

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**TOMOGRAFİ GÖRÜNTÜLERİNDEN AKCİĞER HASTALIKLARININ
TESPİTİ AMAÇLI BİR DERİN ÖĞRENME MODELİNİN GELİŞTİRİLMESİ**

GÖKHAN KARABAĞ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TEMMUZ 2023

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**TOMOGRAFİ GÖRÜNTÜLERİNDEN AKCİĞER HASTALIKLARININ
TESPİTİ AMAÇLI BİR DERİN ÖĞRENME MODELİNİN GELİŞTİRİLMESİ**

GÖKHAN KARABAĞ

FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 26/07/2023 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Prof.Dr. Şükrü ÖZEN (Danışman)

Doç.Dr. Övünç POLAT

Dr.Öğr.Üyesi Gürkan BİLGİN

ÖZET

TOMOGRAFİ GÖRÜNTÜLERİNDEN AKCİĞER HASTALIKLARININ TESPİTİ AMAÇLI BİR DERİN ÖĞRENME MODELİNİN GELİŞTİRİLMESİ

GÖKHAN KARABAĞ

Yüksek Lisans Tezi, Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof Dr. Şükrü ÖZEN

Temmuz 2023 ; 44 sayfa

Sağlık Bilgi Sistemleri ülkemizde son yıllarda önemli gelişmeler göstermiştir. Bu göstergeler tıp bilişiminde Hastane Bilgi Yönetim Sistemleri (HBYS), Görüntü Arşivleme ve İletim Sistemi (PACS) ile ivme kazanmıştır. Bir hastanın hastane girişinde taburcu olana kadar tüm süreçleri dijital olarak takip edilmekte olup verilerin önemi yapay zeka çalışmalarında dikkat çekmektedir. Tıbbi görüntüleme yöntemleri üzerinden yapılan radyolojik çıkarımlar teşhis koymada önemli bir basamaktır. Tıbbi görüntüleri iletmek ve arşivleme için ulusal ve uluslararası alanda Görüntü Arşivleme ve İletim Sistemi (PACS) sistemi kullanılmaktadır.

Yapılan çalışmada Türkiye’de bulunan bir hastanede Görüntü Arşivleme ve İletim Sisteminde (PACS) yer alan akciğer tomografi görüntü verileri kullanılmıştır. Akciğer üzerinde birden fazla görülen hastalıkların erken teşhisi COVID-19 pandemisi ile büyük öneme sahiptir. Çalışmada akciğer hastalıklarından pnömoni teşhisi için derin öğrenme yöntemleri ile sınıflandırma çalışması yapılmıştır. Yapılan çalışmada pnömoni teşhisinde hasta akciğerler üzerinde görülen bal peteği hücresi ve buzlu cam alanları temel alınmıştır.

Görüntü sınıflandırma işleminde evrişimsel sinir ağları kullanılarak özgün bir derin öğrenme modeli kurulmuştur. Evrişimli sinir ağları mimarileri ile aynı veriler üzerinden modeller kurularak oluşturulan derin öğrenme modeli ile karşılaştırılmıştır. Literatürde akciğer x-ray görüntüleri ile akciğer tomografi görüntüleri üzerine yapılan çalışmalar incelenmiştir. Pnömoni ve sağlıklı akciğer tomografi görüntüleri eğitim, test ve validasyon olmak üzere üç sınıfa bölünmüştür. Eğitilen model eğitim verileri üzerinde %98.16, validasyon verileri üzerinde %97.57 ve modelin hiç görmediği test verileri üzerinde %95.19 başarı oranı yakalamıştır.

ANAHTAR KELİMELER: Akciğer Tomografi Görüntüsü, Derin Öğrenme, Evrişimli Sinir Ağları, HBYS, PACS, Pnömoni, Sınıflandırma

JÜRİ: Prof.Dr. Şükrü ÖZEN

Doç.Dr. Övünç POLAT

Dr.Öğr.Üyesi Gürkan BİLGİN

ABSTRACT

DEVELOPMENT OF A DEEP LEARNING MODEL FOR DETECTION OF LUNG DISEASES FROM TOMOGRAPHY IMAGES

MSc Thesis in Department of Electric and Electronic Engineering

Supervisor: Prof.Dr. Şükrü ÖZEN

July 2023; 44 pages

In recent years, Health Information Systems have shown significant developments in our country. These indicators have gained momentum in medical informatics with Hospital Information Management Systems (HIS) and Picture Archiving and Communication System (PACS). From a patient's admission to the hospital until their discharge, all processes are digitally tracked, emphasizing the importance of data in artificial intelligence studies. Radiological deductions made through medical imaging methods play an essential role in diagnosis. The Picture Archiving and Communication System (PACS) is used nationally and internationally for transmitting and archiving medical images.

In this study conducted at a hospital in Turkey, lung tomography image data from the Picture Archiving and Communication System (PACS) were used. Early diagnosis of multiple diseases observed on lungs has become critical during the COVID-19 pandemic. In this study, segmentation and classification work using deep learning methods were carried out for diagnosing pneumonia among lung diseases. In the study, honeycomb cells seen on diseased lungs' surfaces and ground-glass areas formed the basis for diagnosing pneumonia.

In this study, an original deep learning model was developed using Convolutional Neural Networks for image classification tasks. The deep learning model created was compared with models built using architectures of convolutional neural networks on the same dataset. A review of existing literature on studies conducted with lung x-ray images and lung tomography images was conducted. Pneumonia and healthy lung tomography images were divided into three classes: training, testing, and validation. The trained model achieved an accuracy of 98.16% on the training data, 97.57% on the validation data, and 95.19% on previously unseen test data.

KEYWORDS: Classification, Convolutional Neural Networks, Deep Learning, HIS, Lung Tomography Image, PACS, Pneumonia

COMMITTEE: Prof.Dr. Şükrü ÖZEN

Assoc.Prof.Dr. Övünç POLAT

Assist.Prof.Dr. Gürkan BİLGİN

ÖNSÖZ

Sağlık bilgi sistemleri ve tıp bilişimi konularında heyecan verici gelişmeleri görmek ve ülkemizde bu teknolojileri uygulamaya çalışmak motivasyonumu artırıcı etkenlerden olmuştur. Özellikle dijital sağlık verilerinin öneminin arttığı bir dönemde sağlıkta yapay zeka konuları bu çalışmayı yapmamda temel etmen olmuştur.

Bir hastanede, hastaların girişinden taburcu olana kadar tüm süreçlere takip ederek günümüzde temel teknolojik ihtiyaçları sağlıkta dijital dönüşüm çerçevesinde mesleğim ve görevim gereği her gün deneyimlemekteyim. Tıbbi görüntüleme yöntemleri ve akciğer hastalıkları üzerine yaptığım bu çalışmanın ülkemizde sağlık alanında özellikle radyologlara ve hekimlere geliştirilerek yardımcı olacağı kanaatindeyim.

Akademik hayatım süresince tüm desteğini veren ve alanımda beni en doğru şekilde yönlendiren danışman hocam Prof.Dr.Şükrü ÖZEN'e teşekkür ederim. Tezimin fikir aşamasından gelişimine ve sonuçlandırılmasına kadar desteğini esirgemeyen Arş.Gör. Kayhan ATEŞ'e teşekkür ederim. Derin öğrenme ve yapay zeka alanında tecrübeleri ile bana yol gösteren hocalarım Assoc.Prof.Dr. Övünç POLAT ve Assist.Prof.Dr. Gürkan BİLGİN'e teşekkürlerimi sunarım.

Yoğun tempolu iş ve akademik hayatımda manevi tüm desteğini veren annem Ayşegül KARABAĞ'a, babam Aslan KARABAĞ'a ve kardeşim Uğurcan KARABAĞ'a teşekkürü borç bilirim. Çalışmalarım sürecinde fikir aldığım ve sağlık, tıp bilişimi, tıbbi görüntüleme yöntemleri konusunda bana destek veren Sağlık Bakanlığı yöneticileri ve hekimlerine teşekkürlerimi sunuyorum.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ.....	iii
AKADEMİK BEYAN	vi
KISALTMALAR	vii
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK TARAMASI	3
3. MATERYAL VE METOD	5
3.1. Görüntü Arşivleme ve İletim Sistemi.....	5
3.2. Tıbbi Görüntüleme Sistemleri	6
3.3. Kullanılan Veri Seti ve Yöntem	7
3.4. Kullanılan Platformlar ve Kütüphaneler	8
3.4.1. Python.....	8
3.4.2. Jupyter Notebook.....	8
3.4.3. Numpy	9
3.4.4. Pandas	9
3.4.5. Matplotlib	9
3.4.6. Keras	9
3.4.7. Tensorflow	9
3.4.8. Clear Canvas	9
3.4.9. Onis.....	10
3.5. Önerilen Model.....	10
3.5.1.Ön Veri İşleme.....	10
3.5.2. Önerilen Derin Öğrenme Modeli.....	14
3.5.2.1. Tıbbi Görüntülemeye Yapay Zeka.....	14
3.5.2.2.Derin Öğrenme Performans Ölçümünde Kullanılan Temel Metrikler.....	15
3.5.2.3. Yapay Sinir Ağları.....	16
3.5.2.4. Aktivasyon Fonksiyonları.....	18

3.5.2.5. Evriřimli Sinir Ađları.....	18
3.5.2.6. Evriřimli Sinir Ađı Mimarileri.....	23
4. BULGULAR VE TARTIřMA	27
4.1. Grnt Sınıflandırma.....	27
4.2. Kurulan Derin ğrenme Modelinin Değlendirilmesi	32
4.3. Evriřimli Sinir Ađı Mimarilerinin ve Kurulan Modelin Karřılařtırılması	34
5. SONUÇLAR	39
6. KAYNAKLAR	41
7. EKLER.....	44

ZGEÇMİř

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Tomografi Görüntülerinden Akciğer Hastalıklarının Tespiti Amaçlı Bir Derin Öğrenme Modelinin Geliştirilmesi” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

26/07/2023

Gökhan KARABAĞ

KISALTMALAR

Kısaltmalar

HBYS : Hastane Bilgi Yönetim Sistemi

PACS : Görüntü Arşivleme ve İletim Sistemi

YSA : Yapay Sinir Ağları

ESA : Evrişimli Sinir Ağları

IPF : Idiopatik Pulmoner Fibrozis

UIP : Olağan interstisyel pnömoni

DICOM: Digital Imaging and Communications in Medicine

BT : Bilgisayarlı Tomografi

PET : Pozitron Emisyon Tomografi

MRI : Manyetik Rezonans Görüntüleme

fMRI : Fonksiyonel Manyetik Rezonans Görüntüleme

HU : Hounsfield Unit

ŞEKİLLER DİZİNİ

Şekil 3.1. Akciğer Tomografi Görüntülerinin Dijital Ortamda Görüntülenmesi.....	5
Şekil 3.2. DICOM Formatında Akciğer BT Görüntüsü.....	8
Şekil 3.3. Radyolojik Görüntüler İçin Hounsfield Unit (HU) Skalası.....	12
Şekil 3.4. Tomografi Çekim Pencereleri.....	13
Şekil 3.5. Akciğer BT Görüntüsü ve HU Dağılımı.....	13
Şekil 3.6. Yapay Sinir Ağı Mimarisi.....	17
Şekil 3.7. Evrişimli Sinir Ağı Mimarisi.....	20
Şekil 3.8. Evrişim İşlemi Filtre ve Aktivasyon Haritası.....	21
Şekil 3.9. 5x5'lik Giriş Görüntüsüne 2x2 Filtre ile Bir ve İki Adım Kaymalı Maksimum Havuzlama İşleminin Uygulanması.....	22
Şekil 4.1. Derin Öğrenme Modeli Parametreleri ve Katmanları.....	29
Şekil 4.2. Derin Öğrenme Modeli Parametre Sayıları.....	30
Şekil 4.3. Derin Öğrenme Modeli Topolojisi.....	31
Şekil 4.4. Modelin Doğruluk-Epoch Sayısı Grafiği.....	33
Şekil 4.5. Modelin Kayıp-Epoch Sayısı Grafiği.....	34
Şekil 4.6. Test Verileri Üzerinde Başarı ve Kayıp Oranı.....	34
Şekil 4.7. AlexNet Mimarisi ile Doğruluk- Epoch Sayısı Grafiği.....	35
Şekil 4.8. AlexNet Mimarisi ile Kayıp- Epoch Sayısı Grafiği.....	35
Şekil 4.9. GoogleNet Mimarisi ile Doğruluk- Epoch Sayısı Grafiği.....	36
Şekil 4.10. GoogleNet Mimarisi ile Kayıp- Epoch Sayısı Grafiği.....	36
Şekil 4.11. Resnet Mimarisi ile Doğruluk- Epoch Sayısı Grafiği	37
Şekil 4.12. Resnet Mimarisi ile Kayıp- Epoch Sayısı Grafiği	37

ÇİZELGELER DİZİNİ

Çizelge 3.1. Evrişimli Sinir Ağı Mimarileri	25
Çizelge 4.1. Derin Öğrenme Modellerinin Karşılaştırılması	38



1. GİRİŞ

Sağlık alanında tıp bilişimindeki gelişmeler ülkemizde önemli noktalara gelmiştir. COVID-19 salgını ile tıbbi görüntüleme sistemleri ve hastane bilgi yönetim sistemlerinin önemi açığa çıkmıştır. Bir sağlık kuruluşunun işleyişinde temel olarak Hastane Bilgi Yönetim Sistemi (HBYS) ve Görüntü Arşivleme ve İletim Sistemi (PACS) olmak üzere iki adet sistem üzerinde kurgulanmaktadır. Bu sistemlerden elde edilen veriler ve çıktılar ile hastaya gerekli teşhisler koyulmaktadır. COVID-19 pandemisi ile birlikte akciğer üzerinde oluşan hastalıklar büyük öneme sahip olmuştur. Tüm bu sistemler ile tıbbi görüntüleme konusunda akciğer üzerindeki hastalıkların tespitinde önemli çalışmalar yapılmaktadır. Akciğer zatüresi Pnömoni, yaygın akut solunum yolu akciğer hastalıklarından biridir (Kumar ve Satapathy,2020). 5 yaşın altındaki çocuklar bu hastalığa kolayca bulaşır. DSÖ, bu akciğer hastalığının erken evresinde tespit edilememesi nedeniyle yaklaşık 1,4 milyon çocuğun hayatını kaybettiğini tahmin etmektedir (Lakhani ve Sundaram,2017). Bakteriyel ve viral pnömoni insanların solunum sisteminde önemli sorunlara neden olan tipleridir. Bir pnömoni tanısı hastanın radyolojik görüntüleri ve raporları üzerine göğüs hastalıkları uzmanları ve radyologların incelemesi üzerine konmaktadır. Pnömoni tanısına götüren yolda konulan ön tanımlar ve radyolojik bulgular tanının belirleyicisi olmaktadır. Pnömoni tanısı için radyolojik görüntüler üzerinden tespit edilen infiltrasyon, çizgisel atelaktazi, parankimal band, idiyopatik pulmoner Fibrozis (IPF), nodül, amfizem, konsolidasyon, plevrel üfúzyon gibi radyolojik bulgular ve ön tanımlar bulunmaktadır.

Bu çalışmada bir hastanede bulunan modalitelerden (tomografi cihazları) çekilen akciğer tomografi görüntülerini iletmek ve arşivlemek için bir Görüntü Arşivleme ve İletim Sistemi (PACS) kurulmuştur. Bu sistem için açık kaynak bir yazılım olan Clear Canvas kullanılmıştır. Tıbbi görüntüler için uluslararası bir görüntü formatı olan DICOM formatında görüntüler bu sistem üzerinde Microsoft SQL veri tabanında tutulmaktadır. Bir hastanın DICOM formatlı akciğer tomografi görüntüsü içerisinde tomografi görüntüsüne ait cihaz tipi, görüntü özellikleri, hasta, doktor vb. detaylı bilgiler bulunmaktadır. Çalışmadaki ana amaç DICOM görüntü formatındaki veriyi metin ve görüntü verisi şeklinde ayırıp ardından görüntü verileri üzerinden sınıflandırma çalışması yapmaktır. Pnömoni akciğer tomografi görüntüleri ve sağlıklı akciğer tomografi görüntüleri barındıran görüntü verileri Python yazılım dili ile görüntülenerek akciğerin hastalıklı veya tahrip edilmiş kısımları gözlemlenmiştir. Ardından ham akciğer tomografi görüntü verileri eğitim, doğrulama ve test verilerine bölünmüştür. Bir derin öğrenme modeli olan Evrişimli Sinir Ağları metotları ile model kurulup sınıflandırma çalışmaları yapılmıştır.

Yapılan çalışmada akciğer tomografi görüntüleri üzerinden bal peteği ve buzlu cam şeklinde belirtiler incelenmiştir. Bal peteği bulgusu, akciğerde oluşan ve akciğerin çalışma kapasitesini ciddi anlamda kısıtlayabilen bir hastalıktır. Bal peteği görüntüleri bulgulardan İdiyopatik Pulmoner Fbrosis (IPF) şeklinde tanımlanmaktadır. PACS sisteminde tutulan bu görüntüler üzerinden pnömoni tespiti için radyolojik bulguların akciğer üzerindeki etkileri olan bal peteği ve buzlu cam alanları içeren görüntüler tercih edilmiştir.

Toplamda 4030 adet sağlıklı ve 4040 adet pnömoni akciğer tomografi görüntüsü olmak üzere toplamda 8070 adet akciğer tomografi görüntüsü kullanılmıştır. Bu

verilerden 6449 adeti eğitim verisi olarak, bu eğitim verilerinin içinden 1934 adeti doğrulama veri kümesi için ve modelin eğitiminin dışında tutulup hiç görülmeyen 1622 adeti test veri kümesi kullanılmıştır

Tıbbi görüntüleme, modern tıp pratiğinde hastalıkların erken teşhisi ve etkili tedavi süreçlerinin belirlenmesi için hayati öneme sahiptir. Son yıllarda, bilgisayar destekli teşhis sistemlerinin gelişimi, tıbbi görüntü analizinin otomatikleştirilmesi ve tanısal doğruluğun artırılması açısından büyük adımlar atılmıştır. Bu bağlamda, akciğer hastalıklarının teşhisinde temel bir rol oynayan akciğer tomografisi (BT) görüntüleri, tıbbi uzmanların doğru ve güvenilir teşhisler yapmasına yardımcı olmaktadır. Bununla birlikte, BT görüntülerinin manuel olarak analiz edilmesi, zaman alıcı ve uzmanlık gerektiren bir süreçtir ve tıbbi hatalara ve tedavi gecikmelerine neden olabilmektedir.

Son yıllarda, yapay zeka ve makine öğrenimi tekniklerinin tıbbi görüntü analizine entegrasyonu, tıbbi teşhis ve sınıflandırma alanında önemli ilerlemelere yol açmıştır. Özellikle, evrişimli sinir ağları (Convolutional Neural Networks - CNN), tıbbi görüntü sınıflandırma görevlerinde büyük bir başarı elde etmiştir. Akciğer tomografi görüntülerinin sağlıklı ve hasta olarak sınıflandırılması, evrişimli sinir ağlarının derin öğrenme yetenekleri kullanılarak etkin bir şekilde gerçekleştirilebilecek önemli bir uygulama alanı sunmaktadır.

Evrişimli sinir ağları, özellikle görüntü işlemede etkili bir derin öğrenme modelidir. Görüntü sınıflandırma ve özellik çıkarımı gibi görevlerde yüksek performans sergileyen bu sinir ağları, yüksek düzeyde öğrenme kapasitesine sahiptir. Akciğer tomografi görüntülerinin sınıflandırılmasında kullanılan CNN'ler, tıbbi görüntüleme alanındaki çeşitli hastalıkların teşhisinde ve izlenmesinde değerli bir araç olarak kabul edilmektedir.

Akciğer tomografi görüntülerinin sınıflandırılmasında evrişimli sinir ağları, genellikle büyük ölçekli veri kümeleri üzerinde önceden eğitilerek veya transfer öğrenme teknikleri ile öğrenilmektedir. Bu sinir ağları, görüntülerdeki karmaşık özellikleri tanımak ve bu özellikleri kullanarak görüntüleri farklı sınıflara (sağlıklı ve hasta) doğru bir şekilde sınıflandırmak için uyarlanabilir. Derin öğrenme tabanlı bu yaklaşımlar, sınıflandırma sürecini otomatikleştirmek ve doktorların teşhis sürecini desteklemek için önemli bir potansiyele sahiptir.

Yapılan çalışma ile akciğer hastalıkları üzerinde radyologlara ve hekimlere yardımcı olacak bir sınıflandırma çalışması yapılmıştır. Sağlık bilgi sistemleri ve tıbbi görüntüleme sistemleri kullanılarak ham veriler üzerinden büyük bir başarı elde edilmiştir. Tıbbi görüntünün ilk çekildiği anda itibaren iletimi ve depolanmasını sağlayan sistemler incelenmiş ve kullanılmıştır. Ardından modalite cihazlar üzerinden sunucuya çekilen görüntüler ile çalışmalar yapıp tamamlanmıştır. Ülkemizde sağlık bilişimi konularında tüm aşamaları içeren bir çalışma elde edilmiş olup geliştirilebilir bir çalışma oluşturulmuştur.

2. KAYNAK TARAMASI

Biyoinformatik, tıbbi ve biyolojik sorunlara çözüm bulmak için uzun yıllardır kullanılmaktadır. Günümüzde verinin birikmesi ve donanımların gelişmesi ile birlikte veriyi daha kolay ve verimli bir şekilde işlememizi sağlamaktadır. Yapay sinir ağları, derin öğrenme ve makine öğrenmesi teknikleriyle yeni bir çağ başlamıştır. İnsanlık bu yönde çok hızlı büyümeye başlamıştır ve gelişmeler memnun edici olmuştur. Bu tekniklerle akciğer hücrelerindeki anormallikleri bulmaya çalışıyoruz. Derin öğrenme ve makine öğrenmesi teknikleriyle akciğer hücrelerindeki anormallikler tespit edilmektedir.

Evrişimli sinir ağlarındaki çok katmanlı yapı yaklaşımı yapılan çalışmada da benzer şekilde benimsenmiştir. Daha soyut ve kullanışlı örnekler toplamak amacıyla girdi verilerinin çoklu doğrusal ve doğrusal olmayan dönüşümler, örüntü tanıma tekniklerinde olağanüstü bir performans gösterdikleri için son zamanlarda daha popüler hale gelmiştir (X.Yang.,vd,2016).

Bilgisayar tabanlı bilgisayarlı tomografi (BT) görüntülerinin değerlendirilmesi, hangi hastaların güçlü hastalık semptomları gösterdiğini ifade edebilmektedir. Akciğer tomografi görüntüleri üzerinden semptomlar doğrultusunda hastalık teşhisi tahminleri yapılabilmektedir. Bu açıdan, akciğer pnömonisi için bal peteği ve amfizem hücreleri, bağ dokusu hastalıklarını tanımlamak ana odak noktası olmaktadır (Jacob vd 2016)..

Yüksek çözünürlüklü bilgisayar tomografi, akciğer dokusunda hastalığın özelliklerini belirleme ve teşhis etmede temeldir ve hastalığın ilerlemesini değerlendirebilmektedir. Sonuçların doğruluğu; görüntü kalitesine, görüntüleri yakalamak için kullanılan cihaza veya klinisyene bağlı olabilmektedir. Tomografi görüntüleri, kantitatif analizi hasta ve doktor için hastanın tedavi sürecinde daha faydalı olabilmektedir (Bartholmai BJ vd.2013)

Akciğer dokularının pnömoni tespiti ve sınıflandırılmasında, bal peteği hücreleri ve buzlu cam alanlarının tespiti için, akciğer tomografi görüntüleri bölümlere ayrılmalıdır. Bu amacı gerçekleştirmek için "Hounsfield Değerleri" kullanılmaktadır. Hounsfield değerleri, radyo yoğunluğunu tanımlayan bir ölçek olarak işlev görür ve her doku için benzersiz bir piksel aralığına sahiptir. Ardından, akciğerlerdeki damarları temizlemek ve net bir akciğer görüntüsü elde etmek için bağlı bileşenler uygulanmalıdır. Tutarlı görüntüler elde etmek için, tüm eğitim ve test görüntülerine bu ölçeğin uygulanması gerekmektedir.

W. Shen ve diğerleri, akciğerin nodüllerinin sınıflandırılması için çok katmanlı evrişimli sinir ağlarını önermişlerdir. LIDC (Data from The Lung Image Database Consortium) ve IDRI(Image Database Resource Initiative) veri setlerinin CT tarama görüntüleri kullanılmıştır. Evrişimli sinir ağları ile sınıflandırma algoritmaları olarak SVM ve Random Forest kullanılmıştır. Önerilen evrişimli sinir ağları algoritması ile Random Forest sınıflandırıcı, herhangi bir segmentasyon yöntemi kullanmadan akciğer nodüllerinin sınıflandırılmasında %86.84 doğruluk oranı elde edilmiştir (Shen vd., 2015)

N. Bondfale ve S. Banait, akciğer tomografi tarama görüntülerinin ILD (Interstitial lung disease) veri setinin sınıflandırılması için evrişimli sinir ağlarını kullanmışlardır. Sağlıklı, buzlu cam opaklığı, mikro nodüller, retikülasyon, bal peteği oluşumu, konsolidasyon ve retikülasyonlu buzlu cam opaklığının sınıflandırılması için evrişimli sinir ağları sonuçlarının İAH (İnterstisyel akciğer hastalıkları) sınıfının uygun olduğunu bildirmişlerdir (Bondfale ve Banait 2017).

Literatürde akciğer röntgen görüntüleri üzerinden yapılan çalışmalarda başarılar incelendiğinde Okeke Stephen pnömonili ve sağlıklı verileri evrişimli sinir ağları modeli ile sınıflandırmaya çalışmıştır. Çalışmasında 5856 adet akciğer röntgen görüntüsü bulunmaktadır. Veri dağılımı dengesiz olduğundan dolayı sentetik veri artırma işlemi ile mevcut verilerini dengeli dağıtmaya çalışmıştır. Yaptığı sentetik işlemlerde genellikle yön revizyonu, parlaklık düzenleme gibi yöntemleri kullanmıştır. Veri kümesini eğitim, test ve validasyon olacak şekilde düzenleme yapmıştır. Kurguladığı evrişimli sinir ağı modelinde 4 evrişim katmanı, 2 tamamen bağlı katman kullanmıştır. Her katman arasında aktivasyon fonksiyonu olarak ReLu, son bağlı katman çıkışında sigmoid aktivasyon fonksiyonunu kullanmıştır. Kurguladığı modelde aşırı öğrenmeyi (overfitting) engellemek için veri seyreltme (drop out) işlemini 0.5 oranında uygulamıştır. Kuralan modelde 100 epoch tercih edilmiştir. Eğitilen model çıktılarında başarı (accuracy) değeri 0.85 ile 0.95 arasında değişmiş olup elde edilen minimum kayıp (loss) değeri ise 0.18 olmuştur (Jeong vd. 2019)

Q. Wang ve arkadaşları, akciğer kanserini ayırt etmek için destek vektör makineleri ve yapay sinir ağlarına dayalı beş CAD yöntemi uygulamışlardır. Jilin Tümör Hastanesi'nin akciğer tomografi görüntüleri kullanılmıştır. Önerilen beş yöntem, üç boyutlu matrislere dayalı destek vektör makineleri, açılan üç boyutlu matrise sahip destek vektör makineleri, nodüllerin alanına göre destek vektör makineleri, nodüllerin ilgi bölgesine dayalı yapay sinir ağları ve destek vektör makineleri olarak sınıflandırma yöntemleri gözlemlenmiştir. Sonuç olarak kurgulanan modelde destek vektör makineleri üç boyutlu matris algoritmasının nodüllerin sınıflandırılmasında en yüksek performansı elde ettiği görülmektedir. Gerçek Pozitif (TP) değeri ve destek vektör makinesi üç boyutlu matrisinin Roc eğrisi altındaki alan sırasıyla %0,995 ve %98,2 olarak gözlemlenmektedir (Wang vd., 2013)

M. Anthimopoulos ve diğerleri, akciğer hastalıklarını sınıflandırmak için evrişimli sinir ağlarını tercih etmişlerdir. İnterstisyel Akciğer Hastalığı (İAH) veri setleri olarak Cenevre Üniversite Hastanesi ve Bern Üniversite Hastanesi akciğer tomografi görüntüleri tercih edilmiştir. Önerilen evrişimli sinir ağı modeli; beş evrişimli katman, bir havuzlama katmanı ve üç tamamen bağlı katman içermektedir. Önerilen algoritma, diğer evrişimli sinir ağları mimarileri ile karşılaştırılmıştır; LeNet, AlexNet ve VGG Net modelleri incelenmiştir. Sonuç olarak ;dokuların sınıflandırılması ve tespiti için önerilen evrişimli sinir ağı mimarisinin diğer algoritmalara kıyasla üstün olduğunu görülmüştür. Önerilen evrişimli sinir ağı modeli, %85.61 doğruluk oranına ulaşmıştır. (Anthimopoulos vd., 2016)

3. MATERYAL VE METOT

3.1. Görüntü Arşivleme ve İletim Sistemi

Görüntü arşivleme ve iletişim sistemleri (PACS), teşhis görüntülerini ve ek belgelerini bir hastane bilgi sisteminde depolamak ve bunları diğer sağlık uzmanlarına teslim etmek için kullanılan dijital biçimde tıbbi kayıtların veri tabanlarıdır. PACS, sağlık personeline hastaların teşhis ve tedavisini desteklemek için kaliteli bilgi sağlayan ve kayıp radyografik filmlerin ortadan kaldırılması gibi önemli faydaları olan teknoloji tabanlı sistemlerdir (Roelandt, 2012). Dijital görüntü ve ilgili belgeler, PACS'de dijital bir veri tabanı ve ağ içinde depolanarak sağlık personelinin görüntüleri senkronize olarak görüntülemesini sağlar (Abdekhoda ve Salih,2017). Çalışmada tomografi cihazından çekilen görüntünün kurulan PACS sistemine iletilmesi sağlanmıştır.

PACS sistemi kurgulamak için bir sunucu oluşturulmuştur. Oluşturulan bu sunucuda DICOM formatında birden fazla kesitten oluşan tıbbi akciğer tomografi görüntülerini barındırmak için PACS sistemi kurulmuştur. Sistemin oluşturulması Clear Canvas isminde bir açık kaynak PACS yazılımı ile sağlanmıştır. Sisteme kayıpsız olarak tüm görüntüler başarıyla ulaşmıştır. DICOM formatındaki tıbbi görüntüler için Onis isminde bir DICOM görüntüleyici kullanılmıştır. PACS sistemine iletilen ve arşivlenen görüntüleri ONIS isminde açık kaynak bir DICOM görüntüleyicisi ile kolayca görüntüleyip tüm bilgilere ulaşılmaktadır. Clear Canvas ile kurulan PACS sistemindeki DICOM formatındaki görüntülerin tüm bilgileri Microsoft SQL veri tabanında tutulmaktadır. Tomografi görüntülerinin çekilmesinden arşivlenmesine kadar oluşturulan süreç Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Akciğer Tomografi Görüntülerinin Dijital Ortamda Görüntülenmesi

3.2. Tıbbi Görüntüleme Yöntemleri

Radyoloji bilimleri son yirmi yılda tıbbi görüntüleme ve bilgisayarlı tıbbi görüntü işlemede devrim niteliğinde bir ilerlemeye tanık oldu. X-ray mamografi, X-ray bilgisayarlı tomografi (X-ray CT), tek foton bilgisayarlı tomografi (SPECT), pozitron emisyon tomografi (PET), ultrason, manyetik rezonans görüntüleme gibi çok boyutlu tıbbi görüntüleme modalitelerindeki gelişme ve ilerlemeler (MRI) ve fonksiyonel manyetik rezonans görüntüleme (fMRI), sağlık hizmetlerinde önemli iyileşme için hastalık teşhisi, tedavi değerlendirmesi ve müdahalede önemli radyolojik araçlar sağlamıştır (Dhawan,2013). Çalışmada Akciğer BT (Bilgisayarlı Tomografi) görüntüleri tercih edilmiştir.

Akciğer BT (Bilgisayarlı Tomografi) ve X-Ray (Röntgen) görüntüleri, akciğerleri ve solunum sisteminin değerlendirilmesinde kullanılan iki farklı görüntüleme yöntemidir. Her iki yöntem de farklı prensiplere dayanır ve farklı bilgi sağlar.

•**Akciğer BT Görüntüleri:** BT görüntüleme, kesitsel görüntüler elde etmek için kullanılan bir tarama yöntemidir. Bu yöntemde, X-ışınları kullanılarak çok sayıda ince dilimli görüntü alınarak bu dilimler bir araya getirilerek üç boyutlu bir görüntü oluşturulmaktadır. Akciğer BT görüntüleri, yüksek çözünürlüğe ve detaylara sahip olabilir ve akciğerlerin iç yapısını, lezyonları, tümörleri ve diğer anormallikleri gösterme yeteneğine sahiptir. Ayrıca, kontrast maddeleri kullanılarak damarların ve akciğer dokusunun daha ayrıntılı bir şekilde görüntülenmesi de mümkün olabilmektedir.

•**Akciğer X-Ray Görüntüleri:** X-Ray görüntüleme, elektromanyetik X-ışınları kullanılarak elde edilen bir tarama yöntemidir. Bu yöntemde, X-ışınları vücuttan geçerken farklı dokular tarafından farklı oranlarda soğurularak bir film veya dijital detektör üzerinde görüntü oluşturulmaktadır. Akciğer X-Ray görüntüleri, hızlı ve yaygın bir şekilde kullanılabilen bir yöntemdir, ancak BT görüntülerine kıyasla daha düşük çözünürlük ve ayrıntı sağlamaktadır. Akciğer X-Ray'leri genellikle akciğerlerin genel görünümünü değerlendirmek, akciğer hastalıklarının teşhisinde ve takibinde kullanılmaktadır.

Teknik olarak, BT ve X-Ray görüntüleme arasındaki farklar şunlardır:

•**Prensip:** BT görüntüleme, X-ışınlarının vücuttan geçişi sırasında farklı dokuların farklı ölçülerde soğurmasını kullanırken, X-Ray görüntüleme, X-ışınlarının bir film veya detektör üzerinde yansımaları veya soğurulmasını kullanmaktadır.

•**Çözünürlük:** BT görüntüleme, ince kesitler halinde yüksek çözünürlüklü görüntüler sağlayabilirken, X-Ray görüntüleme daha düşük çözünürlük ve ayrıntı sağlamaktadır.

•**Görüntüleme Yapısı:** BT görüntülerinde, kesitsel görüntüler bir araya getirilerek üç boyutlu bir yapı oluşturulurken, X-Ray görüntülerinde tek bir iki boyutlu görüntü elde edilmektedir.

•**Anormallik Tespiti:** BT görüntüleme, akciğer dokusunun iç yapısını, lezyonları ve tümörleri daha ayrıntılı bir şekilde gösterme yeteneğine sahiptir. X-Ray görüntüleme ise

genel olarak akciğerlerin genel görünümünü değerlendirmek için kullanılmaktadır.

Sonuç olarak, BT ve X-Ray görüntüleme farklı prensiplere ve bilgi sağlama yeteneklerine sahip olan iki farklı görüntüleme yöntemidir. Hangi yöntemin kullanılacağı, hastalığın teşhis veya takip amacına, radyoloğun değerlendirme ihtiyaçlarına ve hastanın durumuna bağlı olarak belirlenmektedir.


•**DICOM (Digital Imaging and Communications in Medicine :** Tıpta Dijital Görüntüleme ve İletişim (DICOM) Standardı, biyomedikal görüntüler ve görüntüyle ilgili bilgiler için tescilli olmayan bir veri değişim protokolünü, dijital görüntü formatını ve dosya yapısını belirtir (Bidgood vd., 1997).

3.3. Kullanılan Veri Seti ve Yöntem

Çalışmada tespit edilmek istenen hastalık uluslararası ICD kodu J18.9 Pnömoni olarak hedeflenmiştir. Pnömoni (zatürre) hastalığı çeşitlerinden Olağan İnterstisyel Pnömoni (UIP) tespiti üzerine çalışılmıştır. Olağan interstisyel pnömoni (UIP), idiyopatik pulmoner fibrozisin (İPF) ayırt edici özelliği olan interstisyel akciğer hastalığının histopatolojik ve radyolojik bir paternidir (Lynch,2006). Görüntülemeye, olağan interstisyel pnömoni genellikle bir akciğer hacmi kaybı ve periferik septal kalınlaşma, bronşektazi, buzlu cam bölgeleri ve bal peteği görünümünden oluşan bir görüntü ile kendini göstermektedir. Radyologlar, UIP'de tipik olarak görülen değişiklikleri tanımlamak için genellikle "petek değişikliği" terimini kullanırlar. Çalışmada petek değişikli ve buzlu cam bölgeleri, hastanın akciğer tomografi görüntüsündeki farklı kesitlerdeki değişiklikler göz önüne alınarak derin öğrenme ile sınıflandırma çalışmaları yapılmıştır.

Yapılan çalışmada toplam 8070 adet akciğer BT görüntüsü PACS sisteminde yer almaktadır.

Oluşturulan PACS sistemi üzerinden veri seti olarak toplamda 8070 adet akciğer tomografi görüntüsü yer almaktadır. Bu görüntü verilerinden 4040 adet veri J18.9 ICD kodlu pnömoni teşhisi konulan hastalar ile oluşturulmuştur. 4030 adet görüntü verisi herhangi bir hastalık teşhisi konmamış sağlıklı akciğer görüntülerinden oluşmaktadır. PACS sisteminde bulunan görüntü verilerinin tamamı DICOM formatından oluşmaktadır. Örnek DICOM formatında Akciğer BT görüntüsü Şekil 3.2'de yer almaktadır.



Şekil 3.2. DICOM Formatında Akciğer BT Görüntüsü

3.4. Kullanılan Yazılım Platformları ve Kütüphaneler

Tasarlanan derin öğrenme modeli “Python” yazılım dilinde oluşturulmuş olup “Jupyter Notebook” platformu kullanılmıştır. “Tensorflow” ve “Keras” kütüphaneleri derin öğrenme modeli kurulurken tercih edilmiştir. Ön veri işleme ve grafik oluşturma işlemlerinde “numpy”, “pandas” ve “matplotlib” kütüphaneleri kullanılmıştır. Tıbbi görüntüleme formatları üzerinde yapılan işlemlerde “pydicom” kütüphanesi ile işlemler yapılmıştır.

Akciğer tomografi görüntülerinin depolanması, görüntülenmesi ve iletilmesi için “Clean Canvas” ve “Onis” programları kullanılmıştır.

3.4.1. Python

Python, yüksek seviyeli bir programlama dilidir ve geniş bir kullanıcı tabanına sahiptir. Python, basit ve okunabilir sözdizimiyle dikkat çeker ve veri analizi, yapay zeka ve makine öğrenmesi gibi alanlarda yaygın olarak kullanılmaktadır. Python, modüler ve geniş bir kütüphane ekosistemi sunar, bu da çeşitli işlevlerin gerçekleştirilmesini kolaylaştırmaktadır.

3.4.2. Jupyter Notebook

Jupyter Notebook, Python kodunu çalıştırmak, sonuçları görselleştirmek ve metinleri içeren belgeler oluşturmak için kullanılan bir web tabanlı bir uygulamadır. Jupyter Notebook, interaktif bir ortam sağlar ve kod, sonuçlar, grafikler ve açıklamaların birleşimini sunmaktadır. Bu, araştırma sürecinde kodu adım adım çalıştırmanıza, sonuçları görselleştirmenize ve analizlerinizi metinlerle desteklemenize olanak tanımaktadır.

3.4.3. NumPy

NumPy, Python için bir sayısal hesaplama kütüphanesidir. Geniş ve çok boyutlu dizi ve matris nesneleri sağlar ve bu nesneler üzerinde hızlı ve verimli hesaplamalar yapılmasını sağlamaktadır. NumPy, veri analizi, bilimsel hesaplama ve makine öğrenmesi gibi alanlarda yaygın olarak kullanılmaktadır. Matematiksel işlemler için düşük seviye veri manipülasyonu sağlar ve yüksek performanslı hesaplama yetenekleri sunmaktadır.

3.4.4. Pandas

Pandas, Python için yüksek performanslı bir veri analizi kütüphanesidir. Veri manipülasyonu ve analizi için güçlü ve kullanıcı dostu veri yapıları ve işlevler sağlamaktadır. Pandas, tablo benzeri bir veri yapısı olan DataFrame'i kullanarak veri setlerini işlemeyi kolaylaştırmaktadır. Veri filtreleme, birleştirme, sıralama ve gruplama gibi çeşitli veri manipülasyon işlemleri için kullanılabilir.

3.4.5. Matplotlib

Matplotlib, Python için bir veri görselleştirme kütüphanesidir. Çeşitli grafik türleri oluşturmak için kullanılır ve verilerin görsel olarak temsilini sağlamaktadır. Matplotlib, çizgi grafikleri, histogramlar, dağılım grafikleri ve kutu grafikleri gibi farklı görsel öğeleri destekleyebilmektedir. Bu, verilerin anlaşılmasını kolaylaştırır ve görsel analiz yapmayı sağlamaktadır.

3.4.6. Keras

Keras, Python için yüksek seviyeli bir derin öğrenme kütüphanesidir. Evrişimli sinir ağları, tekrarlayan sinir ağları ve derin öğrenme modelleri oluşturmayı ve eğitmeyi kolaylaştırmaktadır. Keras, kullanıcı dostu bir API sağlar ve altta yatan bir derin öğrenme çerçevesiyle entegre çalışabilmektedir. Bu, araştırmacıların ve uygulamacıların hızlı prototip oluşturmasını ve derin öğrenme modellerini kolaylıkla yapılandırmasını sağlamaktadır.

3.4.7. TensorFlow

TensorFlow, Python için açık kaynaklı bir makine öğrenme ve derin öğrenme kütüphanesidir. Hesaplama grafi oluşturma ve dağıtık hesaplama yetenekleri sunar. TensorFlow, derin öğrenme modellerinin oluşturulması, eğitimi ve değerlendirilmesi için kullanılmaktadır. Evrişimli sinir ağları, tekrarlayan sinir ağları ve diğer derin öğrenme modellerinin özelleştirilmesi ve optimize edilmesi için geniş bir araç seti sunabilmektedir.

3.4.8. Clear Canvas

Clear Canvas, tıbbi görüntüleme alanında kullanılan bir açık kaynak PACS (Picture Archiving and Communication System) çözümüdür. PACS, tıbbi görüntüleme cihazlarından (örneğin, röntgen, MRG, BT) elde edilen görüntülerin depolanması, yönetilmesi ve paylaşılması için kullanılan bir sistemdir. Clear Canvas, bu amaca yönelik bir PACS sunucusu, görüntüleyici ve veri yönetim araçları içermektedir.

Clear Canvas, tıbbi görüntülerin merkezi bir depoda saklanması ve çeşitli sağlık kuruluşlarında erişilebilir olmasını sağlamaktadır. Bu, görüntülerin kolaylıkla paylaşılmasını, uzaktan erişimi ve işbirliğini mümkün kılabilir. Ayrıca, Clear Canvas, görüntülerin görüntüleyici tarafından görselleştirilmesi, analiz edilmesi ve raporlanması için kullanıcı dostu bir arayüz sunmaktadır.

3.4.9. Onis

Onis, tıbbi görüntülerin görüntülenmesi ve analizi için kullanılan bir açık kaynak DICOM (Digital Imaging and Communications in Medicine) görüntüleyici yazılımıdır. DICOM, tıbbi görüntüleme cihazları arasında veri iletişimi ve standardizasyonu için kullanılan bir protokoldür. Onis, bu protokolü destekleyen görüntülerin görselleştirilmesi ve işlenmesi için bir arayüz sağlamaktadır.

Onis, tıbbi görüntüleri görüntülemek, ölçmek, bölge seçmek, zoom yapmak, parlaklık ve kontrast ayarlamak gibi işlevleri desteklemektedir. Ayrıca, görüntüler üzerinde çeşitli analiz işlemleri gerçekleştirilebilir, ölçümler yapılabilir ve raporlar oluşturulabilmektedir. Onis, kullanıcı dostu bir arayüz sunar ve farklı görüntüleme modları (örneğin, manyetik rezonans, bilgisayarlı tomografi) için özelleştirilebilmektedir.

Clear Canvas ve Onis gibi açık kaynak uygulamaları, tıbbi görüntüleme alanında önemli rol oynamaktadır. Clear Canvas, tıbbi görüntüleme verilerinin depolanması ve paylaşılması için bir PACS çözümü sunarken, Onis görüntüleyici yazılımı olarak kullanılmaktadır. Bu uygulamalar, sağlık kuruluşları, araştırma laboratuvarları ve tıbbi görüntüleme uzmanları tarafından görüntüleme, analiz ve raporlama işlemlerinde yaygın olarak kullanılmaktadır.

3.5. Önerilen Model

Yapılan çalışmada akciğer üzerindeki bal peteği ve buzlu cam kısımları ile sağlıklı dokuları sınıflandırmak için derin öğrenme modeli kullanılmıştır. Görüntü işleme algoritmaları ile segmentasyon işlemleri yapılarak akciğer üzerindeki hasta bölgeler daha ayrıntılı incelenmiştir. Çalışma, elde edilen verilerin kurgulanacak modele girmeden önce incelenme amaçlı ön veri inceleme ve önerilen derin öğrenme modeli ile sınıflandırma olmak üzere iki kısımdan oluşmaktadır.

3.5.1. Ön Veri İnceleme

Akciğer tomografi görüntüleri, sağlıklı ve hasta olmak üzere iki ayrı sınıf üzerinden tıbbi görüntülerde yoğunluk seviyeleri incelenmiştir. Akciğer dokusu üzerindeki bal peteği ve buzlu cam kısımları yapılan inceleme sonucu elde edilen verilerde fark edilmiştir. Veri üzerinde yapılan ön incelemeler sonucunda sınıflandırma aşaması öncesinde söz konusu hastalık üzerine akciğer görüntülerini yorumlamak adına yardımcı olmuştur. Radyolojik görüntülerin derin öğrenme modeline girmeden önce yoğunluk seviyeleri ve tomografi çekim pencereleri kavramları incelenmiştir.

Radyolojik görüntüler üzerinde yorum yapabilmek ve görüntülerin çözünürlükleri üzerinden fikir elde edebilmek için Hounsfield Unit (HU) ve tomografi görüntüleme pencereleri kavramlarını incelemek gerekmektedir.

- **Radyolojik Görüntüler İçin Hounsfield Unit (HU) Skalası**

Hounsfield Birimi (HU) Skalası, tıbbi görüntüleme alanında yaygın olarak kullanılan bir ölçüm skalasıdır ve genellikle bilgisayarlı tomografi (BT) görüntülerinde kullanılmaktadır. Bu ölçek, bir dokunun yoğunluğunu ve bileşimini belirlemek için kullanılmaktadır.

HU skalası, CT taraması sırasında alınan görüntülerdeki piksel yoğunluğunu ölçmek için kullanılan özel bir birimdir. Skala, suyun yoğunluğunu sıfır olarak kabul ederken, diğer dokuların yoğunluğunu suya göre daha düşük veya daha yüksek olarak ifade etmektedir. Negatif HU değerleri, suya göre daha düşük yoğunlukta olan dokuları temsil ederken, pozitif HU değerleri, suya göre daha yüksek yoğunlukta olan dokuları temsil etmektedir. Örneğin, beyaz renkli kemik dokusu pozitif HU değerlerine sahipken, siyah renkli hava negatif HU değerlerine sahiptir.


HU skalası, Hounsfield Sayısı olarak da bilinir ve formülü şu şekildedir:

$$HU = (CT \text{ değeri} - \text{Hava CT değeri}) / (\text{Su CT değeri} - \text{Hava CT değeri}) \times 1000 \quad (3.1)$$

Burada, CT değeri, pikselin elde ettiği yoğunluğu temsil etmektedir. Hava CT değeri, HU skalasının belirlediği hava yoğunluğunu ifade ederken, su CT değeri ise suyun yoğunluğunu temsil etmektedir.

HU skalası, tıbbi görüntüleme alanında farklı dokuların ayırt edilmesi ve analiz edilmesi için önemlidir. Örneğin, beyin taramalarında, kanama, tümörler veya beyin dokusundaki lezyonlar gibi anormallikleri tespit etmek ve sınıflandırmak için HU değerleri kullanılmaktadır. Bu skalada belirli HU aralıkları belirli dokuları tanımlamak için kullanılabilir ve bu sayede tıbbi teşhis ve tedavi süreçlerinde önemli bilgiler sağlanabilmektedir.


HU değerleri -1000 Hava, -100 Yağ, -10 ila 20 Yağ, 0 Su, 30-45 Yağ Doku, 60-90 Kan, 100-500 iodonize kontrast, 300-800 Trabeküler kemik, 1000 ve üzeri Kortikal kemik olarak radyolojik görüntülerde incelenebilir. Şekil 3.3'te HU değerleri gösterilmiştir.




Şekil 3.3. Radyolojik Görüntüler İçin Hounsfield Unit (HU) Skalası

Sonuç olarak, Hounsfield Birimi (HU) Skalası, tıbbi görüntüleme alanında farklı dokuların yoğunluğunu ve bileşimini belirlemek için kullanılan bir skaladır. Bu skalada her dokunun CT değeri, suya veya hava yoğunluğuna göre belirli bir ölçekte ifade edilir. HU değerleri, tıbbi görüntü analizi ve tanı süreçlerinde önemli bir role sahiptir.

Akciğer tomografi görüntülerinde iki farklı çekim pencere tiplmesi vardır. Bunlar mediasten ve parenkim pencereleridir. Yapılan çalışmada kullanılan modeller ve görüntü işleme tekniklerinde veri olarak Şekil 3.4’de gösterilen parenkim penceresi görüntü verileri kullanılmıştır. Modelde kullanılan bir 256*256 Akciğer BT görüntü verisi ve Hounsfield Unit (HU) Skalası Şekil 3.5’te gösterilmiştir.



Şekil 3.4. Tomografi Çekim Pencereleri



Şekil 3.5. Akciğer BT Görüntüsü ve HU Dağılımı

Akciğerleri genel olarak segmentlere ayırmak için önce akciğerler HU değer aralığına dayalı bir eşik değeri belirleriz. Akciğer HU değerleri -700 ile -600 arasında yer almaktadır. Belirlenen eşik değerler doğrultusunda görüntü işleme algoritmalarındaki parametreler belirlenerek Akciğer tomografi görüntüsü üzerindeki

hastalıklı bölge teşhis edilebilir hale gelmektedir. Tıbbi görüntüleme yöntemlerinde segmentasyon işlemleri 2 veya 3 boyutlu şekilde uygulanabilmektedir (Memon vd., 2006). Akciğer görüntülerinin segmente edilmesinde COVID vb. hastalıkların tespit edilmesi hastalıklı dokunun segmentasyon işlemi ile akciğer dokusundan ayırt edilerek yapılabilmektedir.

3.5.2. Önerilen Derin Öğrenme Modeli

Derin Öğrenme, yapay sinir ağları olarak bilinen insan beyninin işlevinden esinlenen algoritma yapıları ile makine öğrenmesi alt disiplini. Bu bölümde öncelikle tıbbi görüntülemede yapay zeka, derin öğrenme, makine öğrenmesi, derin öğrenme performans ölçümü, yapay sinir ağları, derin ağ eğitilirken kullanılan aktivasyon fonksiyonları ile başlayıp evrimsel sinir ağları ve matematiksel modellenmesi ile bölüm sonlandırılmıştır.

3.5.2.1. Tıbbi Görüntülemede Yapay Zeka

- **Yapay Zeka ve Tıbbi Görüntüleme**

Tıbbi görüntüleme, hastaların teşhis ve tedavi süreçlerinde önemli bir rol oynayan kritik bir tıbbi görüntüleme yöntemidir. Yapay zeka, tıbbi görüntüleme alanında büyük bir potansiyele sahip olup, teşhis ve tedavi süreçlerinde insan doktorlara yardımcı olabilen önemli bir araç olarak kullanılmaktadır. Yapay zeka yöntemleri, tıbbi görüntülerin analizi, özellik çıkarımı, patolojik bölgelerin tespiti ve hastalıkların sınıflandırılması gibi görevlerde etkili bir şekilde kullanılmaktadır.

- **Makine Öğrenmesi ve Tıbbi Görüntüleme**

Makine öğrenmesi, tıbbi görüntüleme alanında yaygın olarak kullanılan bir yaklaşımdır. Makine öğrenmesi, tıbbi görüntülerden elde edilen büyük miktardaki verileri analiz ederek örüntüleri ve ilişkileri keşfetmeyi amaçlar. Gözetimli, gözetimsiz ve takviyeli öğrenme yöntemleri, tıbbi görüntüleme verilerinin analizinde kullanılan temel makine öğrenmesi teknikleri arasındadır. Makine öğrenmesi algoritmaları, özellik seçimi, boyut indirgeme, sınıflandırma, segmentasyon ve nesne tanıma gibi tıbbi görüntüleme problemlerinin çözümünde önemli bir rol oynamaktadır.

- **Derin Öğrenme ve Tıbbi Görüntüleme**

Derin öğrenme, tıbbi görüntüleme alanında önemli bir etkiye sahip olan güçlü bir yapay zeka yaklaşımıdır. Derin öğrenme, çok katmanlı sinir ağlarından oluşan bir model yapısını kullanarak tıbbi görüntülerde karmaşık örüntüleri tanımlama yeteneğine sahiptir. Derin öğrenme modelleri, otomatik özellik çıkarımı, sınıflandırma, segmentasyon ve anomalilerin tespiti gibi tıbbi görüntü analizi problemlerini çözmek için kullanılır. Derin sinir ağları, genellikle evrimsel sinir ağları (CNN) ve rekürrent sinir ağları (RNN) gibi özel tipleri içerir ve tıbbi görüntüleme verilerinin karmaşıklığını ele almak için tasarlanmıştır.

Tıbbi görüntüleme alanında yapay zeka, derin öğrenme ve makine öğrenmesi yaklaşımları, hastalıkların erken teşhisini, patolojik bölgelerin tanımlanmasını, tedavi

yanıtlarının tahmin edilmesini ve kişiye özgü tedavi stratejilerinin geliştirilmesini desteklemektedir. Bu teknikler, tıbbi görüntülerin daha hızlı, daha doğru ve daha hassas bir şekilde analiz edilmesini sağlayarak klinik karar verme süreçlerine büyük katkılar sağlamaktadır. Ayrıca, bu yaklaşımların tıbbi görüntüleme alanındaki etkinliği ve güvenilirliği üzerine yapılan araştırmalar, daha iyi tanı ve tedavi yöntemlerinin geliştirilmesine yönelik yol gösterici bilgiler sunmaktadır.

Sonuç olarak, yapay zeka, derin öğrenme ve makine öğrenmesi teknikleri tıbbi görüntüleme alanında önemli bir rol oynamaktadır ve klinik uygulamalarda kullanılan tıbbi görüntüleme yöntemlerinin geliştirilmesi ve iyileştirilmesinde büyük bir potansiyel taşımaktadır.

3.5.2.2. Derin Öğrenme Performans Ölçümünde Kullanılan Temel Metrikler

- **Başarı Oranı (Accuracy):**

Başarı oranı, bir derin öğrenme modelinin doğru tahminlerin toplam veri noktalarına oranını ölçen temel bir performans metriğidir. Doğru tahminlerin sayısı TP (True Positive) ve TN (True Negative) olarak ifade edilirken, toplam veri noktalarının sayısı N'dir. Başarı oranı (ACC), aşağıdaki matematiksel ifadeyle hesaplanmaktadır.

$$ACC = (TP + TN) / N \quad (3.2)$$

- **Kayıp Oranı (Loss):**

Kayıp oranı, bir derin öğrenme modelinin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçen bir performans metriğidir. Kayıp fonksiyonu, tahminler ile gerçek değerler arasındaki farkı hesaplar ve bu farkın bir ölçüsünü sağlamaktadır. Kayıp oranı (Loss), genellikle eğitim sürecinde ve modelin performansını optimize etmek için kullanılmaktadır. Farklı derin öğrenme problemleri için farklı kayıp fonksiyonları kullanılabilir. (Örneğin, ortalama kare hata (MSE), çapraz entropi (Cross-Entropy) vb.).

- **Hassasiyet (Precision):**

Hassasiyet, bir derin öğrenme modelinin pozitif olarak tahminlendiği veri noktalarının gerçekten pozitif olduğu oranı ölçer. Hassasiyet (Precision), aşağıdaki matematiksel ifadeyle hesaplanmaktadır.

$$Precision = TP / (TP + FP) \quad (3.3)$$

Burada, FP (False Positive) yanlış pozitif tahminlerin sayısını temsil etmektedir.

- **Duyarlılık (Recall):**

Duyarlılık, gerçek pozitif veri noktalarının ne kadarını doğru bir şekilde tahmin ettiğini ölçen bir performans metriğidir. Duyarlılık (Recall), aşağıdaki matematiksel ifadeyle hesaplanmaktadır.

$$Recall = TP / (TP + FN) \quad (3.4)$$

Burada, FN (False Negative) yanlış negatif tahminlerin sayısını temsil etmektedir.

- **F1-Skoru:**

F1-skoru, hassasiyet ve duyarlılık arasında bir denge sağlamak için kullanılan bir performans metriğidir. F1-skoru, hassasiyet ve duyarlılık arasındaki harmonik ortalamadır ve bir modelin hem pozitif tahminlerde hem de gerçek pozitiflerde iyi performans göstermesini sağlamaktadır. F1-skoru, aşağıdaki matematiksel ifadeyle hesaplanmaktadır.

$$F1\text{-Score} = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (3.5)$$

Bu metrik, hem hassasiyeti hem de duyarlılığı dikkate alarak model performansını bütüncül bir şekilde değerlendirmeye yardımcı olur.

Bu performans ölçüm teknikleri, derin öğrenme modellerinin performansını değerlendirmek ve karşılaştırmak için kullanılan yaygın metriklerdir. Bu metrikler, modelin doğruluk, kayıp, hassasiyet, duyarlılık ve F1-skoru gibi önemli özelliklerini ölçerek modelin performansını objektif bir şekilde değerlendirmeye yardımcı olmaktadır. Ayrıca, bu metriklerin kullanımı, modelin eğitim sürecinde iyileştirilmesi gereken alanları belirlemek ve hata analizini yapmak için de önemlidir.


3.5.2.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin sinir hücrelerinin işleyişinden ilham alınarak tasarlanmış matematiksel modellerdir. YSA'lar, karmaşık problemleri çözmek, veriyi analiz etmek, desenleri tanımak ve tahminlerde bulunmak için kullanılmaktadır. Girdi verilerini işler, çıktılar üretir ve bu süreçte sinir hücrelerinin etkileşimini taklit etmektedir.

YSA'ların kökeni, 1940'lı ve 1950'li yıllarda Warren McCulloch ve Walter Pitts tarafından atılmıştır. McCulloch ve Pitts, sinir hücrelerinin basit matematiksel modellerini tanımlamış ve sinir ağları teorisi için temel bir çerçeve oluşturmuşlardır. Ancak, o dönemdeki bilgisayarların sınırlı işlem gücü ve veri eksikliği nedeniyle YSA'lar üzerindeki çalışmalar sınırlı kalmıştır. YSA'lar, 1980'lerin sonları ve 1990'ların başlarında tekrar popülerlik kazanmıştır. Geri yayılım algoritmasının keşfedilmesi, YSA'ların daha derin katmanlara sahip ve daha etkili hale gelmesini sağlamıştır. Bu dönemde, YSA'lar üzerinde birçok önemli çalışma yapılmış ve görüntü işleme, doğal dil işleme, ses tanıma gibi birçok alanda başarılı sonuçlar elde edilmiştir.

YSA'lar, sinir hücrelerinin matematiksel modelleri ve bu hücreler arasındaki bağlantıların düzenlenmesiyle tanımlanmaktadır. Her sinir hücresi, girdi verilerini işler ve bir çıktı üretebilmektedir. Bu işlem, girdilerin ağırlıklarla çarpılması ve bir aktivasyon fonksiyonundan geçirilmesiyle gerçekleştirilmektedir. YSA'lar, genellikle katmanlarla yapılandırılmaktadır. İlk katman girdi katmanıdır ve verileri almaktadır. Sonraki katmanlar, sinir hücrelerinden oluşur ve birbirleriyle bağlantılıdır. Bu bağlantılar, sinir hücrelerinin çıktılarını bir sonraki katmana iletmek için ağırlıklarla temsil edilmektedir.

Yapay sinir ağı, ağ mimarisi olarak bir giriş katmanı, çıkış katmanı ve doğrusal olmayan elemanları işlemek için en az bir gizli katmanından oluşan çok katmanlı algılayıcıya sahiptir (Joseph ve Douw, 2018). Yapay sinir ağlarının çalışma mantığı Şekil 3.6'da gösterilmiş olan $W1X1$, $W2X2$ diğer ağlardan gelen verileri göstermektedir. Yapay sinir ağı bu veriyi aktivasyon fonksiyonlarından geçirip hesaplanan çıktıyı diğer sinir ağına iletmektedir. Şekil 3.6'da gösterilen işlemde W_iX_i matris çarpımını ifade etmektedir. Çarpım sonucuna Bayes değeri eklenmektedir ve sonuç aktivasyon fonksiyonundan geçirilmektedir. Çıkan değerlere göre hangi sinir ağı daha aktif durumdaysa model ona göre tahmin yapmaktadır. Bu aşamaya kadar içerilen işlemler ileri besleme işlemidir. Modelin eğitilebilir duruma gelmesi için hatalarını inceleyip onları revize etmesi de gerekmektedir. Bu revizyon ise ağırlık ve Bayes değerlerinin değiştirilmesiyle yapılmaktadır.



Şekil 3.6. Yapay Sinir Ağı Mimarisi

YSA'ların modellenmesinde kullanılan önemli konular şunlardır:

- **Aktivasyon Fonksiyonları:** Sinir hücrelerinin çıktılarını sınırlamak ve non-linear davranışı modellemek için kullanılmaktadır. Sigmoid, ReLU, tanh gibi fonksiyonlar yaygın olarak görülmektedir.
- **Kayıp Fonksiyonları:** YSA'nın çıktılarının gerçek çıktılarından ne kadar uzak olduğunu ölçmektedir. Bu fonksiyonlar, ağı performansı değerlendirmek ve ağırlıkların güncellenmesi için kullanılmaktadır. Örnek olarak ortalama kare hata (MSE) ve çapraz entropi kaybı (cross-entropy loss) fonksiyonları verilebilmektedir.
- **Optimizasyon Algoritmaları:** Ağırlıkların güncellenmesi için kullanılmaktadır. Geri yayılım algoritması, en yaygın kullanılan optimizasyon algoritmasıdır. Gradient iniş, Adam, RMSprop gibi diğer optimizasyon algoritmaları da kullanılabilir.
- **Sinir Ağı Mimarisi:** YSA'nın katmanlarının ve bağlantılarının düzenini belirlemektedir. İleri beslemeli sinir ağı en basit mimariye sahiptir, girdiden çıktıya doğru tek yönlü bir akışa sahiptir. Rekürsif sinir ağı ise geri besleme döngüleriyle çalışır ve zaman serileri gibi sürekli verilerin işlenmesi için kullanılmaktadır.

Sonuç olarak YSA'lar, karmaşık problemleri çözmek, desenleri algılamak ve veri analizi yapmak için etkili bir araçtır. Gelişmeler, derin öğrenme gibi YSA tabanlı tekniklerin başarıyla uygulanmasını sağlamıştır. YSA'lar, yapay zeka alanındaki önemli bir araştırma ve uygulama alanı olarak kabul edilmektedir.

3.5.2.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları bir nöronun tetiklenmesi olarak düşünülebilir. Amaçları W(ağırlık) ve b(Bayes) değerlerini ayarlamaktır. Aktivasyon fonksiyonları, temsil ettiği işleve bağlı olarak doğrusal, doğrusal olmayan, nesne tanıma ve sınıflandırma gibi farklı alanlardaki sinir ağlarının çıktılarını kontrol etmek için kullanılır.

- **Sigmoid Aktivasyon Fonksiyonu**

Sigmoid aktivasyon fonksiyonu, çoğunlukla ileri beslemeli sinir ağlarında kullanılan doğrusal olmayan bir fonksiyondur. Doğrusal olmadığı için yapay sinir ağlarında sıklıkla kullanılan bir aktivasyon fonksiyonu olarak karşımıza çıkmaktadır. Aşağıda formülasyonu gösterilen fonksiyon girdi değerleri için 0 ile 1 arasında değer üretmeyi sağlamaktadır. Sigmoid aktivasyon fonksiyonu formül 3.6'da ifade edilmiştir.

$$S(x) = \frac{e^x}{1+e^x} - 1 \quad (3.6)$$

- **ReLU Aktivasyon Fonksiyonu**

ReLU günümüzde derin öğrenme uygulamalarında en yaygın kullanılan ve hızlı öğrenen aktivasyon fonksiyonlarından biridir. Diğer aktivasyon fonksiyonlarına göre daha genelleme ve performans sunmaktadır. Fonksiyonun işlevi aşağıda yer alan formülasyonda gösterildiği gibi gelen değerlerin pozitif mi yoksa negatif bir değer mi olduğuna bakmaktadır. Eğer değer sıfır değerinden küçükse sonuç olarak sıfırı vermektedir. Eğer sıfır değerinden büyükse herhangi bir değiştirme işlemi yapmamaktadır. Örnek olarak ReLU her yıl düzenlenen "Imagenet" veri kümesi üzerinden düzenlenen yarışmalarda AlexNet'te de bu fonksiyon kullanılmıştır. ReLU aktivasyon fonksiyonu formül 3.7'de ifade edilmiştir.

$$f(x) = \max(0, x) \quad (3.7)$$

3.5.2.5. Evrişimli Sinir Ağları


Evrişimli sinir ağları (CNN), görüntü işlemede ve görsel tanımadaki başarılarıyla tanınan derin öğrenme algoritmalarıdır. Temel olarak, görüntülerin özellik çıkarımı ve sınıflandırılması için özel olarak tasarlanmış katmanlardan oluşurlar. Evrişim ve havuzlama katmanları, girdi görüntüdeki lokal özelliklerin çıkarılmasına ve boyutsal azaltmaya yardımcı olur. Son katmanlar ise sınıflandırma yapmak için kullanılır.

Milyonlarca görüntüden binlerce nesneyi öğrenmek için, öğrenme kapasitesi yüksek bir modele ihtiyaç vardır (Krizhevsky vd., 2012). Bununla birlikte, nesne tanımada büyük karmaşıklığa çözüm bulmak elzem olmuştur. Modeli oluşturmak için çok sayıda ön bilgiye ihtiyaç olduğundan dolayı evrişimli sinir ağları (CNN'ler) derin öğrenme modellerinde çözüm oluşturur (Krizhevsky vd., 2012). Bu nedenle, benzer boyutta katmanlara sahip standart ileri beslemeli sinir ağlarıyla karşılaştırıldığında, CNN'ler çok daha az bağlantıya ve parametreye sahiptir ve bu nedenle eğitilmeleri daha kolaydır (Krizhevsky vd., 2012).

Evrişimli sinir ağları ham görüntü piksellerinden görsel kalıpları tanıma eğilimindedirler. Bazı durumlarda, görüntüleri sinir ağlarına beslemeden önce minimum bir ön işleme gerçekleştirilmektedir. Bu derin ağlar, çok katmanlı nöronlar kullanarak ve her evrişimli katmanda paylaşılan ağırlıkları kullanarak giriş görüntüsünün önemli alanlar olarak adlandırılan küçük parçalarına bakar.. Elle yazılmış karakterleri tanımak için önerilen ilk evrişimli sinir ağı modeli (LeNet-5) sunulmuştur (LeCun vd., 1998). CNN'nin bitişik katmanlarının nöronları arasındaki örüntülerin bağlantıları, yani, bir m katmanının gizli birimlerinden gelen girdiler, m-1 katmanındaki birimlerin bir alt kümesi olarak alınmaktadır. Evrişimli sinir ağları, bir özellik haritası oluşturmak için sapma ve ağırlık vektörlerini paylaşmaktadır. Paylaşılan ağırlıkların gradyanı, paylaşılan parametrelerin gradyanlarının toplamına eşit olmaktadır. Tüm görüntünün alt bölgeleri üzerinde konvolüsyon işlemi yapıldığında öznitelik haritası elde edilmektedir. İşlem, giriş görüntüsünün veya özellik haritasının doğrusal bir filtreyle evrilmesini ve ardından bir doğrusal olmayan filtrenin uygulanmasını takip eden bir sapmanın eklenmesini içermektedir (Anwar vd., 2018).

- **Evrişimli Sinir Ağlarının Matematiksel Modellenmesi**

Evrişimli Sinir Ağları (ESA) temel olarak girdi olarak aldığı görüntüyü, görüntü içerisinde bulunan çeşitli nesneleri birbirinden ayırabilen derin öğrenme modellerinden oluşur. Birden fazla katmana sahip olan Evrişimli Sinir Ağları ; Evrişim Katmanı (Convolution Layer) ve Havuzlama Katmanından (Pooling Layer) oluşmaktadır. Son aşamada ise tam bağlı katmandan (Fully Connected Layer) oluşur. Akabinde ise sınıflandırma katmanı bulunmaktadır (Gu vd., 2017). Bilgisayarlı görü ve derin öğrenme konularında Evrişimli Sinir Ağlarının en büyük avantajı girdi olarak görüntü verisinin kendisini almasıdır. Diğer modeller incelendiğinde girdi olarak vektör formatı kullanılmaktadır. Evrişimli sinir ağlarında girdi verisi 2 veya 3 boyutlu görüntülerden oluşmaktadır. Basit bir evrişimli sinir ağı mimarisi Şekil 3.7'de gösterilmiştir.



Şekil 3.7. Evrişimli Sinir Ağı Mimarisi

Çekirdek evrişimi, küçük bir sayı matrisi (çekirdek veya filtre adı verilir) alıp görüntümüzün üzerinden geçirdiğimiz ve filtreden gelen değerlere göre dönüştürdüğümüz bir süreçtir. Aşağıda bulunan formül 3.8’de $F(m, n)$, çıktı özellik haritasındaki (m, n) konumundaki pikselin değerini temsil etmektedir. $I(i, j)$, giriş görüntüsündeki (i, j) konumundaki pikselin değeridir. $H(m-i, n-j)$ ise çekirdek matrisinin $(m-i, n-j)$ konumundaki ağırlık değeri olarak görülmektedir.

$\Sigma(i, j)$ sembolü, tüm çekirdek boyutları (i, j) üzerinde bir döngü yapılması gerektiğini göstermektedir. İlgili giriş bölgesi ile çekirdek arasında nokta çarpımı yapılır ve sonuçlar toplanır. Bu formülde, her bir (m, n) konumu için giriş görüntüsünde belirli bir bölgeye odaklanılmaktadır. Çekirdek boyutları (H) bu odaklanma boyutunu belirlemektedir. Giriş bölgesi ile çekirdek arasında nokta çarpımı yapılır ve sonuçlar toplanarak çıktı özellik haritasında (F) depolanmaktadır.

$$G(m, n) = \Sigma(i, j) I(i, j) * H(m - i, n - j) \quad (3.8)$$

Önerilen çalışmada tıbbi görüntülemeye sınıflandırmaya en uygun Evrişimli Sinir Ağları kullanılarak katmanlar optimize edilmiştir. Akciğer tomografi görüntüleri özgün olarak oluşturulan Evrişimli Sinir Ağı modeline girdi olarak alınmıştır ve görüntülerin hasta ve normal olarak sınıflandırılmasında en yüksek başarı oranı hedeflenmiştir. Filtre seçilen bir pikselin üzerine yerleştirdikten sonra, çekirdekten her bir değeri alıp görüntüden karşılık gelen değerlerle çiftler halinde çarpılmaktadır. Sonuç, çıktı özellik haritasında doğru yere koyulmaktadır.

- **Evrişim Katmanı**

Evrişimli Sinir Ağları’nın ana yapısı, görüntüdeki özellikleri tespit etmek için kullanılan evrişim katmanlarıdır. Görüntüdeki özellikler öne çıkabilen kenarlardan ve eğrilerden daha karmaşık yapılara kadar herhangi bir özellik olabilmektedir. Bu katman ile görüntüdeki özellikler çıkarılmaktadır.

Evrişim işlemi, girdi verisinin filtrelerle nokta nokta çarpımı yaparak özellik haritalarının oluşturulduğu bir işlemdir. Evrişim işlemi matematiksel olarak aşağıda sunulan formül 3.9’daki gibi gösterilmektedir.

$$Y[i, j] = \Sigma(m, n) X[i + m, j + n] * F[m, n] \quad (3.9)$$

Burada, $Y[i, j]$ özellik haritasındaki çıktı pikselini, $X[i+m, j+n]$ girdi verisindeki piksel değerini, $F[m, n]$ ise filtredeki ağırlık değerini temsil etmektedir. M ve N , filtre boyutunu ifade etmektedir. Evrişim işlemi, filtrelerin girdi üzerinde kaydırılması ve nokta nokta çarpımı ile hesaplanmasıyla gerçekleştirilmektedir. Bu işlem sonucunda, her bir filtre için bir özellik haritası elde edilmektedir.

Filtreleme işlemi görüntünün sol üst kısmından başlayarak filtrenin sağa kaydırılması şeklinde yapılmaktadır. Filtreyi uygularken ağırlık matrisi ile girdi matrisinin filtre ile çakışan kısımda yer alan değerler çarpılır (Hadamard çarpımı). Görüntünün en sağ kısmına bakıldığında filtre tekrar görüntünün soluna ancak alttaki kısımlarına gelmektedir ve sağ kısmına ötelenerek işlem devam etmektedir. Ötelenme işlemi genelde 1 piksel olarak uygulansa da bu değer ESA mimarisi ve girdi matrisinin özelliklerine göre ağ tasarımcısı tarafından değiştirilebilmektedir. Literatürde doldurma adı verilen bu işlemde görüntüye yeni piksel değerleri eklenmektedir. Örneğin doldurma değeri p , doldurma işlemi sıfır değeri ile olacağı düşünüldüğü takdirde, bu çerçevenin p piksel değeri ölçüsünde büyütülerek yeni piksellerin sıfır ile doldurulacağı gözükmemektedir.


Görüntü boyutu $Win * Hin * Din$ olan bir işlem sonrası elde edilen aktivasyon oluşumu sonrası aktivasyon oluşumunun genişliği $Wout$, yüksekliği $Hout$ ve derinliği $Dout$ olarak isimlendirildiği takdirde aşağıdaki formüller ile hesaplanmaktadır.

$$Wout = (Win - F + 2P) / S + 1 \quad (3.10)$$

$$Hout = (Hin - F + 2P) / S + 1 \quad (3.11)$$

$$Dout = K \quad (3.12)$$

Burada F değeri $FF \times FF$ boyutundaki filtrenin boyut uzunluk değerini, P padding (doldurma) değerini, S kaydırma (stride) değerini ve K filtre sayısını ifade etmektedir.




Şekil 3.8. Evrişim İşlemi Filtre ve Aktivasyon Haritası

- **Havuzlama Katmanı**

Görüntülerin çok büyük olduğu çalışmalarda eğitim parametrelerinin sayısını azaltmak büyük öneme sahiptir. Sonraki evrişim katmanları arasına periyodik olarak bir

havuzlama katmanı eklemek gerekmektedir. Ortaklama katmanı olarak da isimlendirilen havuzlamanın tek amacı, görüntü alanının boyutunu küçültmektir. Havuzlama birçok biçimde olabilir: Maksimum havuzlama, ortalama Havuzlama, toplam havuzlama şeklindeki katmanlardan en yaygın havuzlama şekli maksimum havuzlama katmanıdır.



Şekil 3.9. 5x5’lik Giriş Görüntüsüne 2x2 Filtre ile Bir ve İki Adım Kaymalı Maksimum Havuzlama İşleminin Uygulanması

Maksimum havuzlama işlemi, belirli bir bölgedeki en büyük değeri seçerek özellik haritasının boyutunu küçültmektedir. Matematiksel olarak, max havuzlama işlemi şu şekilde ifade edilebilmektedir;

$$Y[i,j] = \max(R[i,j]) \quad (3.13)$$

- **Tam Bağlı Katman**

Tam bağlı tanımı üst seviyedeki her nöronun bir sonraki seviyedeki her nöronla birbirine bağlı olduğu anlamına gelmektedir. Evrişim ve havuzlama katmanı bir öznetelik çıkarıcısı olurken, tam bağlantılı katman bir sınıflandırıcı pozisyonunda olmaktadır. Tamamen bağlantılı katman, üst katmanın çıktısını alırken (üst düzey özelliklerin özellik haritasını temsil eder) ve bu özelliklerin hangi kategoriye en uygun olduğunu belirtmektedir. Örneğin bir resmin içeriği bir kuş olarak belirlendiği takdirde daha yüksek değerlere sahip özellik haritası, kanatlar veya gagalar gibi daha gelişmiş bazı özellikleri temsil etmektedir. Tamamen bağlı katman, çıktı katmanı olarak Softmax aktivasyon fonksiyonunu kullanmaktadır. Softmax işlevi, herhangi bir gerçek değere sahip bir vektörü 0-1 ve 1 ögelerinden oluşan bir vektöre dönüştürür.

Genel olarak, tam bağlı katman gelişmiş özelliklerin hangi kategoriyle en yakından eşleştiğini ve hangi ağırlığa sahip olduklarını gözlemlemektedir. Ağırlık ve önceki katmanlar arasındaki iç çarpımı hesaplarken, farklı kategoriler için doğru olasılığı elde edebilmektedir Bu katman işlem girdisi ve ardından N-boyutlu bir vektör çıktısı vermektedir (N, kategori sayısını temsil eder). N-boyutlu vektörün her sayısı, belirli bir kategorinin olasılığını temsil etmektedir.

- **Geri Yayılım (Backpropagation)**

Evrişimli sinir ağlarının eğitimi geri yayılım (backpropagation) algoritması kullanılarak gerçekleştirilmektedir. Geri yayılım algoritması, hata fonksiyonunun ağırlıklar üzerindeki gradyanını hesaplayarak ağırlıkların güncellenmesini sağlamaktadır.

Eğitim sürecinde, girdi verisi ve gerçek çıktılar kullanılarak bir hata fonksiyonu hesaplanmaktadır. Hata fonksiyonunun ağırlıklar üzerindeki gradyanı, zincir kuralı ve gradyan hesaplama ile elde edilmektedir. Bu gradyanlar kullanılarak ağırlıklar güncellenir ve hata azaltılmaya çalışılmaktadır.

Sonuç olarak, evrişimli sinir ağları evrişim işlemi, aktivasyon fonksiyonları, havuzlama işlemi ve geri yayılım algoritması gibi matematiksel formüller ve adımlar kullanılarak modellenmektedir. Bu formüller ve adımlar, ESA'ların görsel verilerdeki örüntüleri tanıma ve işleme yeteneklerini sağlamaktadır.

3.5.2.6. Evrişimli Sinir Ağı Mimarileri

- **ResNet (Residual Network)**

ResNet, Microsoft tarafından 2015 yılında tanıtılan ve evrişimli sinir ağlarının derinliğini artırmak için geliştirilen bir evrişimli sinir ağı modelidir. Standart evrişimli sinir ağlarında , ağı derinliği arttıkça aşırı uyum ve gradient kaybı gibi sorunlar ortaya çıkabilmektedir. ResNet, rezidüel bağlantılar kullanarak bu sorunları aşabilmektedir. Bu bağlantılar, bir katmandan diğerine geçiş yaparken, önceki katmanın çıktısının doğrudan sonraki katmana eklenmesini sağlamaktadır. ResNet'in en dikkat çekici özelliği, rezidüel bağlantılar olarak adlandırılan yapısıdır. Standart evrişimli sinir ağı mimarilerinde, ağı her katmanının çıktısı, bir sonraki katmanın girişi olmaktadır. Ancak derin ağlarda, ağı derinliği arttıkça, gradientlerin kaybolması ve aşırı uyum gibi sorunlar ortaya çıkabilir. Rezidüel bağlantılar, bu sorunları aşmak için geliştirilmiştir. Rezidüel bağlantılar, katmanlardaki orijinal özellikleri korumaktadır ve ağı daha kolay öğrenmesini sağlamaktadır. Özellikle, eğer bir katman bir hata yaparsa ve girişle çıktı arasındaki dönüşümü başarıyla gerçekleştiremezse, rezidüel bağlantı sayesinde orijinal giriş hala bir sonraki katmana iletilmektedir. Bu, ağı gradientlerin daha kolay akışını sağlamaktadır ve daha derin ağların eğitimini daha verimli hale getirmektedir.

ResNet, ImageNet gibi büyük veri kümeleri üzerinde yapılan yarışmalarda üstün performans sergileyerek derin öğrenmenin gelişimine büyük katkıda bulunmuştur. Ayrıca ResNet'in transfer öğrenme ve çeşitli görsel tanıma görevlerinde kullanılabilirliği, onu çeşitli uygulama alanlarında popüler bir seçenek haline getirmiştir. Sonuç olarak, ResNet'in rezidüel bağlantılar kullanarak ağı derinliğini artırma ve daha derin ağlarda daha iyi performans elde etme yeteneği, onu modern derin öğrenme mimarileri içinde önemli bir yer edinmesini sağlamıştır.

- **AlexNet**

AlexNet, 2012 yılında ImageNet yarışmasında çarpıcı bir şekilde başarı elde eden ve derin öğrenmenin popüler hale gelmesini sağlayan bir modeldir. Büyük boyutlu evrişimli sinir ağlarının kullanımını teşvik eden ilk modeldir. 8 katmanlıdır ve evrişim, havuzlama ve tam bağlantı katmanlarından oluşmaktadır. AlexNet, ReLU aktivasyon fonksiyonunu ve dropout düzenlemesini (regularization) tanıtan ilk modeldir. AlexNet, sekiz katmanlı bir mimariye sahiptir ve toplamda 60 milyon parametreye sahiptir. İlk beş katman, evrişim ve havuzlama katmanlarından oluşurken, son üç katman tam bağlantılıdır. AlexNet, o dönemdeki diğer yöntemlere kıyasla daha derin bir ağ ve GPU tabanlı eğitimle hızlı hesaplama yeteneğine sahip olması nedeniyle büyük bir başarı elde etmiştir. ILSVRC yarışmasında, özellikle çok katmanlı yapı ve ReLU aktivasyonlarının kullanımı sayesinde diğer modellere göre önemli ölçüde düşük hata oranları elde etmiştir. Ayrıca, AlexNet, büyük boyutlu CNN'lerin kullanımının artmasına katkıda bulunmuş ve derin öğrenmenin popüleritesini artırmıştır. AlexNet'in başarısı, daha sonraki derin öğrenme modellerinin geliştirilmesine ve görsel tanıma alanında büyük ilerlemelere yol açmıştır.

- **EfficientNet**

EfficientNet, 2019 yılında geliştirilen ve evrişimli sinir ağları için ölçeklenebilir bir modeldir. Ölçeklenebilirlik, modelin derinliği, genişliği ve çözünürlüğünün optimize edilmesiyle elde edilmektedir. Böylece, model hem daha hafif hale gelir hem de daha yüksek doğruluk elde edebilmektedir. Compound Scaling yöntemi, EfficientNet'in performansını diğer modellere göre önemli ölçüde artırmaktadır. EfficientNet, temelde evrişim ve havuzlama katmanlarından oluşan bir evrişimli sinir ağı mimarisidir. Ancak, diğer modellere kıyasla özgün ölçekleme yöntemi sayesinde, ağı derinliği, genişliği ve çözünürlüğü arasında dengeli bir ilişki kurmaktadır. Ölçekleme, derinlik, genişlik ve çözünürlük için katsayılar kullanılarak gerçekleştirilir ve bu katsayılar ağı daha hafif ve daha verimli olmasını sağlamaktadır. EfficientNet, özgün ölçekleme yöntemi sayesinde diğer modellere kıyasla daha hafif ve verimli bir yapıya sahiptir. Bu özellik, modelin daha hızlı eğitilmesine ve daha az hesaplama kaynağı gerektirmesine olanak tanıırken, yüksek doğruluk sağlamasını da mümkün kılabilmektedir. Ölçeklenebilir yapısı sayesinde, EfficientNet farklı uygulama alanlarında ve veri setlerinde kullanılabilir. Ağırlık ayarlaması ve ölçeklendirme katsayıları, farklı boyutlu veri setlerine ve problemlere kolayca adapte olmasını sağlamaktadır. Yüksek doğruluk ve verimlilik, EfficientNet'i çeşitli görsel tanıma ve görüntü sınıflandırma görevlerinde başarılı bir seçenek haline getirmiştir.

- **GoogLeNet (Inception V1)**

GoogLeNet, 2014 yılında tanıtılan ve Inception V1 olarak da bilinen modeldir. Diğer modellere göre daha hafif ve hesaplama açısından daha verimlidir. Inception blokları, farklı filtre boyutlarının (1x1, 3x3, 5x5) paralel olarak kullanılmasını içermektedir ve bu sayede farklı ölçekli özelliklerin çıkarılmasına yardımcı olmaktadır. Bu bloklar, ağıın derinliğini artırmadan daha iyi performans sağlamak için tasarlanmıştır. GoogLeNet, farklı ölçekli özelliklerin paralel olarak çıkarılmasını sağlayarak diğer modellere kıyasla daha geniş bir özellik yelpazesine erişim sağlamaktadır. Bu özelliği, özellikle nesne algılama gibi karmaşık görsel görevlerde daha iyi performans elde etmesini sağlamaktadır. Aynı zamanda, GoogLeNet'in özgün yapısı, daha az parametreye sahip olmasını ve hesaplama maliyetini düşürmesini sağlamaktadır. Bu nedenle, daha hafif ve daha hızlı bir model olarak dikkat çeker ve farklı uygulama alanlarında kullanılabilmektedir.

- **VGG (Visual Geometry Group)**

VGG, 2014 yılında geliştirilen ve farklı boyutlardaki filtrelerin yığılması ile karakterize edilen bir modeldir. 16 veya 19 katmanlı varyantları vardır. VGG, küçük filtre boyutları (3x3) ve küçük havuzlama boyutları (2x2) kullanarak homojen bir mimari sağlamaktadır. Bu nedenle, VGG'nin mimarisi daha kolay anlaşılır ve genelleştirilebilir olması açısından avantajlıdır.

Evrişimli sinir ağı mimarilerinin parametre sayılarının ve performanslarının karşılaştırılması Çizelge 3.1'de gösterilmiştir.

Model	Yıl	Mimari	Parametre Sayısı
AlexNet	2012	Düz CNN	~60 M
VGG	2014	Düz CNN	~138 M
EfficientNet	2019	Evrişim + Ölçeklendirme	~5 M - 66 M
ResNet	2015	Rezidüel Bağlantılar	~1 M - 26 M
GoogLeNet	2014	Inception Blokları	~6 M

Çizelge 3.1.Evrişimli Sinir Ağı Mimarileri

AlexNet, basit bir evrişimli sinir ağıdır ve 2012 ImageNet yarışmasında önemli bir başarı elde etmiştir. Ancak diğer modellere kıyasla daha hafif ve daha az karmaşık bir yapıya sahiptir. VGG, daha derin ve homojen bir yapıya sahip olup, daha büyük parametre sayısına sahiptir. 2014 ImageNet yarışmasında üstün performans sergilemiştir. EfficientNet, ölçeklendirme katsayıları ile daha verimli bir yapıya sahip olup, çok sayıda farklı boyutlu varyanta sahiptir. Yüksek doğruluk ve verimlilik açısından dikkat çeken bir modeldir. ResNet, rezidüel bağlantılar ile ağıın derinliğini artıran bir yapıya sahiptir. Çok derin ağlarda bile iyi performans elde edebilir ve aşırı uyum (overfitting) sorununu azaltmaktadır.

GoogLeNet (Inception V1), inception blokları kullanarak farklı boyutlu filtrelerle paralel işlem yapar ve daha geniş bir özellik yelpazesine erişim sağlamaktadır.

Sonuç olarak parametre sayıları, genellikle daha fazla parametreye sahip modellerin daha karmaşık ve derin olduğunu göstermektedir. Performans, genellikle ImageNet veri kümesi üzerinde yapılan sınıflandırma görevindeki doğruluk ve başarıya göre değerlendirilmektedir.

Bu tablo, farklı modelleri temel özellikleri ve performansları açısından karşılaştırarak ihtiyacınıza en uygun olanı seçmenize yardımcı olabilmektedir. Modellerin farklı avantajları ve uygulama alanları olduğundan, seçiminizi problem ve veri setinize uygun olarak yapmak önemlidir.



4. BULGULAR VE TARTIŞMA

Bu tez çalışmanın temel olarak görüntü arşivleme ve iletim sistemindeki akciğer tomografi görüntülerinin pnömoni hastalığı ve normal sağlıklı akciğer görüntülerinin derin öğrenme algoritmaları ile sınıflandırma çalışmaları yapılmıştır. Ayrıca akciğer tomografi görüntülerinin pnömoni hastalığında nasıl bir görüntüye sahip olduğu ve sınıflandırma öncesi yorum yapılabilmesi açısından ön veri inceleme çalışmaları yapılmıştır. Öncelikle akciğer tomografi görüntüleri görüntü arşivleme ve iletim sisteminden (PACS) bir sanal sunucuya aktarılmıştır. DICOM formatında olan tomografi görüntüleri metin verilerinden arındırılarak sadece görüntü verileri elde edilmiştir. Elde edilen görüntü verileri Python programlama dilinde “Jupyter Notebook” platformu ve Python kütüphaneleri kullanılarak incelenmiştir. Ardından tomografi görüntüleri üzerinde yoğunluk ve uygun çekim penceresi kullanma açısından ön veri inceleme çalışmaları yapılmıştır. Yapılan çalışmalar doğrultusunda normal sağlıklı bir akciğer ve pnömoni hastası bir akciğer arasındaki farklar, uygun tomografi çekim penceresi seçimleri görülerek sınıflandırma öncesi fikir edinilmiştir.

Görüntülerin sınıflandırılma aşamasında Evrişimli Sinir Ağları kullanılmıştır. Yapılan çalışmada özgün evrişimli sinir ağı modeli kurgulanmıştır. Ardından kurgulanan evrişimli sinir ağı modeli diğer evrişimli sinir ağı mimarileri ile karşılaştırılmıştır. Evrişimli sinir ağı mimarilerinden Resnet, Googlenet ve Alexnet ile aynı görüntü verileri üzerinden kurulan modeller kendi kurduğumuz evrişimli sinir ağları modelleri ile başarı ve kayıp oranları kıyaslanmıştır. Ayrıca literatürde akciğer X-Ray görüntüleri üzerinden kurgulanan modeller ile yapılan çalışmada akciğer tomografi görüntüleri üzerinden kurulan modeller karşılaştırılmıştır.

4.1. Görüntü Sınıflandırma

Görüntü Arşivleme ve İletim Sistemi (PACS)’den yapılan çalışma için toplam 8070 adet akciğer tomografi görüntüsü çekilmiştir. İlk olarak temelde veri eğitim ve test olmak üzere ikiye ayrılmıştır. Yaklaşık tüm verinin %80’ini oluşturacak şekilde 6448 adet görüntü eğitim verisi olarak, tüm verinin yaklaşık %20’sini oluşturacak şekilde 1622 adet görüntü test verisi olarak ayrılmıştır. 6448 adet eğitim verisinin içerisinde yaklaşık %30’luk oranı oluşturacak şekilde 1934 adet validasyon verisi ayrılmıştır. Kurulan model üzerinden eğitilen verinin içerisinde seçilen validasyon verileri üzerinden yapılan doğrulama başarısı ve modelin eğitilirken hiç görmediği test verisi üzerinden yapılan test başarısı incelenmiştir. Veriler “normal” ve “pnömoni” şeklinde iki sınıf olmak üzere etiketlenerek dengeli şekilde modele dahil edilmeden dağıtılmıştır. Eğitim verileri 3219 adet “normal”, 3229 adet “pnömoni” olarak etiketlenmiştir. Test verileri 811 adet “normal” ve 811 adet “pnömoni” olarak etiketlenmiştir.

Derin öğrenme modeli evrişimli sinir ağları üzerinden kurulmuştur. Modele girdi olarak 3 kanaldan oluşan görüntülerin piksel değerlerine göre 255*255*3 görüntü verisi verilmiştir. Ardından ölçeklendirme işlemi uygulanarak girdilerin her pikseli 255 değerine bölünmüştür. Ölçeklendirme işlemi uygulanarak tüm değerler belli bir aralığa getirilmiştir. Bu işlem ile birlikte modelin optimal noktaya yakınsaması daha kolay olmaktadır.

Genellikle görüntü verileri üzerinden bir derin öğrenme modeli kurulurken literatürde önceden uygulanmış hazır veri setleri ve başarısı ispatlanmış hazır modeller kullanılmaktadır. Yapılan çalışmada evrişimli sinir ağları kullanılarak özgü bir model oluşturulmuştur. Evrişim katmanında konvolüsyon işlemleri uygulanmıştır. Konvolüsyon işlemi sonrasında matris boyutunda küçülme meydana gelmektedir bu sebepten dolayı bu durumu optimize etmek için “same padding” yöntemi uygulanmaktadır. Bu yöntem ile matris boyutunda konvolüsyon işleminde bir azalma görülmemiştir. Havuzlama katmanında genel olarak kullanılan maksimum havuzlama katmanı kullanılmıştır. Maksimum havuzlama katmanının temel mantığı örneğin (2,2) matrisi değerinde 4 piksel şeklinde uygulanırken en büyük değeri kullanmaktır. Havuzlama katmanı, katman boyutlarını etkilediği için kurulan modelde çok yoğun bir şekilde tercih edilmemiştir.

Temel olarak oluşturulan model 2 blok halindedir. İki blokta da ayrı ayrı 4 tane evrişim katmanı, 2 tane havuzlama katmanı olmak üzere 8 adet evrişim ve 4 adet havuzlama katmanı bulunmaktadır. Son katman tam bağlı katman olarak oluşturulmuştur. Son katman boyutlarının tıbbi görüntüleri işlerken çok kaybolması istenilir bir durum değildir. Maksimum havuzlama katmanı ile maksimum değer, bir sonraki katmana aktarılmaktadır. Bu işlem sonrasında girdi matris boyutu yarı yarıya düşürülerek çıktı matris boyutu hesaplanmaktadır. Oluşturulan modelde düğüm seyrletme (dropout) yöntemi kullanılmıştır. Düğüm seyrletme yöntemi kullanılarak belli bir oranda sinir ağlarının devre dışı kalmasını sağlamaktadır. Bu yöntem modelde 0.3 oranla uygulanmış olup aynı oranda bağlantıların devre dışı kalmasını sağlamıştır. Düğüm seyrletme yönteminin temel amacı aşırı öğrenmeyi (overfitting) azaltmaktır. Evrişimli sinir ağlarında aktivasyon fonksiyonu olarak genellikle relu kullanılmaktadır. Oluşturulan modelde girdi ve ara katmanlarda relu aktivasyon fonksiyonu kullanılmıştır. Relu aktivasyon fonksiyonu ile sıfırdan küçük değerler sıfır değerine çekilmektedir. Kurgulanan modelde son çıktı katmanına tam bağlı katman (flatten) uygulanmıştır. Tam bağlı katman ile matris şeklinde olan veriler dizi haline getirilerek düzleştirilmiştir. Çıktı katmanında aktivasyon fonksiyonu olarak sigmoid kullanılmıştır. İkili sınıflandırmalarda (binary) genellikle sigmoid aktivasyon fonksiyonu kullanılırken ikiden fazla sınıflandırmalarda softmax fonksiyonu tercih edilmektedir.

Oluşturulan derin öğrenme modelinin parametre sayıları ve katmanları ayrıntılı şekilde aşağıda Şekil 4.1’de gösterilmiştir. Kurulan modelin katman yapısı ve parametre sayıları Şekil 4.2’de, topoloji olarak Şekil 4.3’te görülmektedir.

```

inputs= keras.Input(shape=(255,255,3))
x = layers.experimental.preprocessing.Rescaling(1./255)(inputs)

#Blok 1
x = Conv2D(128, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = Conv2D(128, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = MaxPooling2D(pool_size=(2, 2))(x)
x = Dropout(0.3)(x)
x = Conv2D(64, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = Conv2D(64, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = MaxPooling2D(pool_size=(2, 2))(x)
x = Dropout(0.3)(x)

#Blok2
x = Conv2D(32, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = Conv2D(32, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = MaxPooling2D(pool_size=(2, 2))(x)
x = Dropout(0.3)(x)
x = Conv2D(16, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = Conv2D(16, kernel_size=(3, 3), activation='relu',padding='SAME')(x)
x = MaxPooling2D(pool_size=(2, 2))(x)
x = Dropout(0.3)(x)


x = Flatten(name='flatten')(x)
x = Dense(units=8, activation='relu')(x)
outputs = Dense(units=1, activation='sigmoid')(x)
model= keras.Model(inputs=inputs, outputs=outputs)

```

Şekil 4.1. Derin Öğrenme Modeli Parametreleri ve Katmanları

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 255, 255, 3)]	0
rescaling (Rescaling)	(None, 255, 255, 3)	0
conv2d (Conv2D)	(None, 255, 255, 128)	3584
conv2d_1 (Conv2D)	(None, 255, 255, 128)	147584
max_pooling2d (MaxPooling2D)	(None, 127, 127, 128)	0
dropout (Dropout)	(None, 127, 127, 128)	0
conv2d_2 (Conv2D)	(None, 127, 127, 64)	73792
conv2d_3 (Conv2D)	(None, 127, 127, 64)	36928
max_pooling2d_1 (MaxPooling2D)	(None, 63, 63, 64)	0
dropout_1 (Dropout)	(None, 63, 63, 64)	0
conv2d_4 (Conv2D)	(None, 63, 63, 32)	18464
conv2d_5 (Conv2D)	(None, 63, 63, 32)	9248
max_pooling2d_2 (MaxPooling2D)	(None, 31, 31, 32)	0
dropout_2 (Dropout)	(None, 31, 31, 32)	0
conv2d_6 (Conv2D)	(None, 31, 31, 16)	4624
conv2d_7 (Conv2D)	(None, 31, 31, 16)	2320
max_pooling2d_3 (MaxPooling2D)	(None, 15, 15, 16)	0
dropout_3 (Dropout)	(None, 15, 15, 16)	0
flatten (Flatten)	(None, 3600)	0
dense (Dense)	(None, 8)	28808
dense_1 (Dense)	(None, 1)	9
=====		
Total params: 325,361		
Trainable params: 325,361		
Non-trainable params: 0		

řekil 4.2. Derin Öğrenme Modeli Parametre Sayıları



Şekil 4.3. Derin Öğrenme Modeli Topolojisi

4.2. Kurulan Derin Öğrenme Modelinin Değerlendirilmesi

Görüntüleri sınıflandırma çalışmasını değerlendirmek için “doğruluk-epoch sayısı” grafiği ve “kayıp- epoch sayısı” grafikleri üzerinden yorumlamalar yapılmıştır.

Doğruluk- epoch sayısı grafiğinde, y ekseninde doğruluk (accuracy) ölçüsü yer alırken, x ekseninde ise epoch sayısı yer almaktadır. Epoch sayısı, eğitim veri setinin tamamının model tarafından kullanıldığı bir döngüyü ifade etmektedir. Her bir epoch, veri seti üzerinden geçildikten sonra modelin ağırlıkları güncellenmektedir ve bir sonraki epoch başlamaktadır. Bu grafik, modelin eğitimi sırasında iki önemli durumu göstermektedir:

- **Başlangıçta Hızlı İlerleme:** Eğitimin başlarında, model hala veriye tam olarak uyum sağlamamıştır ve doğruluk oranı hızla artmaktadır. Model, veri üzerindeki temel örüntüleri ve ilişkileri öğrenirken, epoch sayısı arttıkça doğruluk hızla yükselmektedir.
- **Sabitlenme:** Eğitimin ilerleyen aşamalarında, modelin doğruluk oranı artık yavaşlamaktadır ve bir noktada sabitlenmektedir. Bu, modelin maksimum performans seviyesine ulaştığı ve daha fazla epoch eklemekle doğrulukta büyük bir iyileşme elde edilemeyeceği anlamına gelmektedir. Bu noktada, eğitimi sonlandırmak ve modeli değerlendirmek en uygun seçenek olabilmektedir.

Doğruluk-epoch grafiği, modelin eğitimi izlemek ve en iyi sonuca ulaşmak için kullanışlı bir araçtır. Grafik, eğitim sırasında aşırı uyum (overfitting) veya yetersiz uyum (underfitting) gibi problemleri tespit etmek ve eğitim parametrelerini (örneğin, öğrenme hızı, batch boyutu) ayarlamak için değerli bilgiler sunmaktadır. Ayrıca, modelin ne zaman durdurulması gerektiğini belirlemek için de kullanılabilir.


Kayıp-epoch sayısı grafiğinde, y ekseninde kayıp (loss) ölçüsü yer alırken, x ekseninde ise epoch sayısı yer almaktadır. Kayıp değeri, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçmektedir. Daha düşük bir kayıp değeri, modelin daha doğru tahminler yaptığı anlamına gelmektedir. Bu grafik, modelin eğitimi sırasında iki önemli durumu göstermektedir.

- **Başlangıçta Yüksek Kayıp Değeri:** Eğitimin başlarında, model rastgele başlangıç ağırlıklarıyla çalışır ve henüz veriye tam olarak uyum sağlamamıştır. Bu nedenle, kayıp değeri yüksektir. Model, veri üzerindeki ilişkileri ve örüntüleri anlamaya başladıkça, kayıp değeri azalmaya başlamaktadır.
- **Kaybın Azalması:** Eğitimin ilerleyen aşamalarında, model doğru tahminleri daha iyi yapmayı öğrenir ve kayıp değeri azalmaya devam etmektedir. Başlangıçta hızlı bir şekilde azalan kayıp, daha sonra daha yavaş bir azalma eğilimi gösterebilmektedir. Model, veriye daha iyi uyum sağladıkça ve daha karmaşık örüntüleri öğrendikçe, kayıp değeri daha da düşmektedir.

Kayıp-epoch grafiği, modelin eğitimi izlemek ve performansını değerlendirmek için önemli bir araçtır. Grafik, eğitim sırasında aşırı uyum (overfitting) veya yetersiz uyum (underfitting) gibi sorunları tespit etmek ve eğitim parametrelerini (örneğin, öğrenme hızı, batch boyutu) ayarlamak için kullanışlı olmaktadır. Ayrıca,


modelin eğitimini ne zaman durdurmak gerektiğini belirlemek için de kullanılabilmektedir. Kayıp değeri ne kadar düşük olursa, modelin daha iyi bir performans sergilediği söylenebilir. Ancak, dikkat edilmesi gereken aşırı uyum (overfitting) sorunudur, yani modelin eğitim verisine çok iyi uyması ancak yeni verilere genelleme yapma yeteneğinin düşük olması durumu olarak görülebilmektedir.

Normal ve pnömoni şeklinde iki sınıfa ayrılan tomografi görüntüleri kurulan evrişimli sinir ağı modelinde epoch sayısı 50 olarak belirlenmiştir. Eğitim sonucunda eğitim başarısı %98.16, validasyon başarısı %97.57 ve test için ayrılan veriler üzerindeki test başarısı %95.19 olarak sonuçlanmıştır. Aşağıda yer alan Şekil 4.4’de epoch sayısı ve modelin başarıları gösterilmektedir. Eğitim ve validasyon verileri üzerinde modelin başarı yüksek seviyede olup modelin eğitim sırasında görmediği test verileri üzerindeki başarısı da yüksek seviyelerde kaldığı gözlenmiştir. Kurulan modelde epoch sayısı ve diğer parametreler aşırı öğrenme (overfitting) gerçekleşmediği için bir revizyon yapılmadan başarıya ulaşılmıştır. Veri sayısı, modelin yüksek başarı oranları yakalayana kadar artırıldığı ve elde edilebildiği için herhangi bir sentetik veri üretim çalışması yapılmamıştır.



Şekil 4.4. Modelin Doğruluk-Epoch Sayısı Grafiği

Modelin kayıp oranları eğitim verisi için %0.0436 ve validasyon kayıp oranı %0.0627 şeklindedir. Kayıp oranı ve epoch sayısı grafiği aşağıdaki Şekil 4.5’te sunulmuştur.



Şekil 4.5. Modelin Kayıp-Epoch Sayısı Grafiği

Sonuç olarak, kurulan modelin eğitim ve doğrulama verileri üzerindeki başarı oranlarını inceledikten sonra modelin daha önce hiç görmediği test için oluşturulan tomografi görüntü verileri üzerinde başarı oranı aşağıda Şekil 4.6’da görüldüğü gibi %95.16 ve kayıp oranı 0.1516 şeklinde gösterilmektedir

```
model.evaluate(test_ds)
26/26 [=====] - 494s 18s/step - loss: 0.1506 - accuracy: 0.9519
[0.15060162544250488, 0.951911211013794]
```


Şekil 4.6. Test Verileri Üzerinde Başarı ve Kayıp Oranı

4.3. Evrişimli Sinir Ağı Mimarilerinin ve Kurulan Modelin Karşılaştırılması

Yapılan çalışmada geliştirilen derin öğrenme modeli literatürde kullanılan diğer evrişimli sinir ağları mimarileri ile aynı veriler kullanılarak sınıflandırma çalışmaları yapılmıştır ve doğruluk kayıp oranları kıyaslanarak en başarılı model gözlemlenmiştir.


Evrişimli Sinir Ağı Mimarilerinden AlexNet, GoogleNet ve Resnet ile kurguladığımız evrişimli sinir ağı modellerinde akciğer tomografi görüntüleri kullanılarak bir model kurulmuştur. 8070 adet akciğer tomografi görüntüsü verisi eğitim ve validasyon olmak üzere ikiye ayrılmıştır. 6448 adet görüntü eğitim verisi olarak, 1622 adet görüntü validasyon verisi olarak ayrılmıştır. Oluşturulan modeller, özgün olarak kurgulanan evrişimli sinir ağı modeli ve literatürdeki akciğer x-ray görüntüleri ile kurulan diğer modeller ile karşılaştırılmıştır.

AlexNet ile kurulan model değerlendirildiğinde eğitim verileri üzerinde %93.16 oranında, validasyon verileri üzerinde %92.66 oranında ve test verileri üzerinde %92.85 oranında başarı elde edilmiştir. Model çıktılarının doğruluk – epoch sayısı grafiği Şekil 4.7’de gösterilmiştir.




Şekil 4.7. AlexNet Mimarisi ile Doğruluk- Epoch Sayısı Grafiği

AlexNet mimarisi ile kurulan modelin kayıp oranları eğitim verisi için %0.1468 ve validasyon kayıp oranı %0.1553 şeklindedir. Kayıp oranı ve epoch sayısı grafiği aşağıdaki Şekil 4.8’de sunulmuştur.




Şekil 4.8. AlexNet Mimarisi ile Kayıp- Epoch Sayısı Grafiği

GoogleNet ile kurulan model değerlendirildiğinde eğitim verileri üzerinde %93.80 oranında ve validasyon verileri üzerinde %93.90 oranında başarı elde edilmiştir. Model çıktılarının doğruluk – epoch sayısı grafiği Şekil 4.9’da gösterilmiştir.




Şekil 4.9. GoogleNet Mimarisi ile Doğruluk-Epoch Sayısı Grafiği

GoogleNet mimarisi ile kurulan modelin kayıp oranları eğitim verisi için %0.1514 ve validasyon kayıp oranı %0.1574 şeklindedir. Kayıp oranı ve epoch sayısı grafiği aşağıdaki Şekil 4.10’da sunulmuştur.




Şekil 4.10. GoogleNet Mimarisi ile Kayıp- Epoch Sayısı Grafiği

Aynı veriler üzerinden ResNet mimarisi ile kurulan modelde, model değerlendirildiğinde eğitim verileri üzerinde %82.57 oranında ve validasyon verileri üzerinde %89.64 oranında başarı elde edilmiştir. Modelin epoch sayısı- doğruluk grafiği aşağıda Şekil 4.11’de gösterilmiştir.



řekil 4.11. Resnet Mimarisi ile Doğruluk- Epoch Sayısı Grafiđi

Resnet ile kurulan modelin kayıp oranları eğitim verisi için %0.3656 ve validasyon kayıp oranı %0.2734 şeklindedir. Kayıp oranı ve epoch sayısı grafiđi ařađıdaki řekil 4.12’de sunulmuřtur.



řekil 4.12. Resnet Mimarisi ile Kayıp- Epoch Sayısı Grafiđi

AkciĐer tomografi g r nt leri kullanılarak derin  Đrenme modellerinden evriřimli sinir aĐları ile kurulan  zg n model, diĐer evriřimli sinir aĐı mimarileri ile karřılařtırılmıřtır. Literat rde genellikle tek kesitli akciĐer x-ray g r nt leri ile  alıřmalar yapılmıřtır. Bu  alıřmaların, akciĐer tomografi g r nt leri ile yapılan  zg  derin  Đrenme modeli ve diĐer evriřimli sinir aĐı modelleri ile  ıktıları karřılařtırılmıřtır. Elde edilen derin  Đrenme modeli sonu ları ařaĐıda yer alan  izelge 4.1’de sunulmuřtur.

Yazar	Veri Tipi	Sınıflar	Model	G�r�nt� Sayısı	Performans (Test DoĐruluĐu)
Bu �alıřma	AkciĐer BT	Normal & Pn�moni	�zg�n CNN Model	8070 adet	95.19%
Bu �alıřma	AkciĐer BT	Normal & Pn�moni	AlexNet	8070 adet	92.85%
Bu �alıřma	AkciĐer BT	Normal & Pn�moni	ResNet	8070 adet	89.64%
Bu �alıřma	AkciĐer BT	Normal & Pn�moni	GoogleNet	8070 adet	93.90%
Ayan vd., 2019	AkciĐer X-Ray	Normal & Pn�moni	VGG16	5856 adet	84.5%
Rajaman vd., 2018	AkciĐer X-Ray	Normal & Pn�moni	AlexNet	5247 adet	94.5%
Rahimzadeh ve Attar, 2020	AkciĐer X-Ray	Normal & Pn�moni	ResNet	14863 adet	91.4%

 izelge 4.1. Derin  Đrenme Modellerinin Karřılařtırılması

5. SONUÇLAR

Sonuçlar, akciğer tomografi görüntülerinin derin öğrenme yöntemleriyle sınıflandırılmasının pnömoni teşhisinde başarılı bir yaklaşım olduğunu göstermektedir. Özgün olarak kurulan derin öğrenme modeli, yüksek doğruluk oranları elde ederek pnömoni teşhisinde etkili bir araç olabileceğini göstermektedir.

Görüntü sınıflandırma işleminde, evrişimli sinir ağları kullanılarak özgün bir derin öğrenme modeli başarılı bir şekilde oluşturulmuştur. Bu model, evrişimli sinir ağları mimarileri ile aynı veri kümesi üzerinden kurulan diğer derin öğrenme modelleriyle karşılaştırılmıştır. Literatürde, akciğer x-ray görüntüleri ve akciğer tomografi görüntüleri üzerine yapılan çalışmalar incelenmiştir. Çalışmada, akciğer tomografi görüntüleri kullanılarak pnömoni ve sağlıklı akciğer görüntülerini sınıflandırmak üzere bir derin öğrenme modeli geliştirilmiştir. Bal peteği hücreleri ve buzlu cam alanları, pnömoni teşhisi için önemli özellikler olarak belirlenmiştir ve kurulan sınıflandırma modelinin bu özelliklere odaklanması sağlanmıştır. Veri kümesi, eğitim, test ve validasyon olmak üzere üç sınıfa bölünmüştür. Eğitilen özgün evrişimli sinir ağı modeli, eğitim verileri üzerinde %98.16, validasyon verileri üzerinde %97.57 ve daha önce hiç görmediği test verileri üzerinde %95.19 başarı oranı elde etmiştir. Bu sonuçlar, geliştirilen özgün derin öğrenme modelinin akciğer görüntülerini başarılı bir şekilde sınıflandırdığını ve genel olarak iyi bir performans sergilediğini göstermektedir.

Yapılan çalışma ile, akciğer hastalıklarının teşhisinde ve tıbbi görüntüleme alanında daha doğru ve etkili sınıflandırma modellerinin geliştirilmesine katkı sağlayabilmektedir. Evrişimli sinir ağları kullanarak yapılan çalışmada, ileri tıp uygulamaları ve teşhis süreçlerinde önemli bir adım olarak değerlendirilebilmektedir. İlerleyen aşamalarda daha büyük veri kümesi ve farklı görüntüleme modaliteleri kullanılarak modelin performansının daha da iyileştirilebileceği düşünülmektedir.

Kurulan özgün derin öğrenme modeli ile yapay zeka yöntemlerinin tıbbi görüntüleme alanında önemli bir potansiyele sahip olduğunu göstermektedir. Bu çalışma, pnömoni teşhisinde doğruluk oranlarının artırılması ve hastalığın erken tespiti için bir temel sağlamaktadır. Bununla birlikte, modelin daha geniş bir hasta veri seti üzerinde test edilmesi, farklı pnömoni türlerinin ve diğer akciğer hastalıklarının sınıflandırılması için yapılacak çalışmalar önemli bir gelecek araştırma alanı olabilmektedir. Ayrıca, modelin klinik uygulamalarda gerçek zamanlı olarak kullanılabilirliği ve performansının değerlendirilmesi de önemli bir adımdır.

Elde edilen yüksek doğruluk değerleri ve sonuçları ile akciğer tomografi görüntülerinin derin öğrenme yöntemleriyle sınıflandırılmasının pnömoni teşhisinde etkili bir araç olduğunu göstermektedir. Yapılan çalışmanın yöntemi ile, tıbbi görüntüleme ve yapay zeka alanında daha ileri çalışmaların yolunu açabilmekte olup pnömoni teşhisinde erken tespit ve tedavi süreçlerine katkı sağlayabilmektedir.

Sağlık bilişimi, hastane bilgi yönetim sistemleri ve görüntüleme sistemlerinin kullanımıyla gerçekleştirilen akciğer tomografi görüntülerinin derin öğrenme ile sınıflandırılması çalışması, Türkiye'de klinik araştırmalara önemli katkılar sağlayabileceği düşünülmektedir. Yapılan çalışmanın ulusalda ve uluslararası alanda sektöre sağlayabileceği potansiyel katkılar “Otomatik Sınıflandırma ve Teşhis”, “Veri

Madenciliği ve Anlamlı Bulgular”, “Veri Paylaşımı ve İşbirliği” şeklinde sonuçlandırılabilir.

“Otomatik Sınıflandırma ve Teşhis” ile derin öğrenme algoritmaları, akciğer tomografi görüntülerindeki patolojik özellikleri tespit etme ve sınıflandırma konusunda yüksek başarı gösterebilmektedir. Yapılan çalışma, otomatik sınıflandırma modellerinin geliştirilmesini ve akciğer hastalıklarının teşhis sürecini destekleyebilmektedir. Bu durum doktorların daha hızlı ve doğru teşhis koymasına yardımcı olabilmektedir. “Erken Teşhis ve İyileştirilmiş Prognoz” ile derin öğrenme modelleri, akciğer tomografi görüntülerindeki subtil patolojileri tespit edebilir ve erken teşhis imkanı sunabilmektedir. Bu durum hastalıkların erken aşamada tespit edilmesini ve tedaviye daha erken başlanmasını sağlayarak prognozu iyileştirebilmektedir. Çalışmanın sonuçları, hastaların sağlık durumunu takip etmek ve gelecekteki komplikasyonları öngörmek için de kullanılabilir.

“Veri Madenciliği ve Anlamlı Bulgular” ile sağlık bilişimi alanındaki bu çalışma, büyük miktarda akciğer tomografi görüntü verisi toplama ve analiz etme fırsatı sunmaktadır. Bu veriler, veri madenciliği ve analitik tekniklerin kullanılmasıyla değerli bilgilerin çıkarılmasına olanak tanımaktadır. Örneğin, belirli bir hastalığın yaygınlığı, risk faktörleri veya tedavi yanıtı hakkında anlamlı bulgular elde edilebilmektedir. Bu tür veri analizleri, epidemiyolojik çalışmalara ve sağlık politikalarının şekillendirilmesine katkıda bulunabilmektedir.

“Veri Paylaşımı ve İşbirliği” ile bu çalışma, Türkiye'deki sağlık kuruluşları arasında veri paylaşımını ve işbirliğini teşvik edebilmektedir. Akciğer tomografi görüntü verilerinin merkezi bir veri tabanında toplanması ve paylaşılması, geniş bir veri kümesinin oluşturulmasını sağlamaktadır. Bu durum ile daha genellemeli ve güçlü derin öğrenme modellerinin oluşturulmasına olanak tanınabilmektedir. Ayrıca, farklı sağlık kuruluşları arasında çalışmaların koordinasyonunu ve veri tabanının büyütülmesini teşvik ederek, daha kapsamlı klinik araştırmaların yapılmasına imkan sağlayabilmektedir.

Sonuç olarak, akciğer tomografi görüntüleri ile kurulan özgün derin öğrenme modeli, diğer evrişimli sinir ağı mimarileri ile kurulan modellere ve literatürde akciğer x-ray görüntüleri ile kurulan derin öğrenme modellerine istinaden daha yüksek bir başarı oranı elde ederek Türkiye'de klinik araştırmalara çeşitli katkılar sağlayabileceği düşünülmektedir. Aynı veriler üzerinden evrişimli sinir ağı mimarilerinin doğruluk oranları %92.85, %93.90 ve %89.64 olarak gözlemlenirken literatürde akciğer x-ray görüntüleri ile yapılan çalışmalardaki başarı oranları %84.5, %91.4 ve %94.5 olarak görülmektedir. Çalışmada kurulan özgün evrişimli sinir ağı modeli ile %95.19 oranında daha yüksek bir başarı oranı elde edilmiştir. Bu çalışma ile akciğer hastalıklarının daha iyi anlaşılması, tedavi stratejilerinin iyileştirilmesi ve sağlık politikalarının geliştirilmesine katkı sağlayacağı öngörülmektedir.

6. KAYNAKLAR

- Kumar Acharya, A., & Satapathy, R. 2020. A Deep Learning Based Approach towards the Automatic Diagnosis of Pneumonia from Chest Radio-Graphs. *Biomedical and Pharmacology Journal*, 13(1),: 449–455.
- Lakhani and B. Sundaram,.2017.Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks, *Radiology*, vol. 284, no. 2:574–582.
- Roelandt J. P, 2012. Evaluating and Measuring the Return on Investment of an Emergency Center Health Care Professional Picture Archiving and Communication Systems Training Program. ProQuest LLC. PhD dissertation, Capella University.
- Abdekhoda M, Salih KM, 2017.Determinant Factors in Applying Picture Archiving and Communication Systems (PACS) in Healthcare. *Perspect Health Inf Manag.* 1;14(Summer):1c. PMID: 28855856; PMCID: PMC5559691.
- Dhawan, A.P,2003.Medical Image Analysis, IEEE Series in Biomedical Engineering, John Wiley & Sons, New Jersey, USA.
- Lynch JP 3rd, Saggar R, Weigt SS, Zisman DA, White ES, 2006. Usual interstitial pneumonia. *Semin Respir Crit Care Med.* 2006 Dec;27(6):634-51.
- Weerakkody, Y., Worsley, C. Usual interstitial pneumonia. Reference article, Radiopaedia.org
- Bidgood WD Jr, Horii SC, Prior FW, Van Syckle DE, 1997. Understanding and using DICOM, the data interchange standard for biomedical imaging:199-212
- Raju TN, 1999.The Nobel chronicles. 1979: Allan MacLeod Cormack (b 1924); and Sir Godfrey Newbold Hounsfield (b 1919):1653
- Memon, N.A., Mirza, A.M. ve Gilani, S.A.M, 2006. Segmentation of Lungs from CT Scan Images for Early Diagnosis of Lung Cancer, *Transactions on Engineering, Computing and Technology*:228-233.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E,2012.Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*: 1097-1105,
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T, 2017.Recent advances in convolutional neural networks. *Pattern Recognition*,
- Joseph Awoamim Yacim & Douw Gert Brand Boshoff, 2018.Impact of Artificial Neural Networks Training Algorithms on Accurate Prediction of Property Values, *Journal of Real Estate Research*: 375-418

- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P., 1998. Gradient- based learning applied to document recognition. *Proc. IEEE* 86(11):2278–2324
- Anwar, S.M., Majid, M., Qayyum, A., 2018. Medical Image Analysis using Convolutional Neural Networks: A Review. *J Med Syst* 42:226
- X. Yang, S. Y. Yeo, J. M. Hong, S. Wong, W. Tang, Z. Z. Wu, G. Lee, S. Chen, V. Ding, B. Pang, et al., 2016. A deep learning approach for tumor tissue image classification,” *Biomedical Engineering*.
- Jacob, J., Bartholmai, B.J., Rajagopalan, S. et al., 2016. Evaluation of computer-based computer tomography stratification against outcome models in connective tissue disease-related interstitial lung disease: a patient outcome study:190
- Bartholmai BJ, Raghunath S, Karwoski RA, Moua T, Rajagopalan S, Maldonado F, Decker PA, Robb RA, 2013. Quantitative computed tomography imaging of interstitial lung diseases. *J Thorac Imaging*:298-307
- Shen, W., Zhou, M., Yang, F., Yang, C. and Tian, J., 2015.. Multi-scale Convolutional Neural Networks for Lung Nodule Classification. *Information Processing in Medical Imaging*:588-599.
- Bondfale N. and Banait, S., 2017. Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *International Journal of Innovative Research in Computer and Communication Engineering*:9851-9856.
- Jeong, D. , Maduh, U. J., Sain, M., Stephen O., 2019. An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare
- Wang, Q., Kang, W., Wu, C. and Wang, B., 2013. Computer-aided detection of lung nodules by SVM based on 3D matrix patterns. *Clinical Imaging*,:62–69.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A. and Mougialakou, S., 2016. Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *The Institute of Electrical and Electronics Engineers Transactions on Medical Imaging*:1207-12
- Ayan, E. Unver, H.M., 2019. Diagnosis of Pneumonia from Chest X-ray Images Using Deep Learning. In *Proceedings of the 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*:24–26
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., Kadir, M. A., & Kashem, S., 2020. Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection Using Chest X-ray. *Applied Sciences*:10(9), 3233

Rahimzadeh, M., and Attar,.2020. A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. Informatics in medicine unlocked:19:100360



ÖZGEÇMİŞ

GÖKHAN KARABAĞ

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2020-2023	Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği AnaBilim Dalı, Antalya
Lisans	Akdeniz Üniversitesi
2014-2019	Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği, Antalya

MESLEKİ VE İDARİ GÖREVLER

Bilişim Uzmanı	Sağlık Bakanlığı
2021-Devam Ediyor	Antalya İl Sağlık Müdürlüğü Sağlık Bilgi Sistemleri Birim Sorumlusu, Antalya
Elektrik Elektronik Mühendisi	Antalya İl Sağlık Müdürlüğü
2020-2021	Sağlık Bilgi Sistemleri, Antalya
Veri Bilimi Uzman Yardımcısı	AGT Ağaç. San.Tic.A.Ş
2019-2020	ArGe Birimi, Antalya