



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS PROGRAMI

**ADAPTİF TRANSFER ÖĞRENME MODELİ GELİŞTİREREK
HASTALIK TEŞHİSİ**

YÜKSEK LİSANS TEZİ

Harun YILMAZ

Danışman: Doç. Dr. Cem EMEKSİZ

TOKAT- 2023

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Cem EMEKSİZ danışmanlığında hazırlamış olduğum “Adaptif Transfer Öğrenme Modeli Geliştirerek Hastalık Teşhisi” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

/ /

Harun YILMAZ

ÖZET

ADAPTİF TRANSFER ÖĞRENME MODELİ GELİŞTİREREK HASTALIK TEŞHİSİ

Yılmaz, Harun
Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı
Tez Danışmanı: Doç. Dr. Cem EMEKSİZ
Aralık 2023, xi + 75 sayfa

Dünya genelinde her yıl zatürre hastalığından milyonlarca insan etkilenmekte ve ölümler yaşanmaktadır. Bu yüzden zatürre hastalığının erken teşhisi, tedavi süreci için hayati öneme sahiptir. Bu çalışmada hastalığın teşhisi için derin öğrenmeye dayalı web tabanlı bir tanı sistemi geliştirilmiştir. Bu amaçla MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 derin öğrenme modelleri kullanılmıştır. İnce ayar stratejisi derin öğrenme modellerinin son katmanının hedef verilerine göre özelleştirilmesiyle uygulanmıştır. Modellerin daha iyi tahminleme yapabilmesi için çeşitli veri artırma yöntemleri kullanılarak görüntü sayısı artırılmıştır. Performans değerlendirmesi için doğruluk, kesinlik, F1 ve Auc-Roc skor parametreleri kullanılmıştır. Deneysel çalışmalarda MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 modellerinin doğruluk yüzdeleri %84.4, %88.6, %88.5, %90, %87.8 iken özelleştirilmiş modellerin doğruluk değerleri sırasıyla %89.2, %92.3, %87.8, %91.5, %89.4'tür. Özgün modeller ile özelleştirilmiş modeller karşılaştırıldığında, özelleştirilmiş ResNet50V2 ve özelleştirilmiş VGG16 modelleri, modeller arasında %92,3 ve %91,5 doğrulukla daha yüksek performans sergiledi.

Anahtar Kelimeler: Derin Öğrenme, Evrişimli Sinir Ağları, Transfer Öğrenme, Zatürre Tespiti

ABSTRACT
**DISEASE DETECTION BY DEVELOPING AN ADAPTIVE TRANSFER LEARNING
MODEL**

Yılmaz, Harun
Master's Thesis, Department of Computer Engineering
Advisor: Assoc.Prof.Dr.Cem EMEKSİZ
December 2023, xi + 75 pages

Millions of people are affected and die from pneumonia every year around the world. Therefore, early diagnosis of pneumonia is vital for the treatment process. In this study, a web-based diagnosis based on deep learning for the diagnosis of the disease system has been developed. For this purpose, MobileNetV2, ResNet50V2, ResNet152V2, VGG16 and VGG19 deep learning models were used. The fine-tuning strategy was applied by customizing the last layers of deep network models based on the target data. In order for the models to make better predictions, the number of images was increased by using various data augmentation methods. The parameters of accuracy, precision, F1 and Auc-Roc score were used to evaluate the model performance. In experimental studies, the accuracy percentages of MobileNetV2, ResNet50V2, ResNet152V2, VGG16 and VGG19 models were 84.4%, 88.6%, 88.5%, 90%, 87.8%. The accuracy values of the customized models are 89.2%, 92.3%, 87.8%, 91.5%, 89.4%, respectively. When comparing the original models with customized models, the customized ResNet50V2 and customized VGG16 models, exhibited a higher performance with accuracy of 92.3% and 91.5% among the models.

Keywords: Deep Learning, Convolution Neural Network, Transfer Learning, Pneumonia Detection

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
İÇİNDEKİLER	iii
ŞEKİLLER LİSTESİ	vi
ÇİZELGELER LİSTESİ.....	ix
KISALTMALAR ve SİMGELER.....	x
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ	5
3. YAPAY SİNİR AĞLARI	11
3.1. Tek Katmanlı Algılayıcı	12
3.2. Çok Katmanlı Algılayıcı.....	13
4. DERİN ÖĞRENME	15
4.1. Evrişimli Sinir Ağları.....	16
4.1.1. Evrişimli sinir ağı katmanları	19
4.2. Tekrarlayan Sinir Ağları	24
4.3. Uzun Kısa Vadeli Bellek	25
5. AKTİVASYON FONKSİYONLARI VE BAŞARIM ARTTIRMA YÖNTEMLERİ	27
5.1. Geri Yayılım Algoritması	27
5.2. Aktivasyon Fonksiyonları.....	28
5.2.1 İkili adım fonksiyonu.....	28
5.2.2 Doğrusal fonksiyon.....	29
5.2.3 Sigmoid fonksiyonu	30

5.2.4	Hiperbolik tanjant fonksiyonu	31
5.2.5	ReLU fonksiyonu.....	32
5.2.6	Sızıntı ReLU fonksiyonu	32
5.2.7	Softmax fonksiyonu	33
5.3	Hata Fonksiyonları.....	34
5.4	Regülerizasyon Yöntemleri	34
5.4.1	Veri setinin boyutunu artırma	35
5.4.2	Cutout.....	36
5.4.3	Düğüm seyreltme ve düğüm bırakma	36
5.4.4	Erken durdurma	36
5.4.5	Toplu normalizasyonu	37
5.4.6	Ağırlık normalizasyonu	37
5.4.7	L2 düzenlemesi	37
5.4.8	L1 düzenlemesi	38
5.5	Optimizasyon Algoritmaları	38
5.5.1	Stokastik gradyan inişi.....	38
5.5.2	Momentumlu gradyan iniş	38
5.5.3	Uyarlanabilir gradyan algoritması (AdaGrad).....	39
5.5.4	Karekök ortalama kare yayılım (RMSProp).....	39
5.5.5	Uyarlanabilir moment tahmini (Adam)	40
6.	MATERYAL ve YÖNTEM	41
6.1.	Öğrenme Aktarımı (Transfer Öğrenme)	41
6.1.1.	VGG16 modeli.....	42

6.1.2.	VGG19 modeli.....	42
6.1.3.	MobileNetV2 modeli	43
6.1.4.	ResNet50V2 modeli.....	45
6.1.5.	ResNet152V2 modeli.....	45
6.1.6.	Özelleştirilmiş model	46
6.2.	Veri Seti	48
6.3.	Web Arayüzünün Geliştirilmesi	49
6.4.	GUI Arayüzü ve Uygulama Prosedürü	50
6.5.	Performans Parametreleri	51
7.	BULGULAR ve TARTIŞMA	53
7.1.	Deneyisel Çalışma Ortamı	53
7.2.	Deneyisel Veriler ve Deneyisel Ayarlar	54
7.2.1.	Deneyisel sonuçlar ve analiz.....	55
8.	SONUÇ ve ÖNERİLER	65
9.	KAYNAKLAR	67
	ÖZGEÇMİŞ	75

ŞEKİLLER LİSTESİ

Şekil No	Sayfa
Şekil 3.1. İnsan beynine ait bir sinir hücresi (nöron) (Konaté, 2019).....	11
Şekil 3.2. Yapay sinir ağının matematiksel modeli (Konaté, 2019)	12
Şekil 3.3. Tek katmanlı sinir ağı yapısı (Jan ve ark., 2020).....	12
Şekil 3.4. Tek katmanlı algılayıcı modeli (Oliveira ve ark., 2017)	13
Şekil 3.5. Çok katmanlı algılayıcı yapısı (Konaté, 2019).....	14
Şekil 4.1. Dijital görüntünün piksellerle temsil edilmesi (Dupont ve ark., 2018)	17
Şekil 4.2. Evrişimli sinir ağı mimarisi (Tammina, 2019)	18
Şekil 4.3. Erişim katmanı özellik çıkarma (Albawi ve ark., 2017).....	18
Şekil 4.4. Evrişimli sinir ağı katmanları (Hussain ve ark., 2019).....	19
Şekil 4.5. Görüntünün ve filtrenin ilk adım evrişim işlemi (Albawi ve ark., 2017).....	20
Şekil 4.6. Görüntünün ve filtrenin ikinci adım evrişim işlemi (Albawi ve ark., 2017)	20
Şekil 4.7. Görüntünün ve filtrenin son adım evrişim işlemi (Albawi ve ark., 2017).....	21
Şekil 4.8. Adım sayısının çıktı matrisine etkisi (Gsaxner ve ark., 2019)	21
Şekil 4.9. Dolgulama işlemi (Wahyudi Setiawan ve ark., 2019).....	22
Şekil 4.10. Maksimum ve ortalama havuzlama işlemi (Albawi ve ark., 2017).....	23
Şekil 4.11. Tam bağlantı ve düzleştirme katmanı (Albawi ve ark., 2017)	24
Şekil 4.12. Tekrarlayan sinir ağı (Murugesan ve ark., 2021)	25
Şekil 4.13. Uzun kısa vadeli bellek mimari yapısı (Murugesan ve ark., 2021).....	26
Şekil 5.1. Geri yayılım algoritması (Li ve ark., 2021).....	27
Şekil 5.2. Basamak fonksiyonu ve türevi (Sharma ve ark., 2017).....	28

Şekil 5.3. Doğrusal fonksiyon ve türevi (Sharma ve ark., 2017).....	29
Şekil 5.4. Sigmoid fonksiyonu ve türevi (Rasamoelina ve ark., 2020)	30
Şekil 5.5. Hiperbolik tanjant fonksiyonu ve türevi (Rasamoelina ve ark., 2020).....	31
Şekil 5.6. ReLU fonksiyonu ve türevi (Rasamoelina ve ark., 2020)	32
Şekil 5.7. Sızıntı ReLU fonksiyonu ve türevi (Sharma ve ark., 2017)	33
Şekil 5.8. Görüntü artırımı uygulanmış x-ray görüntüsü (Kaggle, 2018).....	35
Şekil 5.9. (a) Normal sinir ağı ve (b) seyreltme sonrası (Konaté, 2019)	36
Şekil 5.10. Erken durdurma (Naushad ve ark., 2021).....	37
Şekil 6.1. Öğrenme aktarımı mimarisi (Sharma ve ark., 2022)	41
Şekil 6.2. VGG16 model mimarisi (Kamal ve Hamid, 2023)	42
Şekil 6.3. VGG19 model mimarisi (Sudha ve Ganeshbabu, 2021)	43
Şekil 6.4. MobilenetV2 mimarisi (Sandler ve ark., 2018).....	43
Şekil 6.5. ResNet50V2 model mimarisi (Kvak, 2022)	45
Şekil 6.6. Resnet152V2 model mimarisi (Pustokhin ve ark., 2023).....	46
Şekil 6.7. Özelleştirilmiş model mimarisi	47
Şekil 6.8. Veri seti göğüs röntgeni görüntüleri	48
Şekil 6.9. Eğitim, doğrulama ve test veri setinin yaklaşık yüzdelik dağılımı.....	48
Şekil 6.10. Web uygulamasına ait ekran görüntüsü.....	49
Şekil 6.11. Normal hastaya ait tahmin sonucu.....	50
Şekil 6.12. Pozitif hastaya ait tahmin sonucu	51
Şekil 7.1. Modellere ait eğitim/test kayıp ve eğitim/test doğruluk grafiği (a) MobileNetV2 modeli, (b) MobileNetV2 özelleştirilmiş model, (c) ResNet50V2 modeli, (d) ResNet50V2 özelleştirilmiş model, (e) ResNet152V2 modeli, (f) ResNet152V2 özelleştirilmiş model, (g)	

VGG16 modeli, (h) VGG16 Özelleştirilmiş model, (i) VGG19 Modeli, (k) VGG19 özelleştirilmiş model.....59

Şekil 7.2. Modellere ait elde edilen hata matrisi grafiği (a) MobileNetV2 modeli, (b) MobileNetV2 özelleştirilmiş model, (c) ResNet50V2 modeli, (d) ResNet50V2 özelleştirilmiş model, (e) ResNet152V2 modeli, (f) ResNet152V2 özelleştirilmiş model, (g) VGG16 modeli, (h) VGG16 Özelleştirilmiş model, (i) VGG19 Modeli, (k) VGG19 özelleştirilmiş model.61

Şekil 7.3. Modellere ait elde edilen ROC eğrisi grafiği (a) MobileNetV2 modeli, (b) MobileNetV2 özelleştirilmiş model, (c) ResNet50V2 modeli, (d) ResNet50V2 özelleştirilmiş model, (e) ResNet152V2 modeli, (f) ResNet152V2 özelleştirilmiş model, (g) VGG16 modeli, (h) VGG16 Özelleştirilmiş model, (i) VGG19 Modeli, (k) VGG19 özelleştirilmiş model.62

ÇİZELGELER LİSTESİ

Çizelge No	Sayfa
Çizelge 6.1. Kanalı k 'dan k' 'ne dönüştüren, adımını S olan ve genişleme faktörü T olan darboğaz artıklık bloğu (Sandler ve ark, 2018).	44
Çizelge 6.2. MobileNetV2: T artan boyutun genişleme katsayısı, C çıkış kanallarının sayısı, K sınıflandırma görevinin kategori sayısıdır. N , her modülün tekrarlanma sayısını ifade eder. S , her modülün ilk kez çalıştırıldığı andaki adımdır; bundan sonra adım varsayılan olarak 1 olur. Genişleme faktörü T her zaman Çizelge 6.1'de açıklandığı gibi giriş boyutuna uygulanır (Sandler ve ark, 2018).	44
Çizelge 7.1. Modellere ait performans değerleri	56
Çizelge 7.2. Önerilen yöntemin literatürdeki çalışmalar ile kıyaslanması	63

KISALTMALAR ve SİMGELER

Kısaltmalar	Açıklama
AdaGrad	Uyarlanabilir Gradyan
ADAM	Uyarlanabilir Moment Tahmini
AP	Anterior Posterior
BT	Bilgisayarlı Tomografi
CXR	Göğüs Röntgeni
DSO	Dünya Sağlık Örgütü
ESA	Evrişimli Sinir Ağları
GTB	Geçitli Tekrarlayan Birim
KHDAK	Küçük Hücreli Dışı Akciğer Kanseri
LSTM	Uzun Kısa Vadeli Bellek
ML	Makine Öğrenme
MRG	Manyetik Rezonans Görüntüleri
PA	Poster Anterior
PET	Pozitron Emisyon Tomografi
PQ	Güç Kalitesi
RMSPProp	Karekök Ortalama Kare Yayılımı
RNN	Tekrarlayan Sinir Ağı
SGD	Stokastik Gradyan İnişi
TL	Transfer Öğrenme
UNICEF	Birleşmiş Milletler Çocuklara Yardım Fonu
YSA	Yapay Sinir Ağları

Simgeler	Açıklama
β_1, β_2	Üssel Azalma Oranı
g_t	Kayıp Fonksiyonu İçin Birinci Türev
L_m	Kayıp Değeri
V_t	Gradyanın Üssel Hareketli Ortalaması
γ	Momentum Parametresi
η	Öğrenme Oranını

1. GİRİŞ

Zatürre (Pnömoni), segmental, lobar veya multilobar olabilen radyolojik pulmoner gölgelenme ile ilişkili akciğerleri etkileyen akut solunum yolu enfeksiyon hastalığı olarak tanımlanır (Reid ve Innes, 2010). Akciğerler, sağlıklı bir insanın nefes alması sonucu hava ile dolan ve alveol adı verilen küçük keseciklerden meydana gelmektedir. Bir kişi zatürre olduğunda, alveoller iltihap ve sıvı ile dolar, bu da nefes almayı ağırlı hale getirir ve oksijen alımını sınırlar (WHO, 2020). Bazı hastalarda kuru öksürük, göğüs ağrısı, ateş, titreme, nefes almada zorluk, hipertermi, balgamlı veya balgamsız öksürük gibi akut solunum enfeksiyonu görülmekteyken bazı hastalarda ise; karın ve baş ağrısı, yorgunluk, iştahsızlık gibi genel semptomlarda görülmektedir. Zatürre hastalığı erken teşhis ve tedavi edilmezse ölümcül sonuçlara neden olabilmektedir. 2016 yılında UNICEF tarafından yapılan bir araştırmada, beş yaş altındaki bebeklerin ölümlerinin yaklaşık %16'sını oluşturduğu tespit edilmiştir (Sakthivel ve ark., 2023). Dünya Sağlık Örgütü (DSÖ) verilerine göre zatürre hastalığı, 2017 yılında beş yaş altındaki çocukların 808.000'den fazlasını ölümüne neden olmuş, beş yaş altı tüm ölümlerin %15'ini 2019 yılında ise 740.180 ölüm sayısı ile beş yaş altı tüm ölümlerin %14' ünü oluşturmaktadır (WHO, 2020; WHO, 2022). Yalnızca ABD'de her yıl 1 milyondan fazla yetişkin zatürre nedeniyle hastaneye kaldırılmakta ve yaklaşık 50.000 kişi bu hastalıktan dolayı ölmektedir (Rajpurkar ve ark., 2017).

Yine DSÖ tarafından açıklanan verilere göre her yıl zatürreden etkilenen beş yaş ve altı 155 milyon çocuk bulunmaktadır. Bunlardan yaklaşık 20 milyonu tedavi edilmek için hastaneye yatırılırken 2 milyondan fazla çocuk ise zatürre hastalığından dolayı ölmektedir (Rudan ve ark., 2008). Dünya çapında en çok çocukları ve yaşlıları etkileyerek bulaşıcı ölümlere neden olan ve gelişmiş ülkelere kıyasla gelişmekte olan ülkelerde beş kat daha fazla görülen bu hastalık, Güney Asya ve Sahra altı Afrikada daha yaygın görülmektedir. Bu ölümler her yıl dünya nüfusunun yaklaşık %7,7'sini etkilemektedir (Wang ve ark., 2022). Neyse ki, zatürre hastalığının erken tanısı çeşitli antibiyotikler ve antiviral ilaçlar kullanarak tedavisini mümkün kılmaktadır. Erken tanı kadar hastalığın tespitinde kullanılan yöntemlerde önemli bir yere sahiptir.

Günümüzde göğüs bilgisayarlı tomografisi (BT), göğüs manyetik rezonansı (MR) ve göğüs röntgeni zatürre teşhis araçları olarak kullanılmaktadır (Kumar ve ark., 2023). Yüksek görüntüleme hızı, düşük radyasyon ve düşük maliyet nedeniyle göğüs röntgeni, göğüs anormallikleri olan hastaların tanısal tetkiklerinde en sık kullanılan görüntüleme yöntemidir (Self ve ark., 2013).

Az gelişmiş veya gelişmekte olan ülkelerde göğüs röntgen görüntülerinin tercih edilmesinin nedeni BT makinelerinin az olması veya görüntü kalitesinin düşük olmasından kaynaklanmaktadır. Fakat kullanılan geleneksel röntgen yöntemleri zatürre veya diğer akciğer rahatsızlıklarının teşhisinde uzman doktor ve radyolog bulunmasını zorunlu kılmaktadır. Ek olarak uzmanlar arasındaki görüş farklılıkları ve hastalığın teşhisi için gerekli eğitimleri almış uzman radyolog eksikliği erken teşhis ve doğru tedavi yöntemleri için teknolojiyi zorunlu kılmaktadır.

Yaşanan biyosensör teknolojisindeki gelişmeler zatürre gibi solunum rahatsızlıklarının tedavisinde yardımcı olarak kullanılabilir. Yapılan birçok çalışmada radyologların yalnızca röntgen görüntülerine dayanarak zatürreyi teşhis edemeyeceği görülmektedir (Gupta ve ark., 2021). Ayrıca göğüs röntgeni X-ışını radyografilerinin bulanık olması, akciğerde bulunan kanser ve aşırı sıvı gibi çeşitli lezyonların bulunması tanının konmasını zorlaştırmaktadır. Kan testleri ve balgam mikrobiyal kültürleri hastalığın tespiti için kullanılsa da bu durum zaman alıcı ve maliyetlidir (Zhao ve ark., 2021).

Teknolojinin gelişmesi ile birlikte bilgisayar sistemlerinin ve yapay zeka algoritmalarının teşhis yöntemlerinde kullanılması zamandan tasarruf, maliyet açısından avantaj sağlamaktadır. Aynı zamanda, yapay zeka algoritmaları zatürre tespiti dışında beyin tümörlerinin ve meme kanserinin tespiti başta olmak üzere çeşitli sağlık sorunlarının tespitinde de kullanılmaktadır (He ve ark., 2016). Derin öğrenme; segmentasyon (Zhao ve ark., 2021; Budak ve Mençik, 2022), nesne algılama (Aytekin ve Mençik, 2022), tıbbi görüntü tanıma (Budak ve ark., 2023) ve düşük seviyeli görme görevleri (Wei ve ark., 2021) gibi birçok alanda çığır açan başarılar elde etmiştir.

Bir derin öğrenme tekniği olan Evrişimli Sinir Ağları (ESA) ise ses tanıma (Bae ve ark., 2016), görüntü işleme (Razzak ve ark., 2018) ve örüntü tanılamada (Bishop ve Nasrabadi,

2006) başarılı sonuçlar vermektedir. Gelişmiş performans, girdi olarak verilen görüntüden otomatik olarak özellik çıkarımı ve etkili sonuçlar nedeniyle görüntü sınıflandırmasını araştıran araştırmacılar tarafından geleneksel yaklaşımlar yerine ESA yaklaşımları tercih edilmektedir. Derin öğrenme algoritmalarının kullanılması ile akciğer röntgenlerinden zatürreyi tespit etmek radyologların iş yükünü azaltabilir. Göğüs röntgeni görüntülerine sınıflandırma yöntemleri kullanılarak zatürreyi saptamak için kullanılabilir. Özellikle tıp alanında derin öğrenme yöntemlerinin uygulanması çok sayıda karmaşık zorluğun kolayca üstesinden gelmektedir. Tedavi için gerekli tespit, karar, analiz ve ileri kapsam süreçlerinde derin öğrenme yüksek seviyede doğruluk sağlamaktadır. Hastalıkların tanısı en hızlı şekilde tespiti mümkün kılabilir ve daha iyi kararlar alınabilir (Saikrishna ve ark., 2021). Bu yüzden derin öğrenmenin tıp alanında da birçok uygulaması vardır.

Bu çalışmada, dünyada en çok çocuk ve yaşlı ölümlerine neden olan zatürre hastalığının erken tanısı için transfer öğrenme tabanlı derin öğrenme modelleri kullanarak ve bu modellere çeşitli ayarlar uygulayarak hastalık teşhisi için en iyi tahminleme yapabilen bir derin öğrenme modeli ve hastalığın daha hızlı tespiti için çevrimiçi bir uygulama gerçekleştirilmiştir. Bu çalışmalar için çevrimiçi Kaggle platformunda herkese açık olarak yayınlanan göğüs röntgen görüntülerinden oluşan veri kümesi kullanılmıştır. Veri kümesi hasta ve zatürre olmak üzere iki sınıftan oluşmaktadır. Bu veri tabanı toplamda eğitim için 5216, test için 624 görüntüsü içermektedir. Önceden eğitilmiş derin öğrenme modelleri MobileNetV2, ResNet50, ResNet152V2, VGG16, VGG19 ve gibi modeller özelleştirilerek görüntülerin sınıflandırılması için kullanılmıştır. Bu çalışmanın temel katkıları şunlardır:

- Göğüs röntgeni görüntüleri aracılığıyla zatürre teşhis süreci radyologlar için zaman alıcı ve hata yapmaya açık olabilir. Bu nedenle, uzmanların zatürre hastalarını doğru bir şekilde tanılamalarına yardımcı olabilen bir bilgisayar destekli bir yöntem geliştirme ihtiyacı büyük önem taşımaktadır. Bu bağlamda, transfer öğrenmeye dayalı doğru bir tanı sistemi geliştirilmiştir.
- Göğüs röntgenleri şüpheli hastaların erken teşhisini sağlayabilir. Ayrıca doktor veya radyologların iş yükünü azaltmak, zamandan tasarruf sağlamak amacıyla göğüs

röntgen görüntülerinin bir web uygulaması üzerinden hastalık tanısını daha kısa sürede ve yüksek doğruluk oranı ile belirleyeceği bir uygulama geliştirilmiştir.

- Bir bilgisayar destekli tanı sistemi, kırsal bölgelerde zatürre hastalığı teşhisi için uzaktan destek aracı olarak kullanılabilir.
- Program çok hızlı çalıştığından, hastaneye sağlık sorunu nedeniyle başvuran binlerce hastanın görüntüleri sistemde otomatik olarak taranabilir ve bu sayede zatürre hastalığı tespiti hızlı bir şekilde yapılabilir.



2. LİTERATÜR ÖZETLERİ

Kim ve MacKinnon (2018), yaptıkları çalışmada kemik kırıklarıyla ilgili bir konuyu ele almışlardır. Kullandıkları model derin evrişimli sinir ağıdır ve transfer öğrenme yöntemini içermektedir. Modelin adı Inception v3'tür ve kemik kırığı verisi üzerinde eğitilmiştir. Veri seti radyograflar şeklindeydi ve bu veriler %80 eğitim, %10 doğrulama ve %10 test verisi olacak şekilde ayrılmıştır. Radyograflar olarak temsil edilen veriler önceden işleminden geçmiştir. Bu modelle elde ettikleri doğruluk oranı %95.4'tür. Doğruluk değeri belirli koşulları içermektedir. En yüksek duyarlılık ve özgüllük değerlerinin olduğu noktada doğruluk değeri alınmıştır, yani 0.9 duyarlılık ve 0.88 özgüllük değerlerine sahip olduğu durumda bu değer elde edilmiştir.

Rubin ve ark., (2018), Çift Evrişimli Sinir Ağları'nın uygulanması üzerine bir araştırma yapmışlar ve Çift Ağ Mimarisi, radyolojik bir testten elde edilen hem ön hem de yatay (yan) CXR görüntülerini aynı anda hazırlamayı rutin klinik uygulamayı taklit etmiştir. Bu modelde veri seti olarak Kaggle platformunda paylaşılan MIMIC-CXR görüntüleri kullanmışlardır. MIMIC-CXR veri setinde, çeşitli temel göğüs hastalıklarını tanımak için derin evrişimli sinir ağları eğittiler ve ardından önceki araştırma çabalarından daha az ilgi gören frontal ve yan göğüs röntgenlerini eğitmek için ESA modellerini tanımlamışlar ve kullanmışlardır. Ayrıca anteroposterior (AP) ve posteranterior (PA) frontal görünüm tipleri için farklı modeller geliştirmişler. Son olarak, DualNet tasarımı ön (PA veya AP) ve yan veri görüntülerini tanır. İki evrişimli sinir ağı her veri için eşit olarak eğitilir ve çıktıları son tamamen bağlı bir katmanda birleştirilir, böylece çoklu etiket tahmini oluşturulur. Yazarlar çalışmalarında Dual Net PA + Yan için %62,5 doğruluk ve Dual Net AP+Yan kullanarak %59,3 doğruluk elde etmişlerdir.

Jaiswal ve ark., (2019), derin bir sinir ağı olan Mask-RCNN'nin uygulanması üzerine bir araştırma yapmışlardır ve bu çalışmada veriler, çevrimiçi platformu olan GitHub'dan alınmıştır ve veri tipi CXR görüntülerinden oluşmaktadır. Bu çalışmanın benzersiz özelliği, global ve yerel çıkarılmış özellikleri ayıran bir sinir ağı tanıtmasıdır. ResNet50 ve ResNet101 algoritmaları üzerinde uygulama yapılmış ve ayrıca, daha iyi doğruluk elde etmek için veri artırma tekniği uygulanmıştır. Eğitim sonucunda ResNet50 ile %30, ResNet101 ile %97

doğruluk elde edilmiştir. Ayrıca, yukarıdaki iki modelin birleşik bir modelini oluşturmayı denemişler ve %21.8 doğruluk elde etmişlerdir.

Milliante ve ark., (2020), yaptıkları çalışmalarında VGG-16, ESA modelini uygulayan derin öğrenme modelini kullanarak göğüs röntgeni görüntülerinde Covid -19, bakteriyel ve viral-zatürre hastalığından etkilenmemiş ve etkilenmiş hastalıkları tahmin etmişlerdir. Eğittikleri VGG- 16, ESA modellerinin performansını kanıtlamak için 32 toplu iş boyutuna sahip 224x224 görüntü çözünürlüğü kullanan 20.000 görüntüden oluşan veri setini kullanmışlar ve eğitilmiş modelleri, eğitimin yürütülmesi sırasında %95 doğruluk oranına ulaşmıştır.

Jain ve ark., (2020), ESA ve Transfer Öğrenme'nin uygulanması üzerine bir araştırma yapmış ve bu çalışmada Kaggle platformundan aldıkları Göğüs X-ışınları (CXR) görüntülerinden oluşan veri setini kullanılmaktadır. Bu çalışmanın benzersiz özelliği, global ve yerel çıkarılmış özellikleri ayıran bir sinir ağı tanıtmasıydı. Uygulama dört algoritma üzerinde gerçekleştirilmiştir: VGG16, VGG19, ResNet50 ve InceptionV3. Ayrıca, daha iyi doğruluk elde etmek için veri artırma tekniği uygulanmış ve aşırı uyumun azaltılması için seyreltme kullanılmıştır. Yazarlar eğitim sonucunda VGG16 ile %87,28, VGG19 ile %88,46, ResNet50 ile %77,56 ve InceptionV3 ile %70,99 doğruluk elde etmişlerdir.

Mangal ve ark., (2020), göğüs X-ışınları kullanarak COVID tespiti üzerine derin öğrenme algoritmalarını incelemişlerdir. Bu çalışmada, evrişim katmanıyla CovidNet adında bir model oluşturdular ve COVID-19 hastalığını tespit etmeye yardımcı olmaktadır. RT-PCR testinin sonuçlarının çok uzun sürdüğünü belirttiler ve aynı zamanda modelin tespit sırasında zaman verimliliğini vurguladılar. Modelin eğitimi için kullanılan veri göğüs X-ışınları kullanılmıştır. Modelin %90,5 verimlilikle çalıştığını ve %100 hassasiyete sahip olduğunu iddia etmişlerdir.

Bıçakçı (2021), yapmış olduğu çalışmasında pozitron emisyon tomografi (PET) görüntüleri kullanılarak Küçük Hücreli Dışı Akciğer Kanseri'nin (KHDAK) çeşitli tiplerinin belirlenmesinde derin öğrenme yöntemlerini kullanmıştır. Çalışmasında kullandığı yöntemlerde yapay sinir ağları (YSA) kullanmış ve %73 doğruluk oranına sahip sınıflandırma başarısı elde etmiştir. Çalışmasında kullandığı yöntemlerinde ESA ve ResNet tabanlı sığ ağları içeren çalışmalar yapmıştır ve %71 F skoru elde etmiştir.

Nandi ve Mulimani (2021), yazarlar çalışmalarında göğüs röntgenlerinden Covid-19 varlığını tespit edebilen ve düşük donanım kaynağı tabanlı kişisel dijital asistanlar ile kullanılabilecek bir derin öğrenme modeli önermişlerdir. Hibrit derin öğrenme modeli, ResNet50 ve MobileNet'in bir kombinasyonunu kullanmışlardır. Önerdikleri hibrit modelin performansı, halka açık iki COVID-19 göğüs röntgeni veri seti üzerinde değerlendirmişlerdir. Her iki veri seti de normal, zatürre ve korona virüs ile enfekte akciğer röntgenlerini içermektedir ve Veri Seti 1 ve Veri Seti 2'de diye aldıkları verilerde sırasıyla %84,35 ve %94,43 doğruluk elde etmişlerdir.

Shah ve ark., (2022), yazarlar çalışmalarında Covid-19 hastalığını tespit etmek için evrişimli sinir ağı (ESA) ve geçitli tekrarlayan birime (GTB) dayalı hibrit bir derin öğrenme modeli tercih etmişlerdir. Modelde öznitelik çıkartmak için ESA, sınıflandırma yapmak için ise GTB ve ayrıca model eğitimi sırasında 3 sınıftan (COVID-19, Zatürre ve Normal) oluşan 424 adet göğüs CXR kullanmışlardır. Eğitim sonunda 0.96 doğruluk, 0.96 geri çağırma ve 0.95'lik f1 sonuçlarını elde etmişlerdir.

Jangam ve ark., (2022), yazarlar çalışmalarında hastanın göğüs akciğer taramalarından veya göğüs röntgeni görüntülerinden COVID-19'u saptamak için yeni bir kümelenmiş topluluk önermişlerdir. Önerdikleri yöntemde önceden eğitilmiş dört derin öğrenme modeli dikkate alarak yapmışlardır. Bu modeller şunlardır: Görsel Geometri Grubu (VGG 19), Artık Ağ (ResNet 101), Yoğun Bağlantılı Konvolüsyon Ağları (DenseNet 169) ve Geniş Artık Ağ (WideResNet 50 2). Önceden eğitilmiş her bir modelden, temel sınıflandırıcılar için potansiyel adaylar, ek tam bağlı katmanların sayısı değiştirilerek elde etmişlerdir. Önerdikleri modeli eğitmek ve değerlendirmek için beş farklı göğüs akciğer tomografisi taraması ve göğüs röntgeni görüntüsü kullanmışlar ve her veri setini test seti, doğrulama seti ve eğitim seti olarak ayırmışlardır. Modelin genelliğinin daha iyi değerlendirilebilmesi için test setinin en az 200, en fazla 400 görüntü içermesini sağlamışlardır. Çalışmalarında kullandıkları beş veri setinden üç veri seti BT taramalarından, iki veri seti ise göğüs röntgenlerinden oluşmaktadır. Önerdikleri yöntemlerin diğer dört derin öğrenme modelinden daha yüksek doğruluk ve daha hızlı geri çağırması bakımından daha iyi performans gösterdiğini saptamışlardır.

Sharma ve Guleria (2022), yazarlar çalışmalarında zatürre tespiti ve teşhisi için kullanılabilen göğüs X-ışını taramaları kullanılmıştır. Görüntülerden özellik çıkarımı için bir VGG16 transfer öğrenme modeli kullanılmıştır. Zatürre tespiti için çeşitli mevcut modeller gözden geçirilmiş ve performans sonuçları belirlenmiştir. Çalışma için kullanılan VGG16 modeli, derin öğrenmenin hastalık teşhisindeki çeşitli uygulamalarıyla birlikte açıklanmıştır. Araştırma verileri, 5856 görüntü içeren Kaggle'dan toplanmış ve daha sonra eğitim ve test veri setlerine ayrılmıştır. Daha fazla olarak, sonuçlar doğruluk, hassasiyet, F-skor ve geri çağrı şeklinde sunulmuştur ve sırasıyla %90.8, 0.9102, 0.935 ve 0.9615'tir.

Mathew ve Srinivasan (2022), yazarlar çalışmalarında, nörologlara hızlı ve uygun kararlar verme konusunda yardımcı olmak için MRI kullanarak beyin tümörlerini tespit etmek için etkili ve güvenilir bir yöntem inşa etmeye odaklanılmıştır. 3064 görüntüden oluşan bir veri seti içeren çerçeve oluşturulmuş ve derin öğrenme teknikleri kullanılarak beyin tümörlerini tanımlamak için uygulanmış. Transfer Öğrenme (TL) ile kavramsal modeli kullanarak eğitilmiş ve %98.28 doğruluk, %97.51 geri çağırma ve %97.43 hassasiyet elde edilmiştir. Önerilen TL tabanlı beyin tümörü tespit algoritması mevcut önceden eğitilmiş modelleri geride bırakmıştır.

Shadin ve ark., (2022), maske takmayan bireyleri tanımlamak için oldukça etkili bir yöntem olan derin öğrenme teknikleri olarak transfer öğrenme modelini kullanmıştır. Yüz maskesi tespiti için çevrimiçi bir veri kümesinden toplam 7235 veri görüntüsü kullanmış ve bu işlemi iki derin öğrenme modeli ve bir transfer öğrenme modeli ile yapmıştır. Maksimum havuzlama işlemi ve ortalama havuzlama işlemi kullanan derin öğrenme tabanlı ESA modeli sırasıyla %95.78 ve %95.36 doğruluğa ulaşmıştır. Buna karşılık, transfer öğrenme tabanlı MobileNetV2 modeli ile %99.10 doğruluk elde etmiştir.

Gangadharappa ve Kharola (2022), yazarlar çalışmalarında güç kalitesi (PQ) bozulmalarının tespiti ve sınıflandırması için transfer öğrenmeye dayalı bir derin öğrenme modeli önerilmiştir. Güç bozulmaları istasyonier olmayan ve rastgele olduğu için derin öğrenme, bu tür sinyallerle başa çıkmak için en iyi seçenektir. Çünkü güç kalitesi bozulmalarının farklı rastgele parametrelerini (faz, frekans, amplitüd gibi) tahmin edebilir. Laboratuvarda gerçek zamanlı güç kalitesi bozulmaları oluşturulmuş ve önerilen modelin doğruluğu, yedi farklı

ESA tabanlı derin öğrenme mimarisi modeliyle (örneğin VGG19, ResNet101, ResNet152V2, Xception, InceptionV3, MobileNet ve MobileNetv2) ciddi gürültü koşulları altında karşılaştırılmıştır. Düşük hesaplama yükü ve ciddi gürültü koşullarında yüksek doğruluk, önerilen modelin gerçek zamanlı uygulamalar için uygun olduğunu göstermektedir. Sonuçlar, önerilen modelin %99'un üzerinde doğruluk elde edebildiğini göstermiştir. Ayrıca, önerilen yeni mimari, güç bozulmalarının erken tespiti ve sınıflandırılması için kullanılabilir ve çeşitli akıllı şehir tabanlı IoT modellerine genişletilerek akıllı şebekede güç bozulmalarının doğru, zamanında ve daha hızlı tespiti ve sınıflandırılmasını gerçekleştirebilir.

Phinne (2023), zatürre hastalarının göğüs röntgenlerine göre saptanması ve sınıflandırmasını yapmıştır. Veri seti olarak Kaggle platformundaki göğüs röntgenleri ve zatürre sınıflandırma probleminin çözümü için VGG-19 derin öğrenme yaklaşımını kullanmıştır. Röntgen görüntülerini normal ve zatürre tipi hastalıklar olarak sınıflandırmıştır. Önerdiği sistemde, dengesiz bir veri setinde %86 ve dengeli bir veri setinde %94 doğruluk elde etmiştir.

S. Albawi ve P. Agrawal (2023), yazarlar çalışmalarında, X-ışını görüntülerinde gösterilen anormal özellikleri veya desenleri tanımlamayı ve kategorize etmeyi amaçlamaktadır. Bu yöntemle, evrişimli filtreleri kullanarak derin öğrenme modeline, geniş bir X-ışını görüntü koleksiyonundan otomatik olarak ilgili özellikleri çıkarmayı öğretir. Ardından, özellikler çıkarılarak görüntüler normal veya anormal gibi çeşitli kategorilere veya belirli hastalık kategorilerine sınıflandırılır. Modelin performansı doğruluk, kayıp gibi bir dizi ölçüm kullanılarak değerlendirilir. Bu yaklaşım, klinik ayarlarda hastalık tespitinin doğruluğunu ve etkinliğini önemli ölçüde artırma potansiyeline sahiptir ve %92.83 doğrulukla gerçekleştirilebilir.


Soumya ve ark., (2023), çalışmalarında önerdikleri modelde, çekirdek ağda ResNet-101 mimarisini kullanmışlardır. Önerilen model, beyin manyetik rezonans görüntülerini (MRG) kullanarak eğitilmiş ve model performansını artırmak için transfer öğrenme kullanmışlardır. ResNet-101 mimarisi, artık bloklarını ve atlamalı bağlantıları kullanarak kaybolan gradyan sorununu ele almak ve model doğruluğunu artırmak için kullanılmıştır. Önerilen sistemin değerlendirilmesi için 3060 beyin MRG verisi kullanılmış ve tümörleri sınıflandırmada %97

doğruluk elde edilmiştir. Bu yöntem, beyin kanseri tanısının kesinliğini ve etkinliğini artırabilir, erken teşhis ve tedaviye yardımcı olabilir.

Dewan ve ark., (2023), yazarlar yaptıkları çalışmalarında, önceden eğitilmiş bazı modellerin beyin manyetik rezonans görüntüleri sınıflandırmasında ne kadar etkili olduğunu değerlendirmeyi amaçlamaktadır. Xception, DenseNet121, VGG16, VGG19, ResNet50 ve InceptionV3 gibi önceden eğitilmiş modellerin ince ayarlı versiyonları kullanılmış ve her birinin performansı analiz edilmiştir. Kaggle'dan alınan beyin MRI veri seti üzerinde değerlendirilmiştir ve performans değerlendirmesi için özgüllük, kesinlik, duyarlılık, doğruluk ve F1-skoru gibi performans göstergeleri kullanılmıştır. VGG19 modeli, %97 doğruluk oranına ile bu araştırmada kullanılan tüm transfer öğrenme modellerinin en iyi sonuçlarını sunmaktadır. Model, %97 F1-skoru, %97 kesinlik, %96 duyarlılık ve %99 özgüllük elde etmiştir. ResNet50, %96 F1-skoru, %97 duyarlılık, %96 doğruluk, %96 kesinlik ve %99 özgüllük ile ikinci en iyi performans gösteren modeldir. Gliomlar, menenjiomlar, hipofiz tümörleri ve tümörsüz beyin tümörlerinin birçok kategorisi bu yöntemle doğru bir şekilde sınıflandırılmıştır.

3. YAPAY SİNİR AĞLARI

Yapay sinir ağı (YSA) (Jain ve ark., 1996) beyinde bulunan biyolojik sinir hücrelerinin işlevini taklit ederek eğitilebilen, öğrenme sürecini kendi kendine gerçekleştirebilen ve değerlendirmede bulunabilen, insan beynine ait öğrenme sürecini modellemeye yönelik bir yapıdır. YSA'lar aracılığıyla insanlarda olduğu gibi makineleri eğitilerek, öğrenme ve karar verme süreçlerini gerçekleştirme amaçlanmıştır. Şekil 3.1'de insan beynine ait bir sinir hücresinin yapısı gösterilmektedir.



Şekil 3.1. İnsan beynine ait bir sinir hücresi (nöron) (Konaté, 2019)


Akson: Hücre gövdesinde bulunan elektriksel uyarıları uzağa ileten ince uzun çıkıntıları olan bir sinir lifidir. Aksonun görevi bilgiyi farklı sinir hücrelerine, kaslara ve bezlere taşımaktır.

Dendritler: Dal benzeri bir yapıya benzeyen, bir hücresinin (nöronun) diğer sinir hücresinden (nörondan) aldığı elektrokimyasal uyarıyı hücre gövdesine iletilmesinden sorumlu olan yapıdır.

Sinaps: Sinir hücrelerinin (nöronların) diğer sinir hücrelerine (nöronlara) ya da sinir hücresi olmayan kas ve salgı bezleri gibi hücrelere mesaj iletmek için kullanılan özel bağlantı noktalarıdır.

Miyelin Kılıfı: Uyarıların daha hızlı bir şekilde iletilmesini sağlayan, aksonun üzerinde bulunan yalıtkan bir malzemedir.

Çekirdek: İşaretlerin akson boyunca belli aralıklarla yeniden üretilmesini sağlayan bir yapıdır (Ayık, 2019).



Şekil 3.2. Yapay sinir ağının matematiksel modeli (Konaté, 2019)

3.1. Tek Katmanlı Algılayıcı

Doğrusal bir fonksiyon ile ifade edilen YSA'nın en basit ve tek bir sinir hücresinden meydana gelmiş halidir. Matematiksel olarak;

$$y = f(x) = w * x + b \quad (3.1)$$


şeklinde ifade edilir (Kavitha ver ark., 2016).

y: Girdiye ait skoru belirten, x 'e bağlı çıktı değişkendir.

x: Girdiyi ifade eder ve bağımsız bir değişkendir.

w: Ağırlık parametresini ifade etmektedir.


b: Bias değerini ifade etmektedir (Kavitha ver ark., 2016).



Şekil 3.3. Tek katmanlı sinir ağı yapısı (Jan ve ark., 2020)

YSA veya derin öğrenme modelindeki amaç en iyi w ve b parametrelerini bulup model için en iyi skoru elde etmektir. Algılayıcı modelinin doğru bir sınıflandırma yapabilmesi için

eşik değeri önemli bir faktördür ve aktivasyon fonksiyon eğrisindeki aşağı yukarı yönlü hareketler eşik değeri sayesinde olmaktadır. Böylece gerekli değerler arasındaki giriş eşitlenmiş olur. Algılayıcılar girdinin hangi sınıfa ait olup olmadığına karar veren bir fonksiyondur.



Şekil 3.4. Tek katmanlı algılayıcı modeli (Oliveira ve ark., 2017)


Şekil 3.4'deki modelde x ile ifade edilen giriş değerlerini, w ile ifade edilen değerler ise ağırlıkları temsil etmekte ve öğrenmeyi zorlaştırmak için bias değeri kullanılmaktadır. Giriş ve çıkış katmanından oluşan modelde girdiler eşik değerinin üstünde ise 1, altında ise 0 olarak çıkış değerine aktarılır. Çıkış olması gereken değer değilse ağırlıklar tekrar güncellenip doğru sonuç bulunana kadar algoritma devam eder. Doğru sonuçlar her biri için geçerli olduğunda eğitim tamamlanmış olmaktadır. Çıktı sonucu doğrusal bir fonksiyon elde edilmektedir.

Fakat tek bir yapay sinir hücresinden oluşan algılayıcılar doğrusal olmayan ayrılabilir veri noktalarını sınıflandıramaz ve daha karmaşık sorunları çözemez. Bunun için farklı aktivasyon fonksiyonları ve farklı yollarla birbirine bağlanarak çalışan algılayıcıların birleşmesi ile oluşan çok katmanlı algılayıcılar kullanılmaktadır.

3.2.Çok Katmanlı Algılayıcı

Doğrusal olmayan problemlerin çözümünde tek katmanlı algılayıcıların başarısız olması sonucu girdi katmanı, birden fazla gizli katman ve çıktı katmanına sahip çok katmanlı algılayıcılar geliştirilmiş ve çok katmanlı algılayıcılar ileri ve geri yayılım olarak bilinen geçişlerinden oluşmaktadır. Ağın çıktısı ve hata değerleri ileri yayılım sırasında

hesaplanırken geri yayılım sırasında hata değerlerini en aza indirmek için katmanlar arası ağırlık değerleri yenilenmektedir. Şekil 3.5’te çok katmanlı algılayıcı yapısı gösterilmiştir.



Şekil 3.5. Çok katmanlı algılayıcı yapısı (Konaté, 2019)

İleri yayılım sırasında girdi katmanından gelen değerler her girdinin bireysel ağırlığı ile çarpılarak, elde edilen toplam değere bias değeri eklenerek net girdi hesaplanır. Bu net girdi değerine aktivasyon fonksiyonu uygulanarak bir çıktı değeri alınır ve alınan bu çıktı değeri bir sonraki katmana girdi olarak verilir. Bu işlem tekrar edilerek son olarak nihai çıktı değeri elde edilir. Böylelikle eğitimin ilk aşaması tamamlanmış olmaktadır. Elde ettiğimiz değer ile mevcut değer farklı ise hata var demektir. Geriye yayılım sırasında bu hata ağırlık değerleri dağıtılarak her bir adımda azaltılması beklenmektedir. Hata ağırlık değerlerinin dağıtılması sonucu her bir adım güncellenmiş olmaktadır. Böylelikle bu işlem en iyi ağırlık değerleri elde edilene kadar devam eder (Konaté, 2019).

4. DERİN ÖĞRENME

İnsan beyni, bilim insanları tarafından merak konusu olmuş, üzerine birçok çalışma yapılmasına rağmen halen gizemini korumaktadır. Bilgisayarlar ile mukayese edildiğinde dijital işlemleri gerçekleştirmede daha yavaş olmasına rağmen düşünme ve karar verme ile alakalı sorunları geçmiş tecrübelerinden edindiği deneyimler ile daha hızlı bir şekilde çözmektedir. Bu yüzden bilgisayarlar deneyim ve düşünme gerektiren konularda yetersizdir. Çevrede olan olayları algılama bunlara cevap verme ve aksiyon alma yeteneğine zekâ denir. Zekâ kişiden kişiye farklılık gösteren, durumlar karşısında değişen, gelişen ve olgunlaşan bir yapıya sahiptir. Anlama, anladığını yorumlama, kavrama ve öğrenme gibi süreçlerin bilgisayar programları tarafından problemlerin çözümlenmesinde kullanılması yapay zekâ olarak adlandırılır. Yapay zekanın amacı insan beyni gibi düşünen ve davranan bilgisayarlar geliştirmektir.

Makine öğrenmesi (ML) ise bilgisayar tabanlı çeşitli matematik modeller kullanarak veriler arasındaki ilişkisel örüntüyü çıkartmak için kullanılan yapay zekanın bir alt dalıdır. Günümüzde her an milyonlarca veri oluşmakta ve bunlar çeşitli yerlerde depolanıp analiz edilmeyi beklemektedir. Elimizde bulunan bu verilerin analizi ve değerlendirmesi geleceğe yönelik tahminlerde bulunmamızı sağlar. Birçok makine öğrenme modeli bu analizleri gerçekleştirmek için geliştirilmiştir. Bu yöntemler geçmiş verileri işleyerek bunlar arasındaki örüntüyü bulan modeli tespit etmekte ve tespit edilen bu model sonraki verilere uygulanarak tahminlerde bulunması sağlanmaktadır. Yani makine öğrenmesi, sağlanan veri ve algoritmalar temelinde makineleri eğitmektir. İşlenmiş veri ve bilgi kullanılarak makineler, nasıl kararlar alacaklarını öğrenirler (Fayyad ve ark., 1996).

Makine öğreniminin bir alt dalı olan derin öğrenme, biyolojik sinir ağlarının yapısını ve işleyişini taklit eden hesaplamalı modeller ve algoritmalarla meydana gelir (King Jr, 2017). Birbirine bağlı düğümlerden oluşan sinir ağı mimarisi katmanlar halinde yapılandırılmıştır. Girdi katmanında giriş verileri, gizli katmanda bu verilerden özniteliklerin çıkarıldığı ve çıktı katmanında ise verilere ait sonuçların üretildiği üç farklı katmandan oluşmaktadır.


Derin öğrenme ve bilgi işleme şekli açısından bakıldığında, "derin" kavramı, sinir ağı mimarisindeki katmanların derinliğini ifade ederken her katman, verinin belirli bir yönünü temsil etmeyi öğrenir ve birden çok katmanın yığılmasıyla ağ verideki karmaşık desenleri ve ilişkileri öğrenebilir. Basit özelliklerin öğrenilmesi alt katmanlarda gerçekleşirken daha karmaşık özelliklerin öğrenimi üst katmanlarda alt katmanlardan gelen özelliklerinden türetilerek öğrenilmektedir. Farklı yerlerden toplanan verilerin veya büyük miktardaki verilerin analizi ve bilgi çıkarımı için derin öğrenmenin önemli olduğu anlamına gelmektedir. Bilginin kategorilere ayrılması ve etiketlenmesi gibi, derin öğrenme modelleri de veriyi otomatik olarak kategorize edip sınıflandırmayı öğrenerek, gelen verideki desenleri ve ilişkileri bulabilir. Veriyi hiyerarşik katmanlarda otomatik olarak öğrenme ve temsil etme yeteneği, derin öğrenmeye görüntü ve konuşma tanıma, doğal dil işleme ve daha fazla alandaki görevlerde etkili sonuçlar elde etmiş, ayrıca derin öğrenme algoritmalarındaki son gelişmeler görüntü sınıflandırma ve görüntü bölümlendirme konularındaki performansıyla devrim yaratmıştır (LeCun ve ark.).

Derin öğrenme alanında yapılan çalışmalar ve bu çalışmalar neticesinde elde edilen başarılar sonucu farklı yapı ve işlevlere sahip birçok derin öğrenme modeli geliştirilmiştir.

4.1.Evrişimli Sinir Ağları


Evrişimli sinir ağı (ESA) (Albawi ve ark., 2017), verilerden özellikler çıkarabilen, sınıflandırma, görüntü işleme, ses tanıma gibi çeşitli problemlerin çözümünde kullanılan ileri beslemeli bir sinir ağıdır. Görüntü tanıma ve bilgisayarlı görü işlemlerinde popüler olarak kullanılmakta ve görüntülerdeki nesneleri tanıyan, nesneler arasındaki ilişkileri çıkartan bir derin öğrenme algoritmasıdır. Fakat bilgisayar sistemlerinin görüntü üzerinde işlemler yapabilmesi için analog görüntülerin sayısallaştırılarak bilgisayarların anlayacağı dijital görüntülere dönüştürülmesi gerekmektedir.

İki boyutlu dizi şeklinde ifade edilen, dijital görüntüye ait her bir eleman pikseli temsil etmektedir. Bu pikseller koordinatlarla kontrol edilebilen ve adreslenebilen en küçük görüntü birimidir ve her pikselin yoğunluğu değişkendir. Bu pikseller genellikle bir 2-D matriste temsil edilir. İkili Görüntü, gri tonlu görüntü ve RGB görüntü olmak üzere farklı türleri vardır.



Şekil 4.2. Evrişimli sinir ağı mimarisi (Tammima, 2019)

Görüntü verilerine ait doğru özelliklerin seçilmesi oldukça zor olmaktadır. Fakat özellik seçimi evrişim katmanı tarafından otomatik yapıldığı için evrişimli sinir ağları tercih sebebi olmaktadır. Bu durumdan dolayı hem geliştirici hem de araştırmacılar, daha karmaşık görevleri çözmek için büyük modeller kullanmıştır. Çünkü klasik evrişimli sinir ağları için bu pek mümkün değildir. Örneğin bir yüz tespiti uygulamasında yüzlerin nerede olduğu bizim dikkat etmemiz gereken bir durum olmadığıdır. Burada yapılması gereken bu yüzleri verilen resimlerdeki konumlarına bakılmaksızın yerlerinin tespitini yapmaktır. Girdinin derin katmanlara doğru ilerledikçe soyut özelliklerin elde edilmesi ESA'nın kuvvetli bir yönüdür. (Albawi ve ark., 2017).




Şekil 4.3. Erişim katmanı özellik çıkarma (Albawi ve ark., 2017).

Örnek vermek gerekirse bir görüntü üzerinde sınıflandırma yaptığımızda kenarların, köşelerin tespiti ilk katmanlarda algılanırken, nesnelere ait göz, kulak, burun gibi temel

özellikler orta katmanlarda ve yüzler gibi yüksek seviyeli özellikler son katmanlarda algılanmaktadır. Bu durum Şekil 4.3'te gösterildiği gibidir.

4.1.1. Evrişimli sinir ağı katmanları

ESA'lar evrişim katman, doğrusal olmayan katman, havuzlama katmanı ve tam bağlantılı katman gibi çeşitli katmanlardan oluşmaktadır. Evrişimli sinir ağı katmanları Şekil 4.4'te gösterilmektedir.




Şekil 4.4. Evrişimli sinir ağı katmanları (Hussain ve ark., 2019)

Havuzlama ve doğrusal olmayan katmanlar herhangi bir parametreye sahip değilken evrişim ve tam bağlantılı katmanlar bir parametreye sahiptir.

4.1.1.1. Evrişim Katmanı

Öznitelik çıkarımı için kullanılan bu katmanda giriş görüntüsüne ait kenar bulma, nesne bulma, köşe bulma gibi çıkarımlar yapılmaktadır. ESA'da görüntü dediğimiz şey matrisleri temsil etmektedir. Matrise ait değerler ise aslında görüntüye ait piksel değerlerini ifade etmektedir. Çünkü bilgisayar sistemleri 1'ler ve 0'lardan oluşan sistemlerdir. Verinin işlenebilmesi için bilgisayarın anlayacağı dijital formlara dönüştürülmesi gerekmektedir. Bunun için görüntü matrislere çevrilir. Bu şekilde bilgisayarlar ilgili görüntünün matematik karşılığı olan piksel değerleri üzerinde işlemlerini gerçekleştirir. Evrişim katmanı görüntüye ait öznitelik haritası çıkarmak için çeşitli filtreler kullanmaktadır. Bu filtreler 3x3, 5x5 gibi çeşitli boyutlarda olabilir. Şekil 4.5'te evrişim işleminin nasıl gerçekleştiği gösterilmektedir (Albawi ve ark., 2017).




Şekil 4.5. Görüntünün ve filtrenin ilk adım evrişim işlemi (Albawi ve ark., 2017)

Şekil 4.5'te (5x5) boyuta sahip bir görüntü matrisine (3x3) boyutunda filtre uygulanmaktadır. Filtre, görüntü matrisinin sol üst köşesinden olmak üzere birbirine denk gelen indisleri çarpıp sonra tüm sonuçları toplayıp çıktı olarak sonuç matrisinin ilk elemanı olarak yazmaktadır. Daha sonra filtre ağırlık matrisi bir piksel olacak şekilde sağa doğru kaydırılıp işleme devam edilmektedir. Çıktı matrisinin boyutunu hesaplamak için,

$$\left(\frac{n-f}{s} + 1\right) \times \left(\frac{n-f}{s} + 1\right) \quad (4.1)$$

kullanılmaktadır (Albawi ve ark., 2017).

n: girdi, f: filtre, s: adım(stride)



Şekil 4.6. Görüntünün ve filtrenin ikinci adım evrişim işlemi (Albawi ve ark., 2017)

Şekil 4.6'da filtre ağırlık matrisi bir piksel sağa kaydırılmakta ve önceki işlemler tekrarlanıp sonuç matrisinin ikinci elemanı olarak yazılmaktadır. Daha sonra bu işlem görüntü matrisinin tümüne uygulanmaktadır.

Görüntü Matrisi(5x5) Filtre Matrisi (3x3) Çıktı Matrisi(3x3)

8	3	8	4	4
7	3	2	8	4
4	8	5	7	5
2	3	2	3	3
5	4	7	5	5

x

-1	0	1
-1	0	1
-1	0	1

=

-4	5	2
-4	4	3
2	0	-1


$$\begin{aligned}
 &5x(-1)+2x(-1)+ \\
 &7x(-1)+7x0+3x0+ \\
 &5x0+5x1+3x1+5x1 \\
 &= -1
 \end{aligned}$$

Şekil 4.7. Görüntünün ve filtrenin son adım evrişim işlemi (Albawi ve ark., 2017)

Şekil 4.7’de tüm işlemler sonlandıktan sonra oluşan çıktı matrisi ve bu işlem sonucunda görüntüye ait özellikler elde edilmektedir. ESA’ya ait modelin öğrendiği parametre değerleri aslında fitreye ait değerlerdir. Özelliklerin daha iyi tespiti için bu değerler model tarafından en iyi sonucu bulana kadar güncellenmektedir. Bunun yanı sıra çeşitli filtreler kullanarak kenar tespiti, keskinleştirme ve gürültü ekleme gibi işlemler yapılabilir.

Görüntüdeki özelliklerin birden fazla olması durumunda bunların tespiti için birden fazla filtre uygulanması gerekmektedir. Bundan dolayı ESA algoritmalarında çok sayıda evrişim katmanının varlığından söz edebiliriz. Evrişim katmanında filtre uygulanırken kullanılan adım ve dolgu gibi bilinmesi gereken bazı önemli kavramlar vardır.

Adım: ESA modellerinde parametre olarak değiştirilebilen, görüntü matrisi üzerinde uygulanacak filtrenin kaç piksel boyunca kaydırılacağını belirlememizi sağlamaktadır. Yukarıda Şekil 4.6’daki görüntü matrisine bakıldığında filtre ağırlık matrisinin bir adım kaydırılarak uygulandığı görülmektedir.



Şekil 4.8. Adım sayısının çıktı matrisine etkisi (Gsaxner ve ark., 2019)

Adım sayısının değerinin büyük bir değer olması durumunda ortaya çıkacak öznitelik haritası daha küçük boyutlu olacaktır. Şekil 4.8’de (5x5) bir matrisi (3x3) bir filtre adım sayısı 1 olacak şekilde uygulandığında çıktı matrisi (3x3) olmaktadır. Fakat adım sayısı 2 olacak şekilde uygulandığında çıktı matrisi (2x2) olmaktadır.

Adım sayısının çıktı matrisi boyutunu hesaplamak için,

$$\left(\frac{n+2p-f}{s} + 1\right) \times \left(\frac{n+2p-f}{s} + 1\right) \quad (4.2)$$

kullanılır (Albawi ve ark., 2017).

p: dolgu

Dolgu: Giriş matrisi ile çıkış matrisi boyutları farklı boyutlarda olabilmektedir. Eğer giriş ve çıkış matrislerinin aynı boyutta olması isteniyorsa giriş matrisine piksel eklemek için dolgulama işlemi uygulanmaktadır. Genellikle matrisin dış tarafına dört taraftan çerçeve olacak şekilde sıfırlar eklenmektedir. ESA modellerinde filtreler uygulanırken bilginin bir sonraki evrişimli katmana korunmuş bir şekilde aktarılması önemlidir. Filtre uygulandıktan sonra öznitelik haritasının daha küçük boyutta olması bilgi kayıplarına neden olacaktır. Bu yüzden bilgi kayıplarının önüne geçmek ve görüntünün boyutunu koruyabilmek için dolgulama işlemi kullanılmaktadır (Albawi ve ark., 2017).

1	3	4	7	3
0	2	4	5	1
6	1	0	8	0
3	5	1	8	3
4	4	0	1	6

0	0	0	0	0	0	0	0
0	1	3	4	7	3	0	0
0	0	2	4	5	1	0	0
0	6	1	0	8	0	0	0
0	3	5	1	8	3	0	0
0	4	4	0	1	6	0	0
0	0	0	0	0	0	0	0

Dolgu = 1

1	3	4	7	3
0	2	4	5	1
6	1	0	8	0
3	5	1	8	3
4	4	0	1	6

Dolgu = 0

0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	1	3	4	7	3	0
0	0	0	2	4	5	1	0
0	0	6	1	0	8	0	0
0	0	3	5	1	8	3	0
0	0	4	4	0	1	6	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

Dolgu = 2

Şekil 4.9. Dolgulama işlemi (Wahyudi Setiawan ve ark., 2019)

Dolgulama işlemi iki şekilde gerçekleştirilir. Görüntü matrisine filtre matrisi uygulanırken görüntü matrisinin dışında kalan kısımlara sıfır eklemek veya diğer bir seçenekte rastgele değerler eklemektir. Dolgulama işlemi Şekil 4.9’da gösterilmektedir.


Dolgulama işlemi sonucu çıktı matrisi boyutunu hesaplamak için,

$$(n + 2p - f + 1) \times (n + 2p - f + 1) \quad (4.3)$$

kullanılır (Albawi ve ark., 2017).

4.1.1.2. Havuzlama katmanı

Ağdaki parametre ve hesaplama miktarını azaltarak, gereksiz özellikler göz ardı edilerek daha baskın özellikleri ortaya çıkarmaya yönelik modelin eğitilme sürecini sürdürmesi amaçlanmaktadır. ESA modellerinde genellikle maksimum veya ortalama havuzlama tekniği kullanılmaktadır.




Şekil 4.10. Maksimum ve ortalama havuzlama işlemi (Albawi ve ark., 2017)

Havuzlama katmanında filtre, görüntü matrisi üzerinde gezerken bu sefer evrişim işlemi yerine belirlenen havuzlama tekniğini kullanarak işlemleri gerçekleştirir. Eğer maksimum havuzlama işlemi tekniği seçildiyse filtrenin kapsadığı alandaki en büyük değer, ortalama havuzlama tekniği seçildiyse filtre alanındaki tüm değerlerin ortalaması alınmaktadır. Şekil 4.10’da iki yöntem de gösterilmiştir (Albawi ve ark., 2017).

4.1.1.3. Tam Bağlantı Katmanı

ESA kullanılmasının amaçlarından biri de çeşitli sınıflandırma modelleri tasarlayarak modele verilen girdilerin doğru tahminler vermesini sağlamaktır. Bu katman havuzlama katmanından sonra yer alır ve ESA’nın son aşamasında görev yapmaktadır. Havuzlama

katmanı sonucu elde edilen çıktı değeri vektöre dönüştürülüp evrişimli sinir ağına eklenmektedir. Çünkü model girdinin tek boyutlu bir vektör olmasını beklemektedir. Bu yüzden düzleştirme işlemi uygulayarak çıktı tek boyutlu vektöre dönüştürüp sınıflandırma işlemi gerçekleştirilmektedir.




Şekil 4.11. Tam bağlantı ve düzleştirme katmanı (Albawi ve ark., 2017)

Tam bağlı katmanın (bkz. Şekil 4.11) temel dezavantajı, eğitim sırasında karmaşık hesaplama gereksinimleri olan çok sayıda parametreyi içermesidir. Bu sorunu hafifletmek için seyreltme gibi teknikler kullanılarak düğüm ve bağlantıların sayısı azaltılmaya çalışılır. Örneğin, LeNet ve AlexNet gibi modeller, hesaplama karmaşıklığını kontrol altında tutarak derin ve geniş bir ağ oluşturmak amacıyla tasarlanmıştır (Albawi ve ark., 2017).

4.2. Tekrarlayan Sinir Ağları

Bir Tekrarlayan Sinir Ağı (RNN) (Medsker ve Jain, 2001), standart ileri beslemeli sinir ağının sıralı verileri modellemesine izin vermek için basit bir uyarlama şeklidir. Her adımda RNN (bkz. Şekil 4.12), bir giriş alır, gizli durumunu günceller ve bir tahminde bulunur. RNN'nin yüksek boyutlu gizli durumu ve doğrusal olmayan evrimi, ona büyük bir ifade gücü kazandırır ve RNN'nin gizli durumunun birçok zaman adımı boyunca bilgiyi entegre etmesine ve doğru tahminlerde bulunmasına olanak tanır. Her bir birimin kullandığı doğrusal olmayan işlev bile oldukça basit olsa da zaman içinde bu işlemi tekrar etmek son derece zengin dinamiklere yol açar (Zaremba ve ark., 2014).




Şekil 4.12. Tekrarlayan sinir ağı (Murugesan ve ark., 2021)

Bir RNN, zaman boyunca paylaşılan ağırlıklara sahip olan çok derin bir ileri beslemeli sinir ağıdır. Gizli birimler tarafından kullanılan doğrusal olmayan aktivasyon işlevi, RNN'nin zengin dinamiklerinin kaynağıdır (Zaremba ve ark., 2014).

4.3.Uzun Kısa Vadeli Bellek

Uzun Kısa Vadeli Bellek (LSTM) modeli minimum zaman gecikmeleri çok uzun olduğunda bile uzun vadeli bağımlılıkları öğrenirken ortaya çıkan patlayan/sönme gradyan sorunlarını aşmak için özel olarak tasarlanmış güçlü bir tekrarlayan sinir sistemi olarak bilinmektedir (Hochreiter ve Schmidhuber, 1997). Genel olarak, bu sorun, her bir birim hücresinde hata sinyalini koruyan sabit hata karuseli kullanılarak önlenir. Aslında, bu tür hücreler kendileri tekrarlayan ağlardır ve sabit hata karuseli ek özelliklerle genişletilmiş bir mimariye sahiptir, yani giriş kapısı ve çıkış kapısı oluşturarak hafıza hücresini oluşturur. Kendi kendine tekrarlayan bağlantılar, bir zaman adımı gecikmeli geri bildirimi gösterir.

Vanilya LSTM birimi, bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısından oluşur. Bu unutma kapısı başlangıçta LSTM ağının bir parçası değildi, ancak Gers ve ark. (2000) tarafından ağın durumunu sıfırlamasına izin vermek için önerilmiştir. Hücre, herhangi bir zaman aralığında değerleri hatırlar ve üç kapı, hücre ile ilişkilendirilen bilgi akışını düzenler. Bu bölümün geri kalanında, LSTM, en popüler LSTM mimarisi olduğu için vanilya sürümü olarak adlandırılacaktır (Greff ve ark., 2016). Ancak bu, her durumda üstün olanı da olduğu anlamına gelmez.



Şekil 4.13. Uzun kısa vadeli bellek mimari yapısı (Murugesan ve ark., 2021)

Kısacası, LSTM mimarisi, bellek blokları olarak bilinen tekrarlayan bağlantılı alt ağların bir kümesinden oluşur. Bellek bloğunun arkasındaki fikir, zaman içinde durumunu korumak ve bilgi akışını doğrusal olmayan kapama birimleri aracılığıyla düzenlemektir. Şekil 4.13'te vanilya LSTM bloğunun mimarisini gösterir ve kapıları, giriş sinyalini (x_t), çıkışı (y_t), aktivasyon işlevlerini ve gözlem bağlantılarını içerir (Gers ve Schmidhuber, 2000). Bloğun çıkışı, blok girişi ve tüm kapılarla tekrarlayan bağlantılıdır (Van Houdt ve ark., 2020).


5. AKTİVASYON FONKSİYONLARI VE BAŞARIM ARTTIRMA YÖNTEMLERİ

Büyük veri kümeleri üzerinde yapılan çalışmalar neticesinde başarılı tahminler elde edebilmek için bazı derin öğrenme teknikleri ve çeşitli optimizasyon algoritmaları kullanılmaktadır.

- Geri yayılım algoritması,
- Aktivasyon fonksiyonları,
- Hata fonksiyonları,
- Regülerizasyon yöntemleri bunlardan bazılarıdır.

5.1.Geri Yayılım Algoritması

Yapay sinir ağlarının eğitilmesi için kullanılan ve denetimli bir öğrenme algoritması olan geri yayılım algoritması, ağırlıkların doğru bir şekilde ayarlanarak hata oranının azaltılması ve modelin daha iyi sonuçlar vermesini amaçlamaktadır. Şekil 5.1’de geri yayılım algoritması gösterilmektedir.



Şekil 5.1. Geri yayılım algoritması (Li ve ark., 2021)

Tasarlanan bir sinir ağı eğitime başlarken rastgele ağırlıklar ile başlamaktadır. Fakat bu ağırlık değerleri doğru seçilmeli ve modelimize uygun olmalıdır. Bu değerlerin önceden kesin bir şekilde bilinmesi pek mümkün olmamaktadır. Bunun sonucunda modelin çıktısı ile gerçek çıktımız arasındaki hata değeri çok fazla olabilmektedir. Bunun önüne geçip hata oranını optimum seviyeye gelebilmesi için yapılması gereken şey, başlangıçta rastgele seçilen ağırlıkların tekrardan optimize edilip yeni ağırlıklar ile modelin tekrar eğitilmesi gerekmektedir. İşte bu işleme geri yayılım olarak adlandırılmaktadır. Geri yayılım


algoritması gradyan iniş ve delta kuralı olarak bilinen bir teknik kullanarak hata fonksiyonunu en aza indirecek değerleri aramaktadır.

5.2. Aktivasyon Fonksiyonları

Evrişimli sinir ağlarında doğrusal olmayan problemlerin çözümü ve gerçek dünyaya ait özellikleri tanımak için aktivasyon fonksiyonlarına ihtiyaç duyulmaktadır. Aktivasyon fonksiyonunun görevi evrişimli sinir ağındaki bir düğüme ait giriş sinyaline dönüşüm işlemi uygulayarak bir çıkış sinyali elde etmektir. Elde edilen bu çıkış sinyali başka bir katmana girdi olarak iletilir. Eğer giriş sinyaline aktivasyon fonksiyonu uygulanmazsa çıkış sinyali doğrusal bir fonksiyon yani tek dereceli bir polinom olacaktır. Bu yüzden sınırlı öğrenme gücüne sahip doğrusal bağlanım gibi davranan bir sinir ağı olacaktır. Fakat istenilen şey doğrusal olmayan ve gerçek dünya bilgilerini içeren görüntü, video, metin ve ses gibi karmaşık verilerden sinir ağının öğrenme sürecini gerçekleştirmektir. Daha iyi performans ve daha az hatalı sonuçlar için bir ağıdaki gizli katmanların sayısı, eğitim yöntemleri, hiper parametre ayarlama gibi birçok şey dikkate alınmalıdır ve aktivasyon fonksiyonu bu parametrelerden biri olarak en önemlilerden biridir (Sharma ve ark., 2017).

5.2.1 İkili adım fonksiyonu

Basamak fonksiyonu 0 ile 1 arasında değer alan en basit bir aktivasyon fonksiyonudur. Şekil 5.2’de ikili basamak fonksiyonu gösterilmektedir.



Şekil 5.2. Basamak fonksiyonu ve türevi (Sharma ve ark., 2017)

İkili sınıflandırıcılar oluştururken genellikle ikili aktivasyon fonksiyonları kullanılır. Ancak, ikili adım fonksiyonu, hedef taşınamayan çoklu sınıf sınıflandırma durumlarında

kullanılamaz. Ayrıca, ikili adım fonksiyonunun gradyanı sıfırdır, bu da geriye yayılma adımında bir engel oluşturabilir, yani $f(x)$ 'in x 'e göre türevini hesaplırsak, sıfıra eşittir.


İkili adım fonksiyonu matematiksel olarak,

$$\left. \begin{array}{l} f(x)=1, x \geq 0, \\ f(x)=0, x < 0 \end{array} \right\} \quad (5.1)$$

şeklinde gösterilmektedir (Sharma ve ark., 2017).

5.2.2 Doğrusal fonksiyon

Doğrusal fonksiyon -sonsuz ile +sonsuz arasında değer alan doğrusal olan yalnızca çıkış katmanında kullanılan bir aktivasyon fonksiyonudur. Şekil 5.3'te doğrusal fonksiyon gösterilmektedir. Doğrusal aktivasyon fonksiyonu, doğrudan girdiye orantılıdır. İkili adım fonksiyonunun temel dezavantajı, ikili adım fonksiyonunda x 'in bir bileşeninin olmaması nedeniyle sıfır gradyanına sahip olmasıydı. Bu sorunu ortadan kaldırmak için lineer fonksiyon kullanılabilir.



Şekil 5.3. Doğrusal fonksiyon ve türevi (Sharma ve ark., 2017)

Doğrusal fonksiyonun matematiksel gösterimi,

$$f(x)=ax \quad (5.2)$$


şeklinde ifade edilmektedir (Sharma ve ark., 2017).

Değişken a 'nın değeri, kullanıcı tarafından seçilebilen herhangi bir sabit değer olabilir. İşte burada, $f(x)$ fonksiyonunun türevi sıfır değil, kullanılan sabit değere eşittir. Gradyan sıfır değil, her giriş değerinden bağımsız olan bir sabit değerdir, bu da ağırlıkların ve sapmaların

geriye yayılma adımı sırasında güncelleneceği anlamına gelir, ancak güncelleme faktörü aynı olacaktır. Doğrusal fonksiyon kullanmanın pek bir faydası yoktur çünkü her iterasyon için gradiyent değeri aynı olduğu için sinir ağı hata düzeltme açısından iyileşmez. Ayrıca, ağ verilerden karmaşık desenleri tanıyamaz. Bu nedenle, doğrusal fonksiyonlar yorumlanabilirlik gerektiren ve basit görevler için idealdir (Sharma ve ark., 2017).

5.2.3 Sigmoid fonksiyonu

Sigmoid fonksiyonu 0 ile 1 arasında değer alan doğrusal olmayan bir aktivasyon fonksiyonudur. Genellikle ikili sınıflandırmanın çıkış katmanında kullanılmaktadır. Sigmoid fonksiyonunun değeri yalnızca 0 ile 1 arasında olduğundan elde edilen değer 0.5'ten büyük ise sonuç 1, küçük ise değer 0 olmaktadır. Sigmoid fonksiyonu Şekil 5.4'te gösterilmektedir.



Şekil 5.4. Sigmoid fonksiyonu ve türevi (Rasamoelina ve ark., 2020)

Ayrıca, sigmoid fonksiyonu sıfır etrafında simetrik değildir, bu da nöronların tüm çıkış değerlerinin işaretlerinin aynı olacağı anlamına gelir. Bu sorun, sigmoid fonksiyonunu ölçeklendirerek iyileştirilebilir.

Sigmoid fonksiyonu matematiksel olarak,

$$f(x) = \frac{1}{e^{-x} + 1} \quad (5.3)$$

şeklinde ifade edilir (Sharma ve ark., 2017).


Sigmoid fonksiyonu sürekli türevlenebilir ve düzgün bir S şeklindeki fonksiyondur. Fonksiyonun türevi matematiksel olarak,

$$f'(x) = f(x)(1 - f(x)) \quad (5.4)$$

şeklinde ifade edilmektedir (Sharma ve ark., 2017). Bu özelliklerinden dolayı çıktı katmanında sınıflandırma için sigmoid fonksiyonu kullanılmıştır.

5.2.4 Hiperbolik tanjant fonksiyonu

Hiperbolik Tanjant Fonksiyonu (bkz. Şekil 5.5) -1 ile 1 arasında değer alan doğrusal olmayan bir fonksiyondur. Genellikle bir sinir ağının gizli katmanlarında kullanılmaktadır. Bu nedenle gizli katmanın ortalaması 0 veya çok yakınında olur ve bu veriyi 0'a yakın bir ortalama getirerek veriyi merkezlemeye yardımcı olmaktadır. Bu, bir sonraki katman için öğrenmeyi çok daha kolay hale getirmektedir.



Şekil 5.5. Hiperbolik tanjant fonksiyonu ve türevi (Rasamoelina ve ark., 2020)

Bu, hiperbolik tanjant fonksiyonudur. Tanh fonksiyonu sigmoid fonksiyonuna benzer, ancak orijin etrafında simetrik bir yapıya sahiptir. Bu, önceki katmanlardan gelen çıkışların işaretlerinin farklı olmasına neden olur ve bu çıkışlar bir sonraki katmana giriş olarak verilir. Tanh fonksiyonu matematiksel olarak,


$$f(x)=2sigmoid(2x)-1 \quad (5.5)$$

şeklinde ifade edilir (Sharma ve ark., 2017).

Tanh fonksiyonu sürekli ve türevlenebilir, değerleri -1 ile 1 arasındadır. Sigmoid fonksiyonuna göre tanh fonksiyonunun gradyanı daha dik bir yapıya sahiptir. Tanh, gradyanların belirli bir yönde değişmesine sınırlı olmadığı ve ayrıca sıfır merkezli olduğu için sigmoid fonksiyonuna göre tercih edilir (Sharma ve ark., 2017).

5.2.5 ReLU fonksiyonu

ReLU en çok kullanılan 0 ile sonsuz arasında değer alan doğrusal olmayan bir aktivasyon fonksiyonudur. Daha basit bir matematiksel işlem içerdiğinden Tanh ve sigmoid'e göre daha az hesaplama gücü gerektirmektedir. Aynı anda sadece birkaç nöron etkinleştirildiği için ağı seyrek yapmakta, bu da hesaplama açısından verimli ve kolay hale getirmektedir. Bu yüzden ReLU, sigmoid ve tanh fonksiyonlarına göre çok daha hızlı öğrenmektedir.



Şekil 5.6. ReLU fonksiyonu ve türevi (Rasamoelina ve ark., 2020)

ReLU (bkz. Şekil 5.6), düzeltilmiş doğrusal ünite anlamına gelir ve sinir ağlarında yaygın olarak kullanılan bir non-linear aktivasyon fonksiyonudur. ReLU fonksiyonunu kullanmanın avantajı, tüm nöronların aynı anda etkinleştirilmemesidir. Bu, bir nöronun lineer dönüşümün çıktısı sıfır olduğunda yalnızca deaktif edileceği anlamına gelir. ReLU fonksiyonu matematiksel olarak,


$$f(x) = \max(0, x) \quad (5.6)$$

şeklinde ifade edilmektedir (Sharma ve ark., 2017).

ReLU, diğer fonksiyonlardan daha verimlidir çünkü tüm nöronlar aynı anda etkinleştirilmez, bunun yerine belirli bir sayıda nöron aynı anda etkinleştirilir. Bazı durumlarda gradyan değeri sıfır olduğundan, sinir ağı eğitimi sırasında geriye yayılma adımında ağırlıklar ve sapmalar güncellenmez (Sharma ve ark., 2017). Bu çalışmada negatif değerlerin bir sonraki katmana aktarılmaması için her katmana RELU aktivasyonu eklenmiştir.

5.2.6 Sızıntı ReLU fonksiyonu

Sızıntı ReLU fonksiyonu (bkz. Şekil 5.7), ReLU fonksiyonunun geliştirilmiş bir versiyonudur.



Şekil 5.7. Sızıntı ReLU fonksiyonu ve türevi (Sharma ve ark., 2017)

Negatif x değerleri için, ReLU fonksiyonunun değerini sıfır yerine son derece küçük bir doğrusal bileşen olarak tanımlamak için kullanılır. Sızıntı ReLU fonksiyonu matematiksel olarak,

$$\left. \begin{aligned} f(x) &= 0.01, x < 0, \\ f(x) &= x, x \geq 0 \end{aligned} \right\} \quad (5.7)$$

şeklinde ifade edilmektedir (Sharma ve ark., 2017).

5.2.7 Softmax fonksiyonu

Aynı zamanda bir tür sigmoid fonksiyonu olan softmax fonksiyonu sınıflandırma işlemi için kullanılan doğrusal olmayan bir aktivasyon fonksiyonudur. Genellikle birden fazla sınıfı işlemeye çalışırken kullanılmaktadır. Softmax fonksiyonu, görüntü sınıflandırma problemlerinin çıkış katmanında sıkça bulunur. Softmax fonksiyonu, her sınıf için çıktıları 0 ile 1 arasında sıkıştırır ve aynı zamanda çıktıların toplamına bölünmektedir. Eğer çıkışınız ikili sınıflandırmaysa, sigmoid fonksiyonu çıkış katmanı için çok doğal bir seçenektir. Fakat çıkışınız çoklu sınıf sınıflandırma ise, Softmax, her sınıfın olasılıklarını tahmin etmek için çok kullanışlıdır.

Softmax fonksiyonu, ikili sınıflandırma için kullanılan sigmoid fonksiyonlarından farklı olarak çoklu sınıf sınıflandırma problemleri için kullanılabilir. Bu fonksiyon, tüm bireysel sınıfların her veri noktası için olasılığı döndürür. Softmax fonksiyonu matematiksel olarak,

$$\sigma(x)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ for } i = 1, \dots, K. \quad (5.8)$$

şeklinde ifade edilmektedir (Sharma ve ark., 2017).

Bir ağ veya model oluşturduğumuzda çoklu sınıf sınıflandırması için, ağın çıkış katmanı hedefteki sınıfların sayısı kadar nörona sahip olacaktır.

5.3 Hata Fonksiyonları

Bu fonksiyonlar tahmin sonucunda elde edilen değer ile gerçek değer arasındaki farkı hesaplamaktadır. Aradaki farkın fazla olması tahminin hatalı olduğu anlamına gelmektedir. Bu yüzden aradaki hata farkın zamanla eğitim esnasında sifıra yaklaşması beklenmektedir. Hinge, Kullback-Leibler ve Cross-Entropy gibi kullanılan çeşitli hata hesaplama fonksiyonları vardır (Li ve ark., 2010).


5.4 Regülerizasyon Yöntemleri

Derin öğrenmede çok sayıda parametrenin tanıtılması, daha fazla kesik bilgi öğrenmek için daha derin mimariler oluşturabilse de aşırı uyum sorunlarına yol açabilir. Bu sorunda, modeller çok sayıda terim içerir veya çok karmaşık yaklaşımlar kullanır. Bu nedenle, aşırı uyarmanın neden olduğu sorunları, gerektiğinden daha esnek bir model kullanmanın neden olduğu sorunlardan ayırmak daha pratik olabilir. Örneğin, daha esnek bir model kullanmak, doğrusal modeli sığ bir veri kümesinde kullanıldığında daha düşük performansla karmaşıklığı ekler. Yardımcı işlevselliği olmayan tahmincilerin kullanılması kaynakları boşa harcar ve veri tabanındaki algılanmamış tahmin hatalarının olasılığını artırır. Farklı zamanlarda tahmin yapmak için regresyon kullanılırken, bu tahmincileri ölçmek ve kaydetmek gereklidir, böylece modeldeki değerler değiştirilebilir. Bu, değerli özelliklerin kaybına neden olabilir. Bir kullanıcının sonuçlarının başka bir kullanıcı tarafından kopyalanma yeteneği, taşınabilir modellerde etkilidir. Örneğin, modelle ilişki kuran bir tahmin edici doğrusal regresyon modeli taşınabilir. Herkes bu modeli kendi verilerine uygulayabilir, ancak bazı taşınabilir olmayan modeller, onu modelleyen kullanıcının yazılım verilerini yeniden kullanarak üretilebilir. Tüm bu nedenlerle aşırı uyum istenmeyen bir durumdur. Son zamanlarda, aşırı uyum sorunlarını önlemek için birçok düzenleme tekniği ortaya çıkmıştır. Bu teknikler arasında Veri setinin boyutunu artırma (Reenadevi ve ark., 2021), Cutout (Budak ve ark., 2021), Düğüm Seyreltme ve Düğüm Bırakma (Budak ve ark., 2021), Erken Durdurma (Doan ve Liong, 2004), Toplu normalizasyonu (Budak ve ark.,

2021), Ağırlık normalizasyonu (Budak ve ark., 2021), L2 düzenlemesi (Budak ve ark., 2021), L1 düzenlemesi (Budak ve ark., 2021) yer almaktadır.

5.4.1 Veri setinin boyutunu artırma

Bu, mevcut verilerin yatay ve dikey kaydırma, ölçekleme, sıkıştırma, yatay kaydırma döndürme ve yakınlaştırma gibi çeşitli dönüşümlere tabi tutularak yeni verilerin elde edilmesidir ve ek maliyet oluşturmada yapılabılır (Budak ve ark., 2021). Ön işleme adımını takiben, eğitim veri kümesi, verileri döndürme ve çevirme içeren bir veri artırma stratejisi kullanılarak iyileştirilir. Bu doğrudan sonuç olarak, ESA'nın giriş alanı önemli ölçüde genişletilir. Ayrıca, bu artırma yöntemi ile genelleme performansı artırılır ve eğitim sırasında meydana gelen aşırı uyum sorununu azaltmaya yardımcı olur (Athisayamani ve ark., 2023). Ayrıca görüntü artırma ise elde edilebilir görüntülerde çeşitlilik yaratmak için güçlü bir yaklaşımdır, böylece elde edilen bir görüntü veri kümesi genişletilebilir. Bu, farklı olasılıkları içeren bir elde edilen görüntü veri kümesinden yaratıcı ve yeni görüntüler üretir. Derin öğrenme ağları (ESA), uygun bir şekilde öğrenilebilmesi için çok sayıda görüntüye ihtiyaç duyar. Bu, modelin performansına daha iyi genelleme yapma ve aşırı uyumu azaltma katkıda bulunur. Sonuç olarak, artırma, küçük bir görüntü kümesinden görüntülerin sınıflandırılması, tespiti veya bölütleme için geniş bir çeşitlilik sağlar (Reenadevi ve ark., 2021). Bu çalışmada veri setindeki görüntülere yatay ve dikey çevirme, döndürme, yakınlaştırma, görüntü kaydırma ve en yakın piksel değerine göre doldurma teknikleri kullanılmıştır. Veri artırma işlemi sonucunda elde edilen görüntü örnekleri Şekil 5.8'de gösterilmektedir.




Şekil 5.8. Görüntü artırımı uygulanmış x-ray görüntüsü (Kaggle, 2018)

5.4.2 Cutout

ESA'lar için basit bir düzenleme tekniğidir. Var olan örneklerin kısmen kapalı sürümleriyle veri kümesini artırır. Bu teknik, modellerin görüntü bağlamını daha fazla dikkate almasını sağlar. Cutout ve diğer seyretme teknikleri arasındaki temel fark, nöronların katmanlar yerine giriş aşamasında bırakılmasıdır (Budak ve ark., 2021).

5.4.3 Düğüm seyreltme ve düğüm bırakma

Her eğitim sırasında belirli bir olasılıkla seçilen katmandaki her nöronun çıkışını sıfırlar, böylece veride karmaşıklığı önler ve genelleme yeteneğini iyileştirmeye katkıda bulunur. Bu teknik, ağdaki özellik sensörlerinin birbirine uyarlanmasını önler. Tam bağlı katmanlar düzenleme açısından etkilidir, ancak bu etki evrimsel katmanlarda azalır. Evrimsel katmanların daha az parametresi vardır ve tam bağlı katmanlardan daha az düzenleme gerektirir. Düğüm bırakma, rastgele ağırlıkları bırakan iyi bilinen bir tekniktir (Budak ve ark., 2021).




Şekil 5.9. (a) Normal sinir ağı ve (b) seyreltme sonrası (Konaté, 2019)

Bu çalışmada modelin aşırı öğrenmesini engellemek, genelleme yeteneğini artırmak ve daha yüksek doğruluk oranı elde edebilmek için seyreltme tekniği kullanılmıştır.

5.4.4 Erken durdurma

Erken durdurma yaklaşımı, veri kümesinin üç alt kümeye ayrılmasını gerektirir: eğitim, test ve doğrulama kümeleri. Eğitim ve doğrulama kümeleri, tüm model eğitim süreçlerinde normdur. Test kümesi, modelin eğitim sürecinin bazı aşamalarında eğilimleri test etmek için kullanılır.



Şekil 5.10. Erken durdurma (Naushad ve ark., 2021)

Eğitim sürecinin çok daha sonraki aşamalarında, modelin tahmin doğruluğu test kümesi için kötüleşmeye başlayabilir. İşte bu aşama, modelin aşırı uydurmayı aşmak için eğitilmeyi durdurması gereken aşamadır (Doan ve Liong, 2004). Şekil 5.10'da erken durdurma gösterilmiştir. Bu çalışmada gereksiz eğitim maliyeti ve zamandan tasarruf etmek için erken durdurma yöntemi kullanılmıştır.

5.4.5 Toplu normalizasyonu

Toplu normalizasyonu, eğitim sırasında gizli katmanın giriş dağılımını değiştirir ve giriş dağılımını ortalama değeri 0 ve varyansı 1 olan standart bir dağılıma dönüştürür. Toplu normalleme, gradyanı büyütür ve gradyan sorunlarını ortadan kaldırmaya yardımcı olur. Bu nedenle sinir ağı daha hızlı bir şekilde yakınsar ve eğitim daha kısa sürede gerçekleşir (Budak ve ark., 2021). Bu çalışmada gradyan sorunlarını ortadan kaldırmak ve eğitimi daha kısa sürede gerçekleştirebilmek için toplu normalizasyonu yöntemi kullanılmıştır.

5.4.6 Ağırlık normalizasyonu

Ağırlık normalizasyonu, toplu normalizasyondan esinlenerek geliştirilen bir normalleme yöntemidir. Bu yöntemde, ağırlıklar yeniden parametrelendirilir ve böylece optimizasyon sorunu geliştirilir. Burada her bir nöronun hesaplaması, giriş özelliklerinin ağırlıklı toplamı olarak ele alınır (Budak ve ark., 2021).

5.4.7 L2 düzenlemesi

L2 düzenlemesi: Bu tekniğin temel amacı, terim düzenlemesini düzensiz bir hedefle birleştirmektir.

$$L_T(w) = L_{(w)} + \tau \|w\|_2^2 \quad (5.9)$$

$$L_{(w)} = \sum_{m=1}^M L_m(y(X_m, w, \gamma, \beta)) \quad (5.10)$$

Burada L_m kayıp değerini temsil eder. Bu teknikte, ağırlıklar azaltılmaya zorlanır (Budak ve ark., 2021).

5.4.8 L1 düzenlemesi

Bu teknik, parametreleri 0'a yaklaştırarak aşırı uyum sorununu önlemeyi amaçlar ve bazı özelliklerin önemini azaltır (Budak ve ark., 2021).

5.5 Optimizasyon Algoritmaları

5.5.1 Stokastik gradyan inişi

Stokastik gradyan inişi (SGD) algoritması, tüm eğitim verileri örneklerini düşünmek yerine bir seferde bir eğitim örneği için kayıp fonksiyonunu hesaplar. Bu şekilde bellek yetersizliği sorunları önlenabilir. SGD, toplu gradyan inişi algoritmasının eksikliklerini gidermek için geliştirilmiştir. SGD kullanmanın sorunu, global optimuma ulaşmak ve salınımlardan kaçınmak için doğru öğrenme hızı değerini belirlemektir. Parametre güncellemeleri için aşağıdaki denklemi kullanır (Reyad ve ark., 2023);

$$\theta_{t+1} = \theta - \eta \cdot \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)}) \quad (5.11)$$

Burada η öğrenme oranını, $\nabla_{\theta} J(\theta_t)$, $J(\theta_t)$ kayıp fonksiyonunun θ_t 'ye göre eğimini temsil eder. Ayrıca $x^{(i)}$ ve $y^{(i)}$, giriş-çıkış çiftleri biçimindeki eğitim verisini temsil eder. Eğer kayıp fonksiyonu eğrisi bir boyutta yukarı doğru eğilirken diğer boyutta aşağı doğru eğilen “saddle point” denilen noktalar içeriyorsa, Stokastik Gradyan Azaltma (SGD) algoritması iyi performans göstermez (Reyad ve ark., 2023).

5.5.2 Momentumlu gradyan iniş

Gradient inişi yöntemlerinde öğrenme adımları en iyi sonuca daha hızlı ilerlemeyi hedefler. Öğrenme adımları çok büyük olduğunda global optimum her zaman ulaşılamaz. Bu büyük adımlar, global optimuma ulaşmak için gereken zaman üzerinde doğrudan etki yapabilir. Bu

sorunları ele almak için momentum gradient inişi yöntemi önerilmiştir. Bu yöntem, önceki öğrenme adımlarının ortalama hızını kullanarak bir sonraki öğrenme adımının hızını sınırlar. Bu yöntemde, geçmiş gradyanların dinamik ortalaması (m_{t-1}) kullanılır. Güncelleme kurallarını aşağıdaki gibi ifade edebiliriz (Reyad ve ark., 2023):

$$m_t = \gamma m_t + \eta \cdot \nabla_{\theta} J(\theta_t) \quad (5.12)$$

$$\theta_{t+1} = \theta_t - m_t \quad (5.13)$$

γ momentum parametresidir, genellikle 0,9 veya benzeri bir değere ayarlanır.

5.5.3 Uyarlanabilir gradyan algoritması (AdaGrad)

Uyarlanabilir gradyan (AdaGrad) algoritması, öğrenme hızı bileşenini, anlık zaman t 'ye kadar olan geçmiş ve şu anki gradyanların karelerinin toplamı olan v_t 'nin kareköküne böler. Gradyan bileşeni, SGD'de olduğu gibi değişmez. AdaGrad, her adımda farklı öğrenme hızları kullanarak her parametre için farklı güncellemeler yapar. AdaGrad'ı kullanmanın en büyük avantajı, öğrenme hızının diğer adaptif öğrenme sistemlerinde olduğu gibi manuel olarak ayarlanmamasıdır. AdaGrad'ın güncelleme denklemleri aşağıdaki gibi ifade edilebilir:

$$g_t = \nabla_{\theta_t} J(\theta_t) \quad (5.14)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t + \epsilon}} g_t \quad (5.15)$$

Burada ϵ , sıfıra bölme işleminden kaçınmak için kullanılan düzeltirme terimidir (genellikle 10^{-8} olarak ayarlanır), v_t ise gradyanın üssel hareketli ortalamasıdır (Reyad ve ark., 2023).

5.5.4 Karekök ortalama kare yayılım (RMSProp)

RMSProp, zaman zaman momentum ile kullanılan bir sürümü olan Adam ile yakından ilişkili bir optimizasyon yöntemidir. RMSProp ile momentum kullanımı ve Adam arasında birkaç önemli fark bulunmaktadır. RMSProp ile momentum, yeniden ölçeklenmiş gradyan üzerinde bir momentum kullanarak parametreleri güncellerken, Adam ise parametreleri doğrudan gradyanın birinci ve ikinci anların hareketli ortalamasını v_t kullanarak günceller. RMSProp algoritmasının güncelleme kuralları şunlardır:

$$g_t = \nabla_{\theta_t} J(\theta_t) \quad (5.16)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (5.17)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t + \epsilon}} g_t \quad (5.18)$$

burada g_t , kayıp fonksiyonu için birinci türevdir (gradyan) ve β_2 ise üssel azalma oranıdır (Reyad ve ark., 2023).

5.5.5 Uyarlanabilir moment tahmini (Adam)

Adam, geleneksel stokastik gradyan azaltma yönteminin yerine sıkça kullanılan oldukça verimli bir uyarlanabilir optimizasyon algoritmasıdır. Her parametre için öğrenme oranını dinamik olarak günceller ve düşük bellek gereksinimleri ile hesaplama açısından verimli olduğu düşünülmektedir. Adam, RMSProp ve momentum ile benzer bir parametre güncelleme yöntemi kullanır. RMSProp gibi karesel gradyanın üssel hareketli ortalamasını (v_t) kullanırken, gradyanın üssel hareketli ortalamasını (m_t) da ekler. Bu nedenle RMS-Prop ve momentumun avantajlarını birleştirir. Parametre güncellemeleri için aşağıdaki denklemler kullanılır:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (5.19)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (5.20)$$

$$m_t^\Lambda = \left(\frac{m_t}{1 - \beta_1^t} \right) \quad v_t^\Lambda = \left(\frac{v_t}{1 - \beta_2^t} \right) \quad (5.21)$$


$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t^\Lambda + \epsilon}} m_t^\Lambda \quad (5.22)$$

β_1 , üssel azalma oranıdır. β_1 ve β_2 için varsayılan değerler sırasıyla 0,9 ve 0,999 dur. m_t^Λ ve v_t^Λ , m_t ve v_t için düzeltme sapmalarıdır (Reyad ve ark., 2023). Bu çalışmada hesaplama açısından verimli olması için adam optimizasyon algoritması tercih edilmiştir.

6. MATERYAL ve YÖNTEM

6.1.Öğrenme Aktarımı (Transfer Öğrenme)

Öğrenme aktarımı (bkz. Şekil 6.1), yani önceden eğitilmiş bir modelden yararlanarak onu yeni bir veri kümesine uyarlama, genellikle sıfırdan tamamen yeni bir model oluşturmak yerine kullanılan yaygın bir yöntemdir (Khan ve Yong, 2017).




Şekil 6.1. Öğrenme aktarımı mimarisi (Sharma ve ark., 2022)

Önceden eğitilmiş bir ESA modelinden transfer öğrenme, genellikle en iyi sonuçlar için birçok görevde kullanılan özellik çıkarma ve ince ayarlama olmak üzere iki tekniği içerir. Özellik çıkarma tekniğinde, önceden eğitilmiş modelin evrişim kısmı dondurulur ve çıkışları, ilk sınıflandırıcı yerine yeni bir sınıflandırıcıya eğitmek için kullanılır. İnce ayarlama tekniğinde ise önceden eğitilmiş modelin evrişim kısmının başlangıç katmanları dondurulurken, son katmanlar yeni eklenen sınıflandırıcı ile eğitilir. Transfer öğrenme tekniğinin doğru seçimi farklı faktörlere bağlıdır, ancak en önemli iki faktör, yeni veri kümesinin boyutu ve önceden eğitilmiş modeli eğitmek için kullanılan orijinal veri kümesinin benzerliğidir (Tapas, 2016). VGG16, VGG19, MobileNetV2, ResNet50V2 ve ResNet152V2 literatürde kullanılan öğrenme aktarımı modelleri arasındadır. Ayrıca bu modeller deneysel çalışmada kullanılan modeller arasında yer almaktadır.

6.1.1. VGG16 modeli

VGG16, 2014 ILSVRC yarışmasında daha iyi sonuçlar elde etmek için geliştirilen basit bir ağ modelidir. Bu modeli önceki modellerden ayıran en önemli fark, çift veya üçlü evrişim katmanlarının ardından gelen havuzlama ve tam bağlantı katmanlarıdır. Önceki modellerde VGG16 modeli ise havuzlama, evrişim ve tam bağlı katmanları içerir (Aytekin ve Mençik, 2022).




Şekil 6.2. VGG16 model mimarisi (Kamal ve Hamid, 2023)

VGG16 modeli, 16 evrişim katmanı içeren bir mimariye sahiptir. Ağın giriş görüntüsü, $(224 \times 224 \times 3)$ boyutlarında bir yapıya sahiptir ve toplamda 16 evrişim katmanı ile (3×3) boyutunda bir sabit filtre içerir. Aynı zamanda ağın tamamında (2×2) boyutunda 5 katman Max gruplama içerir. Bununla birlikte, ağın üst kısmında iki tam bağlantılı katman ve bir softmax çıkış katmanı bulunur. VGG16 modeli, yaklaşık 138 milyon parametre ile büyük bir ağ olarak kabul edilir. Gizli özellikleri öğrenme yeteneğini artırmak için çok sayıda evrişim katmanını üst üste ekler. Şekil 6.2’de VGG16 ağının mimarisini göstermektedir (Kamal ve Hamid, 2023).

6.1.2. VGG19 modeli

VGG19 modeli (bkz. Şekil 6.3), 19 katman içeren bir modeldir ve ağırlıklara sahiptir. Bu model, 16 evrişim katmanı ve 3 tam bağlantılı katman içerir ve girişi ortalama RGB değeri çıkarılmış 224×224 boyutlu, 3 kanallı bir görüntüdür. Evrişim katmanları 1 piksel dolgu ve


adım ile küçük 3×3 yuva boyutuna sahiptir. Ayrıca, 2×2 çekirdek boyutu ve 2 piksel adımı olan 5 maksimum havuzlama katmanı içeren bir dizi bulunur (Kamal ve Hamid, 2023).



Şekil 6.3. VGG19 model mimarisi (Sudha ve Ganeshbabu, 2021)

6.1.3. MobileNetV2 modeli

MobileNetV2, 2017’de Howard ve diğerleri tarafından geliştirilen bir evrişimsel sinir ağı mimarisidir. İki bloktan oluşan MobileNetV2 mimarisi (bkz. Şekil 6.4), ilki bir artıklık bloğu olan tek seviyeli bir bloktur ve ikincisi küçültme için iki seviyeli bir bloktur. Her artık blok üç katmandan oluşur: İlk katman, ReLU6 ile (1×1) evrişim içerir ve ikinci katman, ReLU6 ile (3×3) derin evrişimi içerir. Son katman ReLU6 olmadan (1×1) evrişimi içerir (Sandler ve ark, 2018).



Şekil 6.4. MobilenetV2 mimarisi (Sandler ve ark., 2018)

Genel olarak, MobileNetV2 mimarisi 32 filtreli bir evrişim katmanı ve Çizelge 6.2’de açıklanan 19 adet artık darboğaz katmanı içerir. Filtre boyutu varsayılan olarak (3×3)

kullanılmıştır. Bu mimaride her katman, önceki katmanın çıktısını normalize etmek için toplu normalizasyonu ile takip edilir ve bu modelde kullanılan aktivasyon işlevi ReLU6'dır (Sharma ve Singh, 2023).

Çizelge 6.1. Kanalı k 'dan k' 'ne dönüştüren, adımı S olan ve genişleme faktörü T olan darboğaz artıklık bloğu (Sandler ve ark, 2018).


Girdi	Operatör	Çıktı
$h \times w \times k$	1×1 Evrişim, ReLU6	$h \times w \times (Tk)$
$h \times w \times Tk$	3×3 dwise $S = S$, ReLU6	$\frac{h}{S} \times \frac{w}{S} \times (Tk)$
$\frac{h}{S} \times \frac{w}{S} \times Tk$	Doğrusal 1×1 Evrişim	$\frac{h}{S} \times \frac{w}{S} \times (k')$

Çizelge 6.2. MobileNetV2: T artan boyutun genişleme katsayısı, C çıkış kanallarının sayısı, K sınıflandırma görevinin kategori sayısıdır. N , her modülün tekrarlanma sayısını ifade eder. S , her modülün ilk kez çalıştırıldığı andaki adımdır; bundan sonra adım varsayılan olarak 1 olur. Genişleme faktörü T her zaman Çizelge 6.1'de açıklandığı gibi giriş boyutuna uygulanır (Sandler ve ark, 2018).

Girdi	Operatör		T	C	N	S
$224^2 \times 3$	Evrişim		-	32	1	2
$112^2 \times 32$	Darboğaz		1	16	1	1
$112^2 \times 16$	Darboğaz		6	24	2	2
$56^2 \times 24$	Darboğaz		6	32	3	2
$28^2 \times 32$	Darboğaz		6	64	4	2
$14^2 \times 64$	Darboğaz		6	96	3	1
$14^2 \times 96$	Darboğaz		6	160	3	2
$7^2 \times 160$	Darboğaz		6	320	1	1
$7^2 \times 320$	1×1 Evrişim		-	1280	1	1
$7^2 \times 1280$	7×7 Ort. Havuzlama		-	-	1	-
$1 \times 1 \times 1 \times 1280$	1×1 Evrişim		-	K	-	

6.1.4. ResNet50V2 modeli

Resnet50, 26 milyon parametreye sahip 50 katmanlı bir artıklık ağıdır. Microsoft tarafından 2015 yılında tanıtılan derin evrişimli bir sinir ağı modelidir. Artıklık ağında özellikler yerine öğrenilmiş özelliklerin giriş katmanlarından çıkartılması olan artıkları öğrenmektedir (Kamal ve Hamid, 2023). ResNet50V2, geliştirilmiş ResNet50 modelidir. İki model arasındaki temel fark, V2 modelinin her ağırlık katmanından önce toplu normalleştirmeyi kullanmasıdır. Şekil 6.5'te ResNet50V2 model mimarisi gösterilmiştir.




Şekil 6.5. ResNet50V2 model mimarisi (Kvak, 2022)

Ayrıca ResNet mimarisi, ESA'nın birden fazla katmanla çalışmasına olanak sağlamıştır. Çoklu yığılmış katmanlara sahip derin sinir ağları, daha az katmanlı modellere göre daha yüksek eğitim hatası yüzdeleri üretme eğiliminde olmuştur. Bu artık ağ çerçevesi, kısayol bağlantılarının eklenmesine ve artık işlevlerin kullanılmasına olanak tanımış ve böylece derin sinir ağlarının yığılmış katmanlarının eğitim hatalarını azaltmasına olanak tanımıştır (Mascarenhas ve Agarwal, 2021).

6.1.5. ResNet152V2 modeli

Residual ağlar, özellik çıkarma için önerilen bir tür sinir ağıdır ve ResNet, derin sinir ağlarının kötüleşmesini aşmak için bir artıklık öğrenme birimi içermektedir. Bu birim, yeni girişlerin ve çıkışların eklenmesine izin veren bir kısayol bağlantısı ile tasarlanmış bir ileri

beslemeli ağ olarak tasarlanmıştır. Modelin karmaşıklığına katkıda bulunmadan sınıflandırma doğruluğunu artırması bir avantajdır. Bu, daha fazla üç katmanlı bloğun birleştirilmesiyle ResNet-152 katmanı oluşturularak gerçekleştirilir.

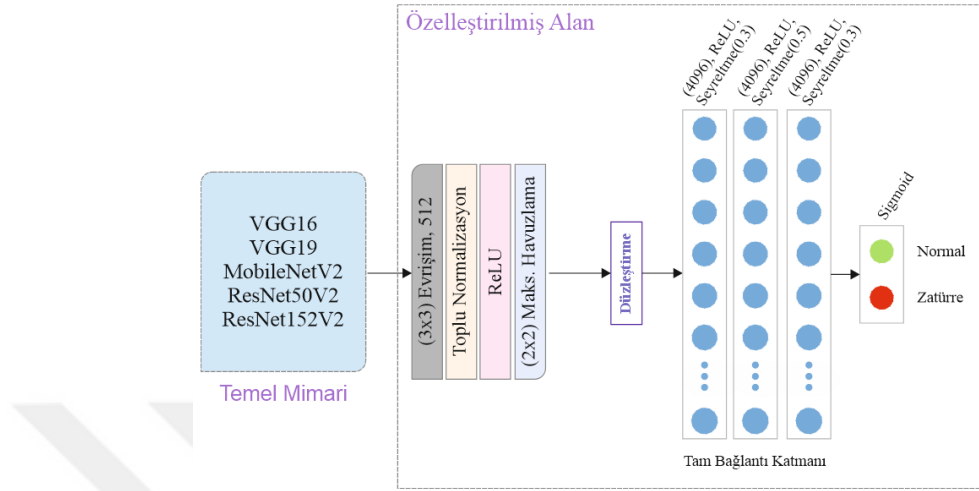


Şekil 6.6. Resnet152V2 model mimarisi (Pustokhin ve ark., 2023)

152 katmanlı ResNet, VGG-16/19 ağının 34 katmanlı ağından daha az karmaşık bir mimariye sahiptir. Artıklık bağlantıları, ResNet mimarisinin önemli faydasını oluşturan artıklık blokları arasındaki bağlantılardır. Bu bağlantılar ağın erken katmanlarından öğrenmesini sağlamayı amaçlar, böylece eğitim sırasında elde edilen bilgiyi korur ve ağın kapasitesini artırarak model oluşturmayı geliştirir. Kanalların artan sayısı, özellik haritasının giderek azaldığını ve baskın uzamsal özellikleri yakaladığını gösterir. Şekil 6.6'da Resnet152V2 mimarisi gösterilmiştir (Reenadevi ve ark., 2021).

6.1.6. Özelleştirilmiş model

Bu çalışmada önceden eğitilmiş ESA modellerinin son katmanı kaldırılarak yeni katmanlar eklenmiş böylece problemin çözümüne uygun bir model oluşturulmuştur. Bu modelin son katmanı veri setindeki sınıf sayıları dikkate alınarak düzenlenmiştir. Mevcut modellerin son bloklarından bazıları değiştirilmiş ve ağırlıkları her eğitim adımında güncellenmiştir. Şekil 6.7'de oluşturulan katman bileşiminin blok diyagramını göstermektedir.




Şekil 6.7. Özelleştirilmiş model mimarisi

VGG16, VGG19, MobileNetv2, ResNet50V2 ve ResNet152V2 temel mimarilerine ek olarak bir evrişim katmanı, bir toplu normalizasyon, bir ReLU, bir havuzlama katmanı ve dört yoğun katman eklenmiştir. Evrişimli ağ katmanında, (3x3) boyutunda bir evrişim çekirdeği kullanılarak evrişim işlemi uygulanmakta ve özellik haritaları çıkartılmaktadır. Gradyan sorunlarını en aza indirmek ve eğitimi daha kısa sürede gerçekleştirebilmek için toplu normalizasyon eklenmiştir. ReLU aktivasyon fonksiyonu eklenerek negatif değerlerin bir sonraki katmanlara aktarılmanın önüne geçilmektedir. Ağdaki parametre ve hesaplama miktarını azaltmak ve gereksiz gürültü ve karmaşıklık göz ardı etmek için (2x2) boyutunda maksimum havuzlama katmanı eklenmiştir. Evrişim ve havuzlama katmanları tarafından çıkarılan özelliklere dayalı olarak sınıflandırmayı gerçekleştirmek için üç adet tam bağlantı katmanı ESA modelinin sonuna eklenmiştir. Eklenen üç tam bağlantı katmanının her birinde 4096 birim, ReLU aktivasyon fonksiyonu ve modellerin aşırı öğrenmesine karşı koruma sağlamak amacıyla sırası ile seyreltme oranı 0.3, 0.5, 0.3 olacak şekilde uygulanmıştır. Dördüncü katman ise yalnızca bir birime sahip ve aktivasyon fonksiyonu ‘Sigmoid’ olarak belirlenmiştir. Bu katmanda çıktı olarak tahmin edilen sınıf (‘normal’ veya ‘zatürre’) değerleri gösterilmektedir. Yapılan tüm bu değişiklikler VGG16, VGG19, MobileNetv2, ResNet50V2 ve ResNet152V2 modellerinin her birine ayrı ayrı uygulanmıştır.


6.2. Veri Seti

Bu çalışmada, Kaggle'dan alınmış olan göğüs röntgeni görüntüleri hastaların tespiti için kullanılmıştır. Veri kümesi, normal ve zatürre vakalarının olduğu göğüs röntgeni görüntülerini içermektedir. Veri kümesindeki her görüntü örneği farklı bir boyuta sahiptir. Bu veri kümesine ait göğüs röntgeni görüntülerinin örnekleri Şekil 6.8'de gösterilmiştir.



Şekil 6.8. Veri seti göğüs röntgeni görüntüleri

Bu çalışmada kullanılan veri setindeki görüntü örneklerinin yaklaşık %80'i eğitim seti, yaklaşık %20'si ise doğrulama seti olarak kullanılmıştır. Eğitim setinden bağımsız olarak hazırlanan test seti, toplam veri setinin yaklaşık %10'unu içermektedir. Yani eğitim setinde kullanılan görsel örnekleri test setinde kullanılmamıştır. Eğitim ve test aşamasında kullanılan veri kümesinin yaklaşık yüzdelik dağılımı Şekil 6.9'da gösterilmiştir.



Şekil 6.9. Eğitim, doğrulama ve test veri setinin yaklaşık yüzdelik dağılımı

Eğitim setindeki toplam 5216 adet eğitim verisinin 1341'ı normal ve 3875'i zatürre, test setindeki 624 test verisinin ise 234 tanesi normal ve 390 tanesi zatürre görüntüsü olacak şekilde ayrılmıştır. Bu çalışmada eğitim seti her katmandaki ağırlıkların öğrenilmesi için, eğitim sürecinin gelişimi hakkında sezgi sağlamak ve doğruluğu hesaplamak için ise doğrulama seti kullanılmıştır.

6.3.Web Arayüzünün Geliştirilmesi

Göğüs radyografisi görüntülerinden zatürre hastalığının tespiti için beş derin öğrenme modeli ince ayar ile özelleştirilerek eğitilmiştir. Eğitim sonucunda elde edilen ve en iyi doğruluk tahmini veren model ağırlığı web uygulaması için seçilmiştir. Geliştirilen bu web uygulaması ücretsiz ve açık kaynaklı Django ile oluşturulmuştur. Django, hızlı, güvenli ve esnek bir yapıya sahip yüksek seviyeli bir Python web çerçevesidir. Web uygulamasına ait ekran görüntüsü Şekil 6.10'da gösterilmiştir.




Şekil 6.10. Web uygulamasına ait ekran görüntüsü

Uygulamaya yüklenen göğüs röntgen görüntüsü, seçilen derin öğrenme modeli uygulanarak tahminleme yapılmaktadır. Sınıflandırma süreci sırasında yüzde doğruluk tahmin sonucu


ekranda görüntülenir. Bu web uygulaması, radyologlar için, hatta kırsal bölgelerde, ek olarak uzaktan sistem olarak kullanılabilir.

6.4.GUI Arayüzü ve Uygulama Prosedürü

Zatürre tespiti için tasarlanan web uygulamasında sayfanın sol tarafında bir görüntü yükleme modülü bulunmaktadır. “Dosya seç” kısmı tıklandığında, kullanıcıdan yüklenmesi istenen göğüs röntgen görüntüsünün konumu istenmektedir. Bu göğüs röntgen görüntüsü seçildikten sonra dosyanın sisteme yüklenmesi için “Yükle” kısmı tıklanarak sisteme aktarılmaktadır. Görüntü yüklendikten sonra uygulama arka planda hastalık tespitini yapan derin öğrenme algoritmasını çalışmaktadır ve tahminlemede bulunmaktadır. Değerlendirme sonucu NORMAL veya ZATÜRRE şeklinde ve yüzdelik değeri ile çıktı olarak gösterilmektedir. Şekil 6.11 ve şekil 6.12’de hastalara ait örnek sonuçlar gösterilmiştir.



Şekil 6.11. Normal hastaya ait tahmin sonucu



Şekil 6.12. Pozitif hastaya ait tahmin sonucu

Geliştirilen uygulamanın dinamik bir yapıya sahip olması nedeniyle sürekli olarak güncellenebilir ve geliştirilebilir bir formatta bulunmaktadır. Bu sisteme yeni derin öğrenme algoritmaları eklenebilir veya çıkarılabilir.

6.5. Performans Parametreleri

Model performansını değerlendirmek için kullanılan dört değerlendirme kriteri, doğruluk, kesinlik, duyarlılık ve F1 skoru parametreleridir. Bu değerlendirme metrikleri için formülasyonlar şu şekildedir:

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (6.1)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (6.2)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (6.3)$$

$$F1 - \text{skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6.4)$$

Doğruluk değeri ne kadar yüksek olursa, en yaygın değerlendirme metriği olarak, sınıflandırma performansı o kadar iyidir. Kesinlik ve duyarlılık, sınıflandırıcının doğruluğunu değerlendirmek için kullanılır. Düşük duyarlılık değeri, sınıflandırıcının birçok yanlış negatif (FN) içerdiğini gösterirken, düşük kesinlik değeri sınıflandırıcının birçok yanlış pozitif (FP) içerdiğini gösterir. Doğru pozitif (TP), doğru bir şekilde sınıflandırılmış hastalıklı durumları ifade ederken, yanlış negatif (FN), yanlış bir şekilde sağlıklı olarak sınıflandırılmış durumları ifade eder. Benzer şekilde, doğru negatif (TN), doğru bir şekilde sınıflandırılmış sağlıklı durumları ifade ederken, FP yanlış bir şekilde sınıflandırılmış hastalıklı durumları ifade eder. F1 skoru parametresi, eşit olmayan bir şekilde dağılmış veri setinde yanlış model seçimini önlemek için kullanıldı (Budak ark., 2023).

7. BULGULAR ve TARTIŞMA

7.1.Deneysel Çalışma Ortamı

Bir veri setinin, derin öğrenme modelleri kullanılarak eğitilmesi için donanımsal olarak güçlü bilgisayarlara ihtiyaç duyulmaktadır. Bu çalışmada eğitim işlemleri Google Colab platformunda Intel Xeon @2.30 GHz 8 çekirdekli, 51GB rastgele erişimli bellek (RAM), NVIDIA Tesla T4 (16GB), Tesla A100 (40GB) ve TeslaV100 (32GB) grafik kartlarına sahip sanallaştırma teknolojisi üzerinde çalışan sanal bilgisayarlarda eğitilmiştir. Python 3 ile çeşitli Python kütüphaneleri kullanılmıştır. Bu çalışmada kullanılan Python kütüphaneleri aşağıda açıklanmıştır.

- **Numpy:** Çok boyutlu diziler üzerinde yüksek performanslı sayısal ve bilimsel hesaplamalar yapmak kullanılan bir kütüphanedir (Nagpal ve Gabrani, 2019).
- **Pandas:** Veri analizini gerçekleştirmek, verileri yüklemek, verileri hazırlamak, değiştirmek, ardından modellemek ve ardından analiz etmek için kullanılan bir kütüphanedir (Nagpal ve Gabrani, 2019).
- **TensorFlow:** Doğal dil işleme, görüntü tanıma, makine çevirisi için sıra-sıra modeller gibi derin sinir ağlarının eğitimi ve çalıştırılması için kullanılan ve geliştiriciler tarafından, verilerin bir dizi düğüm üzerinde nasıl hareket edeceğini açıklayan bir yapı olan veri akış grafiği de oluşturulabilmektedir. Grafikte bulunan tüm düğümler bir matematiksel işlem türü ve düğümler arasındaki kenarlar ise bir "tensor" olarak bilinen çok boyutlu bir veri dizisidir (Nagpal ve Gabrani, 2019).
- **Keras:** TensorFlow üzerinde çalışabilen, derin öğrenme için tasarlanmış, kompakt ve öğrenmesi kolay bir yüksek seviyeli Python kütüphanesidir. Geliştiricilere, sinir ağları için katmanlar oluşturmak gibi derin öğrenme temel kavramlarına odaklanmalarını sağlamaktadır ve tensorların, şekillerinin ve matematiksel detaylarının gerektirdiği detaylara kendisi bakar. TensorFlow, Keras'ın arkasında çalışan bir alt yapıdır. Sıralı API ve işlevsel API olmak üzere iki ana türde çerçeve oluşmaktadır. Sıralı API, katmanlar dizisi fikrine dayanır; bu, Keras'ın en yaygın ve

en kolay kullanılan kısmıdır. Sıralı model, katmanların doğrusal bir yığını olarak düşünülebilir (Manaswi, 2018).

- **Scikit-Learn:** Birçok denetimsiz ve denetimli öğrenme algoritması sunan ve içinde bulunan bazı model grupları arasında kümeleme, veri setleri, topluluk yöntemleri, çapraz doğrulama, özellik seçimi, boyut azaltma, parametre ayarlama, özellik çıkarma yer almaktadır (Nagpal ve Gabrani, 2019).
- **Matplotlib:** Çeşitli türlerde grafikleri farklı platformlarda göstermek için kullanılan bir 2D çizim kütüphanesidir. Birkaç satır kod kullanarak çubuk grafikler, pasta grafikleri, saçılım grafikleri, histogramlar, hata grafikleri vb. gibi şekiller oluşturmamıza olanak tanımaktadır (Nagpal ve Gabrani, 2019).
- **OpenCv:** Genel görüntü işleme fonksiyonları, görüntü piramitleri, geometrik tanımlayıcılar, segmentasyon, dönüşümler, özellik çıkarma, takip, uyarlama, kamera kalibrasyonu, 3D ve makine öğrenimi gibi çok fazla optimize edilmiş algoritma içeren algılama ve tanıma, matris matematiği ve yardımcı veri yapıları ve fonksiyonlardan oluşan bir bilgisayar görüşü kütüphanesidir (Druzhkov ve ark., 2011).

7.2.Deneysel Veriler ve Deneysel Ayarlar

Bu çalışmada zatürre hastalığının tespiti için akciğer x-ray görüntüleri ile beş adet derin öğrenme modeli kullanmıştır. Bu modellere çeşitli ince ayarlar uygulanmıştır. Veri seti, eğitim verisi için 1341 “normal” ve 3875 “zatürre” görüntüsünden oluşmaktadır. Çalışmada eğitim veri setinin %80’i eğitim, %20’si doğrulama için rastgele ayrılmıştır. Eğitim sonucunda elde edilen ağırlıklar test veri seti için test edilmiştir. Çalışmada derin öğrenme modelleri olan VGG16, VGG19, MobileNetV2, ResNet50V2 ve ResNet152V2 modelleri ve bu modellerin özelleştirilmesine ilişkin performans ölçümleri değerlendirilmiştir. Eğitim tur sayısı başlangıçta 50 olarak belirlenmiştir. Fakat eğitim sırasında modelin aşırı öğrenmesini durdurmak için Bölüm 5.4.4’te açıklanan erken durdurma algoritması kullanılmış ve tur sayısı modelin öğrenmesine göre değişmektedir. Veri setindeki görüntülerin farklı boyutta olmasından dolayı tüm görüntü değerleri 224x224x3 olarak yeniden boyutlandırılarak ve görüntülerin piksel değerleri 255’e bölünerek sıfır ile bir arasında düzenlenmiştir.

Bu çalışmada modelleri aynı koşul altında derleme amacıyla tüm modellerde başarımlarını artırmak için Bölüm 5.4.1’de görüntülere uygulanan veri artırma yöntemleri eğitim esnasında kullanılmıştır. Bunun yanı sıra kayıp fonksiyonunu en aza indirmek için optimizasyon algoritması olarak Bölüm 5.5.5’te açıklanan Adam (Uyarlanabilir moment tahmini) optimizasyonu kullanılmış ve öğrenme oranı 5e-5 olarak belirlenmiştir. Özelleştirilen modellerde ek olarak evrişim katmanı, aktivasyon fonksiyonu, toplu normalleştirme ve maksimum havuzlama katmanları kullanılmıştır. Seyreltme yapabilmek için bırakma işlemi değerleri 0.3, 0.5, 0.3 ve her bir yoğunluk katmanına ait değerler 4096 birim olacak şekilde uygulanmıştır. Gradyan sorunlarını ortadan kaldırmak için Bölüm 5.4.5’te belirtilen yöntem kullanılmıştır. Negatif değerlerin bir sonraki katmana aktarılmaması için her katmana düzeltilmiş doğrusal birim aktivasyonu eklenmiştir. Çıktı katmanında sınıflandırma işlemi için sigmoid fonksiyonu kullanılmıştır.

Bu çalışmada modellere ait performansı Auc-Roc puanı ve sınıflandırma doğruluğu ile ölçmekteyiz. Öncelikle hesaplama için modellerin Roc eğrilerinin çizilmesi gerekmektedir. Bu eğriler gerçek pozitif oranı ile yanlış pozitif oranı arasında çizilir. Şekil 7.3’te modellere ait Roc eğrisi grafikleri gösterilmiştir. Roc bir olasılık eğrisidir ve Auc ise ayırt edilebilme derecesini veya ölçüsünü temsil eder. Auc-Roc skoru ne kadar yüksekse, modelin sınıfları ayırt etme yeteneği o kadar iyidir. Doğruluk, modelin bir veri örneğini ne kadar sık doğru bir şekilde sınıflandırdığını ölçerek başka bir önemli göstergedir. Doğruluk ne kadar yüksekse, model o kadar çok veri örneğini doğru bir şekilde tahmin edebilir.

7.2.1. DeneySEL sonuçlar ve analiz



Zatürre dünyadaki en ölümcül hastalıklardan biridir. Bu çalışmada göğüs röntgen görüntülerini normal ve zatürre olacak şekilde sınıflandırmak için beş adet derin öğrenme modeli kullanılmıştır. Modellerin performansını değerlendirmek için aynı veri seti ve metrikler üzerinde deneyler yapılmıştır. Çizelge 7.1’de oluşturulan modelin deneySEL sonuçları gösterilmiştir. Özelleştirilmiş ResNet50V2 ve özelleştirilmiş VGG16 modellerinin sırası ile %92.3, %91.5 doğruluk, %96.4, %97 Auc-Roc skoru ile diğer modellerden daha iyi sonuçlar verdiği görülmektedir. Özelleştirilmiş ResNet50V2 modeli ile ResNet50V2 modeli karşılaştırıldığında başarımların %3.7, Auc-Roc skorunun %0.8 arttığı görülmüştür. Aynı

şekilde özelleştirilmiş VGG16 modelinin ise VGG16 modeline göre başarı oranının %1.5, Auc-Roc skorunun %0.7 arttığı görülmüştür.



Çizelge 7.1. Modellere ait performans değerleri

	Doğruluk	Kesinlik	Duyarlılık	F1 Skor	Auc-Roc
MobileNetV2 Modeli	84.4	81.5	97.1	88.6	95.0
MobileNetV2 Özelleştirilmiş Model	89.2	86.4	98.2	91.9	96.1
ResNet50V2 Modeli	88.6	87.1	95.8	91.3	95.6
ResNet50V2 Özelleştirilmiş Model	92.3	91.5	96.6	94.0	96.4
ResNet152V2 Modeli	88.5	87.5	95.8	91.5	93.5
ResNet152V2 Özelleştirilmiş Model	87.8	85.3	97.1	90.8	94.6
VGG16 Modeli	90.0	87.7	97.6	92.4	96.3
VGG16 Özelleştirilmiş Model	91.5	89.0	98.4	93.5	97.0
VGG19 Modeli	87.8	84.1	99.2	91.0	95.6
VGG19 Özelleştirilmiş Model	89.4	86.0	99.2	92.1	96.3



Ayrıca ResNet152V2 modeli dışındaki diğer özelleştirilmiş modellerde de başarı oranları artmıştır. Bunun temel nedeni modellere uygulanan ince ayar stratejisinin farklı modellerde farklı etkiler göstermesidir. Sonuç olarak deneysel sonuçlar özelleştirilmiş ResNet50V2 ve özelleştirilmiş VGG16 modelleri ile göğüs röntgen görüntü sınıflandırması için daha etkili olduğunu göstermektedir.





(a)





(b)





(c)





(d)





(e)




(f)



(g)




(h)




Şekil 7.1. Modellere ait eğitim/test kayıp ve eğitim/test doğruluk grafiği (a) MobileNetV2 modeli, (b) MobileNetV2 özelleştirilmiş model, (c) ResNet50V2 modeli, (d) ResNet50V2 özelleştirilmiş model, (e) ResNet152V2 modeli, (f) ResNet152V2 özelleştirilmiş model, (g) VGG16 modeli, (h) VGG16 Özelleştirilmiş model, (i) VGG19 Modeli, (k) VGG19 özelleştirilmiş model.


Şekil 7.1’de modellerin eğitimi sırasında doğrulama ve kayıp değerleri arasındaki ilişkiyi gösteren grafikler verilmiştir. Kayıp grafiklerinde devir (epoch) değeri arttıkça kayıp ne kadar küçük olursa model o kadar iyi olur. Eğitim/Test kayıp grafiğine bakıldığında devir sayısı arttıkça eğitim kaybı ve doğrulama kaybının da azalmaya devam ettiği görülmektedir. Doğrulama grafiplerinde doğruluk ne kadar yüksek olursa modelin genelleme yeteneği daha yüksek olmaktadır. Eğitim/Test doğrulama grafiğine bakıldığında ise devir sayısı arttıkça eğitim doğruluğu ve test doğruluğu her ikisi de artmaya devam ettiği görülmektedir. Bu durum modelimizin performansının daha iyi hale geldiğini göstermektedir. Ancak devir sayısı belli bir değere ulaştığında iki eğri düzleşir ve bu durum modelin performansının belirli bir süre geçtikten sonra sabit kaldığını göstermektedir. Daha fazla devir değeri eğitim sırasında etkiyi artırmayacak ve hesaplama maliyetlerini boşa çıkaracaktır. Bu yüzden uygun bir devir değerinin seçilmesi, model eğitimi ve doğrulama için çok önemlidir.




(a)




(b)




(c)




(d)




(e)




(f)



(g)





(h)



Şekil 7.2. Modellere ait elde edilen hata matrisi grafiği (a) MobileNetV2 modeli, (b) MobileNetV2 özelleştirilmiş model, (c) ResNet50V2 modeli, (d) ResNet50V2 özelleştirilmiş model, (e) ResNet152V2 modeli, (f) ResNet152V2 özelleştirilmiş model, (g) VGG16 modeli, (h) VGG16 Özelleştirilmiş model, (i) VGG19 Modeli, (k) VGG19 özelleştirilmiş model.

Şekil 7.2’de modellere ait hata matrisleri tablosu gösterilmektedir. Sıfır değeri “normal”, bir değeri “zatürre” sınıfını ifade etmektedir. Daha iyi sonuç veren özelleştirilmiş ResNet50V2 modeline (d) ait hata matrisinde test verisi için kullanılan 624 görüntüden 576 görüntü doğru tahmin edilmekte iken, özelleştirilmiş VGG16 modelinde (h) 571 görüntü doğru tahmin edilmektedir.





Şekil 7.3. Modellere ait elde edilen ROC eğrisi grafiği (a) MobileNetV2 modeli, (b) MobileNetV2 özelleştirilmiş model, (c) ResNet50V2 modeli, (d) ResNet50V2 özelleştirilmiş model, (e) ResNet152V2 modeli, (f) ResNet152V2 özelleştirilmiş model, (g) VGG16 modeli, (h) VGG16 Özelleştirilmiş model, (i) VGG19 Modeli, (k) VGG19 özelleştirilmiş model.

Şekil 7.3'te modellere ait ROC eğrisi grafiği gösterilmiştir. MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 modelleri özelleştirilmiş modeller ile karşılaştırıldığında, özelleştirilmiş modellerin Auc-Roc skorları sırasıyla %1.1, %0.8, %1.1, %0.7, %0.7 oranında arttığı görülmektedir. Bu durum özelleştirilmiş modellerde yanlış pozitif oranının azaldığını ifade etmektedir.

Literatürdeki çalışmalar ile kıyaslandığında elde edilen sonuçların zatürre hastalığını tespit etmede başarılı sonuçlar elde ettiği görülmektedir. Bu değerlendirme ResNet50V2 modeli ve VGG16 için Çizelge 7.2’de gösterilmektedir.

Çizelge 7.2. Önerilen yöntemin literatürdeki çalışmalar ile kıyaslanması

Çalışma	Kullanılan Yöntem	Doğruluk (%)
Jain ve ark. (2020)	VGG19	88.46
Bıçakçı (2021)	Yapay sinir ağları	73
Nandi ve Mulimani (2021)	Hibrit model	94.43
Sharma ve Guleria(2022)	VGG16	90.8
Phinne (2023)	VGG19	94
S. Albawi ve P. Agrawal(2023)	İlgi bölgesi	92.83
Mangal ve ark. (2020)	Covidnet	90.5
Özelleştirilmiş Model	ResNet50V2	92.3
	VGG16	91.5

Jain ve ark., (2020), ESA ve Transfer Öğrenme'nin uygulanması üzerine bir araştırma yapmış ve bu araştırmada Kaggle platformundan aldıkları Göğüs X-ışınları (CXR) görüntülerinden oluşan veri seti kullanılmaktadır. Uygulama dört algoritma üzerinde gerçekleştirilmiştir: VGG16, VGG19, ResNet50 ve InceptionV3. Yazarlar eğitim sonucunda VGG16 ile %87,28, VGG19 ile %88,46, ResNet50 ile %77,56 ve InceptionV3 ile %70,99 doğruluk elde etmişlerdir. Bıçakçı (2021), yapmış olduğu çalışmada pozitron emisyon tomografi (PET) görüntüleri kullanılarak Küçük Hücreli Dışı Akciğer Kanseri'nin (KHDAK) çeşitli tiplerinin belirlenmesinde derin öğrenme yöntemlerini kullanmıştır. Çalışmasında kullandığı yöntemlerde yapay sinir ağları (YSA) kullanmış ve %73 doğruluk oranına sahip sınıflandırma başarısı elde etmiştir. Çalışmasında kullandığı yöntemlerinde ESA ve ResNet tabanlı sığ ağları içeren çalışmalar yapmıştır ve %71 F skoru elde etmiştir. Nandi ve Mulimani (2021), yazarlar çalışmalarında göğüs röntgenlerinden Covid-19 varlığını tespit edebilen ve düşük donanım kaynağı tabanlı kişisel dijital asistanlar ile kullanılabilecek bir derin öğrenme modeli önermişlerdir. Önerdikleri hibrit modelin performansı, halka açık iki COVID-19 göğüs röntgeni veri seti üzerinde değerlendirmişlerdir. Her iki veri seti de normal, zatürre ve korona virüs ile enfekte akciğer röntgenlerini içermektedir ve Veri Seti 1 ve Veri Seti 2’de diye aldıkları verilerde sırasıyla %84,35 ve %94,43 doğruluk elde etmişlerdir.

Sharma ve Guleria (2022), yazarlar çalışmalarında zatürre tespiti ve teşhisi için kullanılabilen göğüs X-ışını taramaları kullanılmıştır. Çalışma için kullanılan VGG16 modeli, derin öğrenmenin hastalık teşhisindeki çeşitli uygulamalarıyla birlikte açıklanmıştır. Yazarlar doğruluk, hassasiyet, F-skor ve geri çağrı parametrelerini kullanmış ve sırasıyla %90.8, 0.9102, 0.935 ve 0.9615 elde etmişlerdir. Phinne (2023), zatürre hastalarının göğüs röntgenlerine göre saptanması ve sınıflandırmasını yapmıştır. Önerdiği sistemde, dengesiz bir veri setinde %86 ve dengeli bir veri setinde %94 doğruluk elde etmiştir. S. Albawi ve P. Agrawal (2023), yazarlar çalışmalarında, X-ışını görüntülerinde gösterilen anormal özellikleri veya desenleri tanımlamayı ve kategorize etmeyi amaçlamaktadır. Bu yaklaşım, klinik ayarlarda hastalık tespitinin doğruluğunu ve etkinliğini önemli ölçüde artırma potansiyeline sahiptir ve %92.83 doğrulukla gerçekleştirilebilir. Mangal ve ark., (2020), göğüs X-ışınları kullanarak COVID tespiti üzerine derin öğrenme algoritmalarını incelemişlerdir. Modelin %90,5 verimlilikle çalıştığını ve %100 hassasiyete sahip olduğunu iddia etmişlerdir. Bu çalışmada ise beş adet derin öğrenme modeli olan MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 modelleri üzerinde çalışılmıştır. Bu modellere çeşitli ayarlar uygulanarak zatürre hastalığının tespiti için en iyi tahminlemede bulunan model tespit edilmeye çalışılmıştır. Performans değerlendirmesi için doğruluk, kesinlik, F1 ve Auc-Roc skor parametreleri kullanılmıştır. MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 modellerinin doğruluk yüzdeleri %84.4, %88.6, %88.5, %90, %87.8 iken özelleştirilmiş modellerin doğruluk değerleri sırasıyla %89.2, %92.3, %87.8, %91.5, %89.4'tür. Özgün modeller ile özelleştirilmiş modeller karşılaştırıldığında uygulanan ayarların başarılı olduğu görülmektedir. Bu beş model arasından %92.3 ve %91.5 doğruluk ile özelleştirilmiş ResNet50V2 ve özelleştirilmiş VGG16 modelinin daha iyi performans gösterdiği açıktır.

8. SONUÇ ve ÖNERİLER

Bu tez çalışmasının amacı, zatürre hastalığının erken teşhis edilerek tedavi sürecinin erken başlanması ve can kayıplarının azaltılmasına yöneliktir. Dünya genelinde her yıl zatürre hastalığından milyonlarca insan etkilenmekte ve ölümler yaşanmaktadır. Bu yüzden zatürre hastalığının erken teşhisi, tedavi süreci için hayati öneme sahiptir. Zatürre hastalığını teşhis etmenin çeşitli yolları vardır; örneğin bilgisayarlı tomografi, MR ve göğüs röntgen görüntülerini kullanmaktır. Göğüs röntgen görüntüleri yüksek hız, düşük maliyet ve düşük radyasyon gibi nedenlerden dolayı en çok tercih edilen görüntüleme yöntemidir. Fakat geleneksel röntgen yöntemleri hastalığın tespiti için uzman doktor ve radyoloğa ihtiyaç vardır. Bu yüzden çeşitli derin öğrenme yöntemleri kullanılarak ve web uygulaması geliştirilerek hastalığın daha kısa sürede tespitinin sağlanması, uzman doktor ve radyologların iş yükünü azaltmayı amaçlamaktadır.

Bu çalışmada beş adet derin öğrenme modeli olan MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 modelleri üzerinde çalışılmıştır. Bu modellere çeşitli ayarlar uygulanarak zatürre hastalığının tespiti için en iyi tahminlemede bulunan model tespit edilmeye çalışılmıştır. Modellerin daha iyi tahminleme yapabilmesi için çeşitli görüntü artırım yöntemleri kullanılarak görüntü sayısı artırılmıştır. Aynı zamanda modelleri aynı koşul altında değerlendirmek ve her modelin sınıflandırma yeteneğini güçlendirmek için evrişim, havuzlama, toplu normalizasyon ve yoğun katmanlar eklenmiştir. Eğitim sırasında modellerin aşırı öğrenmesini engellemek için seyreltme yöntemi ve daha sonra verileri iki farklı sınıfa ayırmak için sigmoid fonksiyonu kullanılmıştır. Kaggle platformunda herkese açık olarak yayımlanan göğüs röntgen görüntülerinden oluşan veri kümesi %80 eğitim, %20 doğrulama için ayrılmıştır. Performans değerlendirmesi için doğruluk, kesinlik, F1 ve Auc-Roc skor parametreleri kullanılmıştır. MobileNetV2, ResNet50V2, ResNet152V2, VGG16 ve VGG19 modellerinin doğruluk yüzdeleri %84.4, %88.6, %88.5, %90, %87.8 iken özelleştirilmiş modellerin doğruluk değerleri sırasıyla %89.2, %92.3, %87.8, %91.5, %89.4'tür. Özgün modeller ile özelleştirilmiş modeller karşılaştırıldığında uygulanan ayarların başarılı olduğu görülmektedir. Bu beş model arasından %92.3 ve %91.5 doğruluk ile

özelleştirilmiş ResNet50V2 ve özelleştirilmiş VGG16 modelinin daha iyi performans gösterdiği açıktır.

Göğüs röntgeni görüntüleri aracılığıyla zatürre teşhis süreci radyologlar için zaman alıcı ve hata yapmaya açık olabilir. Bu nedenle, uzmanların zatürre hastalarını doğru bir şekilde tanılamalarına yardımcı olabilen bir bilgisayar destekli bir yöntem geliştirme ihtiyacı büyük önem taşımaktadır. Bu bağlamda, transfer öğrenmeye dayalı doğru bir tanı sistemi geliştirilmiştir. Göğüs röntgenleri şüpheli hastaların erken teşhisini sağlayabilir. Ayrıca doktor veya radyologların iş yükünü azaltmak, zamandan tasarruf sağlamak amacıyla göğüs röntgen görüntülerinin bir web uygulaması üzerinden hastalık tanısını daha kısa sürede ve yüksek doğruluk oranı ile belirleyeceği bir uygulama geliştirilmiştir. Bir bilgisayar destekli tanı sistemi, kırsal bölgelerde zatürre hastalığı teşhisi için uzaktan destek aracı olarak kullanılabilir. Program çok hızlı çalıştığından, hastaneye sağlık sorunu nedeniyle başvuran binlerce hastanın görüntüleri sistemde otomatik olarak taranabilir. Bu sayede zatürre hastalığı tespiti hızlı bir şekilde yapılabilir.

Gelecekteki çalışmalarda, ayırt edici özelliklerin öğrenilebilmesi için daha fazla görüntü kullanılarak modelin performansı artırılabilir. Uzman doktor ve radyologların, zatürre ve diğer akciğer hastalıklarını tespiti noktasında yardımcı olmak üzere enfeksiyon bölgesini vurgulamak için segmentasyon işlemi yapılabilir. Geliştirilen web uygulaması aynı anda birçok hastalığın tespitini yapacak şekilde güncellenebilir.

Sonuç olarak bu çalışmada özelleştirilmiş derin öğrenme modelleri, özgün derin öğrenme modellerine göre oldukça iyi performans göstermiştir. Geliştirilen web uygulaması doktorların iş yükünü azaltacaktır.

9. KAYNAKLAR

- Agrawal, S., & Agrawal, P. (2023, May). Detection of Pneumonia Cases from X-ray Chest Images using Deep Learning Based on Transfer Learning CNN and Hyperparameter Optimization. In 2023 Third International Conference on Secure Cyber Computing and Communication (ICSCCC) (pp. 37-42). IEEE.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET) (pp. 1-6). Ieee.
- Athisayamani, S., Antonyswamy, R. S., Sarveshwaran, V., Almeshari, M., Alzamil, Y., & Ravi, V. (2023). Feature Extraction Using a Residual Deep Convolutional Neural Network (ResNet-152) and Optimized Feature Dimension Reduction for MRI Brain Tumor Classification. *Diagnostics*, 13(4), 668.
- Ayık, G. (2019). Akut Periferik Sinir Yaralanmalarının Rejenerasyonunda Epidermal Büyüme Faktörü (EGF)'nün Etkilerinin Tavşan Modeli Üzerinde Histolojik İncelenmesi.
- Aytekin, A., & Mençik, V. (2022). Detection of Driver Dynamics with VGG16 Model. *Applied Computer Systems*, 27(1).
- Bae, H. S., Lee, H. J., & Lee, S. G. (2016, June). Voice recognition based on adaptive MFCC and deep learning. In 2016 IEEE 11th Conference on Industrial Electronics and Applications (ICIEA) (pp. 1542-1546). IEEE.
- BIÇAKÇI, M.(2021). Non-Small Cell Lung Cancer Tumor Characterisation Using Deep Learning .(Doktora Tezi). Kayseri: Abdullah Gül Üniversitesi Fen Bilimleri Estitüsü
- Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer.
- Budak, C., & Mençik, V. (2022). Detection of ring cell cancer in histopathological images with region of interest determined by SLIC superpixels method. *Neural Computing and Applications*, 34(16), 13499-13512.
- Budak, C., Mençik, V., & ASKER, M. E. (2021). Effect on model performance of regularization methods. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(5), 757-765.
- Budak, C., Mençik, V., & Varışlı, O. (2023). Online diagnosis of COVID-19 from chest radiography images by using deep learning algorithms. *Neural Computing and Applications*, 1-18.
- Budak, C., Mençik, V., & Varışlı, O. (2023). Online diagnosis of COVID-19 from chest radiography images by using deep learning algorithms. *Neural Computing and Applications*, 1-18.

- Dewan, J. H., Thepade, S. D., Deshmukh, P., Deshmukh, S., Katpale, P., & Gandole, K. (2023, May). Comparative analysis of deep learning models for brain tumor detection using transfer learning. In 2023 4th International Conference for Emerging Technology (INCET) (pp. 1-7). IEEE.
- Doan, C. D., & Liong, S. Y. (2004, July). Generalization for multilayer neural network bayesian regularization or early stopping. In Proceedings of Asia Pacific association of hydrology and water resources 2nd conference (pp. 5-8).
- Druzhkov, P. N., Erukhimov, V. L., Zolotykh, N. Y., Kozinov, E. A., Kustikova, V. D., Meerov, I. B., & Polovinkin, A. N. (2011). New object detection features in the OpenCV library. *Pattern Recognition and Image Analysis*, 21, 384-386.
- Dupont, B., Stevens, Y., Westermann, H., & Joyce, M. (2018). Artificial Intelligence in the Context of Crime and Criminal justice. Available at SSRN 3857367.
- Fayyad, U. M., Piatetsky-Shapiro, G., & Smyth, P. (1996, August). Knowledge Discovery and Data Mining: Towards a Unifying Framework. In KDD (Vol. 96, pp. 82-88).
- Fourcade, A., & Khonsari, R. H. (2019). Deep learning in medical image analysis: A third eye for doctors. *Journal of stomatology, oral and maxillofacial surgery*, 120(4), 279-288.
- Gangadharappa, M., & Kharola, A. (2022, December). Power Signal Disturbances Analysis based on Transfer Learning in Deep Architecture. In 2022 IEEE International Conference on Current Development in Engineering and Technology (CCET) (pp. 1-5). IEEE.
- Gers, F. A., & Schmidhuber, J. (2000, July). Recurrent nets that time and count. In *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium* (Vol. 3, pp. 189-194). IEEE.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10), 2451-2471.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
- Gsaxner, C., Roth, P. M., Wallner, J., & Egger, J. (2019). Exploit fully automatic low-level segmented PET data for training high-level deep learning algorithms for the corresponding CT data. *PloS one*, 14(3), e0212550.
- Gupta, M., Kumar, R., Chawla, S., Mishra, S., & Dhiman, S. (2021). Clustering based contact tracing analysis and prediction of SARS-CoV-2 infections. *EAI Endorsed Transactions on Scalable Information Systems*, 9(35).

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Hussain, M., Bird, J. J., & Faria, D. R. (2019). A study on cnn transfer learning for image classification. In Advances in Computational Intelligence Systems: Contributions Presented at the 18th UK Workshop on Computational Intelligence, September 5-7, 2018, Nottingham, UK (pp. 191-202). Springer International Publishing.
- Islam, M., & Pathari, F. J. (2023, May). Detection of Pneumonia from Chest X-Ray Images Using Convolutional Neural Network (CNN). In 2023 3rd International Conference on Applied Artificial Intelligence (ICAPAI) (pp. 1-8). IEEE.
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jain, R., Nagrath, P., Kataria, G., Kaushik, V. S., & Hemanth, D. J. (2020). Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, 165, 108046.
- Jaiswal, A. K., Tiwari, P., Kumar, S., Gupta, D., Khanna, A., & Rodrigues, J. J. (2019). Identifying pneumonia in chest X-rays: A deep learning approach. *Measurement*, 145, 511-518.
- Jan, A. U., Khan, M. A., & Mukhtar, N. (2020). Opinion mining and summarization: A comprehensive review. *Journal of Information Communication Technologies and Robotic Applications*, 76-96.
- Jangam, E., Barreto, A. A. D., & Annavarapu, C. S. R. (2022). Automatic detection of COVID-19 from chest CT scan and chest X-Rays images using deep learning, transfer learning and stacking. *Applied Intelligence*, 1-17.
- Kaggle, 2018. Chest X-Ray Images (Pneumonia). <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>; (14.02.2023).
- Kamal, K., & Hamid, E. Z. (2023). A comparison between the VGG16, VGG19 and ResNet50 architecture frameworks for classification of normal and CLAHE processed medical images.
- Kavitha, S., Varuna, S., & Ramya, R. (2016, November). A comparative analysis on linear regression and support vector regression. In 2016 online international conference on green engineering and technologies (IC-GET) (pp. 1-5). IEEE.
- Khan, S., & Yong, S. P. (2017, December). A deep learning architecture for classifying medical images of anatomy object. In 2017 Asia-Pacific Signal and Information

- Processing Association Annual Summit and Conference (APSIPA ASC) (pp. 1661-1668). IEEE.
- Kim, D. H., & MacKinnon, T. (2018). Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks. *Clinical radiology*, 73(5), 439-445.
- King Jr, B. F. (2017). Guest Editorial: Discovery and Artificial Intelligence. *AJR. American Journal of Roentgenology*, 209(6), 1189-1190.
- Konaté, A. (2019). Artificial neural network: A tool for approximating complex functions.
- Kumar, R., Gupta, M., Agarwal, A., Mukherjee, A., & Islam, S. M. (2023). Epidemic efficacy of Covid-19 vaccination against Omicron: An innovative approach using enhanced residual recurrent neural network. *Plos one*, 18(3), e0280026.
- Kvak, D. (2022). Leveraging Computer Vision Application in Visual Arts: A Case Study on the Use of Residual Neural Network to Classify and Analyze Baroque Paintings. *arXiv preprint arXiv:2210.15300*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Li, J., Biondini, G., Kath, W. L., & Kogelnik, H. (2010). Outage statistics in a waveplate hinge model of polarization-mode dispersion. *Journal of Lightwave Technology*, 28(13), 1958-1968.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*.
- M. Sakthivel, P. Sreekarni, P. Rishika, P. Jyoshna and P. Navya, "Pneumonia Detection Using X-Ray Images," 2023 3rd International Conference on Intelligent Technologies (CONIT), Hubli, India, 2023, pp. 1-6, doi: 10.1109/CONIT59222.2023.10205623.
- Manaswi, N. K., & Manaswi, N. K. (2018). Understanding and working with Keras. *Deep learning with applications using Python: Chatbots and face, object, and speech recognition with TensorFlow and Keras*, 31-43.
- Mangal, A., Kalia, S., Rajgopal, H., Rangarajan, K., Namboodiri, V., Banerjee, S., & Arora, C. (2020). CovidAID: COVID-19 detection using chest X-ray. *arXiv preprint arXiv:2004.09803*.
- Mascarenhas, S., & Agarwal, M. (2021, November). A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification. In 2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON) (Vol. 1, pp. 96-99). IEEE.
- Mathew, J., & Srinivasan, N. (2022, June). Deep Convolutional Neural Network with Transfer Learning for Automatic Brain Tumor Detection from MRI. In 2022

- International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS) (pp. 1-6). IEEE.
- Medsker, L. R., & Jain, L. C. (2001). Recurrent neural networks. *Design and Applications*, 5(64-67), 2.
- Militante, S. V., Dionisio, N. V., & Sibbaluca, B. G. (2020, October). Pneumonia and COVID-19 detection using convolutional neural networks. In *2020 Third International Conference on Vocational Education and Electrical Engineering (ICVEE)* (pp. 1-6). IEEE.
- Murugesan, R., Mishra, E., & Krishnan, A. H. (2021). Deep learning based models: Basic LSTM, Bi LSTM, Stacked LSTM, CNN LSTM and Conv LSTM to forecast Agricultural commodities prices.
- Nagpal, A., & Gabrani, G. (2019, February). Python for data analytics, scientific and technical applications. In *2019 Amity international conference on artificial intelligence (AICAI)* (pp. 140-145). IEEE.
- Nandi, R., & Mulimani, M. (2021). Detection of COVID-19 from X-rays using hybrid deep learning models. *Research on Biomedical Engineering*, 37, 687-695.
- Naushad, R., Kaur, T., & Ghaderpour, E. (2021). Deep transfer learning for land use and land cover classification: A comparative study. *Sensors*, 21(23), 8083.
- Oliveira, R., Araújo, R. C., Barros, F. J., Segundo, A. P., Zampolo, R. F., Fonseca, W., ... & Brasil, F. S. (2017). A system based on artificial neural networks for automatic classification of hydro-generator stator windings partial discharges. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, 16, 628-645.
- Padmavathi, K., & Thangadurai, K. (2016). Implementation of RGB and grayscale images in plant leaves disease detection—comparative study. *Indian Journal of Science and Technology*, 9(6), 1-6.
- Phine, S. (2023, February). Pneumonia Classification Using Deep Learning VGG19 Model. In *2023 IEEE Conference on Computer Applications (ICCA)* (pp. 67-71). IEEE.
- Pustokhin, D. A., Pustokhina, I. V., Dinh, P. N., Phan, S. V., Nguyen, G. N., Joshi, G. P., & K, S. (2023). An effective deep residual network based class attention layer with bidirectional LSTM for diagnosis and classification of COVID-19. *Journal of Applied Statistics*, 50(3), 477-494.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
- Rasamoelina, A. D., Adjailia, F., & Sinčák, P. (2020, January). A review of activation function for artificial neural network. In *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)* (pp. 281-286). IEEE.

- Razzak, M. I., Naz, S., & Zaib, A. (2018). Deep learning for medical image processing: Overview, challenges and the future. *Classification in BioApps: Automation of Decision Making*, 323-350.
- Reenadevi, R., Sathiya, T., & Sathiyabhama, B. (2021). Breast cancer histopathological image classification using augmentation based on optimized deep ResNet-152 structure. *Annals of the Romanian Society for Cell Biology*, 25(6), 5866-5874.
- Reid PT, Innes JA (2010) Respiratory Disease. In: Colledge NR, Walker BR and Ralston SH, ed, Davidson's principle and practice of Medicine, 21st ed. Edinburgh: Elsevier publications. 680-682.
- Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 1-18.
- Rubin, J., Sanghavi, D., Zhao, C., Lee, K., Qadir, A., & Xu-Wilson, M. (2018). Large scale automated reading of frontal and lateral chest x-rays using dual convolutional neural networks. *arXiv preprint arXiv:1804.07839*.
- Rudan, I., Boschi-Pinto, C., Biloglav, Z., Mulholland, K., & Campbell, H. (2008). Epidemiology and etiology of childhood pneumonia. *Bulletin of the world health organization*, 86, 408-416B.
- Saikrishna, D., Rao, M. M., Dhanush, B. S., Harshavardhan, S., Prudhvi, B., Rana, P., & Mittal, U. (2021, April). Pneumonia Detection Using Deep Learning Algorithms. In *2021 2nd International Conference on Intelligent Engineering and Management (ICIEM)* (pp. 282-287). IEEE.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- Self, W. H., Courtney, D. M., McNaughton, C. D., Wunderink, R. G., & Kline, J. A. (2013). High discordance of chest x-ray and computed tomography for detection of pulmonary opacities in ED patients: implications for diagnosing pneumonia. *The American journal of emergency medicine*, 31(2), 401-405.
- Shadin, N. S., Sanjana, S., & Ibrahim, D. (2022, February). Face mask detection using deep learning and transfer learning models. In *2022 International Conference on Innovations in Science, Engineering and Technology (ICISSET)* (pp. 196-201). IEEE.
- Shah, P. M., Ullah, F., Shah, D., Gani, A., Maple, C., Wang, Y., ... & Islam, S. U. (2021). Deep GRU-CNN model for COVID-19 detection from chest X-rays data. *Ieee Access*, 10, 35094-35105.
- Sharma, A., Sharma, K., & Kumar, A. (2022). Real-time emotional health detection using fine-tuned transfer networks with multimodal fusion. *Neural Computing and Applications*, 1-14.

- Sharma, S., & Guleria, K. (2022, October). Pneumonia Detection from Chest X-ray Images using Transfer Learning. In 2022 10th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO) (pp. 1-6). IEEE.
- Sharma, S., & Singh, S. (2023). ISL recognition system using integrated mobile-net and transfer learning method. *Expert Systems with Applications*, 221, 119772.
- Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- Soumya, D. R., Reddy, D. K., Nagar, A., & Rajpoot, A. K. (2023, May). Enhancing Brain Tumor Diagnosis: Utilizing ResNet-101 on MRI Images for Detection. In 2023 2nd International Conference on Vision Towards Emerging Trends in Communication and Networking Technologies (ViTECoN) (pp. 1-5). IEEE.
- Sudha, V., & Ganeshbabu, T. R. (2021). A Convolutional Neural Network Classifier VGG-19 Architecture for Lesion Detection and Grading in Diabetic Retinopathy Based on Deep Learning. *Computers, Materials & Continua*, 66(1).
- Tammina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143-150.
- Tapas, A. (2016). Transfer learning for image classification and plant phenotyping. *International Journal of Advanced Research in Computer Engineering and Technology (IJARCET)*, 5(11), 2664-2669.
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53, 5929-5955.
- Wahyudi Setiawan, M., Utoyo, I., & Rulaningtyas, R. (2019). Classification of neovascularization using convolutional neural network model.
- Wang, L., Wang, H., Huang, Y., Yan, B., Chang, Z., Liu, Z., ... & Li, F. (2022). Trends in the application of deep learning networks in medical image analysis: Evolution between 2012 and 2020. *European journal of radiology*, 146, 110069.
- Wei, X., Zhang, X., Wang, S., Cheng, C., Huang, Y., Yang, K., & Li, Y. (2021). Da-drn: Degradation-aware deep retinex network for low-light image enhancement. *arXiv preprint arXiv:2110.01809*.
- WHO, 2020. Pneumonia. https://www.who.int/health-topics/pneumonia#tab=tab_1; (11.08.2023)
- WHO, 2022. Pneumonia in children. <https://www.who.int/news-room/fact-sheets/detail/pneumonia>; (11.08.2023).
- Zaremba, W., Sutskever, I., & Vinyals, O. (2014). Recurrent neural network regularization. *arXiv preprint arXiv:1409.2329*.

Zhao, Z., Yang, C., Wang, Q., Zhang, H., Shi, L., & Zhang, Z. (2021). A deep learning-based method for detecting and classifying the ultrasound images of suspicious thyroid nodules. *Medical Physics*, 48(12), 7959-7970.



ÖZGEÇMİŞ

