T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME TABANLI BİLGİSAYAR DESTEKLİ AKCİĞER KANSERİ TESPİTİ

Büşranur BAHAT

DANIŞMAN
Dr. Öğr. Üyesi Pelin GÖRGEL

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

İSTANBUL-2021

Bu çalışma, 30.12.2021 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Dr.Öğr.Üyesi Pelin GÖRGEL
İstanbul Üniversitesi-Cerrahpaşa
Fakülte

Prof. Dr. Ahmet SERTBAŞ
İstanbul Üniversitesi-Cerrahpaşa
Fakülte

Dr.Öğr.Üyesi Oğuz ALTUN
Yıldız Teknik Üniversitesi
Fakülte

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Bu çalışmanın hayata geçirilmesi sürecinde bilgi ve tecrübelerinden faydalandığım ve her bir aşamasında görüşleriyle beni destekleyen danışman hocam Sayın Dr. Öğr. Üyesi Pelin GÖRGEL' e, her an yanımda olan ve desteklerini hiçbir zaman eksik etmeyen eşime, aileme ve arkadaşlarıma teşekkür ederim.

Aralık 2021 Büşranur BAHAT

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xi**
ÖZET ..... **xiii**
SUMMARY ..... **xv**
1. GİRİŞ **1**
2. GENEL KISIMLAR **4**
2.1. AKCİĞER KANSERİ 4
2.1.1 Akciğer Kanseri Türleri 4
2.1.2 Akciğer Kanseri İçin Risk Faktörleri 5
2.1.3 Akciğer Kanseri Belirtileri 6
2.1.4 Akciğer Kanseri Teşhisi 6
2.1.5 Akciğer Kanseri Tedavisi 9
2.1.6 Akciğer Kanseri Alanında Yapılan Çalışmalar 9
3. MALZEME VE YÖNTEM **13**
3.1. LIDC-IDRI VERİ SETİ 13
3.2. GABOR FİLTRELEME ALGORİTMASI 14
3.3. KONTRAST SINIRLI ADAPTİF HİSTOGRAM EŞİTLEME (CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION-CLAHE) 15
3.4. MAKİNE ÖĞRENMESİ (MACHINE LEARNING-ML) 19
3.5. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS-ANNS) 20
3.6. DERİN ÖĞRENME (DEEP LEARNING-DL) 22
3.6.1. Derin Öğrenme Algoritmaları 23
3.6.1.1. Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNNs) 23
3.6.1.2. Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory Networks-LSTMs) 23
3.6.1.3. Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNNs) 24
3.6.1.4. Üretken Düşman Ağları (Generative Adversarial Networks-GANs) 24

3.6.1.5. Radyal Temel Fonksiyon Ağları (Radial Basis Function Networks-RBFNs) 24
3.6.1.6. Çok Katmanlı Algılayıcılar (Multilayer Perceptrons-MLPs) 24
3.6.1.7. Kendi Kendini Düzenleyen Haritalar (Self Organizing Maps-SOMs) 25
3.6.1.8. Derin İnanç Ağları (Deep Belief Networks-DBNs) 25
3.6.1.9. Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines-RBMs) 25
3.6.1.10. Otomatik Kodlayıcılar (Autoencoders) 25
3.7 EVRİŞİMSEL SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORKS-CNN) 26
3.7.1. Evrişim Katmanı 27
3.7.2. Havuzlama Katmanı 28
3.7.3. Aktivasyon Fonksiyonu 29
3.7.3.1. Sigmoid Aktivasyon Fonksiyonu 30
3.7.3.2. Tanh Aktivasyon Fonksiyonu 30
3.7.3.3. ReLU Aktivasyon Fonksiyonu 30
3.7.3.4. Sızıntı ReLU Aktivasyon Fonksiyonu 30
3.7.3.5. Gürültülü ReLU Aktivasyon Fonksiyonu 31
3.7.3.6. Parametrik Doğrusal Birim Aktivasyon Fonksiyonu 31
3.7.4. Tam Bağlantılı Katman 31
3.7.5. Kayıp (Loss) Fonksiyonları 32
3.7.5.1. İkili Çapraz Entropi Kayıp (Binary Cross-Entropy Loss) Fonksiyonu 32
3.7.5.2. Menteşe Kayıp (Hinge Loss) Fonksiyonu 32
3.7.5.3. Kare Menteşe Kayıp (Squared Hinge Loss) Fonksiyonu 33
3.7.5.4. Çok Sınıflı Çapraz Entropi Kayıp (Multi-Class Cross-Entropy Loss) Fonksiyonu 33
3.7.5.5. Seyrek Çok Sınıflı Çapraz Entropi Kayıp (Sparse Multiclass Cross-Entropy Loss) Fonksiyonu 33
3.7.5.6. Kullback Leibler Divergence Kayıp Fonksiyonu 34
3.8. ÖNERİLEN YÖNTEM 34
3.8.1. Görüntülerin Uzantısının Değiştirilmesi 36
3.8.2. Gabor Filtreleme Algoritmasının Uygulanması 36
3.8.3. CLAHE Algoritmasının Uygulanması 38
3.8.4. Görüntülere Normalizasyon Uygulanması 40
3.8.5. CNN Derin Öğrenme Modeli 40
4. BULGULAR 43
4.1. ÖNERİLEN SINIFLANDIRMA YÖNTEMİNİN PERFORMANS ANALİZİ 43

4.1.1. 32×32 Normalizasyonu ile 3 katmanlı CNN Derin Öğrenme Modeli 44
4.1.1.1. Gabor Filtreleme Algoritmasının Bulgu Değerlerine Etkisi 45
4.1.1.2. CLAHE Algoritmasının Bulgu Değerlerine Etkisi.....46
4.1.2. 128×128 Normalizasyonu ile 3 katmanlı CNN Derin Öğrenme Modeli 49
4.1.2.1. Gabor Filtreleme Algoritmasının Bulgu Değerlerine Etkisi 49
4.1.2.2. CLAHE Algoritmasının Bulgu Değerlerine Etkisi.....51
4.1.3. 128×128 Normalizasyonu ile 5 katmanlı CNN Derin Öğrenme Modeli 54
4.1.3.1. Gabor Filtreleme Algoritmasının Bulgu Değerlerine Etkisi 55
4.1.3.2. CLAHE Algoritmasının Bulgu Değerlerine Etkisi.....56
4.1.4. CNN Derin Öğrenme Modellerinin Doğruluk Değerleri 59
4.1.5. CNN Derin Öğrenme Modellerinin Çalışma Süresi ve Kayıp (Loss) Oranları 61
5. TARTIŞMA VE SONUÇ 62
KAYNAKLAR.....64
ÖZGEÇMİŞ 68

ŞEKİL LİSTESİ

Sayfa No

Şekil 1. 1: Normal Hücre ve Kanserli Hücre Örneği (Amerika Ulusal Kanser Enstitüsü, 2021) 1

Şekil 2. 1: Bilgisayarlı Tomografi Cihazı (Wikipedia, 2004) 7

Şekil 2. 2: Pozitron Emisyon Tomografi Cihazı (Wikipedia, 2004) 8

Şekil 3. 1: LIDC-IDRI Veri Kümesine Ait Akciğer Görüntüleri 13

Şekil 3. 2: Bir Gabor Dalgacık Çekirdeğinin Karesel Bileşenleri, a. Gerçek (Simetrik) Bileşen, b. Hayali (Asimetrik) Bileşen (Loy, 2002) 14

Şekil 3. 3: a. Orjinal Akciğer Görüntüsü, b. Gabor Dalgacığı Uygulanmış Akciğer Görüntüsü 15

Şekil 3. 4: 512×512'lik Bir Görüntünün 64 Eşit Kare Bölgeye Ayrılmış Yapısı (Reza, 2004) 16

Şekil 3. 5: a. Bir IR Bölgesi ve Komşuları, b. (i,j) Bölgesinin 1. Çeyreği Ve Ona En Yakın Dört Bölge ile İlişkisi (Reza, 2004) 17

Şekil 3. 6: CR Grubu Bölgesi ve Komşulukları (Reza, 2004) 18

Şekil 3. 7: a. Orjinal Akciğer Görüntüsü, b. Histogram Eşitlemesi Yapılan Akciğer Görüntüsü, c. CLAHE İşlemi Yapılan Akciğer Görüntüsü 19

Şekil 3. 8: Örnek Bir Yapay Sinir Ağı 21

Şekil 3. 9: Derin Öğrenme, Yapay Sinir Ağları ve Makine Öğrenmesi İlişkisi 22

Şekil 3. 10: Evrişimsel Sinir Ağı Mimarisi 27

Şekil 3. 11: Evrişim Katmanının Her Adımında Yürütülen Birincil Hesaplama Örneği 28

Şekil 3. 12: Ortalama Havuzlama, Maksimum Havuzlama ve Küresel Ortalama Havuzlama 29

Şekil 3. 13: Önerilen Yöntemin Akış Şeması 35

Şekil 3. 14: Önerilen Yöntemin Algoritması 36

Şekil 3. 15: Kanserli Akciğer Görüntüleri ve Gabor Filtre Uygulanması ile Elde Edilen Yeni Görüntüler 37

Şekil 3. 16: Sağlıklı Akciğer Görüntüleri ve Gabor Filtre Uygulanması ile Elde Edilen Yeni Görüntüler.....38

Şekil 3. 17: CLAHE İşleminin Akış Şeması.....39

Şekil 3. 18: CLAHE Algoritmasının Uygulandığı Akciğer Görüntüleri 40

Şekil 3. 19: Önerilen CNN Derin Öğrenme Modeli 41

Şekil 3. 20: Eğitim ve Test Verileri Doğruluk Grafiği 42

Şekil 3. 21: Eğitim ve Test Verileri Kayıp Grafiği 42

Şekil 4. 1: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği.....46

Şekil 4. 2: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği.....47

Şekil 4. 3: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği.....50

Şekil 4. 4: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği.....52

Şekil 4. 5: Gabor Filtreleme Algoritması ve 5 Katmanlı CNN Modeli Sonuç Grafiği.....55

Şekil 4. 6: CLAHE Algoritması ve 5 Katmanlı CNN Modeli Sonuç Grafiği.....57

Şekil 4. 7: 32×32 Boyutlu Görüntülerin 3 Katmanlı 300 Eğitim Tur Sayılı CNN Modeli Doğruluk Grafiği 59

Şekil 4. 8: 128×128 Boyutlu Görüntülerin 3 Katmanlı 150 Eğitim Tur Sayılı CNN Modeli Doğruluk Grafiği.....60

Şekil 4. 9: 128×128 Boyutlu Görüntülerin 5 Katmanlı 150 Eğitim Tur Sayılı CNN Modeli Doğruluk Grafiği.....60

TABLO LİSTESİ

Sayfa No

Tablo 4. 1: Ham Görüntülerin 3 Katmanlı CNN Modeli Performans Metrikleri 44

Tablo 4. 2: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri 45

Tablo 4. 3: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri 47

Tablo 4. 4: Ham Görüntülerin 3 Katmanlı CNN Modeli Performans Metrikleri 49

Tablo 4. 5: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri 50

Tablo 4. 6: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri 52

Tablo 4. 7: Ham Görüntülerin 5 Katmanlı CNN Modeli Performans Metrikleri 54

Tablo 4. 8: Gabor Filtreleme Algoritması ve 5 Katmanlı CNN Modeli Performans Metrikleri 55

Tablo 4. 9: CLAHE Algoritması ve 5 Katmanlı CNN Modeli Performans Metrikleri 57

Tablo 4. 10: CNN Derin Öğrenme Modellerinin Çalışma Süresi ve Kayıp Oranları.....61

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

λ : Gabor Filtresi Kosinüsün Dalga Boyu (Açısı)
θ : Gabor Filtresi Fonksiyonun Yönü (Açısı)

Kısaltmalar **Açıklama**

2D : İki Boyutlu
3D : Üç Boyutlu
AI : Artificial Intelligence
AMIDA : Assessment of Mitosis Detection Algorithms
ANN : Artificial Neural Network
BR : Boarder Regions
BT : Bilgisayarlı Tomografi
CDF : Cumulative Distribution Functions
CLAHE : Contrast Limited Adaptive Histogram Equalization
CNN : Convolutional Neural Network
CR : Corner Regions
DBNs : Deep Belief Networks
DCNN : Deep Convolutional Neural Network
DICOM : Digital Imaging And Communications in Medicine
DL : Deep Learning
DNA : Deoksiribo Nükleik Asit
FN : False Negative
FP : False Positive
GANs : Generative Adversarial Networks
GAP : Global Average Pooling
GPU : Graphics Processing Unit
IR : Inner Regions
KHAK : Küçük Hücreli Akciğer Kanseri
KHDAK : Küçük Hücreli Dışı Akciğer Kanseri
KNG-CNN : Kernel Based Non-Gaussian Convolutional Neural Network

LASSO : Least Absolute Shrinkage and Selection Operator
LIDC-IDRI : The Lung Image Database Consortium
LSTM : Long Short Term Memory Network
ML : Machine Learning
MLPs : Multilayer Perceptrons
NCI : National Cancer Institute
NSCLC : Non-Small Cell Lung Cancer
PET-BT : Pozitron Emisyon Tomografi-Bilgisayarlı Tomografi
PNG : Portable Network Graphics
RBFNs : Radial Basis Function Networks
RBMs : Restricted Boltzmann Machines
ReLU : Rectified Linear Unit
RGB : Red, Green, Blue
RNNs : Recurrent Neural Networks
SDAE : Stacked Denoising Autoencoder
SOMs : Self Organizing Maps
SVM : Support Vector Machine
TCIA : The Cancer Imaging Archive
TN : True Negative
TP : True Positive
WHO : World Health Organization
WSI : Whole Slide Images
YSA : Yapay Sinir Ağları

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME TABANLI BİLGİSAYAR DESTEKLİ AKCİĞER KANSERİ TESPİTİ

Büşranur BAHAT

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Pelin GÖRGEL

Dünya Sağlık Örgütü istatistiklerine bakıldığında 2020' de en yaygın kanser türlerinde ikinci sırada akciğer kanseri yer almaktadır. Bunun yanı sıra kanser ölümlerinin en sık nedeni ise akciğer kanseri olduğu görülmektedir. Akciğer kanseri tedavi sürecinde yapılan bilgisayarlı tomografi taramaları radyologlar tarafından incelenmektedir. Bu görüntülerin analizi uzun zaman alabilmektedir. Nodüllerin tespitinin deneyimli doktorlar tarafından yapılması bile çok zor olduğundan bilgisayarlı tomografi taramaları radyologlar için büyük ölçüde yük oluşturmaktadır. Bundan dolayı bilim insanları, doktorların ve alanında uzman kişilerin yüklerini hafifletmek ve teşhislerde iyileştirme yapmak için bilgisayar destekli çözümler üzerine çalışmaktadırlar. Önerilen çalışmaların çoğu makine öğrenmesi ve derin öğrenme üzerine gerçekleşmektedir. Bu çalışmanın amacı da erken tanı için bilgisayar destekli akciğer kanseri tespitinin yapılmasıdır. Bu tezde derin öğrenme tabanlı evrişimsel sinir ağı kullanılarak akciğer kanseri tespitinin yapılması hedeflenmiştir. Deneysel sonuçlar için Amerikan Ulusal Kanser Enstitüsü' ne ait LIDC-IDRI veri kümesindeki akciğer tomografi görüntüleri kullanılmıştır. Akciğer görüntüleri evrişimsel sinir ağı derin öğrenme modeline girdi olarak

verilmiştir. Fakat akciğer kanseri tespitinin daha yüksek doğruluğa sahip olması için görüntülere ön işlem yapılmıştır. Bu ön işlemlerin ilki Gabor filtrelemedir. Gabor filtreleme ile ilgili parametrelerde farklı değerler denenerek en iyi sonucun elde edilmesi amaçlanmıştır. Sonrasında filtrelenmiş görüntülere CLAHE işlemi uygulanmış, yeni görüntüler farklı evrişimsel sinir ağı derin öğrenme modellerine girdi olarak verilmiş ve sonuçlar kıyaslanmıştır. Deneysel sonuçlara göre en yüksek doğruluk değeri %99.701 olarak elde edilmiştir.

Aralık 2021, 84 sayfa.

Anahtar kelimeler: Derin öğrenme, evrişimsel sinir ağları, gabor filtresi, CLAHE, akciğer kanseri tespiti

SUMMARY

M.Sc. THESIS

DEEP LEARNING BASED COMPUTER AIDED LUNG CANCER DETECTION

Büşranur BAHAT

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Computer Engineering

Supervisor : Assist. Prof. Dr. Pelin GÖRGEL

According to the the statistics of the World Health Organization, lung cancer ranks second among the most common cancer types in 2020. In addition, the most common cause of cancer deaths is lung cancer. Computed tomography images that acquired during the treatment process of lung cancer are examined by radiologists. Analysis of these images can take a long time. Since the detection of nodules is very difficult even for the experienced doctors, computed tomography scans create a great burden for the radiologists. Hence scientists have been studying on computer-assisted solutions to relieve the burden of doctors and experts and also to improve diagnostics. Most of the studies have been proposed are on machine learning and deep learning. The goal of this study is to implement computer aided lung cancer detection for early diagnosis. In this thesis, it is aimed to detect lung cancer using deep learning based convolutional neural network. Lung tomography images in the LIDC-IDRI dataset of the American National Cancer Institute are used for the experimental results. Lung images are given as inputs to the convolutional neural network deep learning model. However, images are pre-processed in order

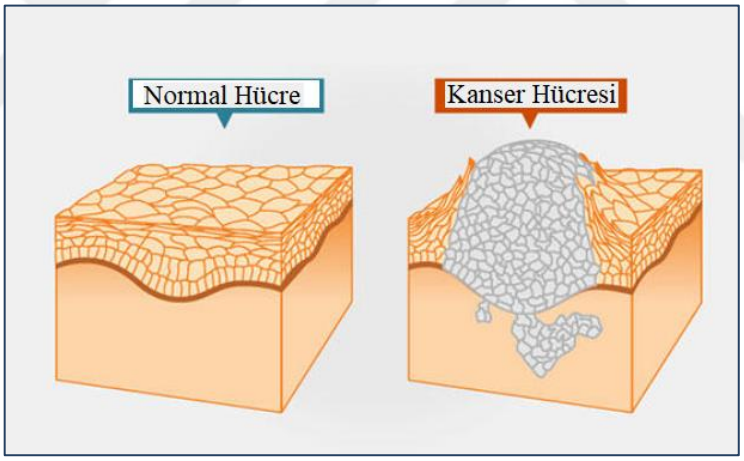
to have a higher lung cancer detection accuracy. One of these pre-processes is Gabor filtering. It is aimed to obtain the best result by trying different parameter values regarding to Gabor filtering. Afterwards, the CLAHE process is applied to the filtered images, then the processed images are given as inputs to the different convolutional neural network deep learning models and the results are compared. According to the experimental results, the highest accuracy is obtained as of 99.701%.

December 2021, 84 pages.

Keywords: Deep learning, convolutional neural networks, gabor filter, clahe, lung cancer detection

1. GİRİŞ

Kanser, vücuttaki bazı hücrelerin kontrolsüz bir şekilde büyüdüğü ve vücudun diğer bölgelerine yayıldığı bir hastalıktır. Kanser, trilyonlarca hücreden oluşan insan vücudunda hemen hemen her yerde başlayabilir. Normalde insan hücreleri, vücudun ihtiyaç duyduğu yeni hücreler oluşturmak için büyür ve çoğalır. Hücreler yaşlandıklarında veya hasar gördüklerinde ölürler ve yerlerini yeni hücreler alır. Bazen bu düzenli süreç bozulur ve anormal veya hasarlı hücreler büyümemeleri gerekirken çoğalır. Bu hücreler, doku topakları olan tümörler oluşturabilir. Tümörler kanserli olabilir veya kanserli olmayabilir (iyi huylu). Kanserli tümörler yakındaki dokulara yayılır veya onları istila eder ve vücutta uzak yerlere seyahat ederek yeni tümörler oluşturabilir. (Amerika Ulusal Kanser Enstitüsü, 2021) Şekil 1.1' de normal ve kanserli hücre örnek olarak gösterilmektedir.



Şekil 1. 1: Normal Hücre ve Kanserli Hücre Örneği (Amerika Ulusal Kanser Enstitüsü, 2021)

Kanser genetik bir hastalıktır; yani, hücrelerimizin işleyişini, özellikle nasıl büyüyüp bölündüklerini kontrol eden genlerdeki değişikliklerden kaynaklanır. Kansere neden olan genetik değişiklikler şu nedenlerle olabilir: (Amerika Ulusal Kanser Enstitüsü, 2021)

- Hücreler bölünürken meydana gelen hataların
- Tütün dumanındaki kimyasallar ve güneşten gelen ultraviyole ışınları gibi çevredeki zararlı maddeler tarafından DNA'ya verilen zarar.
- Kanserin ebeveyn genlerinde bulunması.

Vücut normalde kanserli hale gelmeden önce hasarlı DNA'lı hücreleri ortadan kaldırır. Ancak vücudun bunu yapma yeteneği yaşlandıkça azalır. Bu, daha sonraki yaşamda kanser riskinin daha yüksek olmasının nedeninin bir parçasıdır.

Akciğer kanseri, akciğerlerde başlayan bir kanser türüdür. Akciğer kanseri, yapısal olarak normal akciğer dokusundan olan hücrelerin ihtiyaç ve kontrol dışı çoğalarak akciğer içinde bir kitle oluşturmasıdır. Burada oluşan kitle öncelikle bulunduğu ortamda büyür, daha ileriki aşamalarda ise çevre dokulara veya dolaşım yoluyla uzak oranlara yayılarak hasara yol açabilmektedir. (T.C. Sağlık Bakanlığı, 2021)

Dünya Sağlık Örgütü (World Health Organization-WHO) istatistiklerine bakıldığında 2020'de en yaygın kanser türlerinde 2.26 milyon vaka ile meme kanseri ardından 2.21 milyon vaka ile akciğer kanseri yer almaktadır. Bununla birlikte kanser ölümlerin en sık nedeni ise 1.8 milyon ölüm ile yaklaşık %36' lık bir oranla akciğer kanseri olduğu görülmektedir. (Dünya Sağlık Örgütü, 2020)

Akciğer kanseri tanısı konulması için düz akciğer röntgenleri ile akciğerde kitle görülen hastalara, öncelikle bilgisayarlı tomografi çekilir. Elde edilen üç boyutlu görüntü ile kitleye nasıl ulaşılabileceğine karar verilir. Hastadan ya tomografi rehberliğinde ya da bronkoskopi denilen ince bükülebilir bir tüple akciğerine ulaşılarak iğneyle parça alınır. Bu işleme biyopsi adı verilmektedir.

Tedavi sürecinde yapılan bilgisayarlı tomografi taramaları bir radyolog tarafından incelenmesi gerekmektedir. Bu görüntülerin analizi uzun zaman alabilmektedir. Nodüllerin tespitinin deneyimli doktorlar tarafından yapılması bile çok zor olduğundan bilgisayarlı tomografi taramaları radyologlar için büyük ölçüde yük oluşturmaktadır. Erken teşhis ve önleyici tedbirlerin sayısında beklenen artış ile birlikte bilim insanları, doktorların ve alanında uzman kişilerin yüklerinin hafifletmeye ve teşhislerde iyileştirme yapılması için bilgisayar destekli çözümler üzerine çalışmaktadırlar. Yapılan çalışmaların çoğu makine öğrenmesi ve derin öğrenme üzerine gerçekleşmektedir.

Bu çalışmada kanserin dünya üzerindeki en sık ölüm nedeni olan akciğer kanserinin uzmanlar tarafından erken tanı ve teşhisinde fayda sağlayabilecek bir yöntem sunulmaya çalışıldı. Öncelikle akciğer kanseri hakkında bilgi verilmiştir. Sonrasında kullanılacak olan yöntemler ve literatürde olan teknikler tanıtılmıştır.

Çalışmada, akciğer kanserinin erken teşhisinde önemli yeri olan bilgisayarlı tomografi görüntülerinin uzmanlara yardımcı olması açısından akciğerin kanserli olup olmadığının belirlenmesi hedeflenmiştir. Amerika Ulusal Kanser Enstitüsü (National Cancer Institute-NCI)' ne ait dijital bilgisayarlı tomografi görüntülerini barındıran The Lung Image Database Consortium (LIDC-IDRI) veri kümesi kullanılmıştır. Bu görüntüler üzerinde farklı parametre değerleri için Gabor filtreleme ve CLAHE algoritmaları uygulanarak Evrişimsel Sinir Ağı (Convolutional Neural Network-CNN) derin öğrenme modelinin performansı ölçülmüştür.

Kullanılan yöntemin temeli evrişimsel sinir ağı derin öğrenme modeline dayanmaktadır. Evrişimsel sinir ağı modeli öncesinde görüntülere Gabor filtreleme ve CLAHE algoritmaları uygulanarak ön işlem yapılmıştır. Elde edilen yeni görüntü kümeleri CNN derin öğrenme modeline girdi olarak verilerek kanser tespitinin yapılması amaçlanmıştır. Yapılan ön işlemlerle akciğer kanseri tespiti için derin öğrenme modelinde daha yüksek doğruluk değeri elde edilmesi hedeflenmiştir.

2. GENEL KISIMLAR

2.1. AKCİĞER KANSERİ

Kanser, vücuttaki hücrelerin kontrolden çıktığı bir hastalıktır. Kanser akciğerlerde başladığında buna akciğer kanseri denir. Akciğer kanseri akciğerlerde başlar ve beyin gibi vücuttaki lenf düğümlerine veya diğer organlara yayılabilir. Diğer organlardan gelen kanser de akciğerlere yayılabilir. Kanser hücreleri bir organdan diğerine yayıldığında metastaz olarak adlandırılır. Akciğer kanserleri genellikle küçük hücreli ve küçük hücreli olmayan olarak adlandırılan iki ana tipe ayrılır. Bu akciğer kanseri türleri farklı şekilde büyür ve farklı şekilde tedavi edilir. Küçük hücreli olmayan akciğer kanseri, küçük hücreli akciğer kanserinden daha yaygındır. (CDC, 2021)

2.1.1 Akciğer Kanseri Türleri

Akciğer kanserleri başlıca iki gruba ayrılır: küçük hücreli akciğer kanseri (KHAK) ve küçük hücreli dışı akciğer kanseri (KHDAK). Bu sınıflandırma tümörün mikroskobik görüntüsüne dayanarak yapılır. Bu iki tip kanserin büyüme hızları, yayılımları ve tedavileri farklıdır. (Türk Toraks Derneği, 2021)

Küçük hücreli akciğer kanseri (KHAK): Akciğer kanserlerinin %10-15'ini oluşturur. En hızlı büyüyen ve en hızlı yayılım gösteren tipidir. Sigara ile çok yakından ilişkilidir, bu tümörlerin sadece %1'i sigara içmemiş kişilerde ortaya çıkar. Çok hızlı metastaz yaptığından genellikle tanı konulduğu sırada vücutta yayılmış olduğu görülür. Bununla beraber kemoterapiye yanıtı iyidir. (Türk Toraks Derneği, 2021)

Küçük hücreli dışı akciğer kanseri (KHDAK): En sık görülen akciğer kanseridir, tüm hastaların %85-90'ını oluşturur. KHDAK'nin 3 ana tipi vardır: (Türk Toraks Derneği, 2021)

- *Adenokanser:* Kadınlarda ve sigara içmeyenlerde daha sık görülür. Gelişmiş ülkelerde en sık görülen akciğer kanseri türüdür.
- *Skuamöz hücreli kanser:* Ülkemizde en sık görülen akciğer kanseri türüdür. Erkeklerde daha sık görülür. Sigara kullanımı ile yakından ilişkilidir. Hastalık sıklıkla akciğer içine sınırlı kalır veya komşu lenf bezelerine yayılır.

- *Büyük hücreli kanser:* KHDAK içinde en az sıklıkta görülenidir ve tüm akciğer kanserlerinin %10 kadarını oluşturur. Uzak organlara yayılım yapma eğilimi fazladır.

2.1.2 Akciğer Kanseri İçin Risk Faktörleri

Sigara İçmek: Sigara içmek akciğer kanseri için bir numaralı risk faktörüdür. Puro veya pipo gibi diğer tütün ürünlerini kullanmak da akciğer kanseri riskini artırır. Tütün dumanı, 7.000'den fazla kimyasalın zehirli bir karışımıdır. Birçoğu zehirdir. En az 70'inin insanlarda veya hayvanlarda kansere neden olduğu bilinmektedir. Sigara içen kişilerin akciğer kanserine yakalanma veya akciğer kanserinden ölme olasılığı, sigara içmeyenlere göre 15 ila 30 kat daha fazladır. Günde birkaç sigara içmek veya bazen sigara içmek bile akciğer kanseri riskini artırır. Bir kişi ne kadar çok yıl içerse ve her gün ne kadar çok sigara içerse, risk o kadar artar. Sigarayı bırakan kişilerin akciğer kanseri riski, sigara içmeye devam etmiş olanlara göre daha düşüktür, ancak riskleri hiç sigara içmemiş kişilere göre daha yüksektir. Sigarayı herhangi bir yaşta bırakmak akciğer kanseri riskini azaltabilir. Sigara içmek vücudun hemen hemen her yerinde kansere neden olabilir. Sigara ağız ve boğaz, yemek borusu, mide, kolon, rektum, karaciğer, pankreas, gırtlak, soluk borusu, bronş, böbrek ve renal pelvis, mesane ve serviks kanserine, akut miyeloid lösemiye neden olur. (CDC, 2021)

Pasif İçicilik: Başkalarının sigaralarından, pipolarından veya purolarından çıkan duman da akciğer kanserine neden olur. Bir kişi ikinci el dumanı soluduğunda, sigara içiyor gibi olur. (CDC, 2021)

Radon: Radon, kayalarda, toprakta ve suda oluşan doğal olarak oluşan bir gazdır. Görülemez, tadılamaz veya koklanamaz. Radon, çatlaklardan veya deliklerden evlere veya binalara girdiğinde sıkışabilir ve içeride havada birikebilir. Bu evlerde ve binalarda yaşayan veya çalışan insanlar yüksek radon seviyelerinde nefes alırlar. Radon, uzun süre boyunca akciğer kanserine neden olabilir. (CDC, 2021)

Diğer Maddeler: Bazı işyerlerinde bulunan ve riski artıran maddelere örnek olarak asbest, arsenik, dizel egzozu ve bazı silika ve krom formları verilebilir. Bu maddelerin birçoğu için, sigara içenlerin akciğer kanserine yakalanma riski daha da yüksektir. (CDC, 2021)

Akciğer Kanserinin Kişisel veya Aile Öyküsü: Akciğer kanserinden kurtulan kişilerde, özellikle sigara içiyorsa, başka bir akciğer kanseri geliştirme riski vardır. Ebeveynleri, erkek

veya kız kardeşleri veya çocukları akciğer kanseri olmuşsa, akciğer kanseri riski daha yüksek olabilir. (CDC, 2021)

Göğüse Radyasyon Tedavisi: Göğüs bölgesine radyasyon tedavisi gören kanserden kurtulanlar daha yüksek akciğer kanseri riski altındadır. (CDC, 2021)

Diyet: Bilim adamları, akciğer kanserine yakalanma riskini değiştirip değiştirmediklerini görmek için birçok farklı gıda ve besin takviyesi üzerinde çalışmaktadırlar. Sigara içen ve beta-karoten takviyesi alan kişilerin akciğer kanseri riskinin arttığını bilinmektedir. (CDC, 2021)

2.1.3 Akciğer Kanseri Belirtileri

Farklı kişilerin akciğer kanseri için farklı semptomları vardır. Akciğer kanseri vücudun diğer bölgelerine yayılmış bazı kişilerde vücudun o bölgesine özgü semptomlar görülür. Akciğer kanseri olan çoğu insanda kanser ilerleyene kadar semptom görülmez. Akciğer kanseri belirtileri şunlar olabilmektedir: (CDC, 2021)

- Kötüleşen veya geçmeyen öksürük
- Göğüs ağrısı
- Nefes darlığı
- Hırıltı
- Kan tükürme
- Her zaman çok yorgun hissetmek
- Bilinen bir nedeni olmayan kilo kaybı

Bazen akciğer kanseri ile ortaya çıkabilecek diğer değişiklikler, akciğerler arasındaki alanda göğüs içinde tekrarlayan pnömoni nöbetleri ve şişmiş veya genişlemiş lenf düğümlerini içerebilir. Bu semptomlar diğer hastalıklarda da olabilir. Bu belirtilerden bazılarına sahip kişilerin doktordan yardım almaları gerekir.

2.1.4 Akciğer Kanseri Teşhisi

Göğüs Röntgeni: Göğüs röntgeni genellikle akciğer kanserini teşhis etmek için kullanılan ilk testtir. Çoğu akciğer tümörü, X-ışınlarında beyaz-gri bir kütle olarak görünür. Bununla birlikte, göğüs röntgenleri kesin bir teşhis veremez çünkü genellikle kanser ile akciğer apsesi gibi diğer

durumları ayırt edemezler. Göğüs röntgeni akciğer kanseri olabileceğini gösteriyorsa, göğüs hastalıkları uzmanına sevk edilmelidir. Bir uzman, akciğer kanseri olup olmadığını ve varsa ne tür olduğunu ve ne kadar yayıldığını araştırmak için daha fazla test ayarlayabilir. (Ulusal Sağlık Hizmeti, 2019)

Bilgisayarlı Tomografi Taraması (BT): Bilgisayarlı tomografi taraması genellikle göğüs röntgeninden sonra yapılan bir sonraki testtir. Bilgisayarlı tomografi taraması, vücudunuzun içinin ayrıntılı görüntülerini oluşturmak için X ışınları ve bir bilgisayar kullanır. Bilgisayarlı tomografi taraması yapmadan önce, görüntülerin kalitesini artırmaya yardımcı olan, kontrast madde adı verilen özel bir boya içeren bir enjeksiyon verilerek yapılır. Tarama ağrısızdır ve 10 ila 30 dakika sürer. (Ulusal Sağlık Hizmeti, 2019) Şekil 2. 1' de örnek bilgisayarlı tomografi cihazı görülmektedir.



Şekil 2. 1: Bilgisayarlı Tomografi Cihazı (Wikipedia, 2004)

Pozitron Emisyon Tomografi-Bilgisayarlı Tomografi Taraması (PET-BT): Bilgisayarlı tomografi taramasının sonuçları erken bir aşamada kanseriniz olduğunu gösteriyorsa, PET-BT taraması yapılabilir. PET-BT taraması aktif kanser hücrelerinin nerede olduğunu gösterebilir. Bu, teşhise ve en iyi tedaviyi seçmeye yardımcı olabilir. PET-BT taraması yaptırmadan önce, hafif radyoaktif bir madde enjekte edilir. PET tarayıcıya kayan bir masaya uzanarak yapılır. Tarama ağrısızdır ve 30 ila 60 dakika sürer. (Ulusal Sağlık Hizmeti, 2019) Şekil 2. 2' de örnek bilgisayarlı tomografi cihazı görülmektedir.



Şekil 2. 2: Pozitron Emisyon Tomografi Cihazı (Wikipedia, 2004)

Bronkoskopi ve Biyopsi: BT taraması göğsün orta kısmında kanser olabileceğini gösteriyorsa, bronkoskopi önerilebilir. Bronkoskopi, doktorun solunum yollarının içini görmesini ve küçük bir hücre örneğini (biyopsi) çıkarmasını sağlayan bir prosedürdür. Bronkoskopi sırasında, ucunda kamera bulunan ve bronkoskop adı verilen ince bir tüp ağızdan veya burundan geçirilir, boğazdan aşağıya ve solunum yollarına girer. Prosedür rahatsız edici olabilir, bu nedenle başlamadan önce rahatlamaya yardımcı olması için bir sakinleştirici ve boğazı uyuşturmak için lokal anestezi önerilir. İşlem yaklaşık 30 ila 40 dakika sürer. Bir bronkoskopiyi bir ultrason taraması ile birleştiren endobronşiyal ultrason taraması olarak adlandırılır. Bronkoskopi gibi, endobronşiyal ultrason taramasıda doktorun solunum yollarının içini görmesini sağlar. Bununla birlikte, kameranın ucundaki ultrason probu, doktorun göğsün ortasındaki lenf düğümlerini bulmasını ve onlardan biyopsi alabilmesini de sağlar. İşlem yaklaşık 90 dakika sürer. Lenf düğümleri, vücuda yayılan ve bağışıklık sisteminin bir parçası olarak çalışan bir damar ve bez ağının parçasıdır. Bir lenf düğümünden alınan biyopsi, kanserli hücrelerin orada büyüyüp büyümediğini ve ne tür olduklarını gösterebilir. (Ulusal Sağlık Hizmeti, 2019)

Diğer Biyopsi Türleri: Torakoskopi, mediastinoskopi veya cildinize (perkütan) yerleştirilen bir iğne kullanılarak yapılan biyopsi gibi bir tür cerrahi biyopsiler de bulunmaktadır. (Ulusal Sağlık Hizmeti, 2019)

2.1.5 Akciğer Kanseri Tedavisi

Akciğer kanseri tedavisi, mümkün olan en iyi tedaviyi sağlamak için birlikte çalışan farklı departmanlardaki uzmanlardan oluşan bir ekip tarafından yönetilir. Bu ekip, tanı koymak, kanseri evrelemek ve en iyi tedaviyi planlamak için gerekli sağlık profesyonellerini içerir. Akciğer kanseri için alınan tedavi türü, aşağıdakiler de dahil olmak üzere çeşitli faktörlere bağlıdır: (Ulusal Sağlık Hizmeti, 2019)

- Akciğer kanserinin türü
- Kanserin boyutu ve konumu
- Kanserin hangi aşamada olduğu
- Kişinin genel sağlığı

En yaygın tedavi seçenekleri cerrahi, radyoterapi, kemoterapi ve immünoterapidir. Kanserin tipine ve evresine bağlı olarak, bu tedavilerin bir kombinasyonu alınabilmektedir.

2.1.6 Akciğer Kanseri Alanında Yapılan Çalışmalar

Son yıllarda akciğer kanserinin erken tanısı için bilgisayar destekli çalışmalar yapılmaktadır. Bu çalışmalarda akciğer tomografi görüntülerinde kanser tespiti için birçok yöntem kullanılmıştır. Yapılan çalışmalara bakıldığında;

Alakwaa ve arkadaşları (2017) çalışmalarında Kaggle Data Science Bowl akciğer görüntülerinin olduğu LUNA veri setini kullanmışlardır. Görüntülerini sınıflandırmasında Evrişimsel Sinir Ağı kullanmışlardır. Nodül tespiti için U-net CNN mimarisini kullanmışlardır. Çalışmanın sonucunda U-net CNN yönteminin doğruluk oranı %86.6 olarak bulunmuştur.

Bhatia ve arkadaşları (2019) çalışmalarında akciğer görüntülerinin bulunduğu The Lung Image Database Consortium (LIDC-IDRI) veri setini kullanmışlardır. Yapılan çalışmada akciğer kanseri için derin öğrenme algoritmaları bazında Random Forest ve XGBoost gibi

sınıflandırmaların perfonmansı karşılaştırılmıştır. İkisininde birlikte kullanıldığında ise en yüksek doğruluk oranına ulaşılmıştır ve bu oran %84 olarak bulunmuştur.

Chaunzwa ve arkadaşları (2018) çalışmalarında Non-Small Cell Lung Cancer (NSCLC) veri setini kullanmışlardır. Akciğer kanseri histolojisini tahmin etmek için CNN derin öğrenme metodun ile En Az Mutlak Büzülme ve Seçim Operatörü (LASSO)sınıflandırma yöntemini kullandılar ve %75.1 doğruluk oranı elde ettiler.

Kumar ve arkadaşları (2015) çalışmalarında akciğer görüntülerinin bulunduğu LIDC (TCIA) veri seti ile akciğer görüntülerinde derin özelliklere göre akciğer nodülü sınıflandırması yaptılar. Sistemin bir tümörü iyi huylu veya kötü huylu olarak sınıflandırma yapmayı amaçlamışlardır. Sonuç olarak elde ettikleri doğruluk oranı %75.01 olmuştur.

Kuruvilla ve arkadaşları (2014) çalışmalarında akciğer görüntülerinin bulunduğu The Lung Image Database Consortium (LIDC-IDRI) veri setini kullanmışlardır. Farklı istatistiksel parametreler ile sınıflandırma yapmışlardır. İki farklı fonksiyon önermişlerdir. Ağın on üç kez eğitiminden sonra varolan en iyi fonksiyonun doğruluk değeri %91.1 iken önerilen bu fonksiyonlardan ilki %93.3, ikincisi %93.3 olarak elde edilmiştir.

Monkam ve arkadaşları (2018) çalışmalarında akciğer görüntülerinin bulunduğu The Lung Image Database Consortium (LIDC-IDRI) veri setini kullanmışlardır. Çalışmada CNN modellerinin performansının büyük ölçüde yamaların boyutuna ve evrişimli katmanların sayısına bağlı olduğu bulunmuştur. İki evrişimli katmana sahip CNN modeli, 32 × 32 yama boyutunda en iyi performansı sunarak %88.28 doğruluk oranı elde etmişlerdir.

Moitra ve arkadaşları (2020) çalışmalarında Non-Small Cell Lung Cancer (NSCLC) veri setini kullanmışlardır. Önerilen CNN modelinin doğruluk diğer önde gelen makine öğrenimi yöntemlerinden daha yüksek değerdedir. Çalışmada önerilen model, 1D CNN'nin NSCLC tahmininde geleneksel bir 2D / 3D CNN modeli gibi eşit derecede yararlı olduğunu göstermektedir.

Rossetto arkadaşı (2017) çalışmalarında akciğer görüntülerinin bulunduğu Kaggle Data Science Bowl veri setini kullanmışlardır. Burada, taramaların otomatik etiketlemesinin doğruluğunu artırmak için çoklu ön işleme yöntemlerini kullanan bir Evrişimsel Sinir Ağı (CNN) yapısı

kurmuşlardır. Yapılan çalışma sonucunda CNN yönteminin doğruluk oranı %97.5 olarak bulunmuştur.

Silva ve arkadaşları (2017) çalışmalarında akciğer görüntülerinin bulunduğu The Lung Image Database Consortium (LIDC-IDRI) veri setini kullanmışlardır. Akciğer nodüllerini kötü huylu veya iyi huylu olarak sınıflandırmak için genetik algoritmayla birlikte derin öğrenme tekniğinden yararlanmışlardır. Yapılan çalışmada CNN yönteminin doğruluk oranı %94.78 olarak bulunmuştur.

Sun ve arkadaşları (2016) çalışmalarında Lung Image Database Consortium (LIDC) veri setini kullanmışlardır. Akciğer kanseri görüntü teşhisinde üç farklı derin öğrenme algoritmasının performansını uygulamışlardır ve çıkan sonuçları kıyaslamışlardır. Yapılan çalışmada doğruluk oranları Evrişimli Sinir Ağı (CNN) %79.76, Derin İnanç Ağları (DBN'ler) %81.19, Yığın Gürültü Azaltıcı Otomatik Kodlayıcı (stacked denoising autoencoder-SDAE) %79.29 olarak bulunmuştur.

Teramoto ve arkadaşları (2017) çalışmalarında derin öğrenme tekniği olan derin evrişimli sinir ağı (DCNN) kullanarak mikroskobik görüntülerde sunulan akciğer kanserleri için otomatik bir sınıflandırma şeması geliştirmişlerdir. %71.1 doğruluk oranı elde etmişlerdir. DCNN'nin, hücre morfolojisini ve kanser hücrelerinin yerleşimini, önceden biyoloji ve patoloji bilgisi ve deneyimi olmaksızın yalnızca görüntülerden anlayabilmesi akciğer kanseri tanısında sitolojik incelemeye büyük katkı sağlayacağını ifade etmişlerdir.

Wang ve arkadaşları (2020) çalışmalarında akciğer kanseri görüntülerinin bulunduğu WSI veri setini kullanmışlardır. Evrişimsel Sinir Ağı (CNN) modeli akciğer kanseri sınıflandırması yaptılar. Çalışma sonucunda doğruluk oranı %97.3 olarak bulunmuştur.

Zainudin ve arkadaşları (2019) çalışmalarında AMIDA veri setini kullanmışlardır. Görüntüleri sınıflandırmasında Evrişimsel Sinir Ağı kullanmışlardır. Çalışmada 13 katmanlı ve 20 katmanlı CNN sonuçları kıyaslanmıştır. 13 katmanlı CNN’ nin doğruluk oranı %94.85, 20 katmanlı CNN’ nin doğruluk oranı %94.85 olarak bulunmuştur.

Zhang ve arkadaşları (2019) çalışmalarında akciğer görüntülerinin bulunduğu Luna16 ve Kaggle veri setlerini kullanmışlardır. Yapılan çalışmada CNN yönteminin doğruluk oranı

%83.0 olarak bulunmuştur. Daha fazla verinin elde olması halinde bu metod ile daha doğru sonuçlar elde edileceği belirtilmiştir.

Gupta ve arkadaşları (2020) özellikle CNN ve varyantı üzerinde çalışan LIDC-IDRI veri setine dayalı akciğer kanserine dayalı farklı araştırma makalelerinin incelemesini göstermişlerdir. Açıklanan makalelerde doğruluk %78.2 ile %92.34 arasında değiştiğini göstermişlerdir.

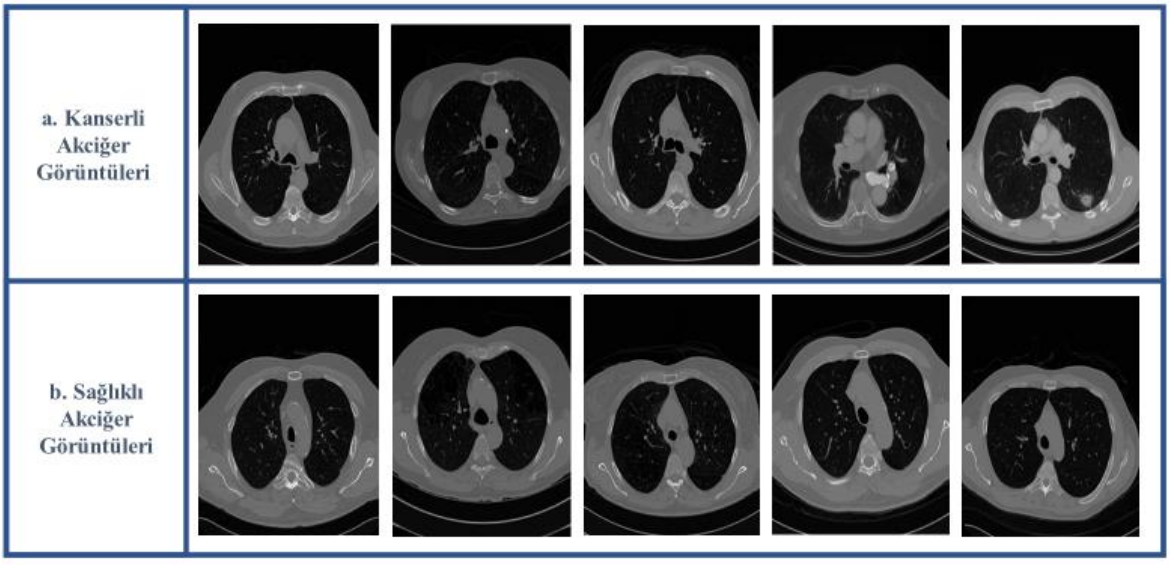
Jena ve arkadaşları (2020) LIDC-IDRI veri setini kullanarak ve Kernel tabanlı Non-Gaussian Convolutional Neural Network (KNG-CNN) ile BT görüntülerinde akciğer kanseri için bir sınıflandırma şeması geliştirmiştir. Bu teknik kullanılarak %87.3 doğruluk elde edilmiştir.

Ashhar ve arkadaşları (2021) beş yeni kurulan Evrişimli Sinir Ağı mimarisinin performansını üzerine çalışmıştır. Akciğer tümörlerini kötü huylu ve iyi huylu kategorilere ayırmak için GoogleNet, SqueezeNet, DenseNet, ShuffleNet ve MobileNetV2, LIDC-IDRI veri kümelerini kullanmıştır. Deneysel sonuçlar, GoogleNet'in %94.53 doğrulukla BT akciğer tümörü sınıflandırması için en iyi CNN mimarisi olduğunu göstermektedir.

3. MALZEME VE YÖNTEM

3.1. LIDC-IDRI VERİ SETİ

Amerika Ulusal Kanser Enstitüsü (National Cancer Institute (NCI)) herkese açık olarak indirilebilen geniş bir kanser tıbbi görüntü arşivini bir web sitesi (The Cancer Imaging Archive) ile internet ortamında paylaşmaktadır. Site farklı veri kümelerini barındırmaktadır. Bu veri kümeleri kanser türlerine göre sınıflandırılmıştır. Bu sınıflandırmaya ilaveten kanserin hangi bölgede olduğu, hangi canlı türüne dair veri olduğu, örnek veri sayısı, görüntüsü var ise görüntü türü, erişimin açık olup olmama durumu, veri kümesinin tamamlanma durumu ve son güncelleme tarihi gibi bilgileri de içermektedir. Veri kümelerindeki görüntüler farklı formatta olabilmektedir. Çalışmada akciğer görüntülerinin olduğu The Lung Image Database Consortium (LIDC-IDRI) veri kümesi kullanılmıştır. Veri kümesindeki akciğer görüntü verileri DICOM formatında tutulmaktadır. 1010 hastaya ait görüntü içermektedir. Toplam 244.527 akciğer görüntüsü bulunmaktadır. Bu görüntü verilerinin otomatik indirme işlemi için ayrıca bir indirme programına da site üzerinden ulaşılabilmektedir. Şekil 3.1' de LIDC-IDRI veri kümesine ait örnek kanserli akciğer görüntüleri a. Kanserli Akciğer Görüntüleri satırında, sağlıklı akciğer görüntüleri b. Sağlıklı Akciğer Görüntüleri satırında gösterilmektedir.

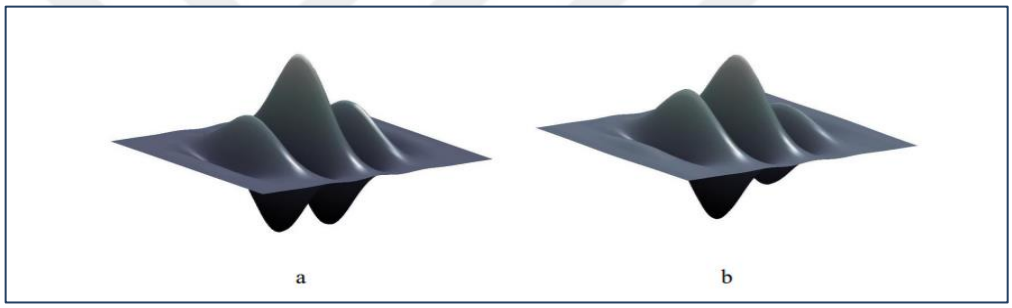


Şekil 3. 1: LIDC-IDRI Veri Kümesine Ait Akciğer Görüntüleri

3.2. GABOR FİLTRELEME ALGORİTMASI

Gabor filtresi görüntü analizi için popüler bir yöntemdir ve bilgisayarla görmede yaygın kullanım alanı bulmuştur. Yapılan çalışmalar arasında doku analizi, yüz izleme, yüz ve nesne tanıma gibi konular yer almaktadır.

Bir Gabor dalgacığı, iki boyutlu bir Gauss zarfıyla sınırlandırılmış karmaşık bir düzlemsel dalgadır. Şekil 3.2' de bir Gabor dalgacığının gerçek ve sanal bileşenlerini gösterilmektedir. Ölçek ve yönelim dışında, iki Gabor dalgacığını farklı kılan tek şey dalga boyu ile Gauss zarfının genişliği arasındaki orandır. Her Gabor dalgacığının belirli bir dalga boyu ve yönü vardır ve bu yaklaşık dalga boyunun yerel frekanslarının büyüklüğünü ve görüntüdeki yönelimi tahmin etmek için bir görüntü ile kıvrılabilir. (Loy, 2002)



Şekil 3. 2: Bir Gabor Dalgacık Çekirdeğinin Karesel Bileşenleri, a. Gerçek (Simetrik) Bileşen, b. Hayali (Asimetrik) Bileşen (Loy, 2002)

Karmaşık bir Gabor Dalgacığı(filtresi), Gauss Kernel ile karmaşık bir sinüsoidin çarpımı şeklinde tanımlanmaktadır. 2 boyutlu bir Gabor dalgacık dönüşümü I(x,y) imgesinin konvolüsyonuyla ifade edilir.(Buciu,2009)

$$J(x,y) = \iint I(x',y')g(x-x',y-y')\,dx'dy' \tag{3.1}$$

Burada g(x,y) fonksiyonu Gabor filtresini ifade eder: (Acar, 2012)

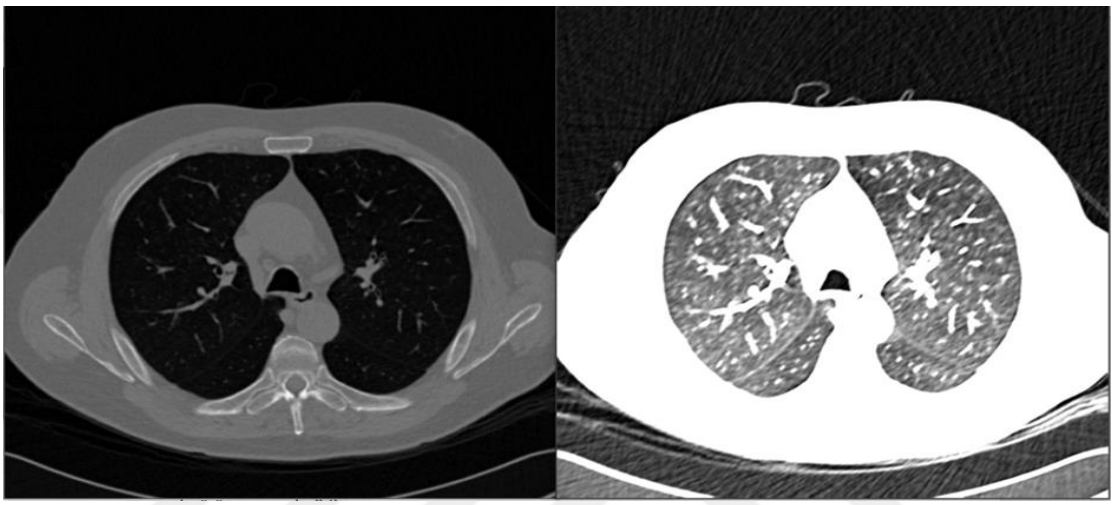
$$g(x,y,\lambda,\theta,\psi,\sigma,\gamma) = exp\left(-\frac{x_1^2+\gamma^2y_1^2}{2\sigma^2}\right)\ exp\left(i\left(2\pi\frac{x_1}{\lambda}+\ \psi\right)\right) \tag{3.2}$$

$$x_1 = x\cos\theta + y\sin\theta \tag{3.3}$$

$$y_1 = -x\sin\theta + y\cos\theta \tag{3.4}$$

Yukarıda tanımlanan λ ve θ parametreleri sırasıyla kosinüsün dalga boyu faktörünü ve Gabor fonksiyonun yönünü (açısal yönelimi) ifade eder. σ Gauss zarfının sigma/standart sapmasını, ψ fazın ofset değerini ve γ uzamsal görüş açısını belirtmektedir.

Şekil 3.3' te bir akciğere ait orjinal görüntüyü ve bu görüntüye Gabor dalgacığı filtresi uygulanmış olan görüntüyü göstermektedir.



a b

Şekil 3. 3: a. Orjinal Akciğer Görüntüsü, b. Gabor Dalgacığı Uygulanmış Akciğer Görüntüsü

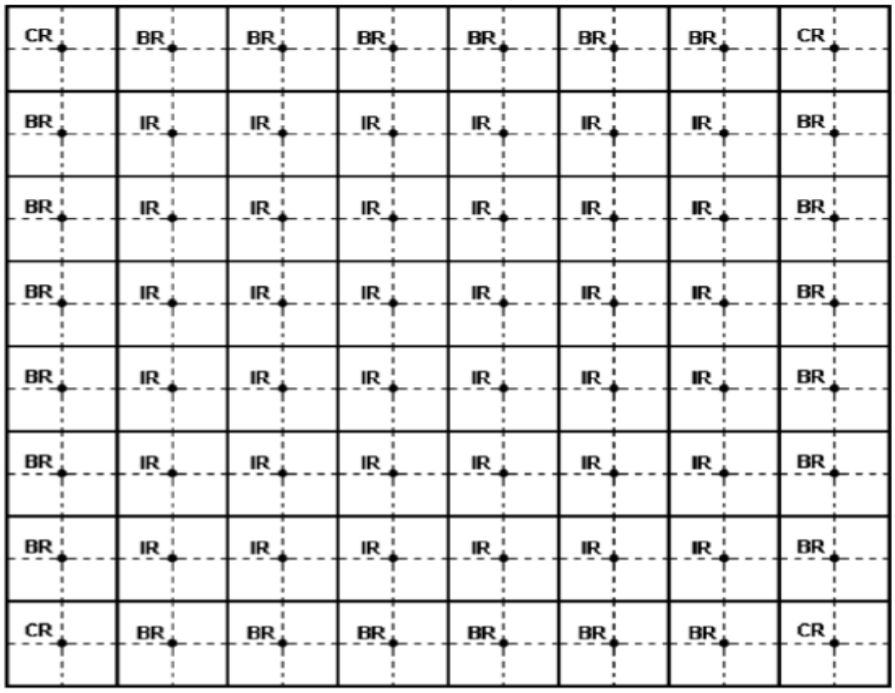
3.3. KONTRAST SINIRLI ADAPTİF HİSTOGRAM EŞİTLEME (CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION-CLAHE)

Görüntü iyileştirmede sıkça kullanılan histogram eşitlemede tüm görüntü histogramı ile yoğunluk dinamik aralığı genişletilerek görüntünün kalitesi iyileştirilebilmektedir. Histogram eşitlemede görüntünün yoğunluk dağılımı normalize edilerek düzgün bir yoğunluk dağılımına sahip sonuç görüntüsü elde edilerek iyileştirme işlemi gerçeklenmiş olur fakat görüntünün tamamının yoğunluk dağılımı kullanıldığı için bazı görüntülerde olumsuz etkiye de sebep olabilmektedir. Bunun gibi problemleri çözmek için farklı histogram eşitleme teknikleri geliştirilmiştir. (Reza, 2004)

Adaptif histogram eşitleme geliştirilmiş bir histogram eşitleme işlemidir ve veri üzerinde iyileştirme işlemini gerçekler. Burada görüntü ızgara şeklinde dikdörtgen bölgelere bölünür ve her bir bölgeye standart histogram eşitleme işlemi uygulanılarak iyileştirme sağlanmıştır fakat gürültü problemi ortaya çıkmıştır. Bunu engellemek için homojen bölgelerde kontrast

iyileştirmenin sınırlandırılması gerekmektedir, bu amaçla da kontrast sınırlı adaptif histogram eşitleme yöntemi geliştirilmiştir. Görüntü kesme sınırı (clip limit) belirlenebilmektedir. (Reza, 2004)

Kontrast sınırlı adaptif histogram eşitleme, tıbbi görüntülerde iyi sonuçlar vermiştir. Bu yöntem, görüntünün birbiriyle örtüşmeyen, hemen hemen eşit boyutlarda birkaç bölgeye bölünmesine dayalı olarak formüle edilmiştir. 512 × 512 görüntüler için, iyi bir istatistiksel tahmin elde etmek için, görüntü her yönde eşit olarak 8'e bölünerek bölge sayısı genellikle 64'e eşit olacak şekilde seçilir. Bu tür bir bölünmenin bir örneği Şekil 3.4' te gösterilmektedir. Bu bölüm, üç farklı bölge grubuyla sonuçlanır. Sadece dört bölgeden oluşan bir grup, köşe bölgeleri (corner regions-CR) sınıfıdır. 24 bölgeden oluşan ikinci grup ise yatılı bölgeler (boarder regions-BR) sınıfıdır. Köşe bölgeleri hariç, görüntü sınırlayıcıdaki tüm bölgeler bu sınıfa aittir. Kalan 36 bölgenin tamamını içeren son grup, iç bölgeler sınıfı (inner regions-IR) olarak adlandırılır. (Reza, 2004)



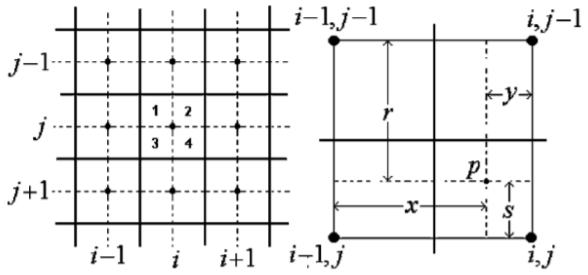
Şekil 3. 4: 512×512'lik Bir Görüntünün 64 Eşit Kare Bölgeye Ayrılmış Yapısı (Reza, 2004)

Bu yaklaşımda öncelikle her bölgenin histogramı hesaplanır. Daha sonra, kontrast genişletmesi için istenen bir sınıra dayalı olarak, kırpma histogramları için bir kırpma sınırı elde edilir. Ardından, her histogram, yüksekliği klip sınırını aşmayacak şekilde yeniden dağıtılır. Son

olarak, gri tonlamalı haritalama için elde edilen kontrast sınırlı histogramların kümülatif dağılım fonksiyonları (Cumulative Distribution Functions -CDF) belirlenir.

CLAHE tekniğinde pikseller, en yakın dört bölgenin eşlemelerinden elde edilen sonuçların doğrusal olarak birleştirilmesiyle eşlenir. IR grubundaki bölgeler için bu yaklaşımın formülasyonu basittir. Ancak, CR ve BR gruplarındaki bölgeler için bu formülasyon bazı özel değerlendirmeleri gerektirir. (Reza, 2004)

Her bölge dört çeyrek parça olarak düşünülür. Böylece, Şekil 3.5' te görüldüğü gibi IR grubundaki her bölgenin her çeyreği dört komşuya sahip olmaktadır. (Reza, 2004)



a. b.

Şekil 3. 5: a. Bir IR Bölgesi ve Komşuları, b. (i,j) Bölgesinin 1. Çeyreği Ve Ona En Yakın Dört Bölge ile İlişkisi (Reza, 2004)

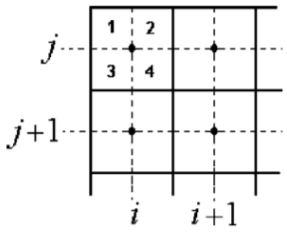
IR grubundaki bölgeler için bölgenin her çeyreği, en yakın dört komşu bölgenin eşlemelerine dayalı olarak eşlenir. Örneğin, Şekil 3.5 a.' ya bakacak olursak, *(i, j)* bölgesinin 1. çeyreğindeki belirli bir piksel, *(i, j)*, *(i, j − 1)*, *(i − 1, j)* ve *(i − 1, j−1)* bölgelerinin merkezlerinden dikey ve yatay uzaklıklarına göre eşlenir. Bu mesafeler (*r*, *s*, *x*, *y* değerleri) Şekil 3.5 b.' de gösterilmiştir. *(i, j)* bölgesindeki pikseller için eşleme işlevi $f_{i,j}$ ile temsil ediliyorsa, o zaman *(i, j)* bölgesinin ilk çeyreğindeki piksel p 'nin yeni değeri, belirtilen mesafelere göre formül 3.5 ile hesaplanmaktadır: (Reza, 2004)

$$p_{yeni} = \frac{s}{r+s}\left(\frac{y}{x+y} f_{i-1,j-1}(p_{eski}) + \frac{x}{x+y} f_{i,j-1}(p_{eski})\right) + \frac{r}{r+s}\left(\frac{y}{x+y} f_{i-1,j}(p_{eski}) + \frac{x}{x+y} f_{i,j}(p_{eski})\right) \quad (3.5)$$

BR grubundaki bölgeler için komşuluk yapısı farklılık göstermektedir. IR grubundaki bölgeler ile bu gruptaki en sağdaki bölgelerin 1. ve 3. çeyreğindeki piksellerin komşuluk yapıları aynıdır. Ancak 2. ve 4. çeyrekteki pikseller için komşuluk yapısı farklıdır ve bu çeyreklerdeki yeni piksel değerleri formül 3.6 ile hesaplanmaktadır. Bu durum BR grubundaki en soldaki bölgeler için ise tam tersidir. (Reza, 2004)

$$p_{yeni} = \frac{s}{r+s} f_{i,j-1}(p_{eski}) + \frac{r}{r+s} f_{i,j}(p_{eski}) \tag{3.6}$$

CR grubundaki bölgelerde farklı çeyrekler farklı karakteristiklere sahiptir. Bu gruptaki 1. çeyreğin hiçbir bölge ile komşuluğu olmadığı için diğerlerinden oldukça farklıdır. Bununla birlikte 4. çeyrek ise IR grubu bölgelerine benzer bir komşuluk yapısına sahip iken 2. ve 3. çeyrekteki pikseller BR bölgelerindeki iki yan çeyreğe benzer bir komşuluk yapısına sahiptirler. (Reza, 2004)

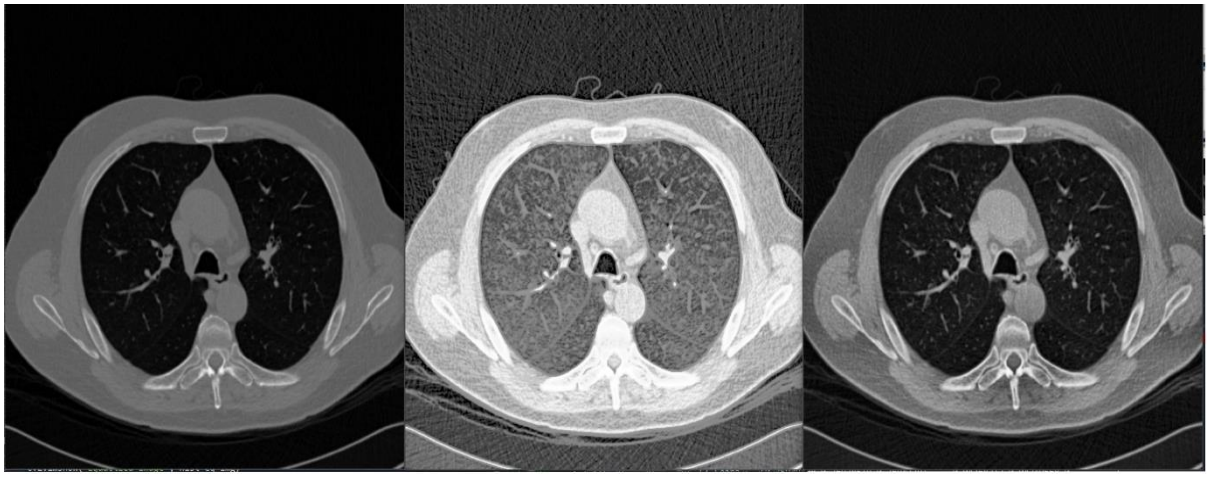


Şekil 3. 6: CR Grubu Bölgesi ve Komşulukları (Reza, 2004)

1. çeyrekteki piksellerin değeri hiçbir bölge ile komşuluğu olmadığı için değişmez. Formül 3.7' deki gibi hesaplama yapılmaktadır. (Reza, 2004)

$$p_{yeni} = f_{i,j}(p_{eski}) \tag{3.7}$$

Bu şekilde her bölge için gri seviye haritalama yapılarak sonuç görüntüsü elde edilmiş olur. Bir akciğer görüntüsüne ait orijinal görüntü, histogram eşitlemesi yapılmış görüntü ve CLAHE işlemi yapılmış görüntü Şekil 3.7' de gösterilmektedir.



a b c

Şekil 3. 7: a. Orjinal Akciğer Görüntüsü, b. Histogram Eşitlemesi Yapılan Akciğer Görüntüsü, c. CLAHE İşlemi Yapılan Akciğer Görüntüsü

3.4. MAKİNE ÖĞRENMESİ (MACHINE LEARNING-ML)

Makine öğrenimi, sistemlere açıkça programlanmadan deneyimlerden otomatik olarak öğrenme ve iyileştirme yeteneği sağlayan bir yapay zeka (artificial intelligence-AI) uygulamasıdır. Makine öğrenimi, verilere erişebilen ve bunları kendileri için öğrenmek için kullanabilen bilgisayar programlarının geliştirilmesine odaklanır. (Expert.ai, 2020)

Öğrenme süreci, verilerdeki kalıpları aramak ve sağladığımız örneklere dayanarak gelecekte daha iyi kararlar almak için örnekler, doğrudan deneyim veya talimat gibi gözlemler veya verilerle başlar. Birincil amaç, bilgisayarların insan müdahalesi veya yardımı olmadan otomatik olarak öğrenmesini sağlamak ve eylemleri buna göre ayarlamaktır. Ancak, klasik makine öğrenimi algoritmalarını kullanarak metin, bir anahtar kelime dizisi olarak kabul edilir; bunun yerine, semantik analize dayalı bir yaklaşım, insanın bir metnin anlamını anlama yeteneğini taklit eder. (Expert.ai, 2020)

Makine öğrenimi algoritmaları genellikle denetimli veya denetimsiz olarak sınıflandırılır. (Expert.ai, 2020)

Denetimli Makine Öğrenimi Algoritmaları: Gelecekteki olayları tahmin etmek için etiketli örnekler kullanarak geçmişte öğrenilenleri yeni verilere uygulayabilir. Bilinen bir eğitim veri kümesinin analizinden başlayarak, öğrenme algoritması, çıktı değerleri hakkında tahminler

yapmak için sonuçlanan ir fonksiyon üretir. Sistem, yeterli eğitimden sonra herhangi bir yeni girdi için hedefler sağlayabilir. Öğrenme algoritması aynı zamanda çıktısını doğru, amaçlanan çıktı ile karşılaştırabilir ve modeli buna göre değiştirmek için hataları bulabilir.

Denetimsiz Makine Öğrenimi Algoritmaları: Eğitmek için kullanılan bilgiler sınıflandırılmadığında veya etiketlenmediğinde kullanılır. Denetimsiz öğrenme, sistemlerin etiketlenmemiş verilerden gizli bir yapıyı tanımlamak için bir işlevi nasıl çıkardığını inceler. Sistem doğru çıktıyı bulmaz, ancak verileri araştırır ve etiketlenmemiş verilerden gizli yapıları tanımlamak için veri kümelerinden çıkarımlar yapabilir.

Yarı Denetimli Makine Öğrenimi Algoritmaları: Eğitim için hem etiketli hem de etiketsiz verileri (genellikle az miktarda etiketlenmiş veri ve büyük miktarda etiketlenmemiş veri) kullandıkları için denetimli ve denetimsiz öğrenme arasında bir yerdedir. Bu yöntemi kullanan sistemler, öğrenme doğruluğunu önemli ölçüde iyileştirebilir. Genellikle, yarı denetimli öğrenme, elde edilen etiketli veriler, onu eğitmek / ondan öğrenmek için yetenekli ve ilgili kaynaklar gerektirdiğinde seçilir. Aksi takdirde, etiketlenmemiş verileri elde etmek genellikle ek kaynaklar gerektirmez.

Güçlendirme Makine Öğrenimi Algoritmaları: Eylemler üreterek çevresiyle etkileşime giren ve hataları veya ödülleri keşfeden bir öğrenme yöntemidir. Deneme yanılma araştırması ve gecikmeli ödül, pekiştirmeli öğrenmenin en alakalı özellikleridir. Bu yöntem, makinelerin ve yazılım aracılarının performansını en üst düzeye çıkarmak için belirli bir bağlamda ideal davranışı otomatik olarak belirlemesine olanak tanır. Temsilcinin hangi eylemin en iyi olduğunu öğrenmesi için basit ödül geri bildirimi gereklidir; bu, takviye sinyali olarak bilinir.

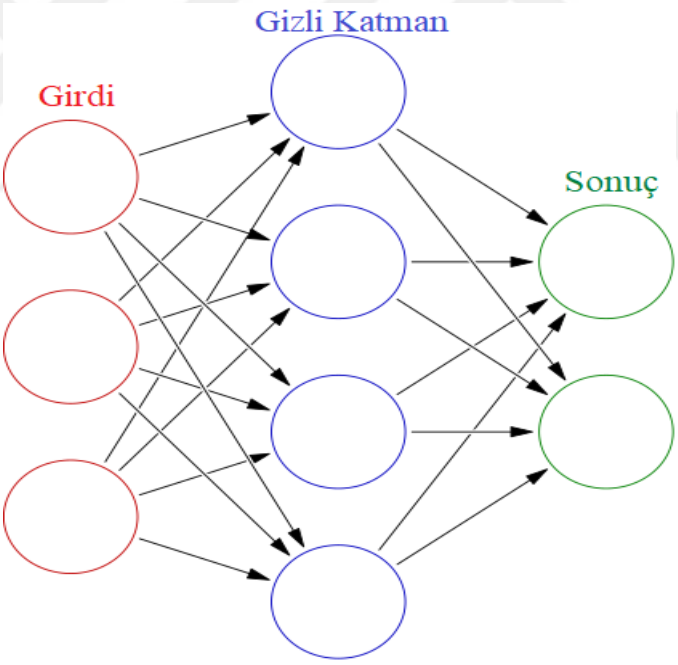
Makine öğrenimi, büyük miktarda verinin analizini sağlar. Kârlı fırsatları veya tehlikeli riskleri belirlemek için genellikle daha hızlı ve daha doğru sonuçlar sağlarken, uygun şekilde eğitmek için ek zaman ve kaynaklar da gerektirebilir. Makine öğrenimini yapay zeka ve bilişsel teknolojilerle birleştirmek, onu büyük hacimli bilgilerin işlenmesinde daha da etkili hale getirebilir. (Expert.ai, 2020)

3.5. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS-ANNS)

Genellikle basitçe sinir ağları olarak adlandırılan yapay sinir ağları (YSA), hayvan beyinlerini oluşturan biyolojik sinir ağlarından esinlenen bilgi işlem sistemlerine denir. Bir YSA, biyolojik

bir beyindeki nöronları gevşek bir şekilde modelleyen, yapay nöronlar adı verilen bağlantılı birimler veya düğümler koleksiyonuna dayanmaktadır. Her bağlantı, biyolojik bir beyindeki sinapslar gibi, diğer nöronlara bir sinyal iletir. Yapay bir nöron bir sinyal alır, ardından onu işler ve kendisine bağlı nöronları işaret edebilmektedir. Bir bağlantıdaki "sinyal" gerçek bir sayıdır ve her bir nöronun çıktısı, girdilerinin toplamının doğrusal olmayan bir fonksiyonu tarafından hesaplanmaktadır. Bağlantılara kenar denmektedir. Nöronlar ve kenarlar tipik olarak öğrenme ilerledikçe ayarlanabilen bir ağırlığa sahiptir. Ağırlık, bir bağlantıdaki sinyalin gücünü artırabilir veya azaltabilir. (Wikipedia, 2003)

Bir yapay sinir ağı, bir beyindeki nöronların sadeleştirilmesinden ilham alan birbirine bağlı bir düğüm grubudur. Burada, her dairesel düğüm bir yapay nöronu temsil etmektedir ve bir ok, bir yapay nöronun çıkışından diğerinin girişine olan bağlantıyı temsil etmektedir. (Wikipedia, 2003) Şekil 3. 8’ de örnek bir yapay sinir ağı gösterilmektedir.



Şekil 3. 8: Örnek Bir Yapay Sinir Ağı

Sinir ağları, her biri bilinen bir "girdi" ve "sonuç" içeren örnekleri işleyerek öğrenir, ikisi arasında ağın kendi veri yapısı içinde depolanan olasılık ağırlıklı ilişkiler oluşturur. Belirli bir örnekten bir sinir ağının eğitimi, genellikle ağın işlenmiş çıktısı ile bir hedef çıktı arasındaki farkın belirlenmesiyle gerçekleştirilmektedir. Bu farka hata denir. Ağ daha sonra ağırlıklı ilişkilerini bir öğrenme kuralına göre ve bu hata değerini kullanarak ayarlamaktadır. Art arda

yapılan ayarlamalar, sinir ağının hedef çıktıya giderek daha fazla benzeyen çıktı üretmesine neden olur. Yeterli sayıda bu ayarlamadan sonra eğitim, belirli kriterlere göre sonlandırılabilmektedir. Bu, denetimli öğrenme olarak bilinmektedir. (Wikipedia, 2003)

3.6. DERİN ÖĞRENME (DEEP LEARNING-DL)

Makine öğrenmesinin bir alt kümesi olan derin öğrenme, insan beyninde bulunan bilgi işleme modellerinden ilham almıştır. Derin öğrenme, çalışması için insan tarafından tasarlanmış herhangi bir kural gerektirmez; bunun yerine, verilen girdiyi belirli etiketlerle eşleştirmek için büyük miktarda veri kullanır. Derin öğrenme, her biri kendilerine beslenen verilerin farklı bir yorumunu sağlayan çok sayıda algoritma katmanı (yapay sinir ağları) kullanılarak tasarlanmıştır. (Alzubaidi, 2021) Şekil 3.9' da yapay zeka, makine öğrenmesi, yapay sinir ağları ve derin öğrenme arasındaki ilişki gösterilmektedir.



Şekil 3. 9: Derin Öğrenme, Yapay Sinir Ağları ve Makine Öğrenmesi İlişkisi

Geleneksel makine öğrenmesi tekniklerini kullanarak sınıflandırma görevine ulaşmak, özellikle ön işleme, özellik çıkarma, akıllı özellik seçimi, öğrenme ve sınıflandırma olmak üzere birkaç ardışık adım gerektirir. Ayrıca, özellik seçiminin makine öğrenimi tekniklerinin performansı üzerinde büyük etkisi vardır. Önyargılı özellik seçimi, sınıflar arasında yanlış ayrım yapılmasına neden olabilir. Tersine, derin öğrenme, geleneksel makine öğrenmesi yöntemlerinden farklı olarak, çeşitli görevler için özellik setlerinin öğrenilmesini otomatikleştirme yeteneğine sahiptir. (Alzubaidi, 2021)

Derin öğrenme, öğrenme ve sınıflandırmanın tek seferde elde edilmesini sağlar. Derin öğrenme, büyük veri alanındaki büyük büyüme ve değişim nedeniyle son yıllarda inanılmaz derecede popüler bir makine öğrenimi algoritması türü haline geldi. Birkaç makine öğrenmesi görevi için yeni performansla ilgili olarak hala sürekli geliştirme aşamasındadır ve görüntü süper çözünürlüğü, nesne algılama ve görüntü tanıma gibi birçok öğrenme alanının iyileştirilmesini basitleştirmiştir. Son zamanlarda, derin öğrenme performansı, görüntü sınıflandırma gibi görevlerde insan performansını aşmaya başlamıştır. (Alzubaidi, 2021)

3.6.1. Derin Öğrenme Algoritmaları

Derin öğrenme algoritmaları kendi kendine öğrenme temsillerine sahip olsa da, beynin bilgiyi hesaplama şeklini yansıtan yapay sinir ağlarına bağımlıdır. Eğitim süreci sırasında, algoritmalar özellikleri çıkarmak, nesneleri gruplandırmak ve faydalı veri kalıplarını keşfetmek için girdi dağılımındaki bilinmeyen öğeleri kullanır. Kendi kendine öğrenmeye yönelik eğitim makinelerine çok benzer şekilde, bu, modelleri oluşturmak için algoritmaları kullanarak birden çok düzeyde gerçekleşir. Derin öğrenme modelleri birkaç algoritmadan yararlanır. Hiçbir ağ mükemmel kabul edilmese de bazı algoritmalar belirli görevleri gerçekleştirmek için daha uygundur. Derin öğrenme algoritmaları neredeyse her tür veriyle çalışır ve karmaşık sorunları çözmek için büyük miktarda bilgi işlem gücü ve bilgi gerektirir. En çok kullanılan derin öğrenme algoritmaları şu şekildedir: (Biswali, 2021)

3.6.1.1. Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNNs)

ConvNets olarak da bilinen CNN'ler, çoklu katmanlardan oluşur ve esas olarak görüntü işleme ve nesne algılama için kullanılır. Yann LeCun, ilk CNN'i 1988'de LeNet olarak adlandırıldığında geliştirdi. Posta kodları ve rakamlar gibi karakterleri tanımak için kullanıldı. CNN'ler, uydu görüntülerini tanımlamak, tıbbi görüntüleri işlemek, zaman serilerini tahmin etmek ve anormallikleri tespit etmek için yaygın olarak kullanılmaktadır.

3.6.1.2. Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory Networks-LSTMs)

Uzun Kısa Süreli Bellek Ağları, uzun vadeli bağımlılıkları öğrenebilen ve ezberleyebilen bir tekrarlayan sinir ağı (RNN) türüdür. Uzun süreler için geçmiş bilgileri hatırlamak varsayılan davranıştır. LSTM'ler zaman içinde bilgileri saklar. Önceki girdileri hatırladıkları için zaman serisi tahmininde faydalıdırlar. LSTM'ler, dört etkileşimli katmanın benzersiz bir şekilde

iletişim kurduğu zincir benzeri bir yapıya sahiptir. Zaman serisi tahminlerinin yanı sıra, LSTM'ler tipik olarak konuşma tanıma, müzik kompozisyonu ve farmasötik geliştirme için kullanılır.

3.6.1.3. Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNNs)

Tekrarlayan sinir ağları, LSTM'den gelen çıkışların mevcut faza giriş olarak beslenmesine izin veren, yönlendirilmiş döngüler oluşturan bağlantılara sahiptir. LSTM'den gelen çıkış, mevcut faz için bir giriş olur ve dahili hafızası sayesinde önceki girişleri hafızaya alabilir. RNN'ler genellikle resim yazısı, zaman serisi analizi, doğal dil işleme, el yazısı tanıma ve makine çevirisi için kullanılır.

3.6.1.4. Üretken Düşman Ağları (Generative Adversarial Networks-GANs)

Üretken düşman ağları, eğitim verilerine benzeyen yeni veri örnekleri oluşturan üretken derin öğrenme algoritmalarıdır. GAN'ın iki bileşeni vardır: sahte veri üretmeyi öğrenen bir oluşturucu ve bu yanlış bilgiden öğrenen bir ayrımcı. GAN'ların kullanımı bir süre içinde artmıştır. Astronomik görüntüleri iyileştirmek ve karanlık madde araştırmaları için kütleçekimsel merceklemeyi simüle etmek için kullanılabilirler. Video oyunu geliştiricileri, eski video oyunlarındaki düşük çözünürlüklü, iki boyutlu dokuları görüntü eğitimi yoluyla 4K veya daha yüksek çözünürlüklerde yeniden oluşturarak yükseltmek için GAN'ları kullanır. GAN'lar gerçekçi görüntüler ve çizgi film karakterleri oluşturmaya, insan yüzlerinin fotoğraflarını oluşturmaya ve üç boyutlu nesneler oluşturmaya yardımcı olur.

3.6.1.5. Radyal Temel Fonksiyon Ağları (Radial Basis Function Networks-RBFNs)

Radyal temel fonksiyon ağları, etkinleştirme işlevleri olarak radyal temel işlevleri kullanan ileri beslemeli sinir ağlarının özel türleridir. Bir girdi katmanına, bir gizli katmana ve bir çıktı katmanına sahiptirler ve çoğunlukla sınıflandırma, regresyon ve zaman serisi tahmini için kullanılırlar.

3.6.1.6. Çok Katmanlı Algılayıcılar (Multilayer Perceptrons-MLPs)

MLP'ler, derin öğrenme teknolojisi hakkında bilgi edinmeye başlamak için mükemmel bir yerdir. MLP'ler, aktivasyon fonksiyonlarına sahip çok sayıda algılayıcı katmanına sahip ileri beslemeli sinir ağları sınıfına aittir. MLP'ler, tamamen bağlı bir giriş katmanı ve bir çıkış

katmanından oluşur. Aynı sayıda giriş ve çıkış katmanına sahiptirler ancak birden fazla gizli katmana sahip olabilirler ve konuşma tanıma, görüntü tanıma ve makine çevirisi yazılımı oluşturmak için kullanılabilirler.

3.6.1.7. Kendi Kendini Düzenleyen Haritalar (Self Organizing Maps-SOMs)

Profesör Teuvo Kohonen, kendi kendini organize eden yapay sinir ağları aracılığıyla verilerin boyutlarını azaltmak için veri görselleştirmeyi sağlayan SOM'ları icat etmiştir. Veri görselleştirme, insanların yüksek boyutlu verileri kolayca görselleştiremediği sorunu çözmeye çalışır. SOM'lar, kullanıcıların bu yüksek boyutlu bilgileri anlamalarına yardımcı olmak için oluşturulur.

3.6.1.8. Derin İnanç Ağları (Deep Belief Networks-DBNs)

DBN'ler, birden çok stokastik, gizli değişken katmanından oluşan üretken modellerdir. Gizli değişkenler ikili değerlere sahiptir ve genellikle gizli birimler olarak adlandırılır. DBN'ler, katmanlar arasında bağlantıları olan bir Boltzmann Makinesi yığınıdır ve her bir Kısıtlı Boltzmann Makinesi katmanı, hem önceki hem de sonraki katmanlarla iletişim kurar. Derin inanç ağları görüntü tanıma, video tanıma ve hareket yakalama verileri için kullanılır.

3.6.1.9. Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines-RBMs)

Geoffrey Hinton tarafından geliştirilen RBM'ler, bir dizi girdi üzerinden bir olasılık dağılımından öğrenebilen stokastik sinir ağlarıdır. Bu derin öğrenme algoritması, boyut azaltma, sınıflandırma, regresyon, işbirlikçi filtreleme, özellik öğrenme ve konu modelleme için kullanılır. RBM'ler, DBN'lerin yapı taşlarını oluşturur.

3.6.1.10. Otomatik Kodlayıcılar (Autoencoders)

Otomatik kodlayıcılar, giriş ve çıkışın aynı olduğu belirli bir ileri beslemeli sinir ağı türüdür. Geoffrey Hinton, 1980'lerde denetimsiz öğrenme sorunlarını çözmek için otomatik kodlayıcılar tasarladı. Verileri girdi katmanından çıktı katmanına kopyalayan eğitimli sinir ağlarıdır. Otomatik kodlayıcılar, farmasötik keşif, popülerlik tahmini ve görüntü işleme gibi amaçlar için kullanılır.

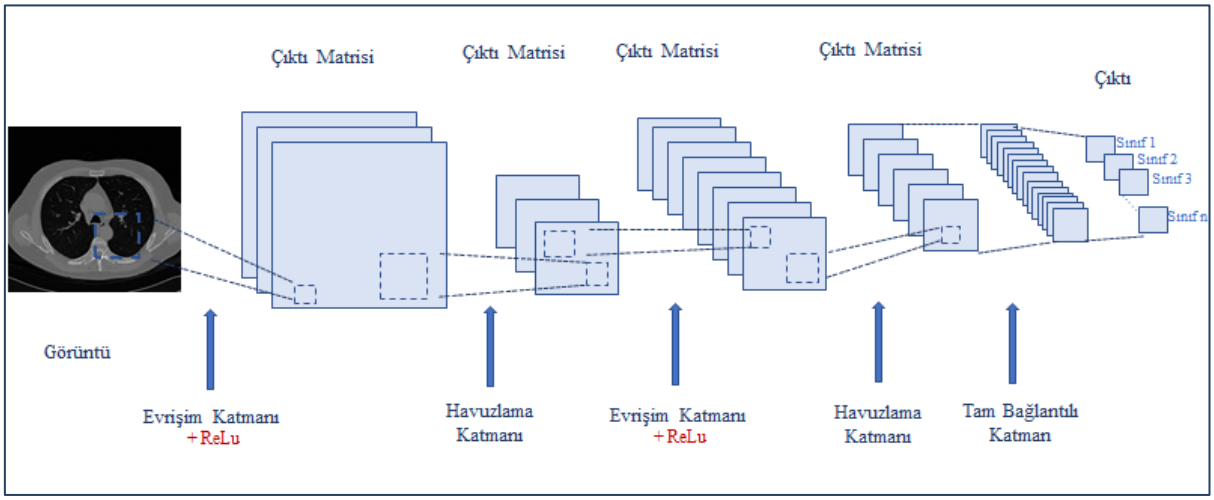
3.7 EVRİŞİMSEL SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORKS-CNN)

Evrişimsel sinir ağlarının temel yapısı, hayvan görsel korteks organizasyonundan esinlenmiştir. Hubel ve Wiesel 1968'de “yerel alıcı alanlar” hakkında bir çalışma sundular. Hayvan görsel korteksinin görsel alanın küçük alt bölgelerinde karmaşık hücre düzenlemelerine sahip olduğunu gösterdiler. CNN'lerle ilgili ilk fikirler, 1980'de Hubel ve Wiesel'deki kavramları kullanarak insan görsel sistemini simüle etmek için hiyerarşik olarak organize edilmiş görüntü dönüşümleriyle Fukushima tarafından verildi. 1990'ların başında CNN'ler, büyük hesaplama yükünün dezavantajı ile literatürde yer almaya başladı.

Günümüzde CNN'ler, güçlü Grafik İşlem Birimlerinin (Graphics Processing Unit-GPU) ortaya çıkmasıyla hem güçlü bir özellik çıkarıcı hem de bir sınıflandırıcı olarak popülerlik kazanmıştır. Kısa bir süre içinde CNN'ler, otonom araçlar, konuşma tanıma ve tıbbi görüntüleme görevleri gibi birçok bilgisayarlı görme alanına başarıyla uygulanmıştır.

CNN derin öğrenme modeli eğitilirken verilerin tamamı aynı anda eğitime katılmaz. Belli sayıda parçalar halinde eğitimde yer almaktadır. İlk parça eğitilir, modelin başarımı test edilir ve sonrasında başarıma göre geriye yayılım ile ağırlıklar güncellenir. Daha sonra yeni eğitim kümesi ile model tekrar eğitilip ağırlıklar tekrar güncellenir. Bu işlem her bir eğitim adımında tekrarlanarak derin öğrenme modeli için en uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine eğitim tur sayısı (Epoch) denilmektedir.

CNN'ler, ileri beslemeli sinir ağlarına benzer çoklu katmanlardan oluşur. Katmanların çıktıları ve girdileri bir dizi görüntü kümesi olarak verilir. Tipik bir CNN mimarisi, Şekil 3.10' da gösterilmektedir. CNN'nin yapısı Evrişim Katmanı, Havuzlama Katmanı, Aktivasyon Fonksiyonu (genellikle ReLU-Rectified Linear Unit kullanılır) ve Tam Bağlantılı Katmanları içerir. CNN'ler, bu katmanların farklı kombinasyonları ile de oluşturulabilir.



Şekil 3. 10: Evrişimsel Sinir Ağı Mimarisi

3.7.1. Evrişim Katmanı

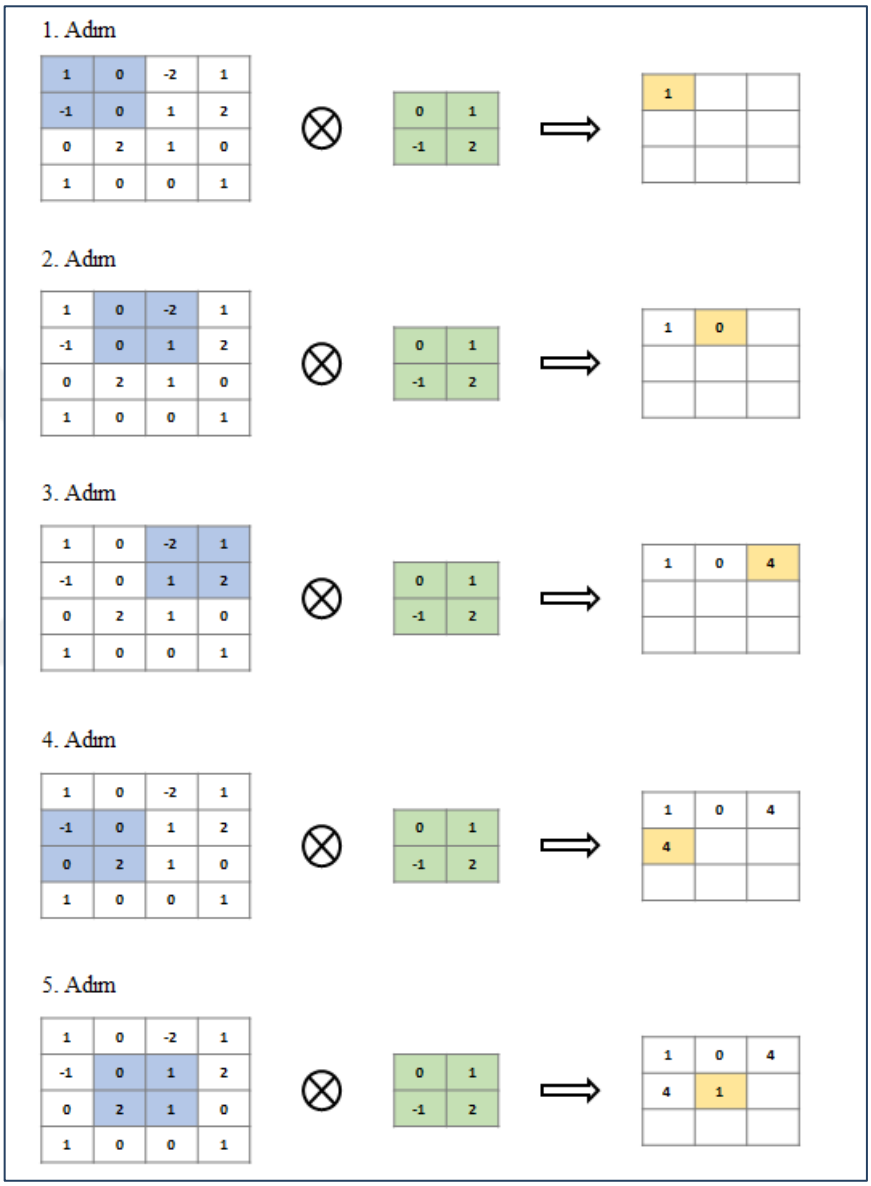
CNN mimarisinde en önemli bileşen evrişim katmanıdır. Bir dizi evrişimsel filtreden (çekirdek adı verilen) oluşur. N-boyutlu metrikler olarak ifade edilen girdi görüntüsü, çıktı özellik haritasını oluşturmak için bu filtrelerle kıvrılır. (Alzubaidi, 2021)

Çekirdek tanımı: Kesikli sayılardan veya değerlerden oluşan bir ızgara, çekirdeği tanımlar. Her değere çekirdek ağırlığı denir. CNN eğitim sürecinin başında çekirdeğin ağırlıkları olarak hareket etmek için rastgele sayılar atanır. Ek olarak, ağırlıkları başlatmak için kullanılan birkaç farklı yöntem vardır. Daha sonra, bu ağırlıklar her eğitim döneminde ayarlanır; böylece çekirdek önemli özellikleri çıkarmayı öğrenir. (Alzubaidi, 2021)

Evrişim İşlemi: Vektör formatı, geleneksel sinir ağının girdisidir, çok kanallı görüntü ise CNN'nin girdisidir. Örneğin, tek kanallı gri tonlamalı görüntünün formatıdır, RGB görüntü formatı ise üç kanallıdır. (Alzubaidi, 2021)

Evrişim işlemi için, 2×2 rastgele ağırlıkla başlatılmış çekirdeğe sahip 4×4 gri ölçekli bir görüntü örneğine bakılacak olunursa, ilk olarak, çekirdek tüm görüntü üzerinde yatay ve dikey olarak kayar. Ek olarak, giriş görüntüsü ve çekirdek arasındaki nokta çarpımı belirlenir, burada karşılık gelen değerler çarpılır ve daha sonra eş zamanlı olarak hesaplanan tek bir skaler değer oluşturmak için toplanır. Daha sonra, daha fazla kayma mümkün olmayana kadar tüm süreç tekrarlanır. Kayma miktarı istenilen değerde olabilir. Hesaplanan nokta çarpım değerlerinin çıktının özellik haritasını temsil eder. (Alzubaidi, 2021) Şekil 3.11, her adımda yürütülen

birincil hesaplamaları grafiksel olarak gösterir. Bu şekilde, yeşil renk 2×2 çekirdeği temsil ederken, mavi renk giriş görüntüsünün benzer boyut alanını temsil eder. Her ikisi de çarpılır; elde edilen çarpım değerlerinin (sarı renkle işaretlenmiştir) toplanmasından sonraki nihai sonuç, çıktı özelliği haritasına bir giriş değerini temsil eder.

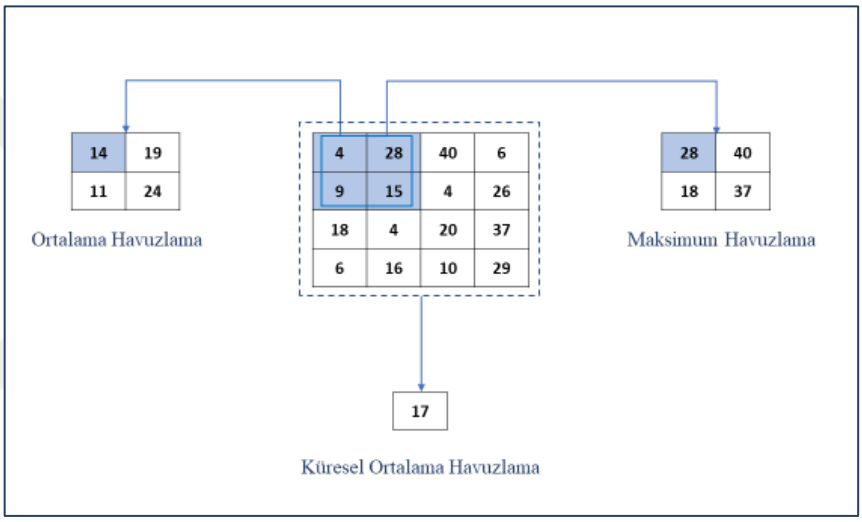


Şekil 3. 11: Evrişim Katmanının Her Adımında Yürütülen Birincil Hesaplama Örneği

3.7.2. Havuzlama Katmanı

Havuzlama katmanının ana görevi, özellik haritalarının alt örneklenmesidir. Bu haritalar, evrişim işlemleri takip edilerek oluşturulur. Başka bir deyişle, bu yaklaşım, daha küçük özellik haritaları oluşturmak için büyük boyutlu özellik haritalarını küçültür. Eşzamanlı olarak,

havuzlama aşamasının her adımında baskın bilgilerin (veya özelliklerin) çoğunluğunu korur. Evrişim işlemine benzer şekilde, hem adım hem de çekirdek, havuzlama işlemi yürütülmeden önce başlangıçta boyut atanır. Çeşitli havuzlama katmanlarında kullanım için çeşitli havuzlama yöntemleri mevcuttur. Bu yöntemler arasında ağaç havuzlama, kapılı havuzlama, ortalama havuzlama, minimum havuzlama, maksimum havuzlama, küresel ortalama havuzlama (global average pooling-GAP) ve global maksimum havuz oluşturma yer alır. En bilinen ve en sık kullanılan havuzlama yöntemleri maksimum, ortalama ve GAP havuzlamadır. (Alzubaidi, 2021) Şekil 3.12, bu üç havuzlama işlemini göstermektedir. Havuzlama katmanı genellikle evrişim katmanı ve tam bağlantılı katman arasında bir köprü görevi görür.



Şekil 3. 12: Ortalama Havuzlama, Maksimum Havuzlama ve Küresel Ortalama Havuzlama

3.7.3. Aktivasyon Fonksiyonu

Girdiyi çıktıya eşlemek, her tür sinir ağındaki her tür aktivasyon fonksiyonunun temel işlevidir. Giriş değeri, (varsa) yanlılığı ile birlikte nöron girişinin ağırlıklı toplamının hesaplanmasıyla belirlenir. Bu, aktivasyon fonksiyonunun, ilgili çıktıyı oluşturarak belirli bir girdiye göre bir nöronu tetikleyip tetiklememe kararını verdiği anlamına gelir. CNN mimarisinde ağırlıkları olan tüm katmanlardan sonra doğrusal olmayan aktivasyon katmanları kullanılır. Aktivasyon katmanlarının bu doğrusal olmayan performansı, girdinin çıktıya eşlenmesinin doğrusal olmayacağı anlamına gelir; dahası, bu katmanlar CNN'ye ekstra karmaşık şeyleri öğrenme yeteneği verir. (Alzubaidi, 2021)

Aktivasyon fonksiyonu ayrıca, ağı eğitmek için hata geri yayılımının kullanılmasına izin verdiği için son derece önemli bir özellik olan ayırt etme yeteneğine de sahip olmalıdır. Aşağıdaki aktivasyon fonksiyon türleri en yaygın olarak CNN ve diğer derin sinir ağlarında kullanılır.

3.7.3.1. Sigmoid Aktivasyon Fonksiyonu

Bu aktivasyon fonksiyonunun girişi gerçek sayılardır, çıkışı ise sıfır ile bir arasında sınırlıdır. Sigmoid fonksiyon eğrisi S şeklindedir ve matematiksel olarak formül 3.8 ile hesaplanmaktadır. (Alzubaidi, 2021)

$$f(x)_{sigm} = \frac{1}{1 + e^{-x}} \tag{3.8}$$

3.7.3.2. Tanh Aktivasyon Fonksiyonu

Girdisi reel sayılar olduğu için sigmoid fonksiyonuna benzerdir, ancak çıktı − 1 ile 1 arasında sınırlandırılmıştır. Matematiksel olarak formül 3.9 ile hesaplanmaktadır. (Alzubaidi, 2021)

$$f(x)_{tanh} = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}} \tag{3.9}$$

3.7.3.3. ReLU Aktivasyon Fonksiyonu

CNN bağlamında en çok kullanılan aktivasyon fonksiyondur. Girişin tüm değerlerini pozitif sayılara dönüştürür. Daha düşük hesaplama yükü, ReLU'nun diğerlerine göre ana avantajıdır. Matematiksel olarak formül 3.10 ile hesaplanmaktadır. (Alzubaidi, 2021)

$$f(x)_{ReLU} = max(0, x) \tag{3.10}$$

3.7.3.4. Sızıntı ReLU Aktivasyon Fonksiyonu

Negatif girişleri küçültmek yerine, bu aktivasyon fonksiyonu bu girişlerin asla göz ardı edilmemesini sağlar. Bu sorunu çözmek için kullanılır. Sızıntı ReLU, matematiksel olarak

formül 3.11 ile hesaplanmaktadır. Sızıntı faktörü m ile gösterilmiştir. Genellikle 0.001 gibi çok küçük bir değere ayarlanır. (Alzubaidi, 2021)

$$f(x)_{SızıntıReLU} = \begin{Bmatrix} x, & x > 0 \\ mx, & x \leq 0 \end{Bmatrix} \tag{3.11}$$

3.7.3.5. Gürültülü ReLU Aktivasyon Fonksiyonu

Bu işlev, ReLU'yu gürültülü yapmak için bir Gauss dağılımı kullanır. σ Gauss sigma/standart sapmasını, N değerlerin sayısını ifade eder. Matematiksel olarak formül 3.12 ile hesaplanmaktadır. (Alzubaidi, 2021)

$$f(x)_{GürültülüReLU} = max(x + Y)\ ,\ Y \sim N\big(0, \sigma(x)\big) \tag{3.12}$$

3.7.3.6. Parametrik Doğrusal Birim Aktivasyon Fonksiyonu

Parametrik doğrusal birim aktivasyon fonksiyonu çoğunlukla Sızıntı ReLU ile aynıdır. Temel fark, bu fonksiyondaki sızıntı faktörünün model eğitim süreci ile güncellenmesidir. Parametrik doğrusal birim, matematiksel olarak formül 3.13 ile hesaplanmaktadır. Öğrenilebilir ağırlık a olarak gösterilmiştir. (Alzubaidi, 2021)

$$f(x)_{\text{ParametrikDoğrusal}} = \begin{Bmatrix} x, & x > 0 \\ ax, & x \leq 0 \end{Bmatrix} \tag{3.13}$$

3.7.4. Tam Bağlantılı Katman

Genellikle bu katman, her CNN mimarisinin sonunda bulunur. Bu katmanın içinde, her nöron, Tam Bağlantılı yaklaşımı olarak adlandırılan bir önceki katmanın tüm nöronlarına bağlanır. CNN sınıflandırıcı olarak kullanılır. Bir tür ileri beslemeli yapay sinir ağı olduğu için geleneksel çok katmanlı algılayıcı sinir ağının temel yöntemini izler. Tam bağlantılı katmanının girişi, son havuzlama veya evrişim katmanından gelir. Bu girdi, düzleştirmeden sonra özellik haritalarından oluşturulan bir vektör biçimindedir. Tam bağlanıtılı katmanının çıktısı, son CNN çıktısını temsil eder. (Alzubaidi, 2021)

3.7.5. Kayıp (Loss) Fonksiyonları

CNN mimarisinin çeşitli katman tipleri anlatılmıştır. Ek olarak, son sınıflandırma, CNN mimarisinin son katmanını temsil eden çıktı katmanından elde edilir. CNN modelinde eğitim örneklerinde oluşturulan tahmini hatayı hesaplamak için çıktı katmanında bazı kayıp fonksiyonları kullanılır. Bu hata, gerçek çıktı ile tahmin edilen çıktı arasındaki farkı ortaya çıkarır. Daha sonra, CNN öğrenme süreci ile optimize edilebilir hale gelir. Ancak, hatayı hesaplamak için kayıp fonksiyonu tarafından iki parametre kullanılır. CNN tahmini çıktısı (tahmin olarak adlandırılır) ilk parametredir. Gerçek çıktı (etiket olarak adlandırılır) ikinci parametredir. Çeşitli problem türlerinde çeşitli kayıp fonksiyonu türleri kullanılır. Aşağıda bazı kayıp fonksiyon türleri kısaca açıklanmaktadır. (Saravanan, 2021)

3.7.5.1. İkili Çapraz Entropi Kayıp (Binary Cross-Entropy Loss) Fonksiyonu

İkili çapraz entropi, ikili sınıflandırma görevlerinde kullanılan bir kayıp fonksiyonudur. İkili çapraz entropi kaybı işlevi, formül 3.14 ile ortalamayı hesaplayarak bir örneğin kaybını hesaplar: (Saravanan, 2021)

$$L = -\frac{1}{N}\sum_{i=1}^{N} y_i . \log p_i + (1 - y_i) . \log(1 - p_i) \tag{3.14}$$

Burada p_i, model çıktısındaki *i.* skaler değeridir, y_i, karşılık gelen hedef değerdir ve N, model çıktısındaki skaler değerlerin sayısıdır. Bu, birçok bağımsız sınıflandırma problemine uygulanan kategorik çapraz entropi kayıp fonksiyonunun ortalama sonucuna eşdeğerdir, her problem y_i ve $(1 - y_i)$ hedef olasılıkları ile sadece iki olası sınıfa sahiptir.

3.7.5.2. Menteşe Kayıp (Hinge Loss) Fonksiyonu

İkili sınıflandırma sorunları için çapraz entropiye bir alternatiftir. Öncelikle Destek Vektör Makinesi (Support Vector Machine-SVM) modelleriyle kullanım için geliştirilmiş olan menteşe kaybı işlevidir. Hedef değerlerin {-1, 1} kümesinde olduğu durumlarda ikili sınıflandırma ile kullanılması amaçlanmıştır. Menteşe kaybı işlevi, gerçek ve tahmin edilen sınıf değerleri arasında işarette bir fark olduğunda daha fazla hata atayarak örnekleri doğru işarete sahip olmaya teşvik eder. Bazen ikili sınıflandırma problemlerinde çapraz entropiden daha iyi performansla sonuçlanır. Amaçlanan çıkış için t = ±1 ve sınıflandırıcı puanı y için y tahmininin menteşe kaybı formül 3.15' deki hesaplanmaktadır. (Saravanan, 2021)

$$L(y) = \max(0, 1- t.y) \quad (3.15)$$

3.7.5.3. Kare Menteşe Kayıp (Squared Hinge Loss) Fonksiyonu

Menteşe kaybı fonksiyonunun birçok uzantısı vardır ve genellikle SVM modellerinde inceleme konusu olur. Çok kullanılan bir fonksiyondur, basitçe skor menteşe kaybının karesini hesaplayan kare menteşe kaybı olarak adlandırılır. Hata fonksiyonunun yüzeyini yumuşatma ve sayısal olarak çalışmayı kolaylaştırma etkisine sahiptir. Bir menteşe kaybı kullanmak, belirli bir ikili sınıflandırma probleminde daha iyi performansla sonuçlanıyorsa, muhtemelen bir menteşe kaybının karesi uygun olabilir. Menteşe kaybı işlevini kullanırken olduğu gibi, hedef değişken {-1, 1} kümesindeki değerlere sahiptir. Kare menteşe kaybı, "maksimum marj" ikili sınıflandırma problemleri için kullanılır. Matematiksel olarak formül 3.16' deki gibi hesaplanmaktadır. p tahmin edilen değerdir ve y ya 1 ya da -1'dir. (Saravanan, 2021)

$$L(y, p) = \sum_{i=0}^{N}(max(0, 1 - y_i p_i)^2) \quad (3.16)$$

3.7.5.4. Çok Sınıflı Çapraz Entropi Kayıp (Multi-Class Cross-Entropy Loss) Fonksiyonu

Çapraz entropi, çok sınıflı sınıflandırma problemlerinde kullanılacak varsayılan kayıp fonksiyonudur. Bu durumda, hedef değerlerin {0, 1, 3, …, n} kümesinde olduğu ve her sınıfa benzersiz bir tamsayı değeri atandığı çok sınıflı sınıflandırma ile kullanılması amaçlanmıştır. Matematiksel olarak, maksimum olabilirlik çıkarım çerçevesi altında tercih edilen kayıp fonksiyonudur. Çapraz entropi, problemdeki tüm sınıflar için gerçek ve tahmin edilen olasılık dağılımları arasındaki ortalama farkı özetleyen bir puan hesaplar. Skor en aza indirilir ve mükemmel çapraz entropi değeri 0'dır. p_i, model çıktısındaki *i.* skaler değeridir, y_i, karşılık gelen hedef değerdir ve N, model çıktısındaki skaler değerlerin sayısıdır. Matematiksel olarak formül 3.17' deki gibi hesaplanmaktadır. (Saravanan, 2021)

$$L = -\sum_{i=1}^{N} y_i . \log p_i \quad (3.17)$$

3.7.5.5. Seyrek Çok Sınıflı Çapraz Entropi Kayıp (Sparse Multiclass Cross-Entropy Loss) Fonksiyonu

Veri kümesinin ilk başta kategorik olmaması ve boyutunun da çok büyük olması problem olabilir. Bu durumda, kategorik verilere bağlı olduğu için kategorik çapraz entropi kullanmak oldukça zor olacaktır. Ancak, hedef olarak kategorik vektörler yerine tamsayı hedefleri

olduğunda, seyrek kategorik çapraz entropi kullanabilir. Bu, kategorik çapraz entropi kaybı fonksiyonunun tamsayı tabanlı bir versiyonudur. Bu durum, artık hedefleri kategorik formata dönüştürülmek zorunda olmadığı anlamına gelir.

3.7.5.6. Kullback Leibler Divergence Kayıp Fonksiyonu

Kullback Leibler Divergence (KL Divergence), bir olasılık dağılımının temel dağılımdan ne kadar farklı olduğunun bir ölçüsüdür.0'lık bir KL sapma kaybı, dağılımların aynı olduğunu gösterir. Pratikte, KL Divergence'ın davranışı çapraz entropiye çok benzer. İstenen hedef olasılık dağılımına yaklaşmak için öngörülen olasılık dağılımı kullanılırsa ne kadar bilginin kaybolduğunu (bit cinsinden) hesaplar. Bu nedenle, KL sapma kaybı fonksiyonu, çok sınıflı sınıflandırmadan daha karmaşık bir işleve yaklaşmayı öğrenen modeller kullanıldığında daha yaygın olarak kullanılır. Bu durumda, KL sapma kaybı tercih edilir. Bununla birlikte, çok sınıflı sınıflandırma için kullanılabilir, bu durumda işlevsel olarak çok sınıflı çapraz entropiye eşdeğerdir. Matematiksel olarak formül 3.18' deki gibi hesaplanmaktadır. (Saravanan, 2021)

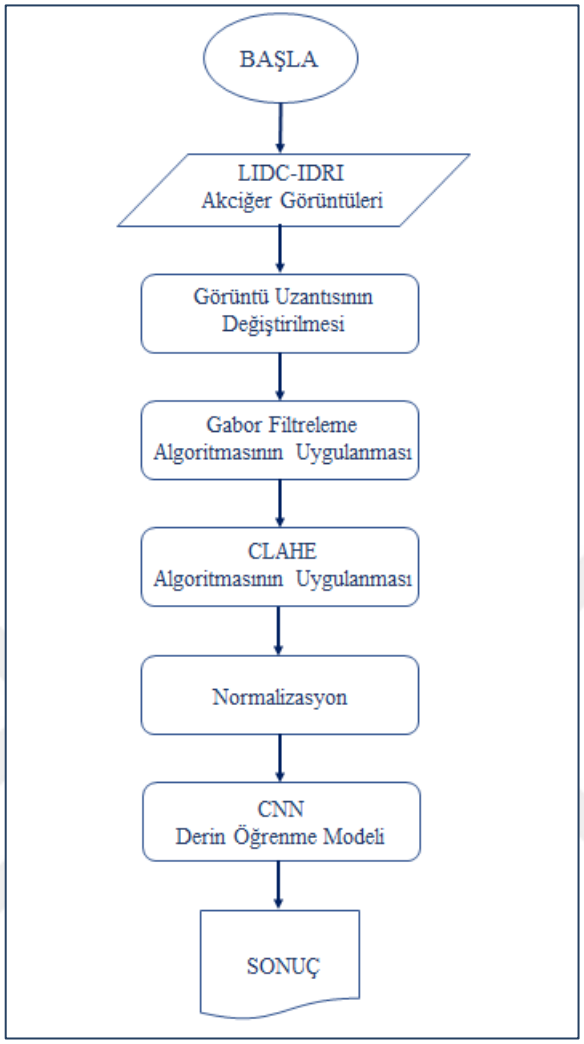
$$D_{KL}(p||q) = \sum_{i=1}^{N} p(x_i).\log(\frac{p(x_i)}{q(x_i)}) \tag{3.18}$$

Burada $q(x)$ tahmindir ve $p(x), q(x)$' i eşleştirmekle ilgilendiğimiz gerçek dağılımdır. Sezgisel olarak bu, belirli bir keyfi dağılımın gerçek dağılımdan ne kadar uzak olduğunu ölçer. İki dağılım mükemmel bir şekilde eşleşirse, hesaplamanın sonucu 0 olur, aksi takdirde 0 ile ∞ arasında değerler alabilir. KL sapma değeri ne kadar düşükse, gerçek dağılım ile tahmin o kadar iyi eşleştirmiş olur.

3.8. ÖNERİLEN YÖNTEM

Akciğer kanserinin erken teşhisinde uzmanlara yardımcı olması amacıyla dijital akciğer görüntüleri üzerinde birçok çalışma yapılmıştır. Bu akciğer görüntüleri farklı açık kaynak veri setlerinden elde edilerek çalışmalarda kullanılmıştır.

Bu tez çalışmasında LIDC-IDRI veri setinde yer alan akciğer görüntüleri kullanılmıştır. Dijital akciğer görüntülerindeki kanser şüphesini tespit etmek için CNN derin öğrenme modeli kullanılmıştır ve görüntü ön işleme teknikleri ile bir arada kullanılarak performans değerlendirmesi yapılmak istenmiştir. Çalışmada 21600 kanserli akciğer görüntüsü, 3525 sağlıklı akciğer görüntüsü olacak şekilde toplam 25125 akciğer görüntüsü kullanılmıştır.



Şekil 3. 13: Önerilen Yöntemin Akış Şeması

Şekil 3.13' te önerilen yöntemin akış şeması görülmektedir. Akciğer kanseri tespiti için CNN derin öğrenme modelinde daha yüksek oranda doğruluk (accuracy) sağlamak adına görüntülere birden fazla algoritma uygulanarak ön işlem yapılmıştır. Yapılan bu ön işlemler sayesinde görüntülerin kanser tespitinin doğruluk oranında yüksek sonuçlar elde edilmiştir. Önerilen yöntemin algoritma yapısı Şekil 3.14' teki gibidir.

ALGORİTMA

1. *Görüntüler Kanserli ve Sağlam olarak ayrıştırılır*
2. *Görüntülere farklı λ ve θ değerleri için Gabor filtreleme uygulanır*

$$g(x,y,\lambda,\theta,\psi,\sigma,\gamma) = exp\left(-\frac{x_1^2 + \gamma^2 y_1^2}{2\sigma^2}\right) exp\left(i\left(2\pi\frac{x_1}{\lambda} + \psi\right)\right)$$

3. *Elde edilen yeni görüntülerin L,A,B formatına dönüştürülür*
4. *L kanalındaki görüntülere CLAHE işleminin uygulanır*
5. *Yeni L kanalı ile A ve B kanallarının birleştirilip yeni görüntüler elde edilir*
6. *2. Adımda oluşan görüntüler ile 5. Adımda oluşan görüntüler için 7,8,9,10adımları ayrı ayrı uygulanır*
7. *Görüntülere Normalizasyon uygulanır*
8. *Görüntülerin deneme ve test verisi olarak bölünür (80:20)*
9. *CNN Derin öğrenme modeline girdi olarak verilir*
10. *Aktivasyon için ReLU fonksiyonu kullanılır*

$$f(x)_{ReLU} = max(0,x)$$

11. *Doğruluk değeri hesaplanır*

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN}$$

12. *Maksimum Doğruluk Değeri için*
    i. *CLAHE işleminin uygulanıp uygulanmamasına karar verilir*
    ii. *Gabor filtreleme işlemindeki λ ve θ değerleri seçilir*
    iii. *CNN derin öğrenme modelinde ise Epoch sayısı ve Evrişim Katmanı sayıları seçilir*

Şekil 3. 14: Önerilen Yöntemin Algoritması

3.8.1. Görüntülerin Uzantısının Değiştirilmesi

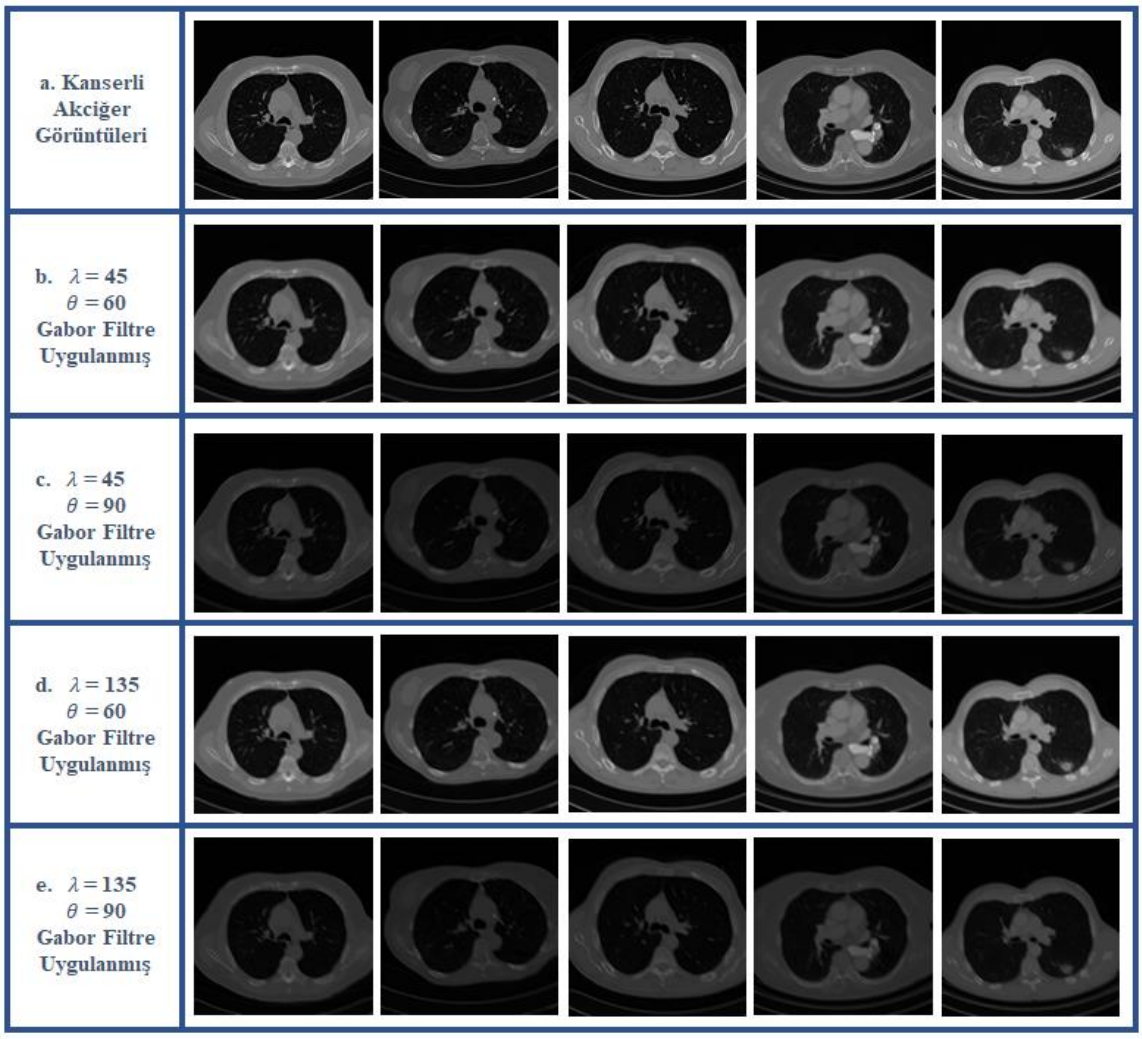
LIDC-IDRI veri setinde akciğer görüntüleri DICOM uzantılı olarak tutulmaktadır. Bu görüntüler normal görüntü açma programları tarafından açılamamaktadır. Bu tip uzantılı görüntülerin görüntülenmesi için özel programlar gerekmektedir. Öncelikle bu görüntü uzantısını değiştirerek normal görüntü haline dönüşüm sağlanmıştır. Bu dönüşüm yazılan bir program ile DICOM formatından PNG formatına değiştirilerek yapılmıştır.

3.8.2. Gabor Filtreleme Algoritmasının Uygulanması

Ön işlemlerdeki amaç kanserli görüntüyü tespit etme işlemini kolaylaştırmaktır. Gabor filtreleme algoritması görüntü analizi için yaygın kullanım alanı bulduğu için kullanılmıştır.

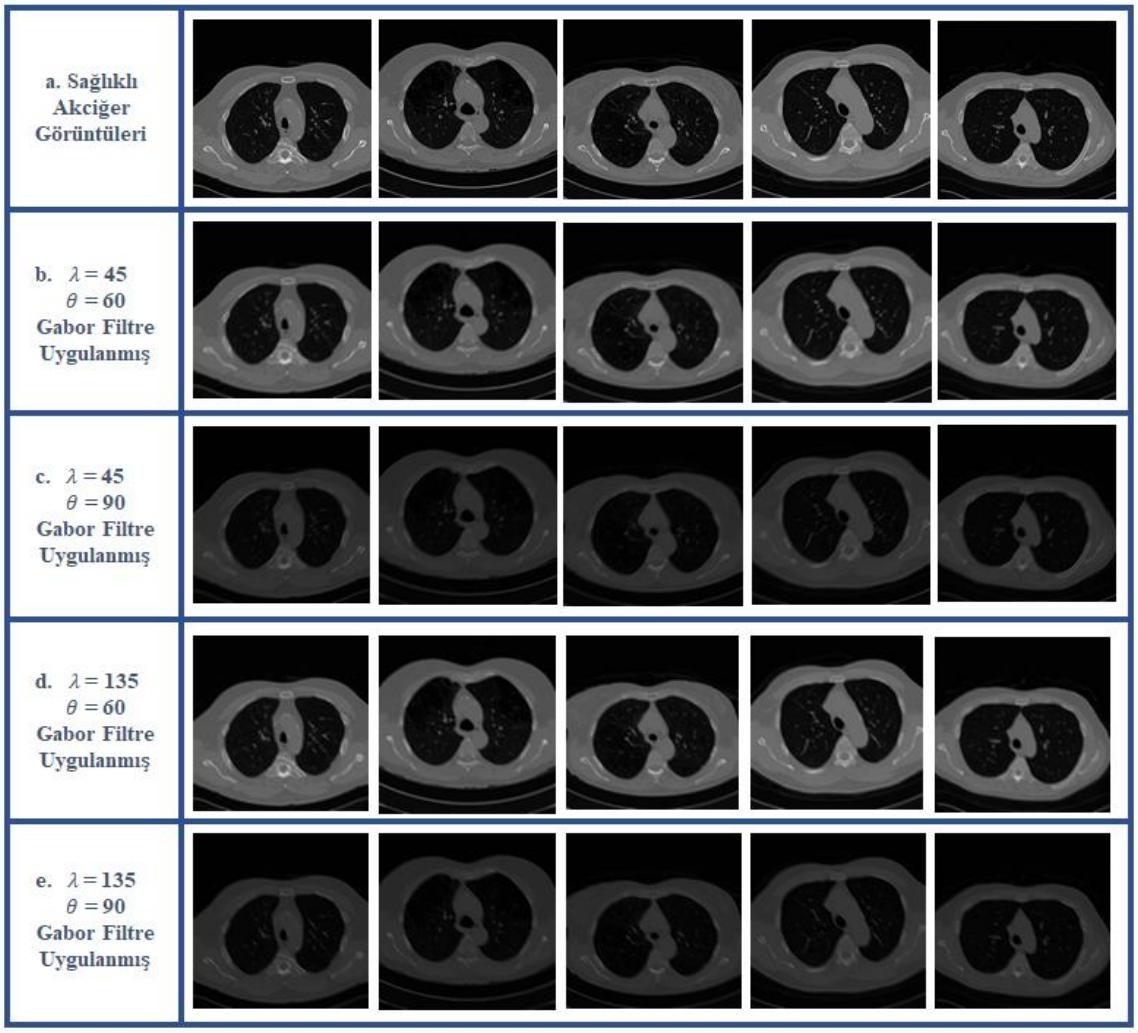
Burada öncelikle Gabor filtreleme algoritması uygulanmış olan görüntüler ile normal görüntüler arasında CNN derin öğrenme modelinin doğruluk sonucu kıyaslanmıştır. Bu kıyaslama sonucunda Gabor filtreleme algoritmasının uygulanması doğruluk sonucunda olumlu yönde etki ettiği görülmüştür. Bu duruma istinaden Gabor filtreleme algoritmasının parametre değerleri değiştirilerek en iyi sonuç sağlayan parametre değerleri saptanmıştır.

Şekil 3.15' te LIDC-IDRI veri setindeki kanserli örnek akciğer görüntüleri gösterilmektedir. a satırındaki kanserli akciğer görüntülerine farklı λ ve θ değerleri için Gabor filtreleme algoritmasının uygulanması ile oluşan yeni görüntüler b, c, d ve e satırlarında görülmektedir.



Şekil 3. 15: Kanserli Akciğer Görüntüleri ve Gabor Filtre Uygulanması ile Elde Edilen Yeni Görüntüler

Şekil 3.16' da ise LIDC-IDRI veri setindeki sağlıklı örnek akciğer görüntüleri gösterilmektedir. a satırındaki sağlıklı akciğer görüntülerine farklı λ ve θ değerleri için Gabor filtreleme algoritmasının uygulanması ile oluşan yeni görüntüler b, c, d ve e satırlarında görülmektedir.

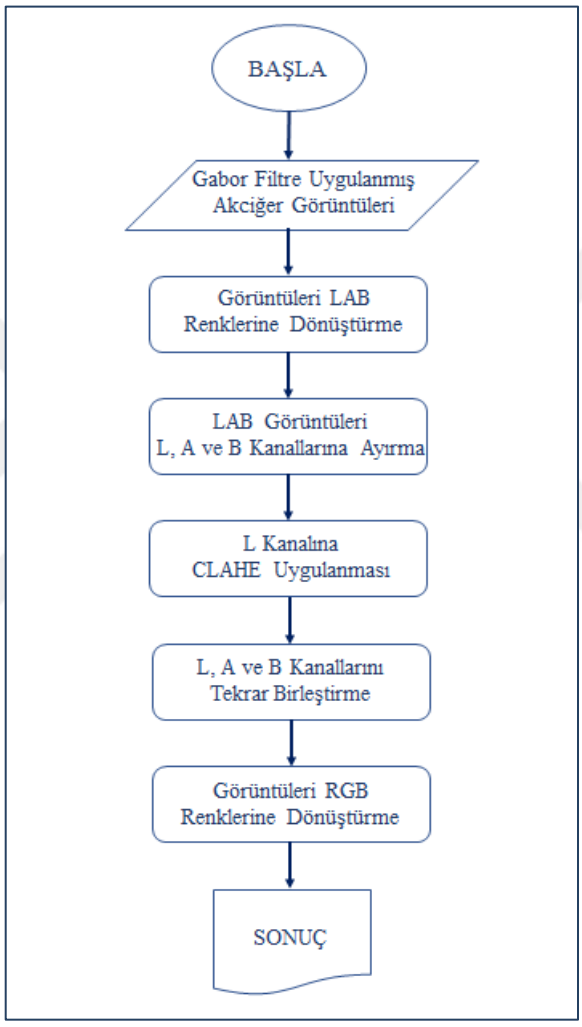


Şekil 3. 16: Sağlıklı Akciğer Görüntüleri ve Gabor Filtre Uygulanması ile Elde Edilen Yeni Görüntüler

3.8.3. CLAHE Algoritmasının Uygulanması

Görüntü işlemede genelde histogram eşitlemesi kullanılmaktadır. Ama histogram eşitlemede görüntünün tamamının yoğunluk dağılımı kullanıldığı için bazı görüntülerde olumlu yönde etki edememektedir. Bu tezde bu problemin önüne geçmek adına CLAHE algoritması kullanılmıştır. Gabor filtreleme yapılmış olan görüntülere CLAHE işlemi uygulanarak daha yüksek oranda başarı sağlanmıştır. CNN derin öğrenme modelinde akciğer kanseri tespiti

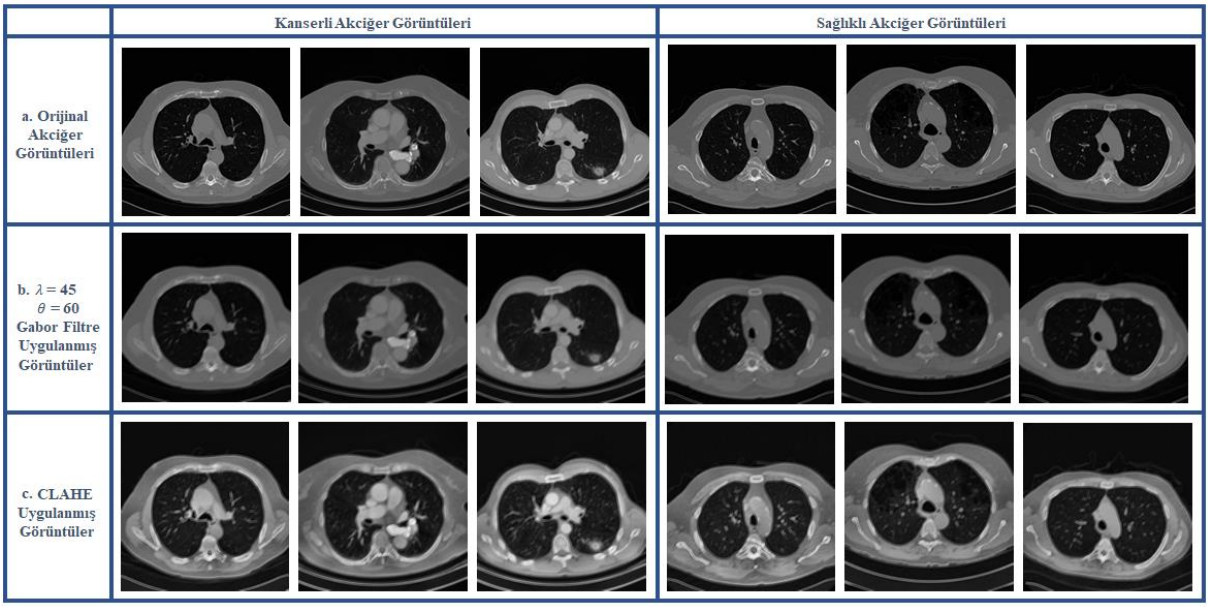
doğruluk oranında CLAHE uygulamanın bazı görüntüler için avantaj elde edilirken bazı görüntüler için de dezavantaj olmuştur. Önerilen CNN derin öğrenme modeli için λ = 45 ve θ = 60 için Gabor filtreleme işleminin uygulanmasının ardından CLAHE işlemi uygulanan görüntüler ile en yüksek doğruluk değeri sağlanmıştır. Önerilen CLAHE algoritmasının akış şeması Şekil 3.17' de gösterilmiştir.



Şekil 3. 17: CLAHE İşleminin Akış Şeması

CLAHE işleminde öncelikle görüntüler RGB formatından LAB formatına dönüştürülmüştür. LAB formatı L, A, B kanallarından oluşmaktadır. CLAHE algoritması L kanalına, görüntünün 8×8 bölünme değeri ve kesme sınırının (clip limit) 3 olduğu değer için uygulanmıştır. Sonrasında yeni oluşan değerler ile A ve B kanalları birleştirilerek yeni görüntü elde edilir. Elde edilen bu görüntü tekrar RGB formatına dönüştürülerek işlem tamamlanmış olur. Şekil 3.18 a.'da orijinal kanserli ve sağlıklı akciğer görüntüleri gösterilmektedir. Bu görüntülere λ = 45 ve

$\theta = 60$ için Gabor filtreleme uygulanmış akciğer görüntüleri Şekil 3.18 b.' de gösterilmektedir. Şekil 3.18 b.' deki görüntülere CLAHE işleminin uygulanması ile elde edilen görüntüler ise Şekil 3.18 c.' de görülmektedir.



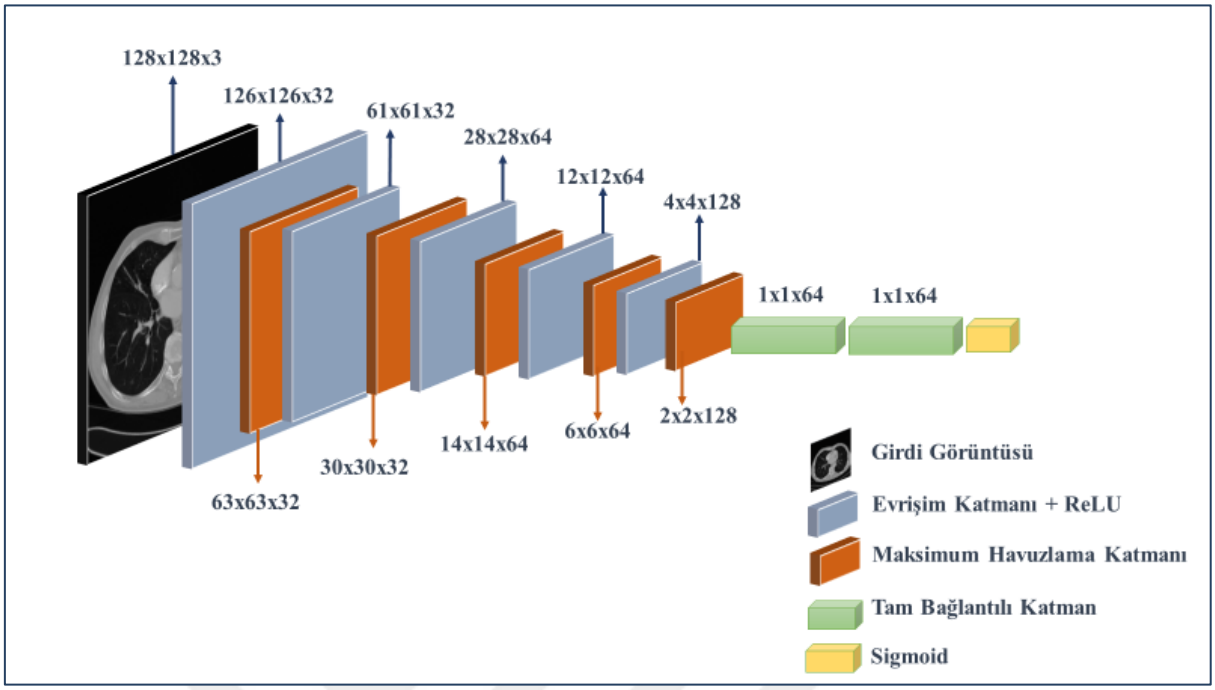
Şekil 3. 18: CLAHE Algoritmasının Uygulandığı Akciğer Görüntüleri

3.8.4. Görüntülere Normalizasyon Uygulanması

Görüntüler bu adıma kadar 566×566 piksel boyutunda tutulmaktadır. Fakat bu kadar büyük boyutlu görüntüler CNN derin öğrenme modelinde avantaj sağlamamaktadır. Çıktı üretme süresi ve sonuçları açısından olumsuz etkiye sebep olmaktadır. Bu problemleri gidermek adına görüntülere 32×32 ve 128×128 piksel boyutlarına dönüştürme işlemi yapılmıştır. Önerilen yöntemdeki normalizasyon tercihi ise 128×128 olmuştur.

3.8.5. CNN Derin Öğrenme Modeli

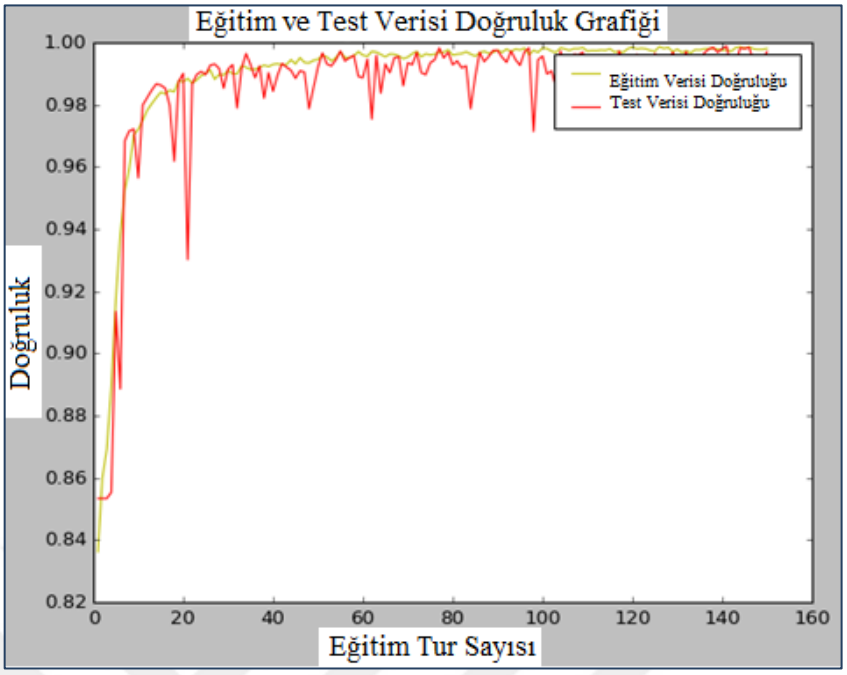
Çalışmanın akış şemasındaki son işlem CNN derin öğrenme modeli adımıdır. Normalizasyon yapılan görüntüler bu adıma girdi olarak verilmiştir. Önerilen CNN derin öğrenme modeli Şekil 3.19' da gösterilmektedir.



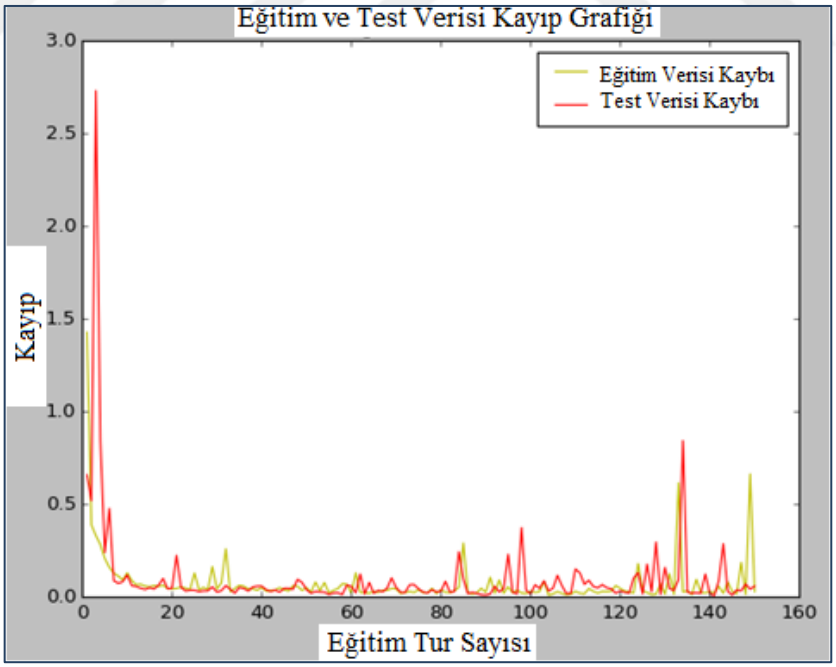
Şekil 3. 19: Önerilen CNN Derin Öğrenme Modeli

Önerilen CNN derin öğrenme modelinde beş evrişim katmanı ile ReLU aktivasyon fonksiyonunun ardından Maksimum havuzlama katmanı vardır. İki adet tam bağlantılı katman bulunmaktadır ve Sigmoid aktivasyonu kullanılarak sınıflandırma gerçeklenmiş olmaktadır.

CNN derin öğrenme modelinin çıktısı olan doğruluk ve kayıp grafikleri sırasıyla örnek olarak Şekil 3.20, Şekil 3.21' de gösterilmektedir. Doğruluk grafiği eğitim tur sayısına bağlı olarak eğitim verisi doğruluğu (training accuracy) ve test verisi doğruluğu (validation accuracy) ile Şekil 3.20' de gösterilmektedir. Kayıp grafiği eğitim tur sayısına bağlı olarak eğitim verisi kaybı (training loss) ve test verisi kaybı (validation loss) ile Şekil 3.21' de gösterilmektedir.



Şekil 3. 20: Eğitim ve Test Verileri Doğruluk Grafiği



Şekil 3. 21: Eğitim ve Test Verileri Kayıp Grafiği

4. BULGULAR

Bu bölümde, Evrişimsel Sinir Ağı (CNN) derin öğrenme modeline dayanan akciğer kanser tespiti yönteminin LIDC-IDRI veri setinden alınan örnekler üzerinde uygulanması sonucu elde edilen bulgular verilmiştir. Veri setinde önerilen Gabor Filtresi, CLAHE ve CNN metodlarına dayalı yöntem kullanılmıştır.

Çalışmada 3 farklı CNN derin öğrenme modeli sunulmuştur. Bunların ilki 3 katmanlı 300 eğitim tur sayılı CNN derin öğrenme modelidir. Bu derin öğrenme modelindeki görüntüler önce normalizasyon işlemi yapılarak 32×32 boyutuna dönüştürülmüştür. İkinci derin öğrenme modeli 3 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelidir. Bu derin öğrenme modelindeki görüntüler önce normalizasyon işlemi yapılarak 128×128 boyutuna dönüştürülür. Üçüncü derin öğrenme modeli ise 5 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelidir. Bu derin öğrenme modelindeki görüntüler önce normalizasyon işlemi yapılarak 128×128 boyutuna dönüştürülür. Bu üç model için elde edilen sonuçlar karşılaştırılmıştır.

4.1. ÖNERİLEN SINIFLANDIRMA YÖNTEMİNİN PERFORMANS ANALİZİ

Bu aşamada görüntülere Gabor Filtresi algoritması, CLAHE algoritması ve Normalizasyon uygulanmasının ardından, önerilen CNN derin öğrenme modelleri ile sınıflandırma yapılması sonucunda elde edilen bulgu değerleri sunulmuştur. Bulgular oluşturulurken yöntemde kullanılan 4 adet parametre değerinin farklı değerleri göz önünde bulundurulmuştur. Bu parametre değerleri:

- Gabor Filtresi Lambda (λ) Açısı
- Gabor Filtresi Teta (θ) Açısı
- CLAHE İşleminin Uygulanması
- CNN Derin Öğrenme Modeli

Önerilen yöntem; Gabor filtresi λ açısı, Gabor filtresi θ açısı, CLAHE işleminin uygulanması ve CNN derin öğrenme modeli olmak üzere 4 temel parametreye bağlı olarak çalıştırılmaktadır. Bu parametrelerin değerlerinin değişimi sonucunda elde edilen bulgular değerlendirilmek istenmiştir ve sonuca etkileri gösterilmiştir.

4.1.1. 32×32 Normalizasyonu ile 3 katmanlı CNN Derin Öğrenme Modeli

CNN derin öğrenme modeli öncesi uygulanan görüntü ön işleme aşamasındaki Gabor filtresi algoritması uygulanırken λ değeri ve θ değerleri, sonuçları belirli değerler için farklı şekilde etki etmektedir. Bununla birlikte CLAHE algoritmasının uygulanması da sonuçları olumlu veya olumsuz yönde etkilemektedir.

Önerilen yöntemin yeniden her çalıştırılmasında, Gabor filtresi farklı λ veya θ değerleri için gerçek pozitif (true positive-TP), gerçek negatif (true negative-TN), yanlış pozitif (false positive-FP) ve yanlış negatif (false negative-FN) değerleri elde edilmiştir. Elde edilmiş olan TP, TN, FP ve FN değerlerine göre Doğruluk (Accuracy), Duyarlılık (Sensitivity), Özgüllük (Specificity), Kesinlik (Precision), F Puanı (F-Score), ROC Eğrisi Alanı (Roc Curve Area) değerleri hesaplanmıştır. Hesaplamalar için formül 4.1, 4.2, 4.3, 4.4 ve 4.5 kullanılmıştır. (Sokolova, 2006)

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \tag{4.1}$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \tag{4.2}$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \tag{4.3}$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \tag{4.4}$$

$$\text{F Puanı} = \frac{2\,x\,TP}{2\,x\,TP+FP+FN} \tag{4.5}$$

Ham görüntüler sadece normalizasyon yapılarak 32×32 boyutlu hale getirilmiştir sonrasında 3 katmanlı CNN derin öğrenme modeline girdi olarak verilmiştir. 300 eğitim tur sayısı içeren CNN derin öğrenme modelinin performans parametrelerinin değerleri Tablo 4.1' de gösterilmektedir.

Tablo 4. 1: Ham Görüntülerin 3 Katmanlı CNN Modeli Performans Metrikleri

Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
0.90070	0.34735	0.99580	0.93431	0.50643	0.94404

Tablo 4.1’ de doğruluk yüzdesi %90.07 olarak elde edilmiştir. Sonraki aşamalarda görüntülere uygulanacak algoritmalar ve parametre değerlerinin farklılıklarına göre sonuçlardaki değişim gösterilecektir.

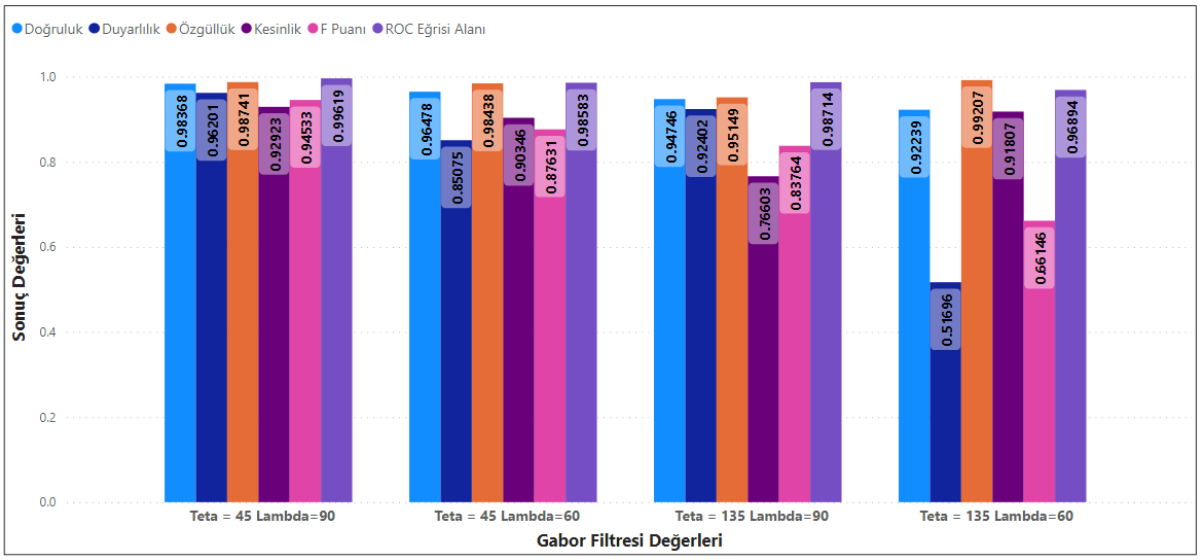
4.1.1.1. Gabor Filtreleme Algoritmasının Bulgu Değerlerine Etkisi

Görüntülere Gabor filtreleme algoritmasının ardından normalizasyon yapılarak 32×32 boyutlu hale getirilmiştir. Bu elde edilen yeni görüntülerin 3 katmanlı 300 eğitim tur sayılı CNN derin öğrenme modelinde ürettiği değerler hesaplanmıştır. Kullanılan Gabor filtresinde λ ve θ değerlerinin değişimine göre değerler Tablo 4.2’ de gösterilmiştir.

Tablo 4. 2: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri

Gabor Filtresi Teta (θ) Değeri	**Gabor Filtresi Lambda(λ) Değeri**	**Doğruluk**	**Duyarlılık**	**Özgüllük**	**Kesinlik**	**F Puanı**	**ROC Eğrisi Alanı**
135	60	0.92239	0.51696	0.99207	0.91807	0.66146	0.96894
135	90	0.94746	0.92402	0.95149	0.76603	0.83764	0.98714
45	60	0.96478	0.85075	0.98438	0.90346	0.87631	0.98583
45	**90**	**0.98368**	**0.96201**	**0.98741**	**0.92923**	**0.94533**	**0.99619**

Tablo 4.2’ de Gabor filtresi algoritmasının kullanılması ile doğruluk oranında ve diğer performans parametreleri oranlarında ham görüntülerin performans değerlerine göre genel olarak daha yüksek sonuçlar elde edilmiştir. Bununla birlikte kullanılan farklı λ ve θ değerleri ile elde edilen sonuçlarda farklılıklar oluşmuştur. Elde edilen sonuçların grafiği Şekil 4.1’ de gösterilmiştir.



Şekil 4. 1: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği

Şekil 4.1' deki grafiğe bakıldığında aynı θ değeri için, λ değerinin 90 olması 60 olmasına göre yaklaşık %2 daha fazla doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. Diğer bir bulgu ise aynı λ değeri için, θ değerinin farklı olması da sonuçlarda farklılıklar meydana getirmiştir. Aynı λ değeri için, θ değerinin 45 olması 135 olması durumuna göre yaklaşık %2 daha fazla doğruluk oranının elde edilmiştir. Diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir.

32×32 boyutlu görüntüler için 3 katmanlı CNN derin öğrenme modelinde Gabor filtresinin λ değerinin 90, θ değerinin 45 olduğu durumda en yüksek doğruluk, duyarlılık, kesinlik, F puanı, roc eğrisi alanı değerleri elde edilmiştir. En yüksek özgüllük değeri ise Gabor filtresinin λ değerinin 60, θ değerinin 135 olduğu durumda elde edilmiştir.

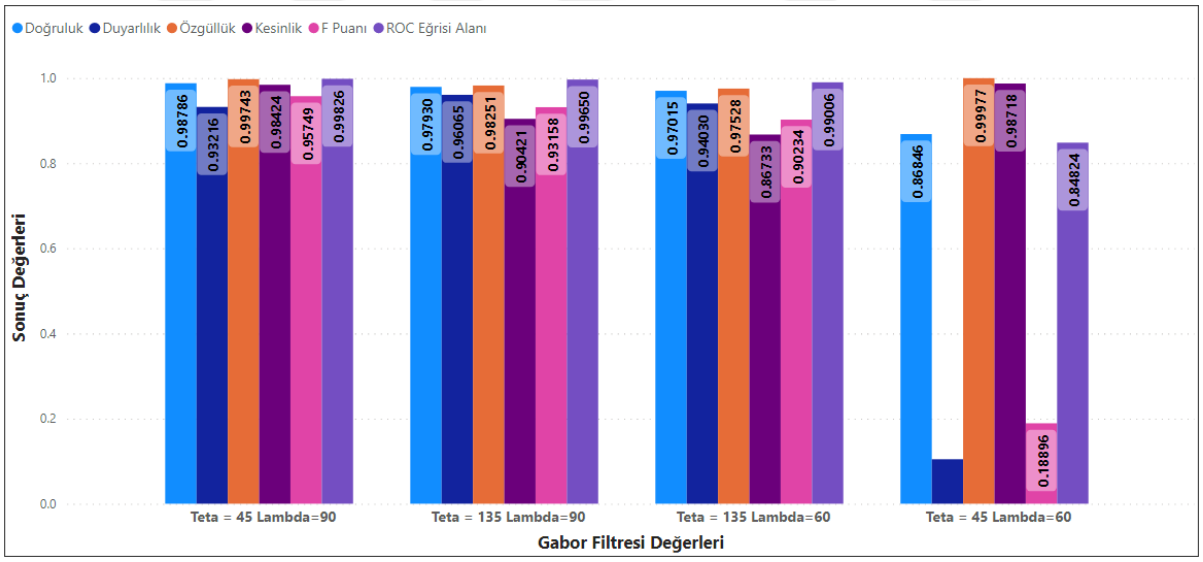
4.1.1.2. CLAHE Algoritmasının Bulgu Değerlerine Etkisi

Gabor filtreleme işlemi yapılmış görüntüler daha sonrasında CLAHE algoritması uygulanmıştır. Sonrasında elde edilen görüntüler normalizasyon yapılarak 32×32 boyutlu hale getirilmiştir. Bu elde edilen yeni görüntülerin 3 katmanlı CNN derin öğrenme modelinde ürettiği değerler hesaplanmıştır.

Tablo 4. 3: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri

Gabor Filtresi Teta (θ) Değeri	Gabor Filtresi Lambda(λ) Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
135	60	0.97015	0.94030	0.97528	0.86733	0.90234	0.99006
135	90	0.97930	0.96065	0.98251	0.90421	0.93158	0.99650
45	60	0.86846	0.10448	0.99977	0.98718	0.18896	0.84824
45	**90**	**0.98786**	**0.93216**	**0.99743**	**0.98424**	**0.95749**	**0.99826**

Tablo 4.3' de Gabor filtresi ve CLAHE algoritmalarının kullanılması ile doğruluk oranında ve diğer performans parametreleri oranlarında ham görüntülerin performans değerlerine göre genel olarak daha yüksek sonuçlar elde edilmiştir. Bununla birlikte kullanılan farklı λ ve θ değerleri ile elde edilen sonuçlarda farklılıklar oluşmuştur. Elde edilen sonuçların grafiği Şekil 4.2' de gösterilmiştir.



Şekil 4. 2: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği

Şekil 4.2' deki grafiğe bakıldığında CLAHE algoritması öncesinde uygulanan Gabor filtresi için aynı θ değeri için, λ değerinin 90 olması 60 olmasına göre daha fazla doğruluk oranı elde edilmiştir. θ değerinin 45 olduğu durumda yaklaşık %12 daha yüksek ve 135 olduğu durumda yaklaşık %1 daha yüksek doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. Diğer bir bulgu ise aynı

λ değeri için, θ değerinin farklı olması da sonuçlarda farklılıklar meydana getirmiştir. λ değerinin 60 olduğu durumda θ değerinin 135 olması 45 olması durumuna göre yaklaşık %11 daha fazla doğruluk oranı elde edilmiştir. λ değerinin 90 olduğu durumda ise θ değerinin 45 olması 135 olması durumuna göre yaklaşık %1 daha fazla doğruluk oranı elde edilmiştir.

Görüntülere önce Gabor filtreleme ve daha sonrasında da CLAHE algoritmalarının kullanılıp 32×32 boyutlu hale getirilen görüntülerin 3 katmanlı CNN derin öğrenme modelinde Gabor filtresinin λ değerinin 90, θ değerinin 45 olduğu durumda en yüksek doğruluk, F puanı, roc eğrisi alanı değerleri elde edilmiştir. En yüksek duyarlılık değeri ise Gabor filtresinin λ değerinin 90, θ değerinin 135 olduğu durumda elde edilmiştir. En yüksek özgüllük ve kesinlik değerleri ise Gabor filtresinin λ değerinin 60, θ değerinin 45 olduğu durumda elde edilmiştir.

Tablo 4.2 ve Tablo 4.3 kıyaslandığında Gabor filtreleme işleminde aynı λ ve θ değerlerine sahip veriler için sonrasında CLAHE algoritmasının uygulanması CNN derin öğrenme modeli sonuçlarında farklılıklar meydana getirmiştir. Doğruluk değerlerine bakıldığında θ 135, λ 60 değerleri için Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %5 daha fazla doğruluk oranı elde edilmiştir. θ 135, λ 90 değerleri için Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %3 daha fazla doğruluk oranı elde edilmiştir. θ 45, λ 90 değerleri için Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %0.5 daha fazla doğruluk oranı elde edilmiştir. θ 45, λ 60 değerleri için sadece Gabor filtreleme işleminin uygulanması durumunda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumuna göre yaklaşık %10 daha fazla doğruluk oranı elde edilmiştir.

Verilere bakıldığında genel olarak CLAHE işleminin doğruluk oranını yükselttiği söylenebilir. En yüksek doğruluk oranı θ 45, λ 90 değerleri için Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda elde edilmiştir.

4.1.2. 128×128 Normalizasyonu ile 3 katmanlı CNN Derin Öğrenme Modeli

CNN derin öğrenme modeli öncesi uygulanan görüntü ön işleme aşamasındaki Gabor filtresi algoritması uygulanırken λ değeri ve θ değerleri, sonuçları belirli değerler için farklı şekilde etki etmektedir. Bununla birlikte CLAHE algoritmasının uygulanması da sonuçları olumlu veya olumsuz yönde etkilemektedir.

Önerilen yöntemin yeniden her çalıştırılmasında, Gabor filtresi farklı λ veya θ değerleri için elde edilmiş olan TP, TN, FP ve FN değerlerine göre Doğruluk, Duyarlılık, Özgüllük, Kesinlik, F Puanı, ROC Eğrisi Alanı yüzde değerleri hesaplanmıştır.

Ham görüntülerin herhangi bir ön işlemden geçirilmeden sadece normalizasyon yapılarak 128×128 boyutlu hale getirilmiştir sonrasında 3 katmanlı CNN derin öğrenme modeline girdi olarak verilmiştir. 150 eğitim tur sayısı içeren CNN derin öğrenme modelinin performans parametrelerinin değerleri Tablo 4.4' de gösterilmektedir.

Tablo 4. 4: Ham Görüntülerin 3 Katmanlı CNN Modeli Performans Metrikleri

Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
0.90328	0.40570	0.98881	0.86167	0.55166	0.93378

Tablo 4.4' de doğruluk yüzdesi %90.328 olarak elde edilmiştir. Tablo 4.1' deki sonuçlar ile karşılaştırıldığında ham görüntülerin 128×128 boyutuna getirilip 3 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelindeki performans değerlerinin daha yüksek olduğu söylenebilir. Sonraki aşamalarda görüntülere uygulanacak algoritmalar ve parametre değerlerinin farklılıklarına göre sonuçlardaki değişim gösterilecektir.

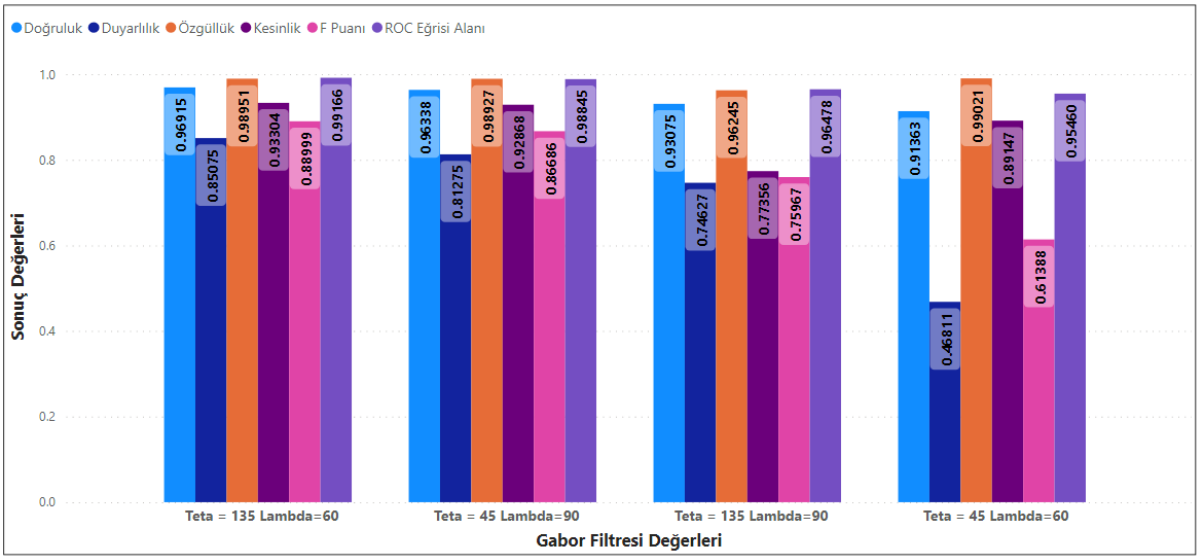
4.1.2.1. Gabor Filtreleme Algoritmasının Bulgu Değerlerine Etkisi

Görüntülere Gabor filtreleme algoritmasının ardından normalizasyon yapılarak 128×128 boyutlu hale getirilmiştir. Bu elde edilen yeni görüntülerin 3 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelinde ürettiği değerler hesaplanmıştır. Kullanılan Gabor filtresinde λ ve θ değerlerinin değişimine göre değerler Tablo 4.5' de gösterilmiştir.

Tablo 4. 5: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri

Gabor Filtresi Teta (θ) Değeri	Gabor Filtresi Lambda(λ) Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
135	**60**	**0.96915**	**0.85075**	**0.98951**	**0.93304**	**0.88999**	**0.99166**
135	90	0.93075	0.74627	0.96245	0.77356	0.75967	0.96478
45	60	0.91363	0.46811	0.99021	0.89147	0.61388	0.95460
45	90	0.96338	0.81275	0.98927	0.92868	0.86686	0.98845

Tablo 4.5' de Gabor filtresi algoritmasının kullanılması ile doğruluk oranında ve diğer performans parametreleri oranlarında ham görüntülerin performans değerlerine göre genel olarak daha yüksek sonuçlar elde edilmiştir. Bununla birlikte kullanılan farklı λ ve θ değerleri ile elde edilen sonuçlarda farklılıklar oluşmuştur. Elde edilen sonuçların grafiği Şekil 4.3' te gösterilmiştir.



Şekil 4. 3: Gabor Filtreleme Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği

Şekil 4.3' teki grafiğe bakıldığında θ değerinin 135 olduğu durumda için, λ değerinin 60 olması 90 olmasına durumuna göre yaklaşık %3 daha fazla doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. θ değerinin 45 olduğu durumda için, λ değerinin 90 olması 60 olmasına göre yaklaşık %5 daha fazla doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans

parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. λ değerinin 60 olması durumda, θ değerinin 135 olması 45 olması durumuna göre yaklaşık %5 daha fazla doğruluk oranının elde edilmiştir. Diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. λ değerinin 90 olması durumda, θ değerinin 45 olması 135 olması durumuna göre yaklaşık %3 daha fazla doğruluk oranının elde edilmiştir. Diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir.

128×128 boyutlu görüntüler için 3 katmanlı CNN derin öğrenme modelinde Gabor filtresinin λ değerinin 60, θ değerinin 135 olduğu durumda tüm performans paramtereleri için en yüksek değerler elde edilmiştir.

Tablo 4.2 ve Tablo 4.5' deki verilere bakıldığında Gabor filtresi uygulanmış 32×32 boyutlu görüntülerin 3 katmanlı 300 eğitim tur sayılı CNN derin öğrenme modelindeki sonuçlar ile Gabor filtresi uygulanmış 128×128 boyutlu görüntülerin 3 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelindeki sonuçlar arasında farklılar oluştuğu söylenebilir. Bu iki tablodan elde edilen verilere göre ilk normalizasyon ve CNN derin öğrenme modeli ikinci normalizasyon ve CNN derin öğrenme modeline göre genel olarak daha yüksek değere sahiptir. θ 135 λ 60 değerleri için sadece Gabor filtresi uygulanmış görüntülerin ikinci normalizasyon ve CNN derin öğrenme modelinde daha yüksek doğruluk oranına sahip olduğu söylenebilir.

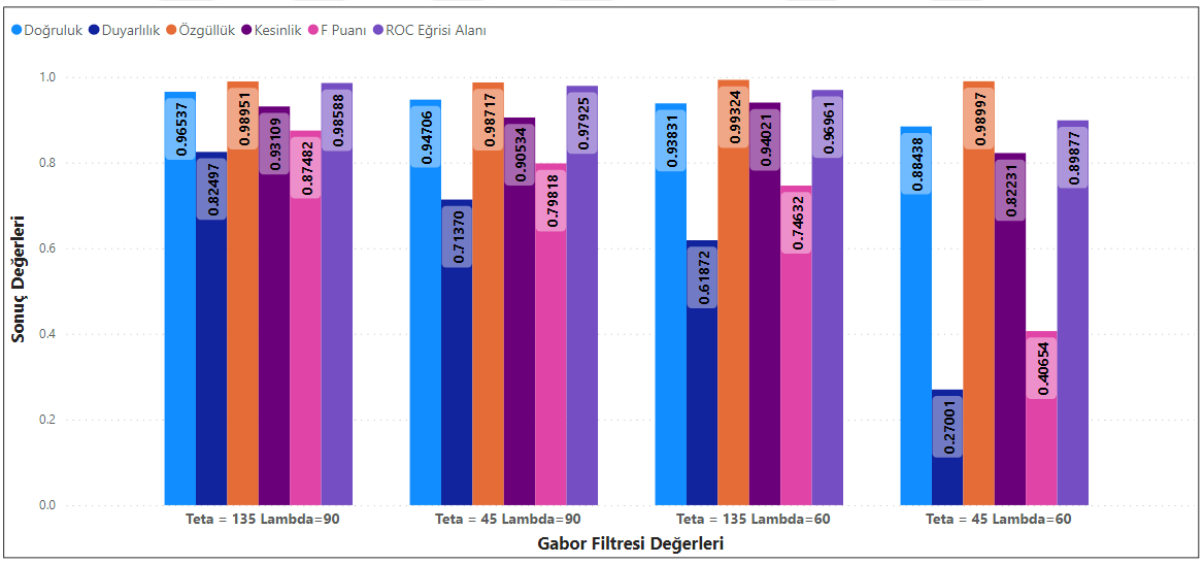
4.1.2.2. CLAHE Algoritmasının Bulgu Değerlerine Etkisi

Gabor filtreleme işlemi yapılmış görüntüler daha sonrasında CLAHE algoritması uygulanmıştır. Sonrasında elde edilen görüntüler normalizasyon yapılarak 128×128 boyutlu hale getirilmiştir. Bu elde edilen yeni görüntülerin 3 katmanlı CNN derin öğrenme modelinde ürettiği değerler hesaplanmıştır.

Tablo 4. 6: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Performans Metrikleri

Gabor Filtresi Teta (θ) Değeri	Gabor Filtresi Lambda(λ) Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
135	60	0.93831	0.61872	0.99324	0.94021	0.74632	0.96961
135	**90**	**0.96537**	**0.82497**	**0.98951**	**0.93109**	**0.87482**	**0.98588**
45	60	0.88438	0.27001	0.98997	0.82231	0.40654	0.89877
45	90	0.94706	0.71370	0.98717	0.90534	0.79818	0.97925

Tablo 4.6' de Gabor filtresi ve CLAHE algoritmalarının kullanılması ile doğruluk oranında ve diğer performans parametreleri oranlarında ham görüntülerin performans değerlerine göre genel olarak daha yüksek sonuçlar elde edilmiştir. Bununla birlikte kullanılan farklı λ ve θ değerleri ile elde edilen sonuçlarda farklılıklar oluşmuştur. Elde edilen sonuçların grafiği Şekil 4.4' te gösterilmiştir.



Şekil 4. 4: CLAHE Algoritması ve 3 Katmanlı CNN Modeli Sonuç Grafiği

Şekil 4.4' teki grafiğe bakıldığında CLAHE algoritması öncesinde uygulanan Gabor filtresi için aynı θ değeri için, λ değerinin 90 olması 60 olmasına göre daha fazla doğruluk oranı elde edilmiştir. θ değerinin 135 olduğu durumda λ değerinin 90 olması 60 olmasına göre yaklaşık %3 daha yüksek ve 45 olduğu durumda λ değerinin 90 olması 60 olmasına göre yaklaşık %6 daha yüksek doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde

de genel olarak daha yüksek sonuçlar elde edilmiştir. Diğer bir bulgu ise aynı λ değeri için, θ değerinin farklı olması da sonuçlarda farklılıklar meydana getirmiştir. Aynı λ değeri için, θ değerinin 135 olması 45 olmasına göre daha fazla doğruluk oranı elde edilmiştir. λ değerinin 90 olduğu durumda θ değerinin 135 olması 45 olmasına göre yaklaşık %2 daha yüksek ve 60 olduğu durumda θ değerinin 135 olması 45 olmasına göre yaklaşık %5 daha yüksek doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. Elde edilen sonuçlara bakıldığında görüntülere önce Gabor filtreleme ve daha sonrasında da CLAHE algoritmalarının kullanılıp 128×128 boyutlu hale getirilen görüntülerin 3 katmanlı CNN derin öğrenme modelinde Gabor filtresinin λ değerinin 90, θ değerinin 135 olduğu durumda en yüksek doğruluk, duyarlılık, F puanı, roc eğrisi alanı değerleri elde edilmiştir. En yüksek özgüllük ve kesinlik değerleri ise Gabor filtresinin λ değerinin 60, θ değerinin 135 olduğu durumda elde edilmiştir.

Tablo 4.5 ve Tablo 4.6 kıyaslandığında Gabor filtreleme işleminde aynı λ ve θ değerlerine sahip veriler için sonrasında CLAHE algoritmasının uygulanması CNN derin öğrenme modeli sonuçlarında farklılıklar meydana getirmiştir. Doğruluk değerlerine bakıldığında θ 135 ve 45, λ 60 değerleri için sadece Gabor filtreleme işleminin uygulanması durumunda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumuna göre yaklaşık %3 daha fazla doğruluk oranı elde edilmiştir. θ 45, λ 90 değerleri için sadece Gabor filtreleme işleminin uygulanması durumunda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumuna göre yaklaşık %2 daha fazla doğruluk oranı elde edilmiştir. θ 135, λ 90 değerleri için Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %3 daha fazla doğruluk oranı elde edilmiştir.

128×128 boyutlu görüntülerin önerilen CNN modelindeki elde edilen verilere bakıldığında sadece Gabor filtreleme işleminin uygulanması durumunda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumuna göre genel olarak doğruluk oranında daha yüksek değerlere sahiptir. En yüksek doğruluk oranı θ 135, λ 60 değerleri için sadece Gabor filtreleme algoritmasının uygulanması durumunda elde edilmiştir.

Tablo 4.3’ de görüntülerin 3 katmanlı CNN derin öğrenme modelindeki sonuçlar Tablo 4.6’ daki diğer 3 katmanlı CNN derin öğrenme modelindeki sonuçları ile kıyaslandığında Tablo 4.6’

da uygulanan normalizasyon ve CNN derin öğrenme modelinin genel olarak başarılı olduğu söylenebilir. Görüntülerin Gabor filtreleme işlemindeki θ değeri 45, λ değeri 90, θ değerinin 135 ile λ değerlerinin 60 ve 90 olması ve ardından CLAHE işleminin uygulanması durumunda ikinci önerilen modelde sırasıyla yaklaşık %4, %4 ve %1 daha fazla doğruluk oranı elde edilmiştir. Görüntülerin Gabor filtreleme işlemindeki θ değeri 45, λ değeri 60 ve ardından CLAHE işleminin uygulanması durumunda ilk önerilen modelde yaklaşık %2 daha fazla doğruluk oranı elde edilmiştir.

4.1.3. 128×128 Normalizasyonu ile 5 katmanlı CNN Derin Öğrenme Modeli

CNN derin öğrenme modeli öncesi uygulanan görüntü ön işleme aşamasındaki Gabor filtresi algoritması uygulanırken λ değeri ve θ değerleri, sonuçları belirli değerler için farklı şekilde etki etmektedir. Bununla birlikte CLAHE algoritmasının uygulanması da sonuçları olumlu veya olumsuz yönde etkilemektedir.

Önerilen yöntemin yeniden her çalıştırılmasında, Gabor filtresi farklı λ veya θ değerleri için elde edilmiş olan TP, TN, FP ve FN değerlerine göre Doğruluk, Duyarlılık, Özgüllük, Kesinlik, F Puanı, ROC Eğrisi Alanı yüzde değerleri hesaplanmıştır.

Ham görüntülerin herhangi bir ön işlemden geçirilmeden sadece normalizasyon yapılarak 128×128 boyutlu hale getirilmiştir sonrasında 5 katmanlı CNN derin öğrenme modeline girdi olarak verilmiştir. 150 eğitim tur sayısı içeren CNN derin öğrenme modelinin performans parametrelerinin değerleri Tablo 4.7’ de gösterilmektedir.

Tablo 4. 7: Ham Görüntülerin 5 Katmanlı CNN Modeli Performans Metrikleri

Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
0.98249	0.88874	0.99860	0.99092	0.93705	0.99467

Tablo 4.7’ de doğruluk yüzdesi %98.249 olarak elde edilmiştir. Tablo 4.1 ve Tablo 4.4’ teki sonuçlar ile karşılaştırıldığında ham görüntülerin 128×128 boyutuna getirilip 5 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelindeki performans değerlerinin daha yüksek olduğu söylenebilir. Sonraki aşamalarda görüntülere uygulanacak algoritmalar ve parametre değerlerinin farklılıklarına göre sonuçlardaki değişim gösterilecektir.

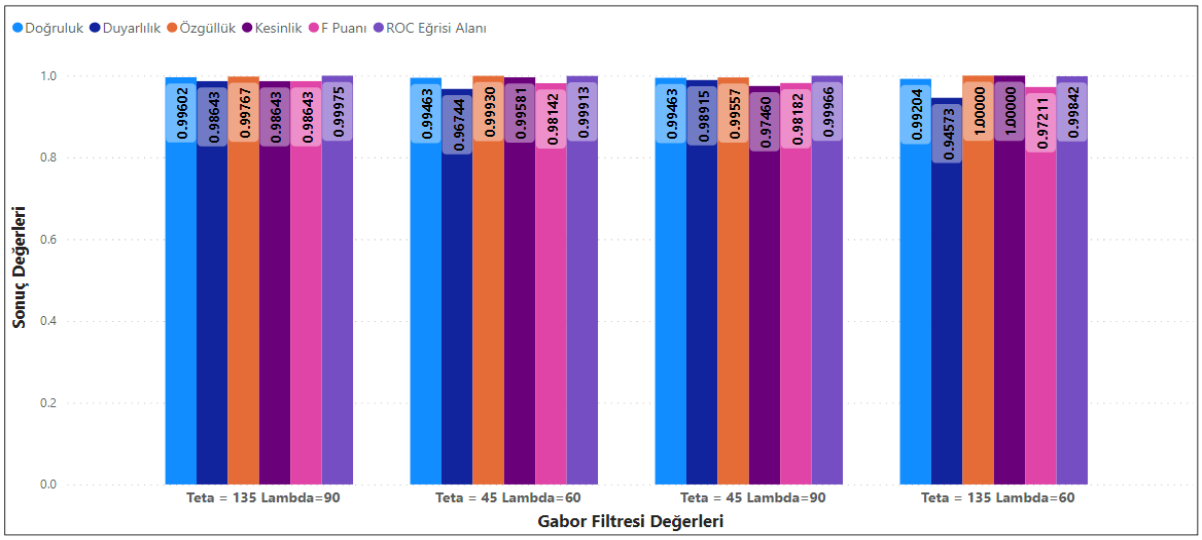
4.1.3.1. Gabor Filtreleme Algoritmasının Bulgu Değerlerine Etkisi

Görüntülere Gabor filtreleme algoritmasının ardından normalizasyon yapılarak 128×128 boyutlu hale getirilmiştir. Bu elde edilen yeni görüntülerin 5 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelinde ürettiği değerler hesaplanmıştır. Kullanılan Gabor filtresinde λ ve θ değerlerinin değişimine göre değerler Tablo 4.8' de gösterilmiştir.

Tablo 4. 8: Gabor Filtreleme Algoritması ve 5 Katmanlı CNN Modeli Performans Metrikleri

Gabor Filtresi Teta (θ) Değeri	Gabor Filtresi Lambda(λ) Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
135	60	0.992040	0.945726	1.000000	1.000000	0.972106	0.998420
135	**90**	**0.996020**	**0.986431**	**0.997668**	**0.986431**	**0.986431**	**0.999754**
45	60	0.994627	0.967436	0.999300	0.995810	0.981418	0.999125
45	90	0.994627	0.989145	0.995569	0.974599	0.981818	0.999662

Tablo 4.8' de Gabor filtresi algoritmasının kullanılması ile doğruluk oranında ve diğer performans parametreleri oranlarında ham görüntülerin performans değerlerine göre daha yüksek sonuçlar elde edilmiştir. Bununla birlikte kullanılan farklı λ ve θ değerleri ile elde edilen sonuçlarda farklılıklar oluşmuştur. Elde edilen sonuçların grafiği Şekil 4.5' te gösterilmiştir.



Şekil 4. 5: Gabor Filtreleme Algoritması ve 5 Katmanlı CNN Modeli Sonuç Grafiği

Şekil 4.5’ teki grafiğe bakıldığında aynı θ değerinin 135 olması durumunda, λ değerinin 90 olması 60 olmasına göre yaklaşık %0.4 daha fazla doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. θ değerinin 45 olması durumunda ise farklı λ değerleri için aynı doğruluk oranı elde edilmiştir. Diğer bir bulgu ise aynı λ değeri için, θ değerinin farklı olması da sonuçlarda farklılıklar meydana getirmiştir. λ değerinin 60 olduğu durumda, θ değerinin 45 olması 135 olması durumuna göre yaklaşık %0.2 daha fazla doğruluk oranının elde edilmiştir. Diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. λ değerinin 90 olduğu durumda, θ değerinin 135 olması 45 olması durumuna göre yaklaşık %0.2 daha fazla doğruluk oranının elde edilmiştir. Diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir.

128×128 boyutlu görüntüler için 5 katmanlı CNN derin öğrenme modelinde Gabor filtresinin λ değerinin 90, θ değerinin 135 olduğu durumda doğruluk, F puanı, roc eğrisi alanı performans parametreleri için en yüksek değerler elde edilmiştir. λ değerinin 90, θ değerinin 45 olduğu durumda en yüksek duyarlılık değeri elde edilmiştir. λ değeri 60, θ değerinin 135 olduğu durumda ise en yüksek özgüllük ve kesinlik değerleri elde edilmiştir.

Tablo 4.2, Tablo 4.5 ve Tablo 4.8’ deki verilere bakıldığında Gabor filtresi uygulanmış görüntülerin en yüksek doğruluk değerlerinin Tablo 4.8’ de olduğu görülmektedir. Doğruluk değerinin yanı sıra diğer tüm performans parametre değerlerinde de en yüksek sonuçlar elde edilmiştir. Gabor filtreleme algoritmasının uygulandığı bu üç tablonun kıyaslamasında görüntülerin en yüksek performans parametre değerlerinin Gabor filtreleme algoritmasının ardından normalizasyon yapılarak 128×128 boyutuna dönüştürülüp sonrasında önerilen 5 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modelinde elde edildiği söylenebilir.

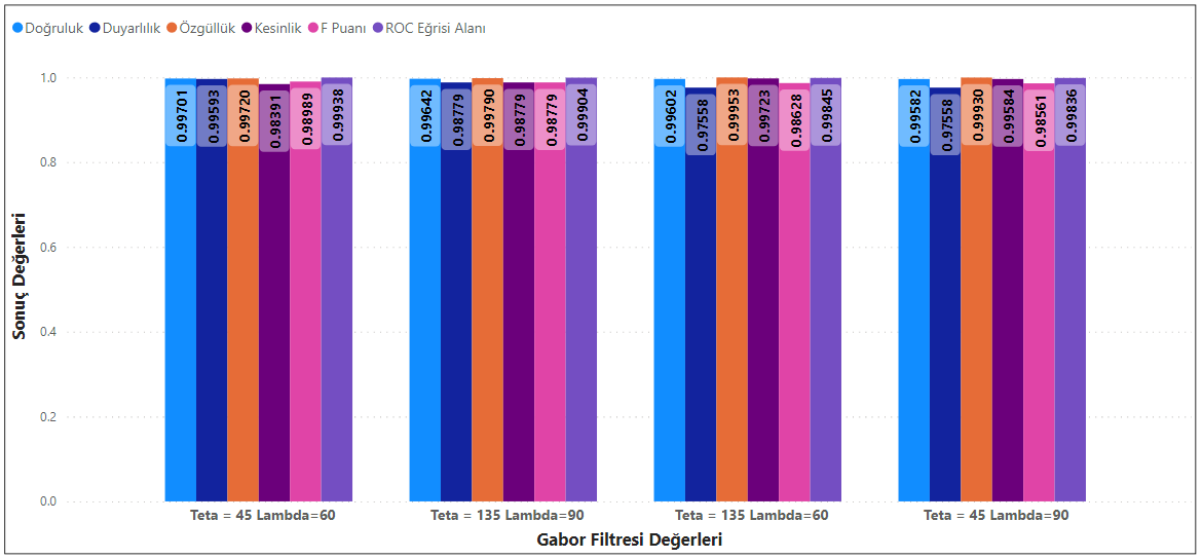
4.1.3.2. CLAHE Algoritmasının Bulgu Değerlerine Etkisi

Gabor filtreleme işlemi yapılmış görüntüler daha sonrasında CLAHE algoritması uygulanmıştır. Sonrasında elde edilen görüntüler normalizasyon yapılarak 128×128 boyutlu hale getirilmiştir. Bu elde edilen yeni görüntülerin 5 katmanlı CNN derin öğrenme modelinde ürettiği değerler hesaplanmıştır.

Tablo 4. 9: CLAHE Algoritması ve 5 Katmanlı CNN Modeli Performans Metrikleri

Gabor Filtresi Teta (θ) Değeri	Gabor Filtresi Lambda(λ) Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F Puanı	ROC Eğrisi Alanı
135	60	0.99602	0.97558	0.99953	0.99723	0.98628	0.99845
135	90	0.99642	0.98779	0.99790	0.98779	0.98779	0.99904
45	**60**	**0.99701**	**0.99593**	**0.99720**	**0.98391**	**0.98989**	**0.99938**
45	90	0.99582	0.97558	0.99930	0.99584	0.98561	0.99836

Tablo 4.9' de Gabor filtresi ve CLAHE algoritmalarının kullanılması ile doğruluk oranında ve diğer performans parametreleri oranlarında ham görüntülerin performans değerlerine göre genel olarak daha yüksek sonuçlar elde edilmiştir. Bununla birlikte kullanılan farklı λ ve θ değerleri ile elde edilen sonuçlarda farklılıklar oluşmuştur. Elde edilen sonuçların grafiği Şekil 4.6' da gösterilmiştir.



Şekil 4. 6: CLAHE Algoritması ve 5 Katmanlı CNN Modeli Sonuç Grafiği

Şekil 4.6' daki grafiğe bakıldığında CLAHE algoritması öncesinde uygulanan Gabor filtresi için θ değerinin 135 olduğu durumda λ değerinin 90 olması 60 olmasına göre yaklaşık %0.3 daha yüksek doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. θ değerinin 45 olduğu durumda λ değerinin 60 olması 90 olmasına göre yaklaşık %0.2 daha yüksek doğruluk oranı elde

edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. Diğer bir bulgu ise λ değerinin 60 olduğu durumda θ değerinin 45 olması 135 olmasına göre yaklaşık %0.1 daha yüksek doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir. λ değerinin 90 olduğu durumda θ değerinin 135 olması 45 olmasına göre yaklaşık %0.1 daha yüksek doğruluk oranı elde edilmiştir. Bununla birlikte diğer performans parametrelerinde de genel olarak daha yüksek sonuçlar elde edilmiştir.

Verilere bakıldığında görüntülere önce Gabor filtreleme ve daha sonrasında da CLAHE algoritmalarının kullanılıp 128×128 boyutlu hale getirilen görüntülerin 5 katmanlı CNN derin öğrenme modelinde Gabor filtresinin λ değerinin 60, θ değerinin 45 olduğu durumda en yüksek doğruluk, duyarlılık, F puanı, roc eğrisi alanı değerleri elde edilmiştir. En yüksek özgüllük ve kesinlik değerleri ise Gabor filtresinin λ değerinin 60, θ değerinin 135 olduğu durumda elde edilmiştir.

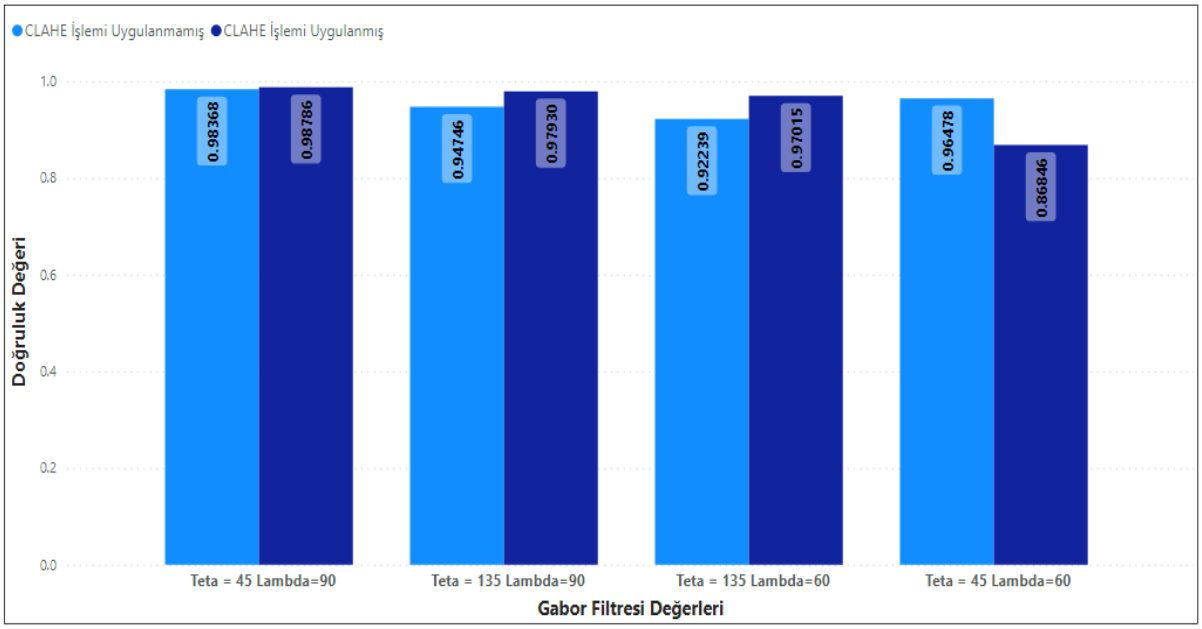
Tablo 4.8 ve Tablo 4.9 kıyaslandığında Gabor filtreleme işleminde aynı λ ve θ değerlerine sahip veriler için sonrasında CLAHE algoritmasının uygulanması CNN derin öğrenme modeli sonuçlarında farklılıklar meydana getirmiştir. Doğruluk değerlerine bakıldığında θ değerinin 135, λ değerinin 60 olduğu durumda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %0.4 daha fazla doğruluk oranı elde edilmiştir. θ değerinin 135, λ değerinin 90 olduğu durumda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %0.04 daha fazla doğruluk oranı elde edilmiştir. θ değerinin 45, λ değerinin 60 olduğu durumda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %0.3 daha fazla doğruluk oranı elde edilmiştir. θ değerinin 45, λ değerinin 90 olduğu durumda Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre yaklaşık %0.1 daha fazla doğruluk oranı elde edilmiştir.

128×128 boyutlu görüntülerin önerilen CNN modelindeki elde edilen verilere bakıldığında Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda sadece Gabor filtreleme işleminin uygulanması durumuna göre doğruluk oranında daha yüksek

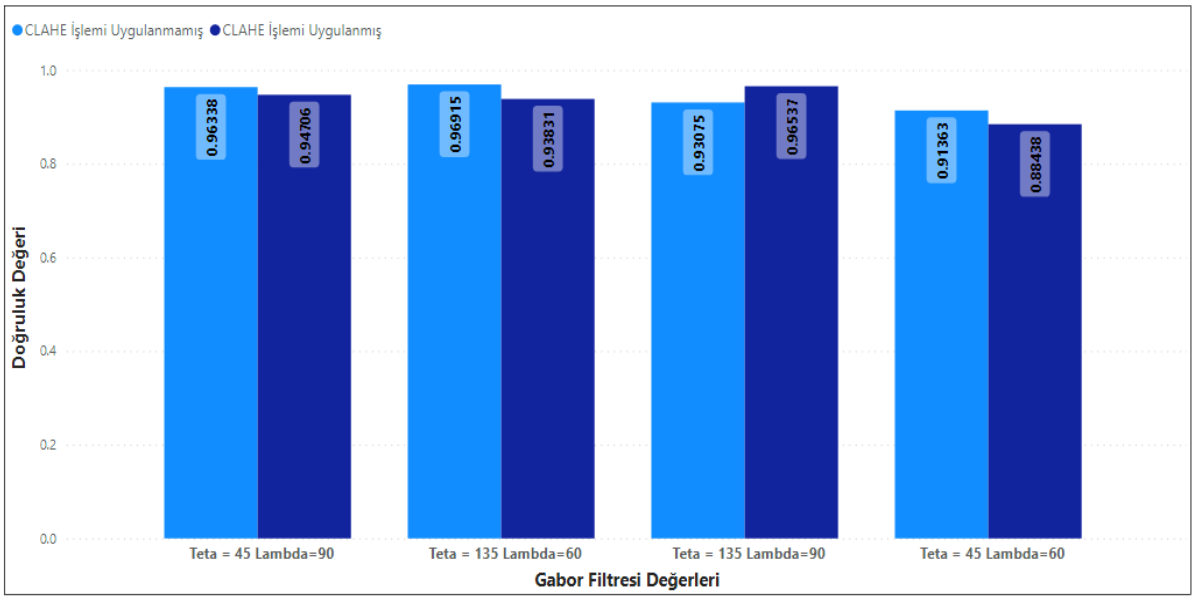
değerlere sahip olduğu görülmektedir. En yüksek doğruluk oranı ise θ 45, λ 60 olduğu değerleri için Gabor filtreleme işlemi yapıldıktan sonra CLAHE algoritmasının uygulanması durumunda elde edilmiştir.

4.1.4. CNN Derin Öğrenme Modellerinin Doğruluk Değerleri

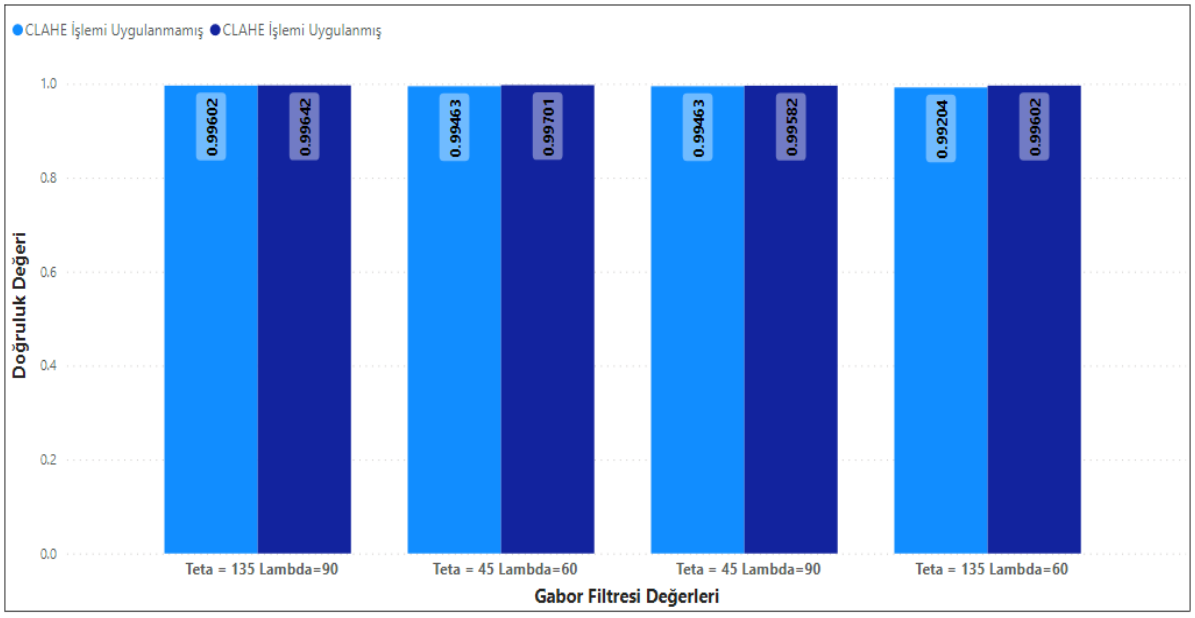
Çalışmada akciğer görüntüleri için normalizasyon, Gabor filtreleme, CLAHE algoritması ve CNN derin öğrenme modellerine göre elde edilen doğruluk değer grafikleri Şekil 4.7, Şekil 4.8 ve Şekil 4.9' da gösterilmektedir.



Şekil 4. 7: 32×32 Boyutlu Görüntülerin 3 Katmanlı 300 Eğitim Tur Sayılı CNN Modeli Doğruluk Grafiği



Şekil 4. 8: 128×128 Boyutlu Görüntülerin 3 Katmanlı 150 Eğitim Tur Sayılı CNN Modeli Doğruluk Grafiği



Şekil 4. 9: 128×128 Boyutlu Görüntülerin 5 Katmanlı 150 Eğitim Tur Sayılı CNN Modeli Doğruluk Grafiği

Şekil 4.7, Şekil 4.8 ve Şekil 4.9' daki grafiklere bakılarak CNN Derin öğrenme ile akciğer kanseri tespitinin yapılmasında en yüksek sonucun θ 45 ve λ 60 değerleri ile Gabor filtreleme işlemi ardından CLAHE işleminin uygulandığı görüntülerin 128×128 normalizasyon yapılarak

girdi olarak verilen **5 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modeli** ile elde edildiği görülmektedir.

4.1.5. CNN Derin Öğrenme Modellerinin Çalışma Süresi ve Kayıp (Loss) Oranları

Gabor filtreleme yapılmış olan görüntüler için CNN derin öğrenme modeline ait çalışma süresi ve kayıp oranları Tablo 4.10' da gösterilmektedir. Bu tabloda farklı θ, λ değerleri ile Gabor filtreleme yapılmış olan görüntüler için model, CLAHE işlemi, görüntü boyutu, eğitim tur sayısı parametreleri bazında gruplama yapılarak CNN model eğitim süresi ve kayıp oranları gösterilmektedir. Bu parametrelerin sonuçları farklı şekilde etkilediği görülmektedir. CNN model eğitim süresi sütununda saat, dakika ve saniye olacak şekilde süre ifade edilmektedir.

Tablo 4. 10: CNN Derin Öğrenme Modellerinin Çalışma Süresi ve Kayıp Oranları

Model	CLAHE	Görüntü Boyutu	Eğitim Tur Sayısı	CNN Model Eğitim Süresi	Kayıp Oranı
5 Katmanlı CNN Model	+	128×128	150	07:40:51	0.0559
5 Katmanlı CNN Model	-	128×128	150	07:42:08	0.0365
3 Katmanlı CNN Model	+	128×128	150	07:16:00	0.3880
3 Katmanlı CNN Model	-	128×128	150	07:23:22	0.1978
3 Katmanlı CNN Model	+	32×32	300	00:57:40	0.3998
3 Katmanlı CNN Model	-	32×32	300	00:50:23	0.2369

Tablo 4.10' a bakıldığında en uzun eğitim süresine sahip olan model 5 katmanlı CNN derin öğrenme modeli ve CLAHE işlemi uygulanmış görüntülerdir. Bununla birlikte de en az kayıp oranı 5 katmanlı CNN derin öğrenme modeli ve CLAHE işlemi uygulanmış görüntüler ile elde edilmiştir. En az eğitim süresine sahip olan model 3 katmanlı CNN derin öğrenme modeli ve CLAHE işlemi uygulanmamış görüntülerdir. En fazla kayıp oranı 3 katmanlı CNN derin öğrenme modeli ve CLAHE işlemi uygulanmış görüntüler ile elde edilmiştir.

5. TARTIŞMA VE SONUÇ

Önerilen tez çalışmasında öncelikle akciğer görüntülerinin görüntü uzantısı değiştirilmiştir. Elde edilen görüntülere farklı ön işlemler uygulanmıştır. Bunlardan ilki Gabor filtreleme algoritması olup bu işlemde farklı parametre değerleri için farklı veri setleri elde edilmiştir. İkincisi Gabor filtreleme algoritmasının uygulanması ile elde edilen her veri setine CLAHE algoritmasının uygulanmasıdır. Elde edilen tüm veri setlerinin CNN derin öğrenme modellerine girdi olarak verilerek akciğer görüntüsünün normal veya hastalıklı olup olmadığı değerlendirilmiştir. Çalışmada LIDC-IDRI veri setinden DICOM formatından PNG formatına dönüştürülmüş 21600 adet kanserli, 3525 adet normal akciğer görüntüsü kullanılmıştır.

Bulgular incelendiğinde Gabor filtresi λ değeri, Gabor filtresi θ değeri, CLAHE işleminin uygulanması ve CNN derin öğrenme modeli gibi parametrelerin sonuca katkı sunduğu gözlemlenmektedir. Akciğer görüntülerinin 32×32 boyutlu hale getirilip girdi olarak verildiği 3 katmanlı 300 eğitim tur sayılı CNN modelinde Gabor filtreleme işleminin ardından CLAHE uygulanması durumu uygulanmaması durumuna göre daha yüksek doğruluk değerine sahip olduğu gözlemlenmiştir. Bu modelde en yüksek doğruluk değerine θ 45, λ 90 değerleri için Gabor filtreleme işlemini yapılmasından sonrasında CLAHE işleminin uygulanması ile ulaşılmıştır. Akciğer görüntülerinin 128×128 boyutlu hale getirilip girdi olarak verildiği 3 katmanlı 150 eğitim tur sayılı CNN modelinde Gabor filtreleme işleminin ardından CLAHE uygulanmaması durumu uygulanması durumuna göre daha yüksek doğruluk değerine sahip olduğu gözlemlenmiştir. Bu modelde θ 135, λ 60 değerleri için sadece Gabor filtreleme işlemininin uygulanması ile en yüksek doğruluk değerine ulaşıldığı söylenebilir. Akciğer görüntülerinin 128×128 boyutlu hale getirilip girdi olarak verildiği 5 katmanlı 150 eğitim tur sayılı CNN modelinde Gabor filtreleme işleminin ardından CLAHE uygulanması durumu uygulanmaması durumuna göre genel olarak daha doğru sonuç verdiği gözlemlenmiştir. Bu modelde ise en yüksek doğruluk değerine θ 45, λ 60 değerleri için Gabor filtreleme işlemini yapılmasından sonrasında CLAHE işleminin uygulanması ile ulaşılmıştır.

CNN Derin öğrenme modellerinin doğruluk oranlarının tamamına bakıldığında en yüksek değere θ 45 ve λ 60 ile Gabor filtreleme işlemi ardından CLAHE işleminin uygulandığı

görüntülerin 128×128 normalizasyon yapılarak girdi olarak verilen **5 katmanlı 150 eğitim tur sayılı CNN derin öğrenme modeli** ile elde edildiği görülmektedir.

CNN derin öğrenme modeli eğitim süresi ve kayıp oranlarına bakıldığında CLAHE işleminin uygulanıp uygulanmaması durumu için CLAHE işlemi uygulanmış görüntülerde genel olarak eğitim süresi daha kısa iken kayıp oranlarının daha yüksek olduğu görülmektedir. 150 eğitim turu ve 300 eğitim turu için 3 katmanlı CNN derin öğrenme modellerine bakıldığında eğitim turu fazla olan 32×32 boyutundaki görüntülerin 128×128 boyutundaki görüntülere göre daha kısa CNN derin öğrenme model eğitim süresine sahip olduğu görülmektedir. Görüntü boyutunun küçük olması CNN derin öğrenme model eğitim süresini kısalttığı söylenebilir. Bunun aksine kayıp oranlarında da artışa sebep olduğu söylenebilir. Aynı görüntü boyutu için CNN derin öğrenme katman sayısının farklı olması ile CNN eğitim süresinde ve kayıp oranlarında farklı sonuçlar elde edilmiştir. 3 katmanlı CNN derin öğrenme modelindeki CNN eğitim süresi, 5 katmanlı CNN derin öğrenme modelindeki CNN eğitim süresine göre daha az olduğu görülmektedir. Bunun yanı sıra kayıp oranlarında ise daha yüksek değerlere sahiptir. Bu duruma göre CNN derin öğrenme modelinde katman sayısının artması süre açısından bir dezavantaja sahip olsa da kayıp oranında avantaj sağlamaktadır.

Bu çalışma ile derin öğrenme modelinde optimizasyon yapılarak akciğer görüntüleri ile kanser teşhisinde doğruluk oranının arttığı gözlemlenmiştir. Yapılan ön işlemlerle ile birlikte doğruluk oranında daha yüksek değerler elde edilmiştir. Bu çalışma akciğer kanseri tespitinde alanında uzman kişilere destek sağlayarak ön tanı ve teşhis için kullanılabilir. Bunun yanı sıra uygulanan ön işlemler ve derin öğrenme modeli farklı kanser türleri için ilgili görüntülere de uygulanarak kanser teşhisinde başarılı sonuçlara ulaşılabilir.

KAYNAKLAR

Acar, E., Ozerdem, M., 2012, Image classification of Kiziltepe cropland by using Gabor Wavelet Transform, *2012 20th Signal Processing and Communications Applications Conference*, SIU 2012, 1-4, DOI:10.1109/SIU.2012.6204755.

Alakwaa, W., Nassef, M., Badr, A., 2017, Lung Cancer Detection and Classification with 3D Convolutional Neural Network (3D-CNN), *International Journal of Advanced Computer Science and Applications 8*, DOI:10.14569/IJACSA.2017.080853.

Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of big data*, *8*(1), 53, https://doi.org/10.1186/s40537-021-00444-8.

Ashhar, S.M., Mokri, S.S., Rahni, A.A., Huddin, A., Zulkarnain, N., Azmi, N., Mahaletchumy, T., 2021, Comparison of deep learning convolutional neural network (CNN) architectures for CT lung cancer classification, *International Journal of Advanced Technology and Engineering Exploration*, 126-134.

Bhatia, S., Sinha, Y., Goel, L., 2019, Lung Cancer Detection: A Deep Learning Approach, *Advances in Intelligent Systems and Computing*, Springer, Singapore. https://doi.org/10.1007/978-981-13-1595-4_55. 2019.

Biswal, A., 2021, *Top 10 Deep Learning Algorithms You Should Know in 2021*, https://www.simplilearn.com/tutorials/deep-learning-tutorial/deep-learning-algorithm, [Ziyaret Tarihi: 01 Aralık 2021].

Boviak, A. C., Clark, M., Geisler, W. S., 1990, Multichannel texture analysising using localized spatial filters, *IEEE Transations on Pattern Analysis and Machine Intelligence*, 12, 55–73, DOI: 10.1109/34.41384.

Buciu, I., Gacsadi, A., 2009, Gabor wavelet based features for medical image analysis and classification, *2nd International Symposium on Applied Sciences in Biomedical and Communication Technologies*, ISABEL 2009, DOI: 10.1109/ISABEL.2009.5373659.

Centers For Dısease Control And Preventıon (CDC), 2021, *Lung Cancer*, https://www.cdc.gov/cancer/lung/basic_info/what-is-lung-cancer.htm , [Ziyaret Tarihi: 01 Aralık 2021]

Chaunzwa, T., Christiani, D., Lanuti, M., Shafer, A., Diao, N., Mak, R., Aerts, H., 2018, Using deep-learning radiomics to predict lung cancer histology, *Journal of Clinical Oncology*.

Dünya Sağlık Örgütü (World Health Organization-WHO), 2021, *Cancer Fact sheet September 2021*, https://www.who.int/news-room/fact-sheets/detail/cancer , [Ziyaret Tarihi: 01 Aralık 2021]

Expert.ai, 2020, *What is Machine Learning? A Definition.*, https://www.expert.ai/, [Ziyaret Tarihi: 01 Aralık 2021]

Gupta, P., Garg, S., Garg, A., 2020, Convolutional Neural Network for Lung Cancer, *International conference on Recent Trends in Artificial Intelligence, IOT, Smart Cities & Applications (ICAISC-2020)*, http://dx.doi.org/10.2139/ssrn.3562893.

Türk Toraks Derneği, 2021, *Akciğer Kanseri*, https://www.toraks.org.tr/site/resources/aegrotationes/p/3, [Ziyaret Tarihi: 01 Aralık 2021]

Jain, A. K., Farrokhnia, F., 1991, Unsupervised texture segmentation using gabor filters, *Pattern Recognition*, 24, 1167–1186, https://doi.org/10.1016/0031-3203(91)90143-S.

Jena, S., George, T., 2020, Morphological feature extraction and KNG-CNN classification of CT images for early lung cancer detection, *International Journal of Imaging Systems and Technology*, 30, DOI:10.1002/ima.22445.

Kumar, D., Wong, A., Clausi, D. A., 2015, Lung Nodule Classification Using Deep Features in CT Images, *2015 12th Conference on Computer and Robot Vision*, Halifax, Yeni İskoçya, 133-138, DOI:10.1109/CRV.2015.25.

Kuruvilla, J., Gunavathi, K., 2013, Lung cancer classification using neural networks for CT images, *Computer methods and programs in biomedicine*, DOI:10.1016/j.cmpb.2013.10.011.

Loy, G., 2002, Fast Computation of the Gabor Wavelet Transform, *DICTA2002: Digital Image Computing Techniques and Applications*, Melbourne, Australia.

McKenna, S. J., Gong, S., Wurtz, R. P., Tanner, J., Banin, D., 1997, Tracking facial feature points with gabor wavelets and shape models, *In Proc 1st International Conference on Audio- and Video-based Biometric Person Authentication*, Springer, Berlin, Heidelberg. https://doi.org/10.1007/BFb0015977.

Moitra, D., Mandal, R., 2020, Classification of Non-Small Cell Lung Cancer using One-Dimensional Convolutional Neural Network, *Expert Systems with Applications*, DOI:10.1016/j.eswa.2020.113564.

Monkam, P., Qi, S., Xu, M., Han, F., Zhao, X., Qian, W., 2018, CNN models discriminating between pulmonary micro-nodules and non-nodules from CT images, *BioMedical Engineering OnLine*, DOI:10.1186/s12938-018-0529-x.

Reza, M.A., 2004, Realization of The Contrast Limited Adaptive Histogram Equaliation (CLAHE) for Real-time Image Enhancement, *Journal of VLSI Signal Processing 2004* ,38 , 35–44, DOI:10.1023/B:VLSI.0000028532.53893.82

Rossetto, A. M., Zhou, W., 2017, Deep Learning for Categorization of Lung Cancer CT Images, *2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, Philadelphia, PA, 272-273, DOI:10.1109/CHASE.2017.98.

Saravanan, P., 2021, *Understanding Loss Functions in Machine Learning*, https://www.section.io/engineering-education/understanding-loss-functions-in-machine-learning/#loss-functions-for-regression, [Ziyaret Tarihi: 01 Aralık 2021].

Silva, G., Neto, O.S., Silva, A., Paiva, A., Gattass, M., 2017, Lung nodules diagnosis based on evolutionary convolutional neural network, *Multimedia Tools and Applications*, 76, 19039-19055, DOI:10.1007/s11042-017-4480-9.

Sokolova, M., Japkowicz, N., Szpakowicz, S., 2006, Beyond Accuracy, F-Score and ROC: A Family of Discriminant Measures for Performance Evaluation, *Australian Conference on Artificial Intelligence*, https://doi.org/10.1007/11941439_114

Sun, W., Zheng, B., Qian, W., 2016, Computer aided lung cancer diagnosis with deep learning algorithms, *SPIE Medical Imaging*, DOI:10.1117/12.2216307.

T.C. Sağlık Bakanlığı, 2021, *Akciğer Kanseri*, https://hsgm.saglik.gov.tr/tr/kanser-turleri/kanser-turleri/akci%C4%9Fer-kanseri.html, [Ziyaret Tarihi: 01 Aralık 2021].

Teramoto, A., Tsukamoto, T., Kiriyama, Y., Fujita, H., 2017, Automated Classification of Lung Cancer Types from Cytological Images Using Deep Convolutional Neural Networks, *BioMed research international*, https://doi.org/10.1155/2017/4067832.

The Cancer Imaging Archive, 2021, *About The Cancer Imaging Archive*, https://www.cancerimagingarchive.net/about-the-cancer-imaging-archive-tcia/, [Ziyaret Tarihi: 01 Aralık 2021].

The Lung Image Database Consortium (LIDC-IDRI), 2021, *LIDC-IDRI*, https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI, [Ziyaret Tarihi: 01 Aralık 2021].

Ulusal Sağlık Hizmeti (National Health Service -NHS), 2019, *Lung cancer*, https://www.nhs.uk/conditions/lung-cancer/ , [Ziyaret Tarihi: 01 Aralık 2021]

Vikipedi, 2008, *Gabor Filtresi*, https://tr.wikipedia.org/wiki/Gabor_Filtresi, [Ziyaret Tarihi: 01 Aralık 2021].

Wang, X., Chen, H., Gan, C., Lin, H., Dou, Q., Tsougenis, E., Huang, Q., Cai, M., Heng, P., 2020, Weakly Supervised Deep Learning for Whole Slide Lung Cancer Image Analysis, *IEEE transactions on cybernetics*, 50(9), 3950–3962, https://doi.org/10.1109/TCYB.2019.2935141. 2020.

Wikipedia, 2003, *Artificial neural network*, https://en.wikipedia.org/wiki/Artificial_neural_network, [Ziyaret Tarihi: 01 Aralık 2021].

Wikipedia, 2004, *CT scan*, https://en.wikipedia.org/wiki/CT_scan, [Ziyaret Tarihi: 01 Aralık 2021].

Wikipedia, 2004, *Positron emission tomography*, https://en.wikipedia.org/wiki/Positron_emission_tomography, [Ziyaret Tarihi: 01 Aralık 2021].

Wiskott, L., Fellous, J.M., Kruger, N., Malsburg, C., 1997, Face recognition by elastic bunch graph matching, *Proceedings of International Conference on Image Processing*, 129-132, DOI:10.1109/ICIP.1997.647401.

Wurtz, R. P., 1997, Object recognition robust under translations, deformations, and changes in background, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7), 769-775, DOI: 10.1109/34.598234.

Zainudin, Z., Shamsuddin, S. M., Hasan, S., 2019, IOP Conference Series: Materials Science and Engineering, Volume 551, *Joint Conference on Green Engineering Technology & Applied Computing 2019*.

Zhang, C. ve diğerleri, 2019, Toward an Expert Level of Lung Cancer Detection and Classification Using a Deep Convolutional Neural Network, *The oncologist*, 24(9), 1159–1165, https://doi.org/10.1634/theoncologist.2018-0908.

Zhou, T., Lu, H., Yang, Z., Qiu, S., Huo, B., Dong, Y., 2021, The ensemble deep learning model for novel COVID-19 on CT images, *Applied soft computing*, 98, 106885, https://doi.org/10.1016/j.asoc.2020.106885.

ÖZGEÇMİŞ