Saatler ilerledikçe çatlak tespit oranı %75'e düşmüş, hava tamamen karanlıkken çatlakların %15'i tespit edilebilmişlerdir.

İnşaat mühendisliğinde derin öğrenme uygulamaları inşaat anabilim dallarına göre sınıflandırılarak Tablo 1’de gösterilmiştir.

Tablo 1. Literatür çalışmalarının inşaat mühendisliği ana bilim dallarına göre derlenmesi

Anabilim Dalı	Uygulama	Referans	Kullanılan Teknoloji
Yapı	Yapısal Hasar Tespiti	(Avcı ve Alemdar, 2019)	Görüntü İşleme
		(Santos vd., 2016)	Makine Öğrenimi
		(Kaçın ve Aydın, 2020)	Görüntü İşleme
		(Abdeljaber vd., 2018)	Derin Öğrenme
		(Lin vd., 2017)	Derin Öğrenme
		(Pathirage vd., 2018)	Derin Öğrenme
	Köprülerde hasar tespiti ve çatlak tahmini	(Mangalathu ve Burton, 2019)	Makine Öğrenimi
		(Neves vd., 2018)	Makine Öğrenimi
		(Okazaki vd., 2020)	Makine Öğrenimi
	Kolon ve kiriş birleşim noktalarının moment tahmini	(Cao vd., 2020)	Makine Öğrenimi

Tablo 1'in devamı

Anabilim Dalı	Uygulama	Referans	Kullanılan Teknoloji
Yapı	Deprem sonrası yapısal güvenliğin değerlendirilmesi	(Zhang vd., 2018)	Makine Öğrenimi
	Kolon-kiriş birleşim yerlerinin arıza modunun tahmini	(Gao ve Lin, 2021)	Makine Öğrenimi
	Betonarme binaların sismik tepkilerinin tahmini	(Hwang vd., 2021)	Makine Öğrenimi
	Deprem etkisi altında olan betonarme kirişsiz plakların eğilme momenti tahmini	(Özbayrak, 2019)	Yapay Sinir Ağları
	Köprü hasar önem ölçümü	(Chun vd., 2015)	Yapay Sinir Ağları
	Beton yüzey çatlaklarının belirlenmesi	(Lee vd., 2013)	Görüntü İşleme
	Beton yüzey çatlaklarının belirlenmesi	(Choudhary ve Dey, 2012)	Görüntü İşleme
	Betonarme yapının hasar türü tespiti	(Cha vd., 2018)	Derin Öğrenme
	Depremden etkilenen binaların hasar derecesine göre sınıflandırılması	(Mangalathu ve Burton, 2019)	Derin Öğrenme
Hidrolik	Baraj seviyeleri değişimi tahmini	(Arslan vd., 2020)	Makine Öğrenimi
	Akarsulardaki debinin hesaplanması	(Gemici vd., 2013)	Yapay Sinir Ağları
	Günlük buharlaşmanın hesaplanması	(Özdülkar vd., 2019)	Bulanık Mantık
Yapı Malzemeleri	Korozyon tespiti	(Atha ve Jahanshahi, 2018)	Derin Öğrenme
	Beton basınç dayanımı tahmini	(Doğan vd., 2017)	Görüntü İşleme
	Beton basınç dayanımı tahmini	(Khademi vd., 2017)	Yapay Sinir Ağları
Ulaştırma	Ulaşım ağı hızı tahmini	(Ma vd., 2017)	Derin Öğrenme
	Trafik kazalarının ve yaralı kişilerin sayılarının tahmin edilmesi	(Cansız vd., 2020)	Yapay Sinir Ağları
Yapı İşletmesi	Şantiyelerde işçilerin ve ağır araç gereçlerin otomatik algılanması	(Fang vd., 2018)	Derin Öğrenme
	Binalarda erken maliyet tahmini	(Günaydın ve Doğan, 2004)	Yapay Sinir Ağları
	İnşaat maliyet tespiti	(Kim vd., 2004)	Makine Öğrenimi
Geoteknik	İnce taneli zeminlerin kıvam sınıflarının tespiti	(Arama vd., 2020)	Makine Öğrenimi
	Geoteknik mühendisliğinde yapay sinir ağları	(Cha vd., 2018)	Yapay Sinir Ağları
	Geoteknik mühendisliğinde derin öğrenme	(Zhang vd., 2021)	Derin Öğrenme

1.3. Derin Öğrenme ile Tarihi Yığma Yapılarda Hasar Tespiti için Yapılan Bazı Çalışmalar

Literatürde tarihi yığma yapılardaki hasar tespitine geleneksel yöntemlerin yanı sıra çeşitli makine öğrenmesi yöntemlerinin sunulduğu görülmektedir. Bu tez kapsamında, tarihi yığma yapılarda hasar tespiti için makine öğrenmesinin bir alt dalı olarak literatürde yer alan derin öğrenme çalışmaları referans alınmıştır. Yapılan çalışmalar incelendiğinde, çalışmaların büyük çoğunluğunda derin öğrenme denilince akla ilk gelen model olan evrişimli sinir ağlarıdır (CNN).

Chaiyasarn vd. (2018), çalışmalarında, tarihi yığma yapılarda çatlak tespiti için evrişimli sinir ağları ve destek vektör makinelerine (SVM) dayalı bir yöntem sunmuşlardır. Çatlak algılama sistemini oluşturmak için evrişimli sinir ağlarını, sınıflandırma yapmak için destek vektör makinelerini kullanmışlardır. Çalışmalarında, ilk olarak insansız hava araçları kullanarak tarihi yığma yapılardan görüntüler elde etmişlerdir. Görüntüleri Tayland'da bulunan Wat Chai Watthanaram tapınağından almışlardır. Ardından, görüntüleri öznetelik çıkarıcı için evrişimli sinir ağlarına ve sınıflandırıcı için destek vektör makinelerine dayalı bir çatlak algılama sistemi oluşturmuşlardır. Toplanan görüntüler, evrişimli sinir ağları tarafından eğitim ve sınıflandırma için bir Matlab algoritması kullanılarak 96x96 boyutuna dönüştürerek 6002 adet görüntü elde etmişlerdir. Bu görüntüleri, çatlak ve çatlak olmayan görüntülere ayırmışlardır. Çatlak ve çatlak olmayan yamalar manuel olarak 0 veya 1 olarak etiketlemişlerdir. Evrişimli sinir ağı mimarisinde Keras kütüphanesini kullanmışlardır. Önerilen sistemin performansını değerlendirmek için ROC grafikleri ve karışıklık matrislerini kullanmışlardır. Önerilen yöntemin test sonuçları incelendiğinde, sadece evrişimli sinir ağlarını kullanarak %67,5, evrişimli sinir ağları ve destek vektör makinesi kombine yöntemi ile %74,9 doğruluk elde etmişlerdir. Bu çalışmanın sonucunda tarihi yığma yapılarda mevcut çatlakların derin öğrenme yöntemi ile otomatik olarak tespit edilebildiği anlaşılmıştır.

Wang vd. (2019), çalışmalarında, tarihi yığma yapıların yüzeylerinde meydana gelen çiçeklenme ve dökülme hasarlarını tespiti için derin öğrenme mimarilerinden olan ResNet-101 tabanlı R-CNN kullanmışlardır. Veri seti görüntüleri, Pekin'de bulunan Saray Müzesi duvarından alınmıştır. Dökülme ve çiçeklenmeden kaynaklanan hasarları içeren bir veri tabanı geliştirmek için toplanan görüntüler kırılarak 400 adet görüntü eğitim seti, 100 adet görüntü doğrulama ve test seti için kullanılmıştır. 500 adet görüntüdeki nesne etiketleri

(hasar türü) ve bunlara karşılık gelen sınırlayıcı kutuların koordinatları, .xml formatlı bir dosyada gösterilmiştir. Çalışmanın sonunda çiçeklenme için %99 ve dökülme için %90 doğruluk elde etmişlerdir.

1.4. Çalışmanın Amacı ve Kapsamı

Bu tez çalışmasında, tarihi yığma yapılarda oluşan çatlak hasarlarının teknolojiye ilerlemeler ve gelişen mühendislik teknikleri dikkate alınarak derin öğrenme yöntemleri ile otomatik tespit edilmesi hedeflenmiştir. Bu amaçla, çalışma kapsamında ResNet-50, VGG-16, VGG-19, Inception-V3 ve Xception önceden eğitilmiş derin öğrenme modelleri kullanılmıştır. Ek olarak, derin öğrenme yöntemlerini görüntü tabanlı veriler üzerinde açıklanabilir düzeye getirmek için Grad-CAM, Grad-CAM++ ve Score-CAM görselleştirme teknikleri kullanılmıştır. Elde edilen sonuçlar karşılaştırmalı olarak incelenmiştir.

1.5. Yapay Zeka

Yapay zeka, insan zekasının incelenmesi ile başlayan bir tarihe sahiptir. Ancak, resmi olarak ilk defa 1955 yılında John McCarthy tarafından Honever, New Hampshire Dartmouth College’da yapılan konferansta kullanılmıştır (McCarthy vd., 2006). Yapay zeka, yüzyıllar boyunca insanın akıl yürütmesini mantıksal bir biçimciliğe indirgeme girişimlerinden ortaya çıkmaktadır. Yapay zekâ, bilgisayarın ya da bilgisayar destekli bir makinenin, genellikle insanlara özgü nitelikler; kendi kendine öğrenme, çözüm bulma, anlama, genelleme ve önceki deneyimlerinden öğrenme gibi mantık süreçlerine ilişkin görevleri yerine getirme yeteneği olarak bilim dünyasında tanımlanmıştır (Nabiyev, 2012). İnsan beyninden esinlenen yapay zeka çalışmaları yaşamın farklı alanlarında (tahmin, sınıflandırma gibi amaçlar için kullanılmaktadır. Yapay sinir ağları, makine öğrenmesi, derin öğrenme gibi yöntemler, genel olarak yapay zeka teknolojileri olarak adlandırılmaktadır. Şekil 1’de yapay zekanın tarihsel gelişim süreci görülmektedir.



Şekil 1. Yapay zekanın tarihsel gelişim süreci (Çalışkan ve Demir, 2022)


1.6. Makine Öğrenimi

Makine öğrenimi, yapay zekanın bir alt dalıdır. Makine öğrenimi insan zekasından esinlenerek, insanın öğrenmesini temel alarak tasarlanmış gelişen bir hesaplama algoritmasıdır. Makine öğrenmesinin amacı, makinelere, bir insanın müdahalesi olmadan eğitim yoluyla öğrenme yeteneği kazandırarak, girilen verileri anlamlı çıktılara dönüştüren eğitilmiş bir sistem çıkarmaktır. Özetle makine öğrenimi, bir sürecin nasıl çalıştığına dair bir model tasarlar ve geliştirilen uygulamalarla işlemi pratik olarak oluşturur ve onu uygular. Bu pratik uygulama sebebi ile insan faktörlerini mühendislik uygulamalarına entegre etmek için makine öğrenimi geliştirilmiştir (Naqa vd., 2015).

Makine öğrenmesi, temelde öğrenme ve kendini geliştirme işlevi görür. Yeni bir veri girildiğinde hangi yolu izleyeceğini belirlemek için geçmiş bilgileri işler ve yeni verilere uyarlamak için harekete geçer. Yukarıda bahsedildiği gibi makine öğrenmesi, yapay zekanın uygulamalı şeklidir. Verileri toplayarak, depolayarak, analiz ederek ve kendi başına bir karar verme yeteneği geliştirerek makinelerin insanlar gibi öğrenmesini sağlar. Daha sonra, istatistiksel analiz kullanılarak yeni verilere karşı tahminde bulunmak için çıkarım yapma yeteneğine sahip model geliştirir (Yaraş, 2020).

Makine öğrenimi algoritmaları genellikle verileri tahmin etmek veya sınıflandırmak için kullanılır. Makine öğrenimi, el yazısı, ses tanıma, bilgisayar oyunları, doğal dil işleme,

beyin-makine arayüzü gibi birçok uygulama alanına sahiptir. Şekil 2’de temel makine öğrenme süreci gösterilmektedir.



Şekil 2. Temel makine öğrenmesi süreci (Gültepe, 2019)

Günümüzde mühendislik uygulamalarında da insan gibi düşünen ve insan gibi davranışlar sergileyebilen uygulamalara ağırlık verilmesi makine öğrenimindeki gelişmeleri hızlandırmaktadır.

1.7. Yapay Sinir Ağlarına Temel Giriş

Yapay sinir ağları (YSA), tamamen insan beyninin bilgi işleme tekniğinden esinlenerek geliştirilmiş bir bilgi işlem teknolojisidir. İlk yapay sinir ağı modeli 1943 yılında Warren McCulloch ve matematikçi Walter Pitts tarafından “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” başlıklı makale ile sunulmuştur (URL-1, 2016). Başlangıçta yapay sinir ağlarının oluşturulmasındaki temel amaç, insandaki sinir ağlarına benzer bir yapıyı matematiksel olarak tasarlayarak, insan gibi düşünebilen makineler oluşturmaktır. YSA yapay sinir hücrelerinin birbirlerine herhangi bir bağlantı şartı olmaksızın bağlanmasıyla oluşur. YSA verilerden öğrenebilme, sınırsız sayıda değişkenlerle çalışabilme gibi birçok önemli özelliğe sahiptir. YSA, girilen veriler ile çıkan veriler arasındaki herhangi bir ön talimata gereksinim duymadan doğrusal ve doğrusal olmayan modellemeyi sağlayabilmektedir (Ataseven, 2013). Yapay sinir ağı Şekil 3’de görüldüğü gibi temel olarak


giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır (Chollet, 2017). Giriş katmanında veriler sisteme aktarılmaktadır. Bu katmanda kullanılan düğüm sayısı var olan veriyi en elverişli şekilde temsil eden öznitelik sayısına eşittir. Giriş katmanındaki değerler gizli katmana aktarılmaktadır. Gizli katmanlarda, girdi katmanından gelen bilgiler işlenip bir çıktıya dönüştürülmektedir. Çıktıya dönüştürme işlemi, yapay sinir ağının ağırlık değerleri kullanılarak gerçekleştirilmektedir. Gizli katman sayısı problemin zorluğuna göre çeşitlilik gösterebilmektedir. Bu işlemler sonucunda elde edilen değerler çıkış katmanına aktarılır. Çıkış katmanında ise bu katmanda bulunan her bir düğüme gelen verilere belirli toplama işlemleri uygulanır. Sonrasında Bölüm 1.8’de bahsedilen aktivasyon fonksiyonlarından ihtiyaca yönelik olan tespit edilerek kullanılır ve sonuç değerleri elde edilir. Sınıflandırma problemlerinde bu katmandaki düğüm sayısı tahmin edilecek olan etiket sayısına eşittir. Yapay sinir ağlarında üç çeşit öğrenme mevcuttur. Bunlar takviyeli öğrenme, denetimli öğrenme ve denetimsiz öğrenmedir. Denetimli öğrenmede, işlemler etiketli veriler ile yapılır. Yani doğruluğunu denetleyerek öğrenme vardır. Denetimsiz öğrenmede, veriler etiketlenmemiş olarak verilir. Makine kendi başına öğrenir. Takviyeli öğrenmede ise, bir öğretici bulunmaktadır (Kılınç ve Baysal, 2018).

YSA tahmin, sınıflandırma, yorumlama, veri ilişkilendirme vb. konularda kullanılmaktadır. YSA modelleri, çok katmanlı yapay sinir ağları, tek katmanlı yapay sinir ağları, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere dört farklı grup olarak incelenebilir (Öztürk ve Şahin, 2018).

Günümüzde yapay zekâ kullanılarak çözümlenen problemlerin çeşitliliği giderek artmakta ve o probleme ilişkin veri sayısı da çoğalmaktadır. Bir uygulamada ne kadar çok veri bulunursa o kadar iyi yapay zekâ özellikleri açığa çıkmakta olup işler daha karmaşık hale gelebilmektedir. Dolayısıyla uygulama tercihleri yapay zekâdan makine öğrenimine doğru kayacaktır. Karmaşıklık düzeyi arttıkça da makine öğreniminden derin öğrenmeye geçişler başlayacaktır. Ayrıca YSA, günümüzde derin öğrenme olarak isimlendirilen yaklaşımının temelini oluşturmaktadır.

1.7.1. Tek Katmanlı Yapay Sinir Ağları


Tek katmanlı yapay sinir ağları girdi ve çıktıdan oluşmaktadır. Genellikle, lineer olarak ayrılabilen sınıflandırma problemlerinde kullanılmaktadır. Çıktı fonksiyonu 1 veya -1 değerini almaktadır (Öztürk ve Şahin, 2018).



Şekil 3. Tek katmanlı yapay sinir ağı modeli (Öztürk ve Şahin, 2018)

1.7.2. Çok Katmanlı Yapay Sinir Ağları


Çok katmanlı yapay sinir ağları; birden çok girdi katmanına ve birden çok gizli katmana sahip olabilmektedir. Gizli katmanların sayısı problemin çözümüne göre artırılabilir veya azaltılabilir. Çok katmanlı yapay sinir ağları, karmaşık problemlerin çözümünde kullanılmaktadır.



Şekil 4. Çok katmanlı yapay sinir ağı modeli (URL-2, 2022)

1.7.3. İleri Beslemeli Yapay Sinir Ağları


İleri beslemeli YSA, çok katmanlı yapay sinir ağlarının bir çeşididir. İleri beslemeli yapay sinir ağlarında, nöronlar giriş katmanından çıkış katmanına doğru düzenli katmanlar şeklindedir. Bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır.



Şekil 5. İleri beslemeli yapay sinir ağı modeli (Öztürk ve Şahin, 2018)

1.7.4. Geri Beslemeli Yapay Sinir Ağları


Geri beslemeli yapay sinir ağlarında, bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmeyip kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir nörona girdi olarak bağlanabilir. Bu yapısı nedeniyle, dinamik bir davranış göstermektedir (Öztürk ve Şahin, 2018). Verilen problemi çözerken oluşabilecek hatayı en aza indirmek üzere yapılandırılmış bir sinir ağıdır.



Şekil 6. Geri beslemeli yapay sinir ağı modeli (Öztürk ve Şahin, 2018)

1.8. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları sinir ağlarında oldukça önemli rol oynamaktadır. Yapay sinir ağındaki girdilere belirli aktivasyon işlemleri uygulayarak çıktı verilerini elde etmemizi sağlayan fonksiyonlardır. Basit bir şekilde anlatmak gerekirse, yapay bir sinir ağında x girdiler, w ağırlıklar olarak tanımlanır ve ağın çıkışına aktarılan değere $f(x)$ yani aktivasyon fonksiyonu uygulanır (URL-3, 2022). Aktivasyon fonksiyonu olmayan bir yapay sinir ağı, verilerdeki karmaşık yapıları öğrenip tespit etmekte zorlanacaktır. Şekil 7’de aktivasyon fonksiyonunun çalışma prensibi gösterilmektedir. Aşağıda yaygın olarak kullanılan aktivasyon fonksiyonları hakkında bilgiler verilecektir.



Şekil 7. Aktivasyon fonksiyonunun çalışma prensibi (Kızrak ve Bolat, 2018)

1.8.1. Sigmoid Aktivasyon Fonksiyonu

Bir Sigmoid fonksiyonu, karakteristik “S” şeklinde bir eğriye sahip olan matematiksel bir işlevdir. Sigmoid fonksiyonu, doğrusal olmaması ve türevinin hesaplanma basitliği nedeniyle ileri beslemeli sinir ağlarında kullanılan en yaygın olarak bilinen işlevdir. Aldığı değerler $[0,1]$ arasındaki karşılığını üretir. Olasılık problemlerinin çözümlerinde kullanılan bir fonksiyondur (Ding vd., 2018). Denklem 1’de sigmoid aktivasyon fonksiyonunun matematiksel ifadesi verilmiştir.

$$Sigmoid(x) = \frac{1}{1+e^x} \quad (1)$$

Yukarıdaki denklemde; x girdi verisi, e Euler sayısıdır.

1.8.2. Hiperbolik Tanjant Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonu ile benzerlik göstermektedir. Bu aktivasyon fonksiyonu $[-1, 1]$ arasında deęerler üretir. Denklem 2’de hiperbolik tanjant aktivasyon fonksiyonunun matematiksel ifadesi gösterilmiştir.

$$\tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (2)$$

Yukarıdaki denklemde verilen x girdi verisi e ise Euler sayısıdır.

1.8.3. ReLU Aktivasyon Fonksiyonu

Günümüzde en çok kullanılan aktivasyon fonksiyonudur. Doğrultulmuş doğrusal birimler anlamına gelmektedir. ReLU aktivasyon fonksiyonu $[0, +\infty]$ arasında deęerler üretmektedir (Zeiler vd., 2013). ReLU aktivasyon fonksiyonunun çok tercih edilmesinin sebebi sıfırdan büyük olan girdiler için sabit türev deęerine sahip olmasıdır (URL-4, 2022). Bir dięer sebep de, hesaplama yükünün az olmasıdır. Bu da, çok katmanlı yapay sinir aęlarında rahatlıkla kullanılmasına neden olmuştur. Fonksiyonun matematiksel modeli Denklem 3’de gösterilmiştir.

$$ReLU(x) = \max(0, x) \quad (3)$$

Yukarıdaki denklemde verilen x girdi verisidir.

1.8.4. Sızdıran ReLU Aktivasyon Fonksiyonu

Sızdıran ReLU aktivasyon fonksiyonu, ReLU aktivasyon fonksiyonunun geliştirilmiş bir sürümü olarak düşünülebilir.

1.8.5. Softmax Aktivasyon Fonksiyonu

Softmax, bir sayı vektörünü bir olasılık vektörüne dönüştüren matematiksel bir fonksiyondur. Softmax fonksiyonunun uygulamalı makine öğreniminde en yaygın kullanım şekli, bir sinir ağı modelinde aktivasyon fonksiyonu olarak kullanılmasıdır. Çoğunlukla sınıflandırma problemlerinde kullanılmaktadır. Yapay sinir ağı kullanılışında genellikle sinir ağının en son katmanı olarak kullanılır. Fonksiyonun matematiksel ifadesi Denklem 4'te gösterilmiştir.

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (4)$$

Yukarıdaki denklemde; $\vec{z}$ softmax fonksiyonunun girdi vektörü i, j ve k verilen değerlerdir.

1.9. Derin Öğrenme

Derin Öğrenmenin temelleri, 1943 yılında 1 ve 0'larla basit bir sinir ağı modeli tasarlayan Warren McCulloch ve Walter Pitts tarafından atılmıştır. İsmi geçen iki sibernetikçi çözümlenmesi istenen bir problemi, sinir ağındaki çıkış değerinde eşik değerini aşarsa "1", aşamazsa "0" değerini veren ve bu şekilde çalışan basit bir hesaplama yöntemi geliştirmişlerdir. 1958 yılında ise Frank Rosenblatt, başka bir eğitim algoritması modeli geliştirerek şu anki öğrenme mantığına yakın bir durumda olan bir sistemle ikili sınıflandırma problemini tek bir sinir ağında hesaplama yöntemi oluşturmuştur. 1958 yılından 1990'lı yıllara kadar çeşitli yöntemler geliştirilse de teknolojik gelişmelerin o yıllarda ki yavaşlığından dolayı derin öğrenme konusunda fazla bir ilerleme olmamıştır (Ayas, 2020). Ancak 1990'lı yıllardan sonra bilgisayar çalışma hızlarının artması ve grafik işlemci birimlerinin (GPU) ve diğer donanımsal gelişmelerin hız kazanmasıyla bu birimler hesaplamalarda kullanılmaya başlanmıştır. Böylece, çok sayıda gizli katmandan oluşan yapay sinir ağları hesaplama maliyetlerini düşürmektedir. Derin öğrenmede büyük gelişmeler gerçekleşerek hesaplama hızı, 10 yıllık bir sürede yaklaşık 1000 kat artmıştır (Schmidhuber, 2015). Yapay sinir ağı bağlamında ilk kez "Derin Öğrenme" ifadesi 2000 yılında Igor Aizenberg ve arkadaşları tarafından tanıtılmıştır (Aizenberg vd., 2000).

ILSVRC 2012 ImageNet Challenge yarışması, toplamda 1,2 milyon eğitim görüntüsünden ve 1000 tane sınıftan oluşan bir veri kümesindeki verileri doğru sınıflara ayıracak model önermeye dayalı bir yarışma gerçekleştirilmiştir. 2012 yılında düzenlenen bu yarışmadan sonra derin öğrenme konusu bilim dünyasında yankı uyandırarak çalışmaların hızlanmasına sebep olmuştur (Ayas, 2020). 2015 yılında LeCun ve arkadaşlarının (1989), Nature Dergisi'nde yayımladığı bir makalede de derin öğrenmenin günümüzde kullanılan şekli tanımlanmıştır (İnik ve Ülker, 2017).

Derin öğrenme, bir veya birden fazla katman içeren yapay sinir ağlarına dayanır ve makine öğrenmesi algoritmalarını kapsar. Başka bir deyişle; üzerinde herhangi bir işlem yapılmamış veri girdisinden aşamalı olarak üst düzey özellikleri çıkarmak için birden fazla katman kullanan bir makine öğrenmesi algoritmaları sınıfıdır (Şeker vd., 2017). Derin öğrenme, bir makinenin önceki katmanındaki temsilden yararlanarak her katmandaki gösterimi hesaplamak için kullanılan dâhili parametrelerin nasıl değiştirilmesi gerektiğini belirleyebilmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder (LeCun vd., 1989). Böylece girdi verisinin üst düzey özelliklerini öğrenebilmektedir. Ayrıca derin öğrenme, kalabalık veri kümelerinde yüksek doğruluk sağlayan bir mekanizmaya sahiptir.

Derin öğrenme, birden fazla işlem katmanından oluşan hesaplama modellerinin birden fazla soyutlama düzeyiyle verilerin temsillerini öğrenmesine de olanak tanımaktadır. Makinelerin düşünce gerektiren herhangi bir problem hakkındaki karmaşık sorunların çözümünü gerçekleştirebilir. Derin öğrenmenin sağladığı diğer bir kolaylık da kalabalık veri kümelerinde yüksek doğruluk sağlaması ve pek çok işlemi bir arada yürüterek sonuca gidebilmesidir (He vd., 2016). Son yıllarda makine öğreniminin bir türevi olan derin öğrenme, dillerin çevrilmesi, konuşmaların tanınması, nesnelerin algılanması, tahmin, sınıflandırma gibi birçok görevde yaygın olarak kullanılmaya başlanılmıştır. Derin öğrenme, günümüzde akla gelebilecek hemen hemen her alanda kullanılmaktadır. Bu kullanım alanlarının en bilindikleri şu şekildedir:

Çeviriler: Derin öğrenme algoritmaları sayesinde farklı diller arasında çeviri yapabilmektedir.

Sanal Yardımcılar: Siri vb. çevrimiçi servis sağlayıcıların sanal asistanları, konuşmaları ve insanların onlarla iletişime geçtiklerinde kullandıkları dili anlamalarına yardımcı olmak için derin öğrenme kullanmaktadır (URL-5, 2022).

Güvenlik ve Savunma Sistemlerinde: Siber tehdit çözümlemelerinde de derin öğrenme yöntemleri geliştirilmektedir. Savunma sistemlerine örnek olarak Türkiye’de ASELSAN’ın ARGE merkezinde yürütülen güvenlik sistemleri için görüntü ve doğal dil işleme alanlarındaki faaliyetleri örnek gösterilebilir (URL-6, 2022).

Yüz Tanıma ve Ses Tanıma Sistemlerinde: Derin öğrenme yüz tanıma özelliği sayesinde yalnızca güvenlik amaçlı değil, aynı zamanda Facebook gibi uygulamalarda gönderilerdeki insanları etiketlemek için de kullanılmaktadır. Yüz tanıma derin öğrenme algoritmalarının karşılaştığı zorluklar vardır, ancak derin öğrenme yeteneklerinin gelişmesiyle birlikte kişilerin saç stilleri değiştiğinde, sakal bıraktıklarında, tıraş olduklarında veya kişi görüntüsünün kötü aydınlatma gibi nedenlerle zayıf olduğu durumlarda bile aynı kişinin yüz tanımlamasını yapabilmeleridir (URL-5, 2022).

İlaç ve Tıbbi Ürünler: Hastalıkların erken tanısında, kanserli hücre örneklerinin tanıtıldığı derin öğrenme algoritmaları, yeni hücrelerin kanserli olup olmadığı tanısını koymakta hem daha hızlı hem de daha başarılı olmaktadır.

Görüntü Renklendirme: Derin öğrenme algoritmaları ile resimlerdeki kaynağı ve nesneleri, siyah-beyaz görüntüyü renkli olarak oluşturmak için kullanabilmektedir.

Kişiselleştirilmiş Alışveriş ve Eğlence: Yani, Netflix gibi video, film platformlarında kişi yönelimine göre sonradan izlenmesi potansiyeli olan filmlerin önerilmesi ya da Amazon gibi alışveriş sitelerinde dolaşırken kişi eğilimine göre ürün önerilerinin çıkması gibi tavsiye edilen ürünlerin hepsi derin öğrenme algoritmaları tarafından yönetilmektedir.

Yukarıda derin öğrenmenin kullanım alanlarından birkaçı verilmiştir. Görüntü sınıflandırma, nesne bulma, nesne takip etme vb. örneklerle bu uygulama alanlarını genişletmek mümkündür.

Geleneksel derin öğrenme mimarileri derin sinir ağları, oto kodlayıcılar, derin inanç ağları, sınırlı Boltzmann makinesi, tekrarlayan sinir ağları ve evrیشimli sinir ağlarıdır (Akinosho vd., 2020).


1.9.1. Evrişimli Sinir Ağı (CNN)

Derin öğrenme denilince akla ilk gelen model Evrişimli Sinir Ağı modelidir. Biyolojiden ilham alınarak üretilmiştir ve ismini matrisler arasındaki matematiksel işlemlerden alır. Evrişimli sinir ağları, 2012 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması’nda birinci olan AlexNet algoritmasında kullanıldıktan sonra popülerlik kazanmış


ve günlük hayatımızda farklı alanlarda yer almaya başlamıştır. Görüntü işlemeden ses tanımaya kadar birçok alanda kullanılarak bir çığır açmıştır. Şekil 8’de verilen ilk evrişimli sinir ağı (CNN), 1988 yılında Yann LeCun tarafından ortaya atılan, LeNet isimli mimaridir.

Evrişimli sinir ağı yaygın olarak görüntü işleme problemlerinde kullanılmaktadır. Evrişimli sinir ağı bilgisayarda görüntüyü girdi olarak alır ve görüntünün çözünürlüğüne ve boyutuna bağlı olarak bir dizi piksel değeri gösterir. Girdi olarak sağlanan görüntüler, bilgisayarlar tarafından bir formata çevrilmelidir. Bu nedenle görüntüler kullanımdan önce bilgisayar tarafından tanınabilecek matris formatına dönüştürülür. Ardından bilgisayar görüntünün boyutuna ve çözünürlüğüne bağlı olarak bir takım sayı dizisi oluşturur.

Evrişimli sinir ağı evrişim katmanı, havuzlama katmanlarından meydana gelmektedir (Akdoğan, 2021). Örnek bir evrişimli sinir ağı yapısı Şekil 9’da gösterilmiştir.



Şekil 8. LeNet ağı mimarisi (Le Cun vd., 1989)




Şekil 9. Örnek evrişimli sinir ağı yapısı (Peemen vd., 2016)

1.9.1.1. Evrişim Katmanı

Evrişim katmanı, evrişimli sinir ağının ana yapı taşıdır. Eğitim boyunca parametreleri öğrenebilecek bir dizi filtre içerir. Filtrelerin boyutu gerçek görüntü boyutundan daha küçüktür. Her filtre, görüntü ile birleşir ve bir aktivasyon haritası oluşturur. Evrişim katmanında kullanılacak örnek bir filtre Şekil 10’da gösterilmektedir. Ayrıca, evrişim katmanında gerçekleşen matris işlemleri de Şekil 11’de verilmiştir.

0	1	2
2	2	0
0	1	2

Şekil 10. Evrişim katmanında kullanılacak örnek bir filtre (Akdoğan, 2021).



Şekil 11. Evrişim katmanında gerçekleşen matris işlemleri (Akdoğan, 2021).

Şekil 11’de görülen 3 x 3 boyutunda bir filtre matrisi ile mavi renkli 5 x 5 boyutundaki ana matris işleme girer. Burada gerçekleşen işlem filtre matrisinin ana matris üzerinde her


adımında kayarak ilerlemesiyle gerçekleşir. İlk adımda gerçekleşen işlem ayrıntılı olarak incelenirse;

$(3 \times 0) + (3 \times 1) + (2 \times 2) + (0 \times 2) + (0 \times 2) + (1 \times 0) + (3 \times 0) + (1 \times 1) + (2 \times 2) = 12$ değeri elde edilir (Akdoğan, 2021).

1.9.1.2. Havuzlama Katmanı

Havuzlama katmanı, bir evrişimli sinir ağının başka bir yapı taşıdır. Parametreleri ve hesaplama miktarını azaltma işlemini görür. Bu işlem bir sonraki ağ katmanları için daha az hesap yükü oluşturur ve ayrıca sistemin ezberlemesini önler. Havuzlama katmanının çalışma prensibi de evrişim katmanının çalışma prensibine benzer. Evrişim katmanında olduğu gibi ortaklama katmanında da belirli filtreler tanımlanır. Ortaklama katmanı isteğe bağlıdır. Bir filtre seçilerek önceki evrişim katmanının çıktı özellik haritası üzerinde kaydırılır. Havuzlama için birkaç yaklaşım vardır. En yaygın olarak kullanılan yaklaşımlar, maksimum havuzlama ve ortalama havuzlamadır. Şekil 12’de havuzlama işleminin yapılışı ile ilgili örnek verilmiştir.


Şekil 12’de giriş görüntüsünün boyutu 4x4 ve filtre boyutu 2x2’dir. Bir adım kaydırılacak şekilde oluşan görüntünün boyutu 3x3 olacaktır. İki adım kaydırılacak şekilde oluşan görüntünün boyutu ise 2x2 olacaktır.



Şekil 12. 4x4’lük boyuta sahip giriş görüntüsüne 2x2 boyuta sahip filtre ile bir ve iki adım kaymalı maksimum havuzlama işleminin uygulanması (İnik ve Ülker, 2017)

1.9.2. Öğrenme Aktarımı

Öğrenme aktarımı, bir görev için eğitilmiş bir modelin farklı bir görev için yenilendiği bir makine öğrenme yöntemidir (Hacıfendioğlu vd., 2022). Böylelikle sakladığı bilgiyi karşılaştığı problemde kullanabilir. Öğrenme aktarımının çalışma prensibi; özellikleri bilinen bir modelden elde edilen öğrenme, modele yeni katmanlar eklenip taşınarak yeni veri kümesine uygulanması şeklindedir. Bu sayede, daha az eğitim verisi ile daha yüksek performans gösteren modeller elde edilir. Ayrıca, öğrenme aktarımı bir ağı sıfırdan eğitmekten çok daha hızlı, daha kolay ve daha etkilidir. Bu nedenle, sıklıkla kullanılmaktadır. Örnek tabanlı öğrenme aktarımı, özellik tabanlı öğrenme aktarımı, parametre tabanlı öğrenme aktarımı ve ilişki tabanlı öğrenme aktarımı dahil olmak üzere bilgi aktarımı için dört genel aktarım kategorisi vardır. VGG-16, VGG-19, ResNet, Inception-V3, Xception ve ImageNet gibi modeller, öğrenme aktarımında önceden eğitilmiş modeller için kullanılmaktadır. Şekil 13’de öğrenme aktarımı süreci gösterilmektedir.




Şekil 13. Çatlak tespiti için öğrenme aktarımı

1. 9. 3. ResNet-50 Modeli

Bu model, evrimsel sinir ağlarının geliştirilmiş bir versiyonudur (He vd.,2016) ve ResNet yapısında, “artık” olarak isimlendirilen bloklardan oluşmaktadır. Şekil 14’de artık blok örneği gösterilmektedir. ResNet birkaç eğitim katmanını atlayarak doğrudan çıktı katmanına bağlanmaktadır. Yığılmış katmanların sayısı, modelin özelliklerini zenginleştirebilirken, sinir ağının katman sayısının artması ile doğruluk seviyelerini doygun hale getirebilir ve bir noktadan sonra yavaş yavaş düşürebilir. Bu bozulma, modelin aşırı


uyum göstermesinin bir sonucu değildir. Bunun yerine, ağı başlatılmasından, optimizasyon işlevinden veya daha da önemlisi, yok olma veya gradyanların patlaması sorunundan kaynaklanabilir. Bu sebeple, ResNet-50 mimarisi, katman sayısı arttıkça eğitim başarısı artar yanılığını ortadan kaldırarak kaybolan gradyan sorununu önlemiş olur (Hacıfendioglu vd., 2022). ResNet mimarisinin matematiksel modeli Deklem 5’de gösterilmiştir Burada $f(x)$ aktivasyon fonksiyonunu, x ise girdiğimiz kısayol bağlantılarını ifade etmektedir. $H(x)$ ise gerçek çıktıyı ifade etmektedir.

$$H(x) = f(x) + x \quad (5)$$



Şekil 14. Artık blok örneği (He vd., 2016)

Resnet-50, ImageNet (14 milyondan fazla görüntüden oluşan bir görüntü veri tabanı) veri setinde eğitilmiş 50 katmanlı bir ağıdır. ResNet, diğer derin öğrenme mimari yapılarına göre daha fazla katman içermektedir ve aynı VGGNet’lerde olduğu gibi giriş görüntüsü $224 \times 224 \times 3$ boyutundadır. Resnet modeli 2 adet (3×3) evrişim katmanı kullanmak yerine (1×1) , (3×3) , (1×1) evrişim katmanlarını kullanır. ResNet-50, VGG-16 ve VGG-19’den çok daha derin olmasına rağmen, model boyutu daha küçüktür. ResNet-50 modelinin birçok avantajı vardır. Bunlardan birkaçı derin ağlar için eğitimde hızlanma sağlamasıdır. Görüntü sınıflandırmalarında daha yüksek doğruluk sağlamaktadır. Ağı genişletmek yerine ağı derinliğinde artış sağlamaktadır. Sonuç olarak ResNet-50, hata yüzdesini en aza indirerek derin sinir ağlarının verimliliğini artırmaktadır. Şekil 15’de ResNet-50 mimarisinin modeli gösterilmektedir.




Şekil 15. ResNet-50 mimarisi (He vd., 2016)

1.9.4. VGG-16 Modeli

VGG'nin kısaltması bu ağı oluşturan Görsel Geometri Grubu'ndan gelmektedir. VGGNet modeli, ImageNet veri setinden alınmış bir milyondan fazla görüntü ile eğitilmiş bir evrişimli sinir ağı modelidir (Simonyan ve Zisserman 2015). Büyük ölçekli görsel tanımayı için tasarlanmıştır. VGG modelleri, önceden eğitilmiş modellere kıyasla hem hız hem de doğruluk açısından büyük gelişmeler sağlamıştır. Bu durum, modelin derinliğinin daha gelişmiş olmasından ve önceden eğitilmiş modellerin tanıtılmasından kaynaklanmaktadır. VGG modelleri evrişim katmanlarını ikili, üçlü ve dördü olarak kullanabilmektedir. Modelin her evrişim katmanı çıkışında ağırlıkları farklı olan filtreler hesaplanmaktadır.

VGG-16, 16 katmandan oluşan evrişimli bir sinir ağıdır. VGG-16 mimarisi, havuz ve tamamen bağlı katmanlardan oluşur (Toğaçar vd., 2020). VGG-16 modelleri evrişim katmanlarında 3x3 filtre içermektedir. Giriş katmanı 224x224x3 boyutundadır. VGG-16 mimarisi şekil 16'da gösterilmektedir.



Şekil 16. VGG-16 mimarisi (Simonyan ve Zisserman, 2015)

1.9.5. VGG-19 Modeli


VGG-19 modeli, VGG-16 algoritmasının hemen ardından geliştirilen bir ağ modelidir (Simonyan ve Zisserman, 2015). VGG-19 modelleri evrişim katmanlarında 3x3 boyutunda filtre içermektedir. Giriş katmanı 224x224x3 boyutundadır. ImageNet veri seti ile %88 doğruluk yakalamış bir derin öğrenme ağ modelidir. Bu modelin en büyük avantajı, kodunun açık kaynak kodlu olması, öğrenme aktarımını kolayca uygulayabilir ve ağı diğer mimariler için çalışmasını sağlayabilmesidir (Khilar vd., 2021). VGG-19 modeli 19 eğitilebilir katmandan oluşmaktadır. Şekil 17’de VGG-19 mimarisi gösterilmektedir.



Şekil 17. VGG-19 mimarisi (Jeong vd., 2020)

1.9.6. Xception Modeli


Xception, Keras üreticisi Francois Chollet tarafından önerilen bir mimaridir. Birden fazla katman ve derin ayrılabilir evrişimli katmanlar içermektedir (Chollet, 2017). Xception modeli 14 artık blok, 3 ortak evrişim katmanı ve toplamda 33 derinlemesine ayrılabilir evrişim katmanını içermektedir (Gao ve Lin, 2021). Üç ortak evrişim katmanının tümü ön işleme modülündedir. Xception modeli, ImageNet veri setinde %94,5 doğruluk oranı elde etmiştir. Görüntü girişi 299x299x3 boyutundadır. Şekil 18’de Xception modelinin mimarisi gösterilmektedir.



Şekil 18. Xception mimarisi (Güldemir ve diğerleri, 2021)

1.9.7. Inception-V3 Modeli

Inception-V3, öncelikle Keras tarafından geliştirilen ve Image Net'te önceden eğitilmiş bir ağ yapısıdır. Inception-V3'e dayalı ağ yapısı çok küçük veri kümeleri üzerindeki mükemmel performansı nedeniyle son yıllarda bilim adamlarının dikkatini çekmektedir (Dong vd., 2020). Inception-V3 modülü tipik olarak üç farklı boyutta evrişim ve bir maksimum havuzlama içermektedir. Varsayılan görüntü giriş boyutu $299 \times 299 \times 3$ 'dür. Inception-V3 yapısı Şekil 19'da gösterilmektedir. Inception-V3 ağ yapısı, büyük hacimli integralleri küçük kıvrımlara bölmek için bir evrişim çekirdeği bölme yöntemi kullanır. Bölme yöntemi ile parametre sayısı azaltılabilir; bu nedenle, uzamsal özellik daha etkin bir şekilde çıkarılırken ağ eğitim hızı hızlandırılabilir. Inception-V3 ağı, nesne algılamada kullanıldığında, küçük ve düşük çözünürlüklü nesneleri sınıflandırmada iyi performans göstermektedir. VGGNet modelleri ile karşılaştırıldığında, Inception-V3 modelinin hem ağ tarafından üretilen parametre sayısı hem de bellek ve diğer kaynaklar açısından hesaplama açısından daha verimli olduğu kanıtlanmıştır (Hacıfendioğlu vd., 2022).



Şekil 19. InceptionV3 mimarisi (Hacıfendioğlu vd., 2022)

1.9.8. Sınıf Aktivasyon Haritası Yaklaşımı (Grad-CAM)

Sınıf aktivasyon haritası yaklaşımı derin öğrenme tekniklerini görüntü tabanlı veriler üzerinde açıklanabilir düzeye getirmek için sıklıkla tercih edilen yöntemlerden biridir. Başka bir deyişle evrişimli sinir ağ tabanlı ağ için görsel açıklamalar üreten ve sınıf ayrımı yapan bir yerleştirme tekniğidir. Bu yaklaşım, özellik haritalarının farklı sınıf sonuçları neticesinde bir araya toplanarak aktivasyon haritaları oluşturulması ve bu haritaların giriş verisi üzerinde modelin odaklandığı görsel bölgeleri gösterecek şekilde kullanıcıya yansıtılmasına imkan sağlamaktadır (Fu vd., 2019). Ayrıca, yüksek çözünürlüklü ve sınıf ayrımcılığı olan görselleştirmeleri oluşturmaya imkan sağlamaktadır. İlgili karara karşılık gelen görüntünün önemli bölgeleri, olası kavram için birden fazla kanıt içeriyor olsa bile, sınıf aktivasyon haritası yaklaşımı sayesinde karar yüksek çözünürlüklü ayrıntılarla görselleştirilir (Şeker vd., 2017).

Sınıf aktivasyon haritası yaklaşımı çoğunlukla görüntü sınıflandırma problemlerinde kullanılmaktadır. Görüntü sınıflandırma problemlerinde, veri kümesindeki önyargıları ortaya çıkararak arıza modlarının teşhis edilmesine yardımcı olur. Sınıf aktivasyon haritası yaklaşımı belirli bir ilgilenilen karar için her bir nörona önem değerleri atamak için evrişimli sinir ağlarının son evrişimsel katmanına akan gradyan bilgisini kullanır.

Grad-CAM++, bir Grad-CAM yönteminin bir uzantısıdır (Chattopadhyay vd., 2018). Çok etiketli sınıflandırma problemlerinde, aynı sınıfın tanımlanmış özelliklerinin daha iyi yerleştirilmesinde faydalıdır. Ek olarak, belirli bir sınıf sıralamasına göre son evrişimli katman gradyanı özellik haritasındaki her pikselin değerini yakalamak için modeldeki diğer

piksellere farklı ağırlıklar atar ve bu da daha iyi görselleştirmesiyle sonuçlanır (Chattopadhyay vd., 2018).

Gradyan tabanlı CAM'lerdeki mevcut sorunlara bir çözüm olarak yeni bir CAM tabanlı görsel açıklama yöntemi olan Score-CAM önerilmektedir (Wang vd., 2020). Score-CAM, evrişimli katmanlardan oluşan bir koleksiyon kullanarak belirli bir sınıf için görüntüler oluşturur. Aktivasyon haritasını oluşturmak için evrişimli sinir ağlarının son katmanındaki gradyan bilgisini kullanan Grad-CAM ve Grad-CAM++'ın aksine, Score-CAM belirli bir hedef sınıf için elde edilen puanın ağırlıklarını kullanır. Sonuç olarak, Score-CAM, gradyan bağımlılığını ortadan kaldırır ve yalnızca modelin sınıf etkinleştirme haritasına ve performans puanına erişim gerektiren daha genel bir sistem olarak işlev görür (Wang vd., 2020). Score-CAM anlamlı bir belirginlik haritası oluşturmak için gereksiz gürültüyü ve gradyanlara olan bağımlılığı ortadan kaldırır. Özetle Grad-CAM, Grad-CAM++ ve Score-CAM herhangi bir evrişimli sinir ağı mimarisinde kullanılabilir.

1.10. Ölçüm Metrikleri

Derin öğrenmede, performans ölçümü önemli bir konudur. Çeşitli sınıflandırma problemlerinin çözümünde çözümün verimliliğini değerlendirecek farklı yöntemler kullanılabilir. Bu tez çalışmasında kullanılacak yöntemlerden ilki karışıklık matrisidir. Karışıklık matrisi, sınıflandırma problemlerindeki tahmin sonuçlarının özetini sunmaktadır. Karışıklık matrisi kullanılarak sınıflandırıcı ile yapılan hatalar hakkında fikir edinilebilmektedir. Karışıklık matrisi aynı zamanda modelin yaptığı hata türleri hakkında da fikir verir. Sınıflandırma problemlerinde modelin performansını tanımlamak için sıklıkla kullanılmaktadır. Karışıklık matrisi için dört farklı durum söz konusudur. Bu terimler True:1 ve False:0 olmak üzere aşağıda açıklanmaktadır.

True Positive- Doğru Pozitif (TP): 1 olarak isimlendirilen ve gerçekten de 1 olan değerlerin sayısı.

False Positive- Yanlış Pozitif (FP): 1 olarak isimlendirilen fakat gerçekte 0 olan değerlerin sayısı.

True Negative -Doğru Negatif (TN): 0 olarak isimlendirilen ve gerçekten de 0 olan değerlerin sayısı.

False Negative-Yanlış Negatif (FN): 0 olarak isimlendirilen fakat gerçekte 1 olan değerlerin sayısı.

Tahmin Edilen

Gerçekleşen	True Positives (TP) Doğru Pozitif	False Negatives (FN) Yanlış Negatif
	False Positives (FP) Yanlış Pozitif	True Negatives (TN) Doğru Negatif

Şekil 20. Karışıklık matrisi (URL-7, 2021)

Ölçüm metrikleri karışıklık matrisini oluşturan TN, FN, FP ve TP terimlerinden oluşmaktadır. Bu tez çalışmasında, çalışma çıktılarının değerlendirilmesinde doğruluk (accuracy), duyarlılık (recall), kesinlik (precision), F ölçütü (F-Score), alıcı işletim karakteristiği (ROC-Receiver Operator Characteristic) ve bu karakteristiğin altında kalan gelen bölge (AUC -Area Under Curve) metrikleri göz önüne alınacaktır. Bu metriklerin matematiksel ifadelerine aşağıda yer verilmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (7)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (8)$$

$$F \text{ ölçütü} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (9)$$

2. YAPILAN ÇALIŞMALAR

2.1. Giriş

Bu çalışma, tarihi yığma yapılarında derin öğrenme yöntemi ile otomatik hasar tespiti yapabilmek amacı ile hazırlanmıştır. Çalışmada, derin öğrenmeye dayalı önceden eğitilmiş olan VGG-16, VGG-19, ResNet-50, Inception-V3 ve Xception modelleri kullanılmıştır. Derin öğrenme modellerinin tahmin performanslarını görüntü tabanlı veriler üzerinde açıklanabilir düzeye getirmek için ise Grad-CAM, Grad-CAM++ ve Score-CAM teknikleri kullanılmış ve çatlak bölgeleri görselleştirilmiştir.

2.2. Ön Hazırlık Çalışmaları

Bu tez çalışmasında, Sanal Grafik İşlemci Ünitesi (GPU)'ne sahip, yapay zeka ve derin öğrenme projeleri üzerinde çalışanlar için etkileşimli, tamamen bulut tabanlı, kullanımı oldukça kolay ve ortak çalışmaya dayalı bir programlama olan Google Colab Notebook kullanılmıştır. Derin öğrenme uygulamaları oluşturmak için Keras, TensorFlow gibi yaygın kitaplıklar kullanılmıştır.

TensorFlow, derin öğrenme için geliştirilmiş açık kaynaklı bir matematik kütüphanesidir. Esnek mimarisi ile bir veya birden fazla sanal grafik işlemci (GPU) kullanılmasına olanak sağlamıştır.

Keras, Python aracılığı ile yazılmış ve neredeyse her tür derin öğrenme modelini tanımlayan TensorFlow üzerinde çalışan bir derin öğrenme kütüphanesidir.

2.3. Veri Kümesinin Oluşturulması

Bu tez çalışmasında kullanılan veriler, Gümüşhane kent merkezine yaklaşık 82 kilometre uzaklıkta Yağmurdere Bucağı Dumanlı Köyü sınırlarında yer alan ve tarihi yapı olarak koruma altına alınan Santa Harabeleri'nden elde edilen görüntülerden oluşmaktadır. Elde edilen veriler eğitim veri seti ve test veri seti olarak iki sınıfa ayrılmıştır. En doğru sonuçlara ulaşmak için eğitim setinin gerçek durumları yansıtması oldukça önemlidir.

Verilerden “çatlak” ve “çatlak olmayan” olarak isimlendirilen iki sınıf oluşturulmuştur. Ardından tüm fotoğrafların uzantıları ‘JPG’ olarak Google Drive’a aktarılmıştır. Resnet-50, VGG-16, VGG-19, Inception-V3 ve Xception modelleri eğitim ve araştırma için kullanılmıştır. Daha önce bahsedildiği gibi Resnet-50, VGG-16, VGG-19 modelleri için veri giriş boyutları 224x224 olup Inception-V3 ve Xception için veri giriş boyutları 299x299'dur. Yapılan tüm analizlerde Tensorflow = 2.3 versiyonu ile Keras kütüphanesi kullanılmıştır. Bu çalışmanın veri setinde 1004 görüntü kullanılmıştır. Her veri kümesi örneği JPG formatına dönüştürülmüş ve daha önce açıklanan önceden eğitilmiş evrişimli sinir ağı modelleri kullanılarak yeniden boyutlandırılmıştır. Çalışmada kullandığımız veri seti 502 adet çatlak ve 502 adet çatlak olmayan görüntülerden oluşmaktadır. Şekil 21’de çatlak ve Şekil 22’de çatlak olmayan örnek görüntüler gösterilmektedir.




Şekil 21. Çatlak içeren görüntü örnekleri



Şekil 22. Çatlak içermeyen görüntü örnekleri


2.4. ResNet-50 Modeli ile Analiz Sonuçları

ResNet-50 modeli ve diğer kullanılan modellerde 502 adet kırılmış çatlak ve 502 adet kırılmı  çatlak olmayan veri olmak üzere toplamda 1004 adet kırılmış fotoğraf kullanılmıştır. Kullanılan bütün modeller analizlerinde veri setini rastgele %70 eğitim veri seti ve %30 test veri seti olacak şekilde ikiye bölmüştür. Ayrıca analizlerde döngü sayısı (epoch) 50 olarak belirlenmiştir. Grafiklerde gösterilen “çatlak” ve “çatlak olmayan” sınıfları sırasıyla 0 ve 1 olarak adlandırılmıştır. ResNet-50 modelinin eğitimi sonucunda elde edilen kayıp değeri %10 ve doğruluk değeri %97 olarak belirlenmiştir. ResNet-50 modeli ile elde edilen eğitim ve test kayıp değerlerinin (training loss ve validation loss) grafiksel gösterimi Şekil 23’de ve eğitim ve test doğruluk değerlerinin (training accuracy ve validation accuracy) grafiksel gösterimi Şekil 24’de verilmiştir.



Şekil 23. ResNet-50 modelinin eğitim ve test kayıp değerlerinin grafiği


Şekil 23'te görüldüğü üzere eğitim kaybı her bir döngüde bir önceki değerine göre azalmalar göstermiş olup 40-50 döngüleri arasında artış göstermiştir. Test kayıpları ise eğitim kaybında olduğu gibi her bir döngüde önceki değerine göre azalmalar gösterirken her bir döngüde dalgalanmalar gözükmemektedir.



Şekil 24. ResNet-50 modelinin eğitim ve test doğruluk değerlerinin grafiği

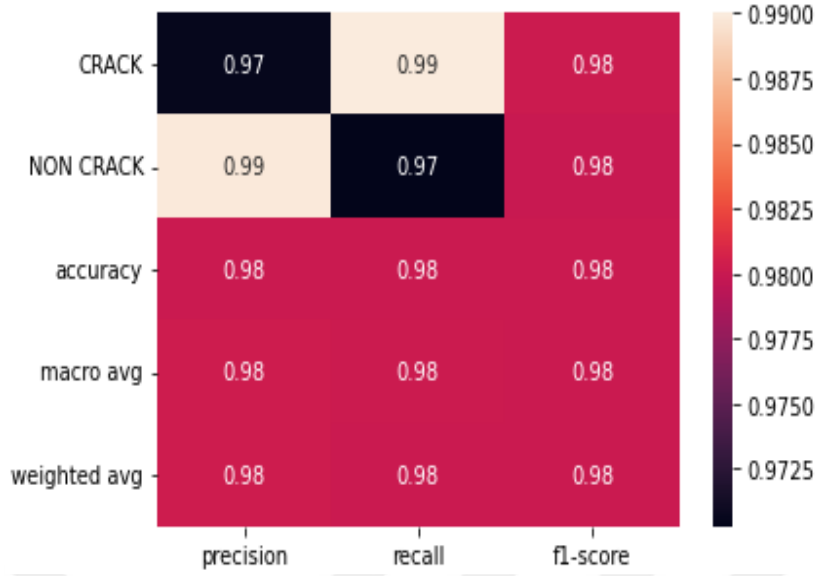
Şekil 24’de ResNet-50 modelinin eğitim ve test doğruluk değerlerinin paralellik gösterdiği görülmektedir. Her bir döngüde doğruluk değerleri artarak 1’e yaklaşmıştır.

ResNet-50 modelinin eğitimi neticesinde elde edilen karışıklık matrisi Şekil 25’de gösterilmiştir. Şekil 26’da ise ResNet-50 modelinin analize ait değerlendirme metriklerinin çıktıları gösterilmiştir.




Şekil 25. ResNet-50 modelinin karışıklık matrisi

Şekil 25’te ResNet-50 modelinin karışıklık matrisi incelendiğinde 102 adet çatlak içeren veri setinde 99 adedin sınıfını doğru, 3 adedin sınıfını yanlış tespit ettiği görülmektedir. Ayrıca 99 adet çatlak olmayan veri içeren sınıfın 98 adedinin sınıfını doğru tespit ettiği, 1 adedinin sınıfını yanlış tespit ettiği görülmektedir.



Şekil 26. ResNet-50 modelinin değerlendirme metrikleri


Şekil 26’da verilen ResNet-50 modelinin değerlendirme metrikleri incelendiğinde modelin %98 doğruluğa sahip olduğu görülmektedir. Çatlak ve çatlak olmayan sınıf tespiti için kesinlik değerleri sırasıyla %97 ve %99’dur. Çatlak ve çatlak olmayan sınıf tespiti için duyarlılık değerleri sırasıyla %99 ve %97’dir. Ayrıca ResNet-50 modeli için f1 skorunun %98 olduğu görülmektedir.



Şekil 27. ResNet-50 modelinin ROC eğrisi


Şekil 27’de ResNet-50 modelinin ROC eğrisi incelendiğinde AUC değerlerinin giderek arttığı ve birbirlerine paralellik gösterdiği görülmektedir. Çatlak (Class:0) ve çatlak olmayan (Class:1) sınıfın AUC değerlerinin 0.98 olduğu görülmektedir. Ayrıca ROC eğrisi altında kalan bölgenin büyük olduğu görülmektedir.

Şekil 28 ve Şekil 29’da iki farklı sınıf için kullanılan üç CAM modeline göre görselleştirilmeleri gösterilmektedir.



Şekil 28. ResNet-50 modelinde çatlak sınıfı için CAM çıktıları

Şekil 28’deki görseller incelendiğinde ResNet-50 modelinin çatlak sınıfını doğru tespit ettiği anlaşılmakta ve kullanılan CAM modellerinin boyama başarılarılarının benzer olduğu görülmektedir.




Şekil 29. ResNet-50 modelinde çatlak olmayan sınıf için CAM çıktıları

Şekil 29’da ResNet-50 modelinin CAM çıktıları incelendiğinde modelin çatlak olmayan sınıfı doğru tespit ettiği görülmektedir. Ayrıca kullanılan CAM modellerinin boyama başarıları arasında bir fark görülmemektedir.


2.5. VGG-16 Modeli ile Analiz Sonuçları

Modelin eğitimi sonucunda elde edilen kayıp değeri %34 ve doğruluk değeri %82 olarak belirlenmiştir. VGG-16 modelinin eğitimi sonucunda elde edilen eğitim ve test kayıp değerlerinin (training loss ve validation loss) grafiksel gösterimi Şekil 30’da eğitim ve test doğruluk değerlerinin (training accuracy ve validation accuracy) grafiksel gösterimi Şekil 31’de verilmiştir



Şekil 30. VGG-16 modelinin eğitim ve test kayıp değerlerinin grafiği


Şekil 30'da görüldüğü üzere VGG-16 modelinin eğitim kaybının her bir döngüde bir önceki değerine göre azalmalar gösterdiği eğitim ve test kayıp değerlerinin birbirleriyle paralel ilerlediği anlaşılmaktadır.



Şekil 31. VGG-16 modelinin eğitim ve test doğruluk değerlerinin grafiği


Şekil 31’de VGG-16 modelinin eğitim ve test doğruluk değerlerinin yaklaşık 15’inci döngüye kadar paralellik gösterdiği ve test doğruluk değerlerinin arttığı görülmektedir. 40-50 döngüleri arasında doğruluk değerlerinde ciddi azalmalar görülürken eğitim doğrulama değerlerinde artış görülmektedir. Döngü sonunda test değeri %85’in üzerinde, eğitim doğrulama değerinin ise %85’in üzerinde bir değer aldığı görülmektedir.

VGG-16 modelinin eğitimi neticesinde elde edilen karışıklık matrisi Şekil 32’de gösterilmiştir. Şekil 33’de ise analize ait değerlendirme metriklerinin çıktıları gösterilmiştir.




Şekil 32. VGG-16 modelinin karışıklık matrisi

Şekil 32’de VGG-16 modelinin karışıklık matrisi incelendiğinde 116 adet çatlak içeren veri setinde 90 adedin sınıfını doğru 26 adedin sınıfını yanlış tespit ettiği görülmektedir. Ayrıca 85 adet çatlak olmayan veri içeren sınıfın 75 adedin sınıfını doğru tespit ettiği 10 adedin sınıfını yanlış tespit ettiği görülmektedir.



Şekil 33. VGG-16 modelinin değerlendirme metrikleri


Şekil 33'te verilen VGG-16 modelinin değerlendirme metrikleri incelendiğinde modelin %82 doğruluğa sahip olduğu görülmektedir. Çatlak ve çatlak olmayan sınıf tespiti için kesinlik değerleri sırasıyla %78 ve %88'dir. Çatlak ve çatlak olmayan sınıf tespiti için duyarlılık değerleri sırasıyla %90 ve %74'dür. Ayrıca VGG-16 modeli için f1 skorunun %82 olduğu görülmektedir.



Şekil 34. VGG-16 modelinin ROC eğrisi


Şekil 34’de VGG-16 modelinin ROC eğrisi incelendiğinde AUC değerlerinin giderek arttığı ancak dalgalanmaların yaşandığı görülmektedir. Çatlak ve çatlak olmayan sınıflarının AUC değerlerinin 0.90 olduğu görülmektedir.

Şekil 35 ve Şekil 36’da iki farklı sınıf için kullanılan üç CAM modeline göre görselleştirilmeleri gösterilmektedir.



Şekil 35. VGG-16 modelinde çatlak sınıfı için CAM çıktıları

Şekil 35’teki görseller incelendiğinde VGG-16 modelinin çatlak sınıfını doğru tespit edemediği görülmektedir.




Şekil 36. VGG-16 modelinde çatlak olmayan sınıf için CAM çıktıları

Şekil 36'daki görseller incelendiğinde, VGG-16 modelinin çatlak olmayan sınıfı doğru tespit edemediği görülmektedir.


2.6. VGG-19 Modeli ile Analiz Sonuçları

Modelin eğitimi sonucunda elde edilen kayıp değeri %25 ve test değeri %90 olarak belirlenmiştir. VGG-19 modelinin eğitimi sonucunda elde edilen eğitim ve test kayıp değerlerinin (training loss ve validation loss) grafiksel gösterimi Şekil 37'de, eğitim ve test doğrulama değerlerinin (training accuracy ve validation accuracy) grafiksel gösterimi Şekil 38'de verilmiştir.



Şekil 37. VGG-19 modelinin eğitim ve test kayıp değerlerinin grafiği


Şekil 37’de görüldüğü üzere VGG-19 modelinin eğitim ve test kaybı, her bir döngüde bir önceki değerine göre azalmalar göstermiş olup eğitim ve test kayıp değerleri birbirleriyle paralellik göstermektedir.



Şekil 38. VGG-19 modelinin eğitim ve test doğruluk değerlerinin grafiği


Şekil 38’de VGG-19 modelinin eğitim ve test doğruluk değerlerinin artarak yaklaşık 0.90 değeri aldığı görülmektedir. 25-35 döngüleri arasında VGG-19 modelinin test doğruluk değerlerinde dalgalanma görülmektedir.

VGG-19 modelinin eğitimi neticesinde elde edilen karışıklık matrisi Şekil 39’da gösterilmiştir. Şekil 40’da ise analize ait değerlendirme metriklerinin çıktıları gösterilmiştir.




Şekil 39. VGG-19 modelinin karışıklık matrisi

Şekil 39’da VGG-19 modelinin karışıklık matrisi incelendiğinde, 104 adet çatlak içeren veri setinde 92 adedin sınıfını doğru, 12 adedin sınıfını yanlış tespit ettiği görülmektedir. Ayrıca, 97 adet çatlak olmayan veri içeren sınıfın 89 adedin sınıfını doğru tespit ettiği, 8 adedin sınıfını yanlış tespit ettiği görülmektedir.



Şekil 40. VGG-19 modelinin değerlendirme metrikleri


Şekil 40’da verilen VGG-19 modelinin değerlendirme metrikleri incelendiğinde, modelin %90 doğruluğa sahip olduğu görülmektedir. Çatlak ve çatlak olmayan sınıf tespiti için kesinlik değerleri sırasıyla %88 ve %92’dir. Çatlak ve çatlak olmayan sınıf tespiti için duyarlılık değerleri sırasıyla %92 ve %88’dir. Ayrıca VGG-19 modeli için f1 skorunun %90 olduğu görülmektedir.



Şekil 41.VGG-19 modelinin ROC eğrisi


Şekil 41’de VGG-19 modelinin ROC eğrisi incelendiğinde AUC değerlerinin giderek arttığı görülmektedir. Çatlak ve çatlak olmayan sınıfın AUC değerlerinin 0.87 olduğu görülmektedir.

Şekil 42 ve Şekil 43’de iki farklı sınıf için kullanılan üç CAM modeline göre görselleştirilmeleri verilmektedir.



Şekil 42. VGG-19 modelinde çatlak sınıfı için CAM çıktıları

Şekil 42’deki görseller incelendiğinde VGG-19 modelinin çatlak sınıfını doğru tespit edemediği görülmektedir.




Şekil 43. VGG-19 modelinde çatlak olmayan sınıf için CAM çıktıları

Şekil 43'te VGG-19 modelinin CAM çıktıları incelendiğinde VGG-19 modelinin çatlak olmayan sınıfı doğru tespit edemediği görülmektedir.


2.7. Xception Modeli ile Analiz Sonuçları

Modelin eğitimi sonucunda elde edilen kayıp değeri %14 ve doğruluk değeri %97 olarak belirlenmiştir. Xception modelinin eğitimi sonucunda elde edilen eğitim ve test kayıp değerlerinin (training loss ve validation loss) grafiksel gösterimi Şekil 45'de, eğitim ve test doğruluk değerlerinin (training accuracy ve validation accuracy) grafiksel gösterimi Şekil 46'da verilmiştir.



Şekil 44. Xception modelinin eğitim ve test kayıp değerlerinin grafiği


Şekil 44’de verilen Xception modelinin eğitim ve test kayıp değerlerinin grafiği incelendiğinde 0-10 eğitim adımları arasında kayıp değerlerinde düzenli bir azalma olduğu görülmektedir. 20-30 ve 40-50 eğitim adımları arasında test kayıp değerlerinde ciddi bir artış görülmektedir. Bunun yanı sıra eğitim kayıp değerleri eğitim adımları boyunca azalma göstermiştir.



Şekil 45. Xception modelinin eğitim ve test doğruluk değerlerinin grafiği

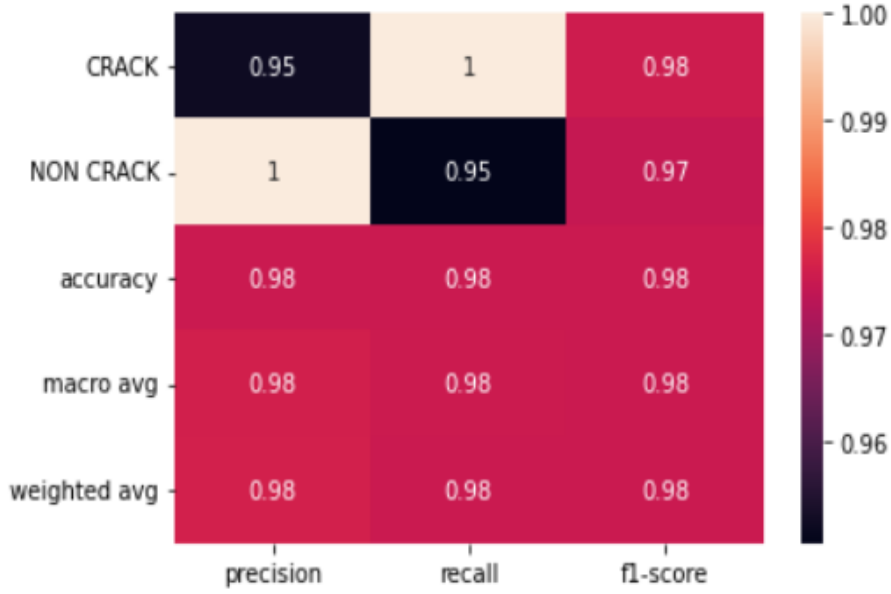
Şekil 45’de verilen Xception modelinin eğitim ve test doğruluk değerlerinin grafiği incelendiğinde, eğitim doğruluk değerleri her bir eğitim adımında artarak 1 değerine yaklaşmıştır. Test doğruluk değerlerinde ise 20 ve sonrası eğitim adımlarında ciddi azalmalar görülmektedir.

Xception modelinin eğitimi neticesinde elde edilen karışıklık matrisi Şekil 46’da gösterilmiştir. Şekil 47’de ise analize ait değerlendirme metriklerinin çıktıları gösterilmiştir.




Şekil 46. Xception modelinin karışıklık matrisi

Şekil 46’da Xception modelinin karışıklık matrisi incelendiğinde 105 adet çatlak içeren veri setinde 100 adedin sınıfını doğru 5 adedin sınıfını yanlış tespit ettiği görülmektedir. Ayrıca 96 adet çatlak olmayan veri içeren sınıfın hepsini doğru tespit etmiştir.



Şekil 47. Xception modelinin değerlendirme metrikleri


Şekil 47’de verilen Xception modelinin değerlendirme metrikleri incelendiğinde modelin %98 doğruluğa sahip olduğu görülmektedir. Çatlak ve çatlak olmayan sınıf tespiti için kesinlik değerleri sırasıyla %95 ve %100’dür. Çatlak ve çatlak olmayan sınıf tespiti için duyarlılık değerleri sırasıyla %100 ve %95’dir. Ayrıca Xception modeli için f1 skorunun %98 olduğu görülmektedir.



Şekil 48. Xception modelinin ROC grafiği


Şekil 48’de Xception modelinin ROC eğrisi incelendiğinde çatlak ve çatlak olmayan sınıfın AUC değerleri sırasıyla 0.50 ve 0.48 olduğu görülmektedir.

Şekil 49 ve Şekil 50’de iki farklı sınıf için kullanılan üç CAM modeline göre görselleştirilmeleri gösterilmektedir.



Şekil 49. Xception modelinde çatlak sınıfı için CAM çıktıları

Şekil 49’deki görseller incelendiğinde Xception modelinin çatlak sınıfını doğru tespit ettiği ve kullanılan CAM modellerinin boyama başarıları arasında fark görülmemiştir.




Şekil 50. Xception modelinde çatlak olmayan sınıf için CAM çıktıları

Şekil 50’de Xception modelinin CAM çıktıları incelendiğinde modelin çatlak olmayan sınıfı doğru tespit ettiği görülmektedir. Ayrıca kullanılan CAM modellerinin boyama başarılarının birbirlerine yakın olduğu görülmemektedir.


2.8. Inception-V3 Modeli ile Analiz Sonuçları

Modelin eğitimi sonucunda elde edilen kayıp değeri %73 ve doğruluk değeri %77 olarak belirlenmiştir. Inception-V3 modelinin eğitimi sonucunda elde edilen eğitim ve test kayıp değerlerinin (training loss ve validation loss) grafiksel gösterimi Şekil 51’de, eğitim ve test doğruluk değerlerinin (training accuracy ve validation accuracy) grafiksel gösterimi Şekil 52’de verilmiştir.



Şekil 51. Inception- V3 modelinin eğitim ve test kayıp değerlerinin grafiği


Şekil 51’de verilen Inception-V3 modelinin eğitim ve test kayıp değerlerinin grafiği incelendiğinde eğitim ve test kayıp değerlerinde ciddi dalgalanmalar görülmektedir. Başlangıç değerlerine göre son eğitim adımında kayıp değerlerinin azaldığı görülürken 40-50 eğitim adımları arasında test kayıp değerlerinde ise ciddi artışın olduğu görülmektedir.



Şekil 52. Inception-V3 modelinin eğitim ve test doğruluk değerlerinin grafiği

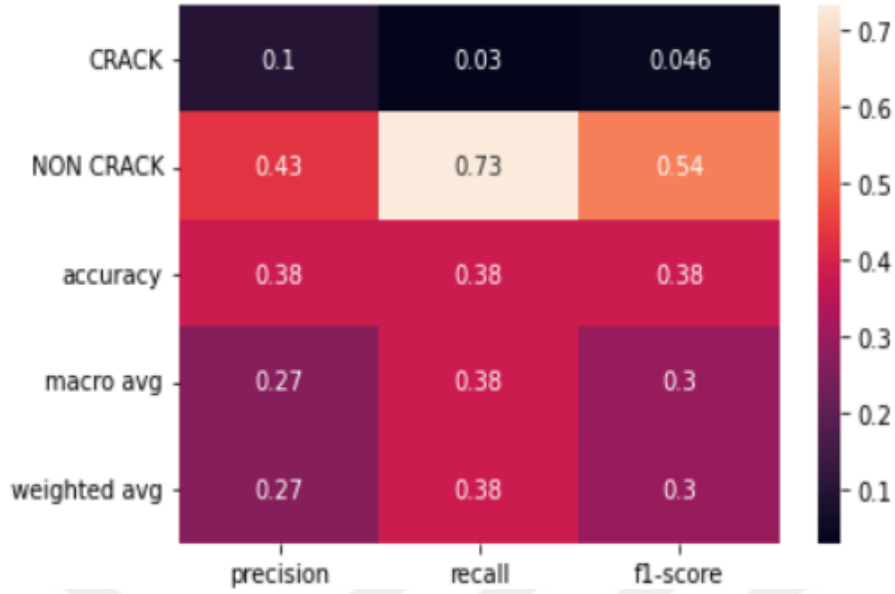
Şekil 52’de verilen Inception-V3 modelinin eğitim ve test doğruluk değerlerinin grafiği incelendiğinde eğitim ve test doğruluk değerlerinde ciddi dalgalanmalar görülmektedir. Başlangıç değerlerine göre son eğitim adımında kayıp değerleri azalmıştır. Ancak 40’ıncı adımda test doğruluk değerlerinde ciddi azalma görülmektedir. Eğitim doğruluk değerlerinde ise dalgalanmalar mevcuttur.

Inception-V3 modelinin eğitimi neticesinde elde edilen karışıklık matrisi Şekil 53’de gösterilmiştir. Şekil 54’de ise analize ait değerlendirme metriklerinin çıktıları gösterilmiştir.




Şekil 53. Inception-V3 modelinin karışıklık matrisi

Şekil 53’te Inception-V3 modelinin karışıklık matrisi incelendiğinde 30 adet çatlak içeren veri setinde 3 adedin sınıfını doğru 27 adedin sınıfını yanlış tespit ettiği görülmektedir. Ayrıca 171 adet çatlak olmayan veri içeren sınıfın 74 adedin sınıfını doğru tespit ettiği 97 adedin sınıfını yanlış tespit ettiği görülmektedir.



Şekil 54. Inception-V3 modelinin değerlendirme metrikleri


Şekil 54’te verilen Inception-V3 modelinin değerlendirme metrikleri incelendiğinde modelin %38 doğruluğa sahip olduğu görülmektedir. Çatlak ve çatlak olmayan sınıf tespiti için kesinlik değerleri sırasıyla %10 ve %43’dür. Çatlak ve çatlak olmayan sınıfların tespiti için duyarlılık değerleri sırasıyla %3 ve %73’dür. Ayrıca Inception-V3 modeli için f1 skorunun %30 olduğu görülmektedir.



Şekil 55. Inception-V3 modelinin ROC eğrisi


Şekil 55'te Inception-V3 modelinin ROC eğrisi incelendiğinde çatlak ve çatlak olmayan sınıfın AUC değerleri 0.53 olduğu görülmektedir.

Şekil 56 ve Şekil 57'de iki farklı sınıf için kullanılan üç CAM modeline göre görselleştirilmeleri gösterilmektedir.



Şekil 56. Inception-V3 modelinde çatlak sınıfı için CAM çıktıları

Şekil 56'daki görseller incelendiğinde Inception-V3 modelinin çatlak sınıfını doğru tespit edemediği görülmektedir.



Şekil 57. Inception-V3 modelinde çatlak olmayan sınıf için CAM çıktıları

Şekil 57’de Inception-V3 modelinin CAM çıktıları incelendiğinde modelin çatlak olmayan sınıfı doğru tespit ettiği görülmektedir. Ayrıca kullanılan CAM modellerinin boyama başarıları arasında bir fark görülmemektedir.

3. BULGULAR VE İRDELEMELER

Bu bölümde, yapılan çalışmalar neticesinde elde edilen model çıktıları gerçekleştirilen beş ayrı analize (ResNet-50, VGG-16, VGG-19, Xception, Inception-V3) göre kıyaslamalı olarak değerlendirilmiştir. Bu modellere ek olarak, Grad-CAM, Grad-CAM++, Score-CAM olarak isimlendirilen sınıf aktivasyon haritası yaklaşımları kullanılarak çatlak bölgelerinin yerleri görselleştirilmiştir. Kullanılan tüm yöntemlerin performansları karşılaştırılarak avantaj ve dezavantajları bu bölümde yorumlanmıştır. Tez çalışmada kullanılan modellerin çıktılarının değerlendirilmesinde, doğruluk (accuracy), duyarlılık (recall), kesinlik (precision), f1 skoru (f1-score), alıcı işletim karakteristiği (ROC-Receiver Operator Characteristic) ve bu eğri altında kalan bölge (AUC -Area Under Curve) metrikleri göz önüne alınmıştır.

Doğruluk, doğru olarak sınıflandırılan örneklerin yüzdesidir. Duyarlılık, pozitif olarak tahmin edilmesi gereken işlemlerin ne kadarının pozitif olarak tahmin edildiğini gösteren bir metriktir. Kesinlik, pozitif olarak tahmin edilen değerlerin gerçekten kaç adedinin pozitif olduğunu göstermektedir. Alıcı işletim karakteristiği (ROC); farklı sınıflar için bir olasılık eğrisidir. Alıcı işletim karakteristiği altında kalan bölge de (AUC) model performansının bir özeti olarak kabul edilmektedir. Bu bölge ne kadar fazlaysa, derin öğrenme modelleri verilen sınıfları ayırt etmede o kadar iyi sonuca varacaktır. AUC ulaşılacak istenen değer 1'dir. Tablo 2'de kullanılan her bir model için doğruluk, duyarlılık, kesinlik, özgünlük, f1 skoru ve AUC değerleri gösterilmektedir.

Tablo 2. Derin öğrenme modelleri tarafından elde edilen performans değerleri

Model	Doğruluk	Kesinlik	Duyarlılık	f1skoru	AUC
VGG-16	%81.77	%78	%90	%83	0.90
VGG-19	%89.58	%88	%92	%90	0.87
Inception-V3	%77.08	%10	%3	%5	0.53
Xception	%97.40	%95	%100	%98	0.48
Resnet-50	%97.92	%97	%99	%99	0.98

Tablo 2'deki veriler incelendiğinde alıcı işlem karakteristik eğrisi ve altında kalan alan (AUC) değerlendirme kriteri için ResNet-50 modeli 0.98 değeri ile en iyi performansa sahip

olduğu görülmektedir. 0.48 AUC değerlendirme kriteri değeri ile Xception modeli en düşük değere sahiptir. Ek olarak Bölüm 2’de ResNet-50 modelinin ROC grafiği incelendiğinde, %80’in üzerine hızlıca çıkan iki sınıfın (çatlak:0, çatlak olmayan:1) doğruluk oranlarının yüksek ve birbirlerine paralel olduğu görülmektedir. Aynı zamanda sınıfların geçtiği eğrinin altında kalan AUC bölgeleri kıyaslandığında, ResNet-50 modelinin başarısının diğer modellerin başarısına göre daha yüksek olduğu söylenebilmektedir.

(Stoyanov ve Nixon, 2020)’e göre f1 skoru derin öğrenmede yaygın olarak kullanılan bir ölçüm metriğidir. f1skoru, bir testin doğruluğunun ölçüsü olarak tanımlanabilir. Kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Maksimum 1 değerine (mükemmel kesinlik ve duyarlılık) ve minimum 0 değerine sahip olabilir. Genel olarak, modelin kesinliğinin ve sağlamlığının bir ölçüsüdür. Örneğin iki modeli düşük kesinlik ve yüksek duyarlılık ile kıyaslamak zordur. Bu yüzden, iki modeli karşılaştırılabilir hale getirmek için f1 skoru kullanılmaktadır. ResNet-50 modeli %97.92 ile en yüksek doğruluğa ve %99 ile en yüksek f1 skoruna sahiptir. Ek olarak Xception modeli, pozitif durumların ne kadar başarılı tahmin edildiğini gösteren parametre olarak bilinen recall (duyarlılık) değeri %100 ile en iyi duyarlılığa sahiptir.

Karışıklık matrisi, sınıflandırma problemlerindeki tahmin sonuçlarının özetini sunmaktadır. Karışıklık matrisi kullanılarak sınıflandırıcı ile yapılan hatalar hakkında fikir edinilebilmektedir. Aynı zamanda modelin yaptığı hata türleri hakkında da fikir sunmaktadır. Dolayısıyla karışıklık matrisini kullanılarak doğrulama olarak verdiğimiz görüntülerden kaç tanesinin çatlak (crack), kaç tanesinin çatlak olmayan (non crack) sınıfına ait olduğunun tahmini yapılabilir. Bölüm 2’de modellerin karışıklık matrisleri incelendiğinde ResNet-50 modeli çatlak ve çatlak olmayan sınıf tespitinde sırasıyla %97 ve %98 başarı ile en iyi sınıf tespit başarısına sahiptir. Inception-V3 modeli çatlak sınıfı tespit başarısı %10, çatlak olmayan sınıf tespit başarısı %43 ile en düşük sınıf tespit performansına sahiptir.

Bölüm 2’de her bir model için elde edilen eğitim ve test kayıp değerlerinin grafiği ile eğitim ve test doğruluk değerlerinin grafiği incelendiğinde, ResNet-50 modelinde, eğitim kaybı her döngü sayısında (epoch) düşerken eğitim başarısı artmaktadır. Inception-V3 modelinin eğitim başarısında ise ciddi dalgalanmaların olduğu görülmektedir.

3.1. Görselleştirme Tekniklerinin Karşılaştırılması

Bu bölümde, VGG-16, VGG-19, Resnet-50, Inception-V3 ve Xception modellerinin tarihi yığma yapılarıdaki çatlak tahminindeki başarısı ile Grad-CAM, Grad-CAM++, Score-CAM gibi görselleştirme tekniklerinin çatlak bölgelerini tanımlaması incelenmektedir. Bu bölümde Bölüm 2’de her bir model için verilen CAM çıktıları dikkate alınmaktadır.

ResNet-50 ve Xception modelinde üç farklı görselleştirme tekniği için de sınıflandırma doğru olarak belirlenmiş olup haritalama başarısına göre modellerin birbirlerine yakın olduğu anlaşılmaktadır. VGG-16, VGG-19, Inception-V3 modelleri üç farklı görselleştirme teknikleri için de sınıflandırmayı doğru belirleyememiştir.



4. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, tarihi yığma yapılarda derin öğrenmeye dayalı sınıflandırma ve görselleştirme yöntemleri otomatik hasar tespiti için gerçekleştirilmiştir. Bu amaçla, ResNet-50, VGG-16, VGG-19, Xception, Inception-V3 modelleri ile birlikte görselleştirme için Grad-CAM ve uzantılarından olan Grad-CAM++, Score-CAM kullanılmıştır. Her bir model için elde edilen veriler incelendiğinde, ResNet-50 modeli %97 doğruluk ve AUC değerlendirme kriteri için 0.98 değeri ile en iyi performansa sahip derin öğrenme modeli olarak değerlendirilmiştir. AUC değerlendirme kriteri 0.48 değeri ile Xception en düşük performansa sahip model olarak değerlendirilmiştir. Çatlak yerinin belirlenmesi için kullanılan görselleştirme tekniklerinin haritalama başarılarının birbirlerine çok yakın olduğu görülmüştür.

Derin öğrenme uygulamalarında yüksek performans değerlerine ulaşmak için çok sayıda görüntüye ihtiyaç duyulmaktadır. Ancak, az sayıdaki veri ile ve donanımsal yetersizliklere rağmen sistem başarıyla eğitilmiş ve kullanılan veriler ışığında kabul edilebilir performanslar elde edilmiştir. Bu tez çalışması sonucunda elde edilen bulgular neticesinde, derin öğrenme yönteminin tarihi yığma yapılarda otomatik hasar tespitinde kullanılabilecek önemli bir araç olacağı gösterilmiştir.

Yapılan bu çalışmada, gelecek çalışmalara yol gösterebilecek öneriler aşağıda verilmiştir:

- Kullanılan veri setinin daha fazla genişletilmesi ile eğitim ağının doğru karar vermesi o kadar kolay olacaktır.
- Kullanılan veri setleri üzerinde farklı derin öğrenme mimarilerinden yararlanılarak daha iyi performans ve daha iyi başarı oranı elde edilebilecektir.

5. KAYNAKLAR

- Abdeljaber, O., Avcı, O., Kiranyaz, M. ve Boashash, B., 2018. 1-D CNNs for Structural Damage Detection: Verification on A Structural Health Monitoring Benchmark Data, Neurocomputing, 275, 1308-1317.
- Abdeljaber, O., Avcı, O., Kiranyaz, S., Gabbouj, M. ve Inman, D., 2017. Real-Time Vibration-Based Structural Damage Detection Using One-Dimensional Convolutional Neural Networks, Journal of Sound and Vibration, 388,3, 154-170.
- Aizenberg, I., 2000. Complex- Valued Neural Networks with Multivalued Neurons.
- Akcay, C. ve Manisalı, E., 2018. Fuzzy Decision Support Model for the Selection of Contractor in Construction Works, Journal of Construction, 17,2, 258-266.
- Akdoğan, A., 2021. Derin Öğrenme Yaklaşımıyla Fatura Görüntülerinden Bilgi Çıkarma Algoritmaları ve Uygulamaları, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Akgün, D., 2020. An Evaluation of VGG16 Binary Classifier Deep Neural Network for Noise and Blur Corrupted Images, Sakarya University Journal of Computer and Information Sciences, 3,3, 264-271.
- Akilotu, B., N., Kayaoğlu, M., Kadiroğlu, Z. ve Sengur, A., Researchgate. https://www.researchgate.net/publication/334112281_Malaria_Detection_using_both_Convolutional_Neural_Networks_and_Transfer_Learning_Method 21 Mart 2022
- Akinosho, T., D., Oyedele, L., O., Bilal, M., Ajayi, A., O., Delgado, M., D., Akinade, O., O. ve Ahmed, A., A., 2020. Deep Learning in the Construction Industry: A Review of Present Status and Future Innovations, Journal of Building Engineering, 32 1-14.
- Arama, Z., A., Akın, M., S., Nuray, S., E. ve Dalyan, İ., 2020. Estimation of Consistency Limits of Fine-Grained Soils Via Regression Analysis: A Special Case for High and Very High Plastic Clayey Soils in Istanbul, International Advanced Researches and Engineering Journal, 04,03 255-266.
- Arslan, H., Üneş, F., Demirci, M., Taşar, B. ve Yılmaz, A., 2020. Keban Baraj Gölü Seviye Değişiminin ANFİS ve Destek Vektör Makineleri ile Tahmini, Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 3,2 71-77.
- Arslan, M., Ceylan, M., Koyuncu, T. 2015. Determining Earthquake Performances of Existing Reinforced Concrete Buildings by Using ANN, World Academy of

Science, Engineering and Technology International Journal of Civil and Environmental Engineering, 9,8 1089-1093.

Ataseven, B., 2013. Yapay Sinir Ağları ile Öngörü Modellemesi, Dergipark, 10,39 101-115.

Atha, D., J. ve Jahanshahi, M., R., 2018. Evaluation of Deep Learning Approaches Based on Convolutional Neural networks for Corrosion Detection, Structural Health Monitoring, 17,5 1110–1128.

Avcı, N. ve Alemdar, F., 2019. Sarsma Masası Testlerindeki Dinamik Parametrelerin Görüntü İşleme Yöntemi ile Ölçülmesi, DÜMF Mühendislik Dergisi, 10,3 1099-1112.

Ayas, S., 2020. 2020-2021 Güz Yarıyılı BILL5190 Machine Learning Yüksek Lisans Dersi Ders Notları, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon.

Başığit, C., Kaçar Akkaş, A. ve Kurtarıcı, M., N., 2012. Betonların Radyasyon Zırh Kalınlıklarının Yapay Sinir Ağları ve Çoklu Regresyon Metotları ile Tahmini, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 16,1, 77-81.

Buyukyildiz, M., Tezel, G. ve Yılmaz, V., 2014. Estimation of the Change in Lake Water Level by Artificial Intelligence Methods, Water Resources Management, 28, 4747–4763.

Çakıroğlu, M. A. ve Süzen, A., A., 2020. Assessment and Application of Deep Learning Algorithms in Civil Engineering, El-Cezeri Journal of Science and Engineering, 7,2, 906-922.

Çalışkan, D. ve Demir, Ö., 2022. Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti, International Periodical of Recent Technologies in Applied Engineering, 3, 1, 28–43.

Çankaya, G., Arslan, M. H. ve Ceylan, M. 2013. Görüntü İşleme ve Yapay Sinir Ağları Yöntemleri ile Betonun Basınç Dayanımının Belirlenmesi, Selçuk Üniversitesi Mühendislik Bilim ve Teknik Dergisi, 1,1, 1-12.

Cansız, Ö., F., Ünsalan, K. ve Erginer, İ., 2020. Karayolları Enerji Tüketiminin Yapay Zeka ve Regresyon Yöntemleri ile Modellenmesi, Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 25,3, 1297–1314.

Cao, Y., Wakil, K., Alyousef, R., Jermisittiparsert, K., Si Ho, L., Alabduljabbar, H., Alaskar, A., Alrshoudi, F. ve Mohamed, A., 2020. Application of Extreme Learning Machine in Behavior of Beam to Column Connections, Structures, 25, 861–867.

Cha, Y., J., Choi, W., Suh, G., Mahmoudkhani, S. ve Büyüköztürk, O., 2018. Autonomous Structural Visual Inspection Using Region-Based Deep Learning for Detecting

Multiple Damage Types, Computer-Aided Civil and Infrastructure Engineering, 33, 9, 731–747.

Chaiyasarn, K., Khan, W., Ali, L., Sharma, M., Brackenbury, D. ve DeJong, M., 2018. Crack Detection in Masonry Structures Using Convolutional Neural Networks and Support Vector Machines, 35th International Symposium on Automation and Robotics in Construction, July, Berlin.

Chattopadhyay, A., Sarkar, A. ve Prantik, H., 2018. Grad-CAM++: Generalized Gradient-Based Visual Explanations for Deep Convolutional Networks, 2018 IEEE Winter Conference on Applications of Computer Vision, USA, 839-847.

Chollet, F., Deep Learning with Python. [http://silverio.net.br/heitor/disciplinas/eeica/papers/Livros/\[Chollet\]-Deep_Learning_with_Python.pdf](http://silverio.net.br/heitor/disciplinas/eeica/papers/Livros/[Chollet]-Deep_Learning_with_Python.pdf) 5 Nisan 2022.

Chollet, F., 2017. Xception: Deep Learning with Depthwise Separable Convolutions, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA, 1800–1807.

Choudhary, G., K. ve Sayan, D., 2012. Crack Detection in Concrete Surfaces Using Image Processing, Fuzzy Logic and Neural Networks, 2012 IEEE 5th International Conference on Advanced Computational Intelligence (ICACI), China, 404–411.

Chun, P., Yamashita, H. ve Furukawa, S., 2015. Bridge Damage Severity Quantification Using Multipoint Acceleration Measurement and Artificial Neural Networks, Shock and Vibration, 2015, 40-50.

Dalkılıç, H., Y. ve Okkan, U., 2012. Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi, Teknik Dergi, 23, 112, 5957-5966.

Ding, B., Qian, H. ve Zhou, J., 2018. Activation Functions and Their Characteristics in Deep Neural Networks. 2018 Chinese Control and Decision Conference (CCDC), June, China, 1836–1841.

Doğan, F.ve Türkoğlu, İ., 2018. Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, Sakarya University Journal of Computer and Information Sciences, 1, 1-12.

Doğan, G., Arslan, M., H. ve Ceylan, M., 2017. Concrete Compressive Strength Detection Using Image Processing Based New Test Method, Measurement, 109, 137–148.

Dong, N., Zhao, L., Wu, C., H. ve Chang, J., F., 2020. Inception V3 Based Cervical Cell Classification Combined with Artificially Extracted Features, Applied Soft Computing, 93, 106311.

- Fang, W., Ding, L., Zhong, B., Love, P. ve Luo, H., 2018. Automated Detection of Workers and Heavy Equipment on Construction Sites: A Convolutional Neural Network Approach, Advanced Engineering Informatics, 37, 139–149.
- Fu, K., Dai, W., Zhang, Y., Wang, Z., Yan, M. ve Sun, X., 2019. Remote Sensing MultiCAM: Multiple Class Activation Mapping for Aircraft Recognition in Remote Sensing Images, Remote Sensing, 11, 544, 1-18.
- Gao, X. ve Lin, C., 2021. Prediction Model of the Failure Mode of Beam-Column Joints Using Machine Learning Methods, Engineering Failure Analysis, 120, 105072.
- Garzón-Roca, J., Marco, C., O. ve Adam, J., M., 2013. Compressive Strength of Masonry Made of Clay Bricks and Cement Mortar: Estimation Based on Neural Networks and Fuzzy Logic, Engineering Structures, 48, 21–27.
- Gemici, E., Ardıçlıoğlu, M. ve Kocabaş, F., 2013. Akarsularda Debinin Yapay Zekâ Yöntemleri ile Modellenmesi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 29, 2, 135–143.
- Golafshani, E., Rahai, A., Sebt, M., H. ve Akbarpour, H., 2012. Prediction of Bond Strength of Spliced Steel Bars in Concrete Using Artificial Neural Network and Fuzzy Logic, Construction and Building Materials, 36, 411–418.
- Güldemir, N., H., Alkan, A., 2021. Derin Öğrenme ile Optik Koherens Tomografi Görüntülerinin Sınıflandırılması, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 33, 2, 607-615.
- Gültepe, Y., 2019. Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme, European Journal of Science and Technology, 16, 8–15.
- Günaydin, H., M. ve Doğan, S., Z., 2004. A Neural Network Approach for Early Cost Estimation of Structural Systems of Buildings, International Journal of Project Management, 22, 7, 595–602.
- Hacıfendioğlu, K., Başağa, H., B., Yavuz, Z. ve Karimi, M., T., 2022. Intelligent Ice Detection on Wind Turbine Blades Using Semantic Segmentation and Class Activation Map Approaches Based on Deep Learning Method, Renewable Energy, 182, 1–16.
- Hacıfendioğlu, K., Başağa, H., 2022. Concrete Road Crack Detection Using Deep Learning Based Faster R-CNN Method, Iranian Journal of Science and Technology, Transactions of Civil Engineering, 46, 1621-1633.
- Hakim, S., J., Hashim, A., R. ve Ravanfar, S., A., 2015. Fault Diagnosis on Beam-Like Structures from Modal Parameters Using Artificial Neural Networks, Measurement, 76, 45–61.

- He, K., Zhang, X., Ren, S. ve Sun, J., 2016. Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 2016, USA, 770–778.
- Hou, Y., Li, Q., Zhang, C., Lu, G., Ye, Z., Chen, Y., Wang., L. ve Cao, D., 2021. The State of the Art Review on Applications of Intrusive Sensing, Image Processing Techniques, and Machine Learning Methods in Pavement Monitoring and Analysis, Engineering, 7, 6, 845–856.
- Hu, W., Wang, W., Ai, C., Wang, J., Wang, W., Meng, X., Liu, J., Tao, H. ve Qiu, S., 2021. Machine Vision-Based Surface Crack Analysis for Transportation Infrastructure, Automation in Construction, 132, 103973.
- Hwang, S., H., Mangalathu, S., Shin, J. ve Jeon, J., S., 2021. Machine Learning-Based Approaches for Seismic Demand and Collapse of Ductile Reinforced Concrete Building Frames, Journal of Building Engineering, 34, 101905.
- İnce, R., 2004. Prediction of Fracture Parameters of Concrete by Artificial Neural Networks. Engineering Fracture Mechanics, 71, 15, 2143–2159.
- İnik, Ö. ve Ülker, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6, 3, 85–104.
- Jeong, S., H., Yun, J., P., Yeom, H., G., Lim, H., J., Lee, J. ve Kim, B., C., 2020. Deep Learning Based Discrimination of Soft Tissue Profiles Requiring Orthognathic Surgery by Facial Photographs, Scientific Reports, 10, 16235.
- Kaçın, S. ve Aydın, M., 2020. Görüntü İşleme Yöntemi ile Betonarme Kiriş Deplasmanlarının Belirlenmesi, Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 23, 2, 107–117.
- Kara, H., G., 2009. Tarihi Yığma Yapıların Taşıyıcı Sistemleri, Güvenliğinin İncelenmesi, Onarımı ve Güçlendirilmesi, Yüksek Lisans Tezi, İ.T.Ü., Fen Bilimleri Enstitüsü, İstanbul.
- Khademi, F., Akbari, M., Jamal, S., M. ve Nikoo, M., 2017. Multiple Linear Regression, Artifical Neural Network and Fuzzy Logic Prediction of 28 Days Compressive Strength of Concrete, Frontiers of Structural and Civil Engineering, 11, 1, 90–99.
- Kim, G., H., An, S., H. ve Kang, K., I., 2004. Comparison of Construction Cost Estimating Models Based on Regression Analysis, Neural Networks, and Case-Based Reasoning, Building and Environment, 39, 10, 1235–1242.
- Kılınç, H. ve Baysal, C., V., 2018. Derin Öğrenmeli Konvolüsyonel Sinir Ağları Kullanarak Fotoğraftan Trizomi 21(Down Sendromu) Tespiti, Ç.Ü Fen ve Mühendislik Bilimleri Dergisi, 36, 2, 13–19.

- Kızrak, M., A. ve Bolat, B., 2018. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma, Bilişim Teknolojileri Dergisi, 11, 3, 263–286.
- LeCun, Y., Jackel, L., D., Boser, B., Graf, H., P. ve Denker, J., S., 1989. Handwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning, IEEE Communications Magazine, 27, 11, 41–46.
- LeCun, Y., Boser, B., Denker, J., S., Henderson, D., Howard, R., E., Hubbard, W. ve Jackel, L., D., 2015. Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation, 1, 4, 541–551.
- Lee, B., Y., Kim, Y., Y., Yi, S., T. ve Kim, J., K., 2013. Automated Image Processing Technique for Detecting and Analysing Concrete Surface Cracks, Structure and Infrastructure Engineering, 9, 6, 567–577.
- Lin, Y., Z., Nie, Z., H. ve Ma, H., W., 2017. Structural Damage Detection with Automatic Feature-Extraction Through Deep Learning, Computer-Aided Civil and Infrastructure Engineering, 32, 12, 1025–1046.
- Ma, X., Dai, Z., He, Z., Ma, J., Wang, Y. ve Wang, Y., 2017. Learning Traffic as Images: A Deep Convolutional Neural Network for Large-Scale Transportation Network Speed Prediction, Sensors, 17, 4, 818.
- Mangalathu, S. ve Burton, H., V., 2019. Deep Learning-Based Classification of Earthquake-Impacted Buildings Using Textual Damage Descriptions, International Journal of Disaster Risk Reduction, 36, 101111.
- McCarthy, J., Minsky, M., L., Rochester, N. ve Shannon, C., E., 2006. A proposal for the Dartmouth Summer Research Project on Artificial Intelligence, AI Magazine, 27, 4, 12–14.
- Mohanaselvi, S. ve Hemapriya, G., 2018. Application of Fuzzy Logic to Earthquake Damage Predictions, AIP Conference Proceedings, June 2019, India, 1-10.
- Nabiyev, V., 2012. Yapay Zeka, Seçkin Yayınevi, Ankara,
- Naqa, I., E., Li, R. ve Murphy, M., J., 2015. Machine Learning in Radiation Oncology, Springer Cham, Switzerland.
- Neves, A., C., González, I., Leander, J. ve Karoumi, R., 2018. International Conference on Experimental Vibration Analysis for Civil Engineering Structures, July, 2017, 73-84.
- Nishikawa, T., Yoshida, J., Sugiyama, T. ve Fujino, Y., 2012. Concrete Crack Detection by Multiple Sequential Image Filtering, Computer-Aided Civil and Infrastructure Engineering, 27, 29–47.

- Okazaki, Y., Okazaki, S., Asamoto, S. ve Chun, P., J., 2020. Applicability of Machine Learning to a Crack Model in Concrete Bridges, Computer-Aided Civil and Infrastructure Engineering, 35, 8, 775–792.
- Özbayrak, A., 2019. Deprem Etkisi Altındaki Betonarme Kirişsiz Plak Döşemelerin Eğilme Momentlerinin YSA Analizi ile Tahmin Edilmesi, Ömer Halis Demir Üniversitesi Mühendislik Bilimleri Dergisi, 8, 2, 979–991.
- Özdülkar, K., Üneş, F., Demirci, M. ve Kaya, Y., Z., 2019. Günlük Buharlaşma Miktarının Bulanık Mantık Yöntemleri Kullanılarak Bölgesel Olarak Modellenmesi, Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2, 1, 23–29.
- Öztürk, K. ve Şahin, M., E., 2018. A General View of Artificial Neural Networks and Artificial Intelligence, Takvim-i Vekayi, 6, 2, 25–36.
- Pathirage, C., S., N., Li, J., Li, L., Hao, H., Liu, W. ve Ni, P., 2018. Structural Damage Identification Based on Autoencoder Neural Networks and Deep Learning, Engineering Structures, 172, 1, 13–28.
- Peemen, M., Shi, R., Lal, S., Juurlink, B., Mesman, B. ve Corporaal, H., 2016. The Neuro Vector Engine: Flexibility to Improve Convolutional Net Efficiency for Wearable Vision, 2016 Design, Automation & Test in Europe Conference & Exhibition (DATE), March 2016, Germany, 1604-1609.
- Santos, A., Figueiredo, E., Silva, M., F., M., Sales, C., S. ve Costa, J., C., W., A., 2016. Machine Learning Algorithms for Damage Detection: Kernel-Based Approaches, Journal of Sound and Vibration, 363, 584–599.
- Schmidhuber, J., 2015. Deep Learning in Neural Networks: An Overview, Neural Networks, 61, 85–117.
- Şeker, A., Diri, B. ve Balık, H., H., 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, Gazi Mühendislik Bilimleri Dergisi, 3, 3, 47–64.
- Simonyan, K., ve Zisserman, A., 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition. In: 3rd International Conference on Learning Representations, ICLR 2015- Conference Track Proceedings, 1–14.
- Stoyanov, D., B. ve Nixon, J., D., 2020. Alternative Operational Strategies for Wind Turbines in Cold Climates, Renewable Energy, 145, 2694–2706.
- Sünbül, A., B., Uzun, R. ve ErKaymaz, H., 2015. Zemin Sıvılaşma Potansiyelinin Bulanık Mantık ile Modellenmesi, Karaelmas Fen ve Mühendislik Dergisi, 5, 2, 101–104.
- T., S., Khilar, R. ve Christo, S., M., 2021. Withdrawn: A Comparative Analysis on Plant Pathology Classification Using Deep Learning Architecture – Resnet and VGG19, Materials Today: Proceedings, 1.

- Toğaçar, M., Ergen, B., Özyurt, F. ve Özyurt, F., 2020. Evrişimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması, Fırat Üniversitesi Mühendislik. Bilimleri Dergisi, 32, 1, 47–56.
- Topçu, İ., B. ve Sarıdemir, M., 2008. Yüksek-Düşük Kireçli Uçucu Kül İçeren Betonların Basınç Dayanımının YSA ve BM Kullanarak Tahmin Edilmesi, Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi, 21, 1, 39–56.
- URL-1, <http://kod5.org/yapay-sinir-aglari-ysa-nedir/> Yapay Sinir Ağları (YSA) Nedir. 5 Mart 2022.
- URL-2, <https://ekblc.files.wordpress.com//2013/09/esnek-hesaplamaya-giric59f.pdf> Esnek Hesaplamaya Giriş. 15 Nisan 2022.
- URL-3, <https://ayyucekizrak.medium.com/derin-ogrenme-icin-aktivasyon-fonksiyonlari-nin-karstlastirilmasi-cee17fd1d9cd> Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması. 15 Nisan 2022.
- URL-4, <https://medium.com/deeper-deep-learning-tr/aktivasyon-fonksiyonu-120769040f7b> Aktivasyon Fonksiyonları. 3 Haziran 2022.
- URL-5, <https://www.forbes.com/sites/bernardmarr/2018/10/01/what-is-deeplearning-ai-a-simple-guide-with-8-practical-examples/?sh=1dde3a048d4b> What Is Deep Learning AI? A Simple Guide With 8 Practical Examples. 7 Temmuz 2022.
- URL-6, https://www.beyaz.net/tr/yazilim/makaleler/derin_ogrenme_deep_learning_nedir.htm l, Derin Öğrenme (Deep Learning) Nedir?. 7 Temmuz 2022.
- URL-7, <https://burhanbilen.medium.com/karışıklık-matrisi-confusion-matrix-990dfc718653> Karışıklık Matrisi. 15 Temmuz 2022.
- Wang, N., Zhao, X., Zhao, P., Zhang, Y., Zou, Z. ve Ou, J., 2019. Automatic Damage Detection of Historic Masonry Buildings Based on Mobile Deep Learning, Automation in Construction, 103, 53–66.
- Wang, H., Zifan, W. ve Yang, F., 2020. Score-CAM: Score-Weighted Visual Explanations for Convolutional Neural Networks, 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June, USA, 111-119.
- Yaraş, N., 2020. Vehicle Type Classification with Deep Learning, Yüksek Lisans Tezi, İzmir Yüksek Teknoloji Enstitüsü, İzmir.
- Yurtcu, Ş. ve Özocak, A., 2016. İnce Daneli Zeminlerde Sıkışma İndisi'nin İstatistiksel ve Yapay Zeka Yöntemleri ile Tahmin Edilmesi, Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 31, 3, 597–608.

- Zeiler, M., D., Ranzato, M., Monga, R., Mao, M., Yang, K., Le, Q., V., Nguyen, P., Senior, A., Vanhoucke, V., Dean, J., Hinton, G., E., 2013. On Rectified Linear Units for Speech Processing, 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, May, 2013, Canada, 3517–3521.
- Zhang, W., Li, H., Li, Y., Liu, H., Chen, Y. ve Ding, X., 2021. Application of Deep Learning Algorithms in Geotechnical Engineering: A Short Critical Review, Artificial Intelligence Review, 54, 8, 5633–5673.
- Zhang, Y., Burton, H., V., Sun, H. ve Shokrabadi, M., 2018. A Machine Learning Framework for Assessing Post-Earthquake Structural Safety, Structural Safety, 72, 1–16.



ÖZGEÇMİŞ

Tuğba ABDİOĞLU, ilk ve orta öğrenimini Yomra Yavuz Selim İlkokulu'nda, lise öğrenimini ise Arsin Anadolu Lisesi'nde tamamladı. 2014 yılında, Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü'nü kazandı. Lisans eğitimini 2018 yılında tamamladı ve 2019 yılında Karadeniz Teknik Üniversitesi, İnşaat Mühendisliği Bölümü'nde yüksek lisans öğrenimine başladı.

