



T.C.

ALTINBAŞ ÜNİVERSİTESİ

Lisansüstü Eğitim Enstitüsü

Elektrik ve Bilgisayar Mühendisliği Anabilim Dalı

**DERİN ÖĞRENME YÖNTEMLERİ
KULLANILARAK MEME KANSERİ TEŞHİSİ**

Peren Jerfi CANATALAY

Doktora Tezi

Danışman

Prof. Dr. Osman Nuri UÇAN

İstanbul, 2022

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK MEME KANSERİ TEŞHİSİ

Peren Jerfi CANATALAY

Elektrik ve Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

ALTINBAŞ ÜNİVERSİTESİ

2022

Peren Jerfi CANATALAY tarafından hazırlanmış ve 16.05.2022 tarihinde sunulmuş “DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK MEME KANSERİ TEŞHİSİ” başlıklı tez Elektrik ve Bilgisayar Mühendisliği Anabilim Dalında Doktora Tezi olarak **oy birliği** ile kabul edilmiştir.

Prof. Dr. Osman Nuri UÇAN

Danışman

Tez Savunma Sınavı Jüri Üyeleri:

Prof. Dr. Osman Nuri UÇAN

Uygulamalı Bilimler
Fakültesi,

Altınbaş Üniversitesi

Doç. Dr. Metin ZONTUL

Mühendislik- Mimarlık
Fakültesi,

Topkapı Üniversitesi

Doç. Dr. Ferdi SÖNMEZ

Mühendislik- Mimarlık
Fakültesi,

Fenerbahçe Üniversitesi

Dr. Öğr. Üyesi Oğuz ATA

Mühendislik- Mimarlık
Fakültesi,

Altınbaş Üniversitesi

Dr. Öğr. Üyesi Doğu Çağdaş ATILLA

Mühendislik- Mimarlık
Fakültesi,

Altınbaş Üniversitesi

Bu tezin Doktora. tezi olarak bütün şartları sağladığımı beyan ederim.

Tezin Lisansüstü Eğitim Enstitüsüne teslim tarihi: ____/____/____

Bu tezdeki tüm bilgilerin akademik kurallara ve etik davranışlara uygun olarak edinildiğini ve sunulduğunu beyan ederim. Ayrıca, bu kuralların ve davranışların gerektirdiği şekilde, bu çalışmada, orijinal olmayan tüm materyalleri ve sonuçları tamamen alıntı yaptığımı ve referans gösterdiğimi de beyan ederim.

Peren Jerfi CANATALAY

ÖNSÖZ

Bu tez çalışmasındaki paha biçilmez rehberliği ve destekleri ile eğitimime olan katkılarından ötürü Prof. Dr. Osman Nuri UÇAN hocama teşekkür etmek istiyorum. Bu tezin hazırlanması boyunca yaptıkları çok değerli yorum ve geri bildirimler için Doç. Dr. Metin ZONTUL, Dr. Öğretim Üyesi Doğu Çağdaş ATILLA ve Dr. Öğretim Üyesi Oğuz ATA hocalarımın teşekkür etmek istiyorum. Aynı zamanda bu zorlu süreçte yanımda olan aileme, özellikle anneme tüm desteklerinden ötürü minnettarım.

Peren Jerfi CANATALAY

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK MEME KANSERİ TEŞHİSİ

CANATALAY, Peren Jerfi

Doktora, Elektrik ve Bilgisayar Mühendisliği, Altınbaş Üniversitesi

Danışman: Prof. Dr. Osman Nuri UÇAN

Tarih: Mayıs / 2022

Sayfa: (89)

Meme kanseri, kadınlar arasındaki başlıca ölüm sebeplerindedir. Mamografi ekipmanı aracılığıyla elde edilen X-Ray görüntüleri, meme kanserinin erken teşhisine yardımcı olmak açısından en sık kullanılan araçlardan biridir. Bu çalışmadaki amaç, meme kanseri görüntülerinin tümör içeren türlerini derin öğrenme tekniklerine odaklamaktır. Bu yöntemde pek çok parametre bulunmaktadır. Meme kanseri, fenomenin çok karmaşık olduğu ve ayrıca tümör türlerine ilişkin sayısız özelliğin bulunduğu bir hastalıktır. Bu çalışmada, meme kanserinin sınıflandırılabilmesi açısından mamogram görüntü işleme teknikleri ve çeşitli örüntü tanıma teknikleri kullanılmıştır. Tümör görüntü iyileştirmeleri, bölütleme, doku bazlı görüntü özelliği çıkarma ve daha sonra meme kanseri mamogram görüntüsünün sınıflandırılması için örüntü tanıma teknikleri başarılı bir biçimde gerçekleştirilmiştir. Hastalığın doğru metodolojiyle saptanması, tedavi edilebilmesi bakımından oldukça önemli bir rol oynamaktadır.

Bu çalışmada; Derin Öğrenme tekniği ile 731186 X-Ray görüntüleri veri seti üzerinde işlem yapılarak; hastanın meme kanserine sahip olup olmadığı, kanser olduğu takdirde ise bunun iyi huylu (benign) ya da kötü huylu (malignite) olup olmadığına ilişkin karar verilmesi ele alınmaktadır. Bu X-Ray görüntülerinin %80'i eğitim amaçlı, %20'si ise test olarak uygulanmıştır. Yapılan çalışmada, X-Ray görüntülerinde farklı Derin Öğrenme tekniklerinin kullanılmasıyla meme kanseri teşhisi yapılmaktadır. Çalışma kapsamında iki metot önerilmiştir. Önerilen birinci metotta VGG19, ikinci metotta ise Resnet50 tekniği

kullanılmıştır. Deneysel sonuçlar neticesinde; performansın VGG19 için %91,74 oranında, Resnet50 için ise %98.81 oranında hatasızlık oranına ulaştığı görülmüştür. Böylece Resnet50 metodunun daha başarılı olduğu sonucuna ulaşılmıştır. Ek olarak bu verilerden hareketle yapılan çalışmada, meme kanseri X-Ray görüntülerinde kanser olup olmadığı, kanser ise hangi tür kansere sahip olduğu gösterilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Veri Ön İşleme, Meme Kanseri, VGG19, Resnet50

ABSTRACT

DIAGNOSES OF BREAST CANCER USING DEEP LEARNING TECHNIQUES

CANATALAY, Peren Jerfi

PhD, Electrical and Computer Engineering, Altınbaş University,

Supervisor: Prof. Dr. Osman Nuri UÇAN

Date: May / 2022

Pages: (89)

Breast cancer is a leading cause of death among women. Mammography images obtained by X-ray equipment are one of the most often utilized tools in order to detect breast cancer at an early stage the goal of this research is to look at deep learning approaches for tumor-filled breast cancer images. ESA-based systems were created for the purpose sensitive identification of breast cancer, which is particularly difficult to identify when many characteristics are related. There is a molasses parameter in this method. Breast cancer is a disease with a highly complex etiology and various characteristics associated with tumor kinds. Breast cancer was classified in this study using mammography image processing techniques and various pattern recognition techniques. Pattern recognition techniques have been effectively used to enhance tumor images, segment them, extract tissue-based image features, and finally classified mammography images of breast cancer. Accurate illness detection is critical for effective therapy.

In this study, the Deep Learning technique is used to evaluate a dataset of 731186 X-Ray images to determine whether a patient has breast cancer and, if so, whether the cancer is benign (benign) or malignant (malignant) (malignant). 80% of these X-Ray images were used for instruction purposes, while 20% were used for testing purposes. The study makes a breast cancer diagnosis utilizing a variety of Deep learning techniques applied to X-Ray images.

Within the scope of the study, two methodologies have been offered. The first proposed method employed the VGG19 technique, whereas the second method used the Resnet50 technique. The performance achieved a 91.74 percent error-free rate for VGG19 and 98.81 percent for Resnet50 due to the experimental results. Consequently, it was determined that the Resnet50 method was more effective. Additionally, the study assigne whether or not there is cancer in breast cancer X-Ray images and what form of cancer there is.

Keywords: Deep Learning, Data Preprocessing, Breast Cancer, VGG19, Resnet50.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
ABSTRACT.....	viii
ŞEKİL LİSTESİ.....	xii
ÇİZELGE LİSTESİ.....	xiii
KISALTMALAR	xiv
SEMBOL LİSTESİ.....	xv
1. GİRİŞ.....	1
1.1 TEMEL KAVRAMLAR	1
1.2 PROBLEM TANIMI.....	1
1.3 MEME KANSERİ.....	5
1.4 TEZ AMACI	7
1.5 TEZ DÜZENİ.....	7
2. LİTERATÜR ÇALIŞMASI.....	9
3. VERİ VE YÖNTEM.....	13
3.1 DENEYLERDE KULLANILAN VERİ KÜMELERİ VE YÖNETİMİ.....	13
3.2 VERİ BÜTÜNLÜĞÜ	13
3.3 YÖNTEM VE TEKNİKLER	15
3.3.1 Makine Öğrenmesi	16
3.3.2 Derin Öğrenme	17
3.3.3 CNN Mimarisi	19
3.3.4 Evrişim Katmanı.....	22
3.3.5 Havuzlama Katmanı	26
3.3.6 Tam Bağlı Katman.....	27
3.3.7 VGG19 Ağı	28
3.3.8 Resnet50 Ağı	29
3.4 PERFORMANS METRİKLERİ	31
3.4.1.1 Sınıflandırmayla ilgili metrikler	33

4. MODEL ÇALIŞMALARINA YÖNELİK VERİ ÖNİŞLEM SÜRECİ	36
4.1 GÖRÜNTÜ ÖNİŞLEME	36
4.2 GÖRÜNTÜ SEGMENTASYONU	37
4.3 ÖZNİTELİK ÇIKARMA	37
5. UYGULAMA	38
5.1 UYGULANAN ÖĞRENME AKTARIMI TABANLI TEKNİKLER.....	39
5.1.1 Resnet50 Ağı	39
5.1.2 VGG19 Ağı	44
6. TARTIŞMA.....	51
7. SONUÇLAR.....	66
REFERANSLAR.....	70

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: a’da malignite meme, b’de benign ve c’de ise sağlıklı normal X-Ray görüntüsü.....	2
Şekil 1.2: X-Ray meme kanseri lezyonu görüntüsü.....	5
Şekil 1.3: Kanserli X-Ray veri kümesi	6
Şekil 2.1: Farklı büyütme faktörlerinde görülen meme malign tümörünün görüntüsü.	11
Şekil 3.1: Eğitim ve test X-Ray görüntüsü	15
Şekil 3.2: Tez çalışmasında uygulanan mimarinin birinci bölümü.....	20
Şekil 3.3: Tez çalışmasında uygulanan mimarinin ikinci bölümü.....	21
Şekil 3.4: Makine öğrenmesinde evrişimli sinir ağlarının uygulanışı	23
Şekil 3.5: Evrişimli sinir ağında girdi ve çekirdek temsili gösterim.....	23
Şekil 3.6: Dolgu değerleri ve sıfır ile doldurulmuş filtre.	25
Şekil 3.7: Maksimum ve ortalama havuzlama katmanı	26
Şekil 3.8: Modelde uygulanan Tam Bağlı katman.....	28
Şekil 3.9: VGG19 ağı mimari yapısı uygulanışı	29
Şekil 3.10: Kalıntı (Residual) öğrenme blokları yapısı	30
Şekil 3.11: Uygulanan farklı model ve mimariler	31
Şekil 5.1: Resnet50 ile elde edilmiş en iyi sonuçlar	40
Şekil 5.2: Uygulanan Resnet50 mimarisi.....	41
Şekil 5.3: Resnet50 hata matrisi gösterimi	43
Şekil 5.4: Resnet50 ağı ROC eğrisi sonuçları.....	43
Şekil 5.5: Resnet50 doğruluk ve kayıp oranları.....	44
Şekil 5.6: Uygulanan VGG19 Şeması gösterimi	45
Şekil 5.7: VGG19 hata matrisi gösterimi.....	46
Şekil 5.8: VGG19 ROC sonuçları gösterimi.....	46
Şekil 5.9: GG19 ile Resnet50 çalışma ve başarı grafiği	47
Şekil 5.10: Meme görüntülerinde yüksek ve düşük risk tahmini sonucu	48

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 1.1: Meme kanserinin farklı evreleri.	6
Çizelge 3.1: Derin öğrenme meme kanseri tespit literatüründe kullanılan metrikler.	32
Çizelge 3.2: Performans ölçümü parametreleri	32
Çizelge 5.1: Resnet50 model Sonuçları	42
Çizelge 5.2: VGG19 model Sonuçları	45
Çizelge 6.1: Geliştirilen modelin literatür ile karşılaştırması	52
Çizelge 6.1: VGG19 uygulama kodlar.....	53
Çizelge 6.2: Resnet50 uygulama kodları	61

KISALTMALAR

DICOM	Tıpta Dijital Görüntüleme ve İletişim
DİA	Derin İnanç Ağı
DN	Doğru Negatif
DOK	Derin/Yığılanmış Oto-kodlayıcı
DP	Doğru Pozitif
DRM	Deneysel Risk Minimizasyonu (Empirical Risk Minimization)
DSA	Derin Sinir Ağı
DVM	Destek Vektör Makineleri
ESA	Evrimsel Sinir Ağı
ESA	Evrişimli Sinir Ağları
FD	Fourier Dönüşümü
FD	Fourier Dönüşümü
GPU	Grafik İşlem Birimi

SEMBOL LİSTESİ

- \bar{Y} : Yeni test girdileri için tahmin edilen etiket
- n_x : Her bir eğitim örneği için özniteliklerin sayısı
- \bar{y} : Bir eğitim örneğinin tahmini çıkış etiketi
- μ : Ortalama
- c : Küme merkezleri
- d : Uzaklık (birim)
- f : Örnekleme aralığı
- h : Hausdorff uzaklığı (birim)
- T : Esik değeri
- A : Z 'nin doğrusal olmayan dönüşümü, aktivasyon fonksiyonu çıkışı
- C : Çoklu sınıflayıcı için sınıf sayısı
- J : Tüm eğitim örnekleri
- L : Derin sinir ağındaki toplam katman sayısı (giriş katmanı hariç)
- Y : Çıkış matrisi: her bir sütun X eğitim setinin etiketi olarak tanımlanır.
- Z : X 'in doğrusal dönüşümü
- a : Z 'nin doğrusal olmayan dönüşümü, aktivasyon fonksiyonu çıkışı
- b : Bias matrisi
- m : Eğitim örneklerinin sayısı
- w : X için ağırlık matrisi
- x : Eğitim örneğinin öznitelikleri
- y : Eğitim örneğinin çıkış etiketi
- z : X 'in doğrusal dönüşümü
- X : Giriş matrisi: her sütun bir eğitim örneği
- Ψ : Ana dalgacık fonksiyonunun Fourier dönüşümü
- σ : Sigmoid fonksiyonu
- ψ : Ana dalgacık fonksiyonu
- $\omega(t)$: Anlık frekans

1. GİRİŞ

1.1 TEMEL KAVRAMLAR


Çalışmanın bu bölümünde; soruna ilişkin tanım, tedavi yöntemleri, veri toplama ve veri işleme teknikleri ve çalışmanın amaçları açısından karşılaşılan güçlükler ele alınmaktadır.

1.2 PROBLEM TANIMI

Vücudun herhangi bir organ veya dokusundaki anormal hücrelerin kontrolsüz bir şekilde çoğalarak büyümesi neticesinde ortaya çıkan hastalığa kanser adı verilmektedir [1]. Meydana geldiği dokuya göre adlandırılan (örneğin meme kanseri, akciğer kanseri, kolorektal kanser vb.) kanser; yalnızca insan vücudunda değil aynı zamanda hayvanlar da ve diğer canlı organizmalarda da görülebilir. Her yıl yaklaşık 14 milyon kişi kansere yakalanmaktadır ve dünya genelinde kanser mortalitesi ortalama 8,2 milyon olarak bildirilmiştir [2].

Kanser türlerinden biri olan meme kanseri, bugün Batılı ülkelerde olduğu gibi Türkiye’de de sıklıkla karşılaşılan önemli bir sağlık problemidir. Bu sağlık problemi dünya genelinde en sık teşhis edilen iki kanser türünden biridir [3]. Meme kanseri genellikle kanallarda, sütü meme ucuna taşıyan tüplerde ve sütü oluşturan lobüllerde ortaya çıkmaktadır. Hem erkek hem de kadınlarda görülebilen bir sağlık problemi olmasına rağmen meme kanseri erkeklerde ender olarak rastlanılan bir hastalıktır. Fakat bunun yanı sıra dünya genelinde kanser olan her dört kadından birine meme kanseri teşhisi konulmaktadır [4]. Meme kanserinin belirtileri arasında en belirgin olanı memede elle hissedilebilen bir kitledir. Ele gelen bu kitle yalnızca memede değil koltuk altında da olabilir. Eğer söz konusu kitle büyümüş ise meme ucunun içeri doğru çekilmesi de meme kanseri belirtilerindedir. Nadiren görülse de meme ucundan kanlı ya da kansız akıntı da meme kanserini işaret edebilmektedir [5].

Aşağıda verilen Şekil 1.1 a’da X-Ray malignite meme, Şekil 1.1 b’de X-Ray benign meme ve Şekil 1.1 c’de ise sağlıklı normal X-Ray görüntüsü gösterilmektedir.



Şekil 1. 1: a’da malignite meme, b’de benign ve c’de ise sağlıklı normal X-Ray görüntüsü

Yukarıda verilen Şekil 1.1 a’da malignite meme görüntüsü bulunurken, 1b’de benign ve 1c’de ise sağlıklı meme görüntüsü gösterilmektedir. 1a’da görülen kitle sık rastlanılan bir bulgudur. Tespit edilen her kitle kanser anlamına gelmemektedir. Kitleler iyi huylu (benign) ve kötü huylu (malign) olmak üzere ikiye ayrılmaktadır.

Uzun süreli tedavi gerektiren hastalıklar kapsamında (kanser, fibroadenomlar, mastitler vb.) yoğun bakıma ihtiyaç duyan hastalar, ayakta tedavi gören hastalara göre tedavisi hem daha maliyetli hem de ölüm riski daha fazla olan hastalardır. Söz konusu maliyet ve ölümler, her geçen gün artış göstermektedir. Artan maliyet ve ölümler nedeniyle Dünya Sağlık Örgütü (DSÖ) tarafından, bireylerin hastalığa yakalanmadan önce hastalık önleme yöntemlerine başvurmaları gerektiğine dikkat çekilmeye çalışılmaktadır. Bir diğer ifadeyle bireyler; genetik, çevresel ve diğer faktörlerin sebep olduğu hastalık risklerine karşı, belirli periyotlarla doktor kontrolünden geçmelidirler. Bu kontroller sonucunda elde edilen bulgular; hastalığın gelişme riskini ortaya koyarak riskin büyüklüğü ve ortaya çıkma süresinin kısaltılabilmesi açısından erken teşhisi mümkün kılmaktadır. Dolayısıyla bu gibi durumların meydana gelmemesi için bireyler herhangi bir semptom göstermeseler de kanser hastalığını tespit eden tarama testi yapılmalıdır. Tarama testi, erken aşamalarındaki bir kanser tümörünün keşfedilebilmesine büyük oranda yardımcı olmaktadır.

Özellikle kadınlar arasında sıklıkla dile getirilen ve en çok görülen kanser türlerinden biri olması sebebiyle literatürde meme kanseri üzerine yapılmış olan birçok çalışma bulunmaktadır [5, 6]. Yapılan araştırmalara göre makine öğrenimi, hastalığın erken teşhisi açısından en çok kullanılan yöntemlerden biridir. İnsan hayatını birçok alanda kolaylaştıran bilgisayarların, insan gibi düşünebilmesi amacıyla yapılan çalışmalar neticesinde makine öğrenimi meydana gelmiştir. İnsan zekâsını taklit etmeyi amaçlayan bu öğrenme stiline yapay zekâ adı verilmektedir. Yapay zekâ olarak adlandırılan bu teknolojik gelişme, hastalığın tedavisinde önemli bir rol oynamaktadır. Ancak insanlar ve makineler geliştikçe hastalığa neden olan faktörler de gelişerek hastalığı önlemek veya tedavi etmek için kullanılan ilaçlara karşı bağışıklık kazanmaktadır.

Meme kanserinin histopatolojik görüntülerinin bilgisayar destekli teşhis uygulamaları aracılığıyla otomatik olarak iyi huylu ve kötü huylu kanser olarak adlandırılması ve buna göre hastalığa erken teşhis ile önceden müdahale edilmesi hayati önem taşımaktadır. Meme kanserinin teşhisi amacıyla kullanılan yöntemler içerisinde; Mamografi Manyetik Rezonans Görüntüleme (MRI), tomografi ve ses dalgalarını kullanarak analiz işleminin gerçekleştirildiği yöntemlerden biri olan ultrason teknikleri kullanılarak, doğru tanı amacıyla meme dokusundan örnek alınması gerekmektedir [7]. Patologlar, biyopsi yöntemi kullanarak hücrelerin veya dokuların histolojik örneklerini, mikroskop altında memede meydana gelen değişiklik hakkında kesin tanı koymaya ve meme dokusundan biyopsi alarak iyi huylu, kötü huylu ve normal dokuları sınıflandırmaya çalışmaktadırlar [8]. Biyopsi ile elde edilen doku örnekleri çeşitli mikroskopik büyütme oranları altında analiz edilmektedir. Görüntülerin analizi sırasında patologların deneyimi ve ilgisi, doğru teşhis ve nihai teşhis açısından büyük önem taşımaktadır. Fakat histopatolojik görüntülerin analizi zaman alan bir süreç olduğundan bu görüntülerin bilgisayar destekli yöntemlerle değerlendirilmesi, doğru tanı ve teşhis noktasında ciddi katkılar sağlamaktadır. Dolayısıyla bilgisayarlı destek sistemlerinin; patologların gün içerisinde ortaya çıkabilecek yorgunluk, dikkat dağınıklığı vb. olumsuz koşulların etkisi altında kalınarak yapılabilecek yanlış tanıları en aza indirebildiği ifade edilebilir. Bir diğer ifadeyle bilgisayar destek sistemleri sayesinde uzmanlar, hastalığın teşhis edilebilmesi açısından zor vakalara daha kolay bir şekilde odaklanabilir [9].

Çalışmada yukarıda açıklanan ve araştırma problemini oluşturan durumlar neticesinde; Mamografik Görüntü Analizi Derneği (MIAS)'ndeki halka açık X-ray meme görüntü veri kümesi alınarak alınan bu görüntüler üzerinde bazı temizleme yöntemleri ve bütünlük sağlama gibi işlemler yapılmıştır. Yapılan işlemler ile görüntü veri kümesi, %20'si test ve


%80'i eğitim şeklinde olmak üzere 2 gruba ayrılmıştır. Daha sonra, gruplara ayrılan bu görüntüler üzerine makine öğrenme algoritmaları uygulanarak, görüntülerin kanserli olup olmadığının araştırılması amaçlanmıştır. Bu amaçlar doğrultusunda araştırmanın uygulama aşaması gerçekleştirilmiştir. Araştırmada izlenen uygulama yöntemi, çalışmanın 3. bölümünde detaylı olarak anlatılmıştır.

Patolojinin tıbbi uzmanlığı, hasta tedavisine ve yönetim kararlarına rehberlik etmek için kesin hastalık tanıları sağlamakla görevlidir [10]. Hassas tıbbi ilerletmek için standartlaştırılmış, doğru ve tekrarlanabilir patolojik teşhisler gereklidir. 19. yüzyılın ortalarından beri patoloğların tanı koymak için kullandıkları birincil araç mikroskop olmuştur [11]. Mikroskopik görüntülerin kalitatif görsel analizinin sınırlamaları arasında standardizasyon eksikliği, tanı hataları ve tipik bir patoloğun iş gününde yüzlerce slaytta milyonlarca hücreyi manuel olarak değerlendirmek için gereken önemli bilişsel yük yer almaktadır [12]. Sonuç olarak, son on yılda patolojide mikroskopik görüntülerin analizine yardımcı olacak hesaplama yöntemlerinin geliştirilmesine artan bir ilgi olmuştur [13]. Ekim 2015'ten Nisan 2016'ya kadar, Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI), dijital tam slayt görüntülerinde metastatik meme kanserini otomatik olarak tespit etme görevi için üstün performanslı hesaplamalı görüntü analiz sistemlerini belirlemek için Camelyon Grand Challenge 2016 “düzenlenmiştir. Sentinel lenf nodu biyopsileri, meme sentinel lenf nodlarının değerlendirilmesi, sentinel lenf nodu metastatik kanser için pozitif olan hastaların, sentinel lenf nodu negatif olan hastalardan daha yüksek bir patolojik TNM (tümör) evresi alacağı Amerikan Kanser TNM meme kanseri evreleme sisteminin önemli bir bileşenidir. Metastaz, sıklıkla aksiller lenf nodu diseksiyonu dâhil olmak üzere daha agresif klinik yönetimle sonuçlanır [14]. Sentinel lenf düğümlerinin manuel patolojik incelemesi, özellikle lenf düğümlerinin kanser için negatif olduğu veya yalnızca küçük metastatik kanser odakları içerdiği durumlarda zaman alıcı ve zahmetlidir. Birçok merkez, kanser metastazı saptama duyarlılığını artırmak için meme kanseri hücrelerinde eksprese edilen ve normalde lenf düğümlerinde bulunmayan proteinler olan pansitokeratinler için immünohistokimya ile sentinel lenf düğümlerinin testini uygulamıştır. Bununla birlikte, sentinel lenf nodlarının pansitokeratin immünohistokimya testinin sınırlamaları arasında şunlar yer alır: artan maliyet, LAM (Doğurganlık çağındaki kadınları etkileyen nadir kistik hastalık) hazırlama için artan süre ve patolojik inceleme için gereken LAM sayısının artması. Ayrıca, immünohistokimya lekeli slaytlarda bile küçük kanser metastazlarının tanımlanması sıkıcı ve yanlış olabilmektedir.

1.3 MEME KANSERİ


Meme kanseri, ilgili dokuda bulunan hücre gruplarından birinin farklılaşmaya uğrayarak kontrolsüz bir şekilde çoğalmasıyla oluşan tümör ile gelişen bir hastalıktır. Hem erkek hem de kadınlarda görülebilen bir sağlık problemi olmasına rağmen erkeklerde meme kanserine ender olarak rastlanmaktadır. Son yıllarda oldukça artmış olan meme kanserinin görülme sıklığı, küresel ölçekteki istatistiklere göre 100.000’de 40-50 civarlarındadır [15]. Amerika verilerine göre, sağlıklı bir kadının meme kanserine yakalanma risk oranı 1/8’dir.

Meme kanserine neden olan risk faktörleri, önlenebilir ve değiştirilemeyen risk faktörleri olmak üzere iki temel başlık altında toplanmaktadır. Alkol ve sigara tüketimini azaltmak, aktif bir yaşam sürdürmek, sağlıklı beslenmek gibi bireylerin değiştirebileceği alışkanlıklar önlenebilir riskler arasında yer almaktadır. Cinsiyet, yaş, yoğunlaşmış meme dokusu, erken regl dönemi veya geç menopoz süreci ile epigenetik faktörler ise değiştirilemeyen riskler arasında yer almaktadır. Aşağıda verilen Şekil 1.2’de meme Mamografik Görüntü Analizi Topluluğu (MIAS)’tan alınmış meme X-Ray görüntüleri gösterilmektedir [16].



Şekil 1. 2: X-Ray meme kanseri lezyonu görüntüsü

Her kanser türünde olduğu üzere meme kanserindeki erken tanı da büyük ölçüde önem taşımaktadır. Meme kanserinin erken evrelerde teşhis edilmesiyle hayat kurtarma açısından elzem sonuçlar elde edilebilir. Bir diğer ifadeyle meme kanserinin erken teşhisi sayesinde, memeye herhangi bir zarar gelmeden hastalık atlatılabilir. Şekil 1.3’te kanserli X-Ray veri kümesinden alınan veriler gösterilmektedir.



Şekil 1.3: Kanserli X-Ray veri kümesi

Şekil 1.3'te memede ortaya çıkan tümör yapılarına ait veri seti gösterilmektedir. İyi huylu tümörler genellikle kanser olarak değerlendirilmemektedir. İyi huylu tümörlerin vücuttan alınmaları hâlinde bir daha tekrarlama riskleri bulunmamaktadır. Aşağıda verilen Çizelge 1.1'de meme kanserinin farklı evreleri gösterilmektedir. Söz konusu evreler yedi adımdan oluşmaktadır.

Çizelge 1.1: Meme kanserinin farklı evreleri.

<ul style="list-style-type: none">• Mamografi: Meme dokusunun röntgen yardımıyla incelenmesine dayanan bir yöntemdir. Hastanın şikâyeti olmadan görüntüleme sistemlerinden elde edilen ilk mamografi, başlangıç mamografisidir. Mamografi, inceleme veya teşhis amacıyla yapılabilir. Herhangi bir şikâyeti olmayan veya belirti hissetmeyen bireylere tarama mamografisi yapılırken tanısal mamografide riskli görünen kitle veya riskli olarak tanımlanan bölgenin detaylı olarak incelenmesi mümkündür.
<ul style="list-style-type: none">• Ultrasonografi: Ses dalgalarının dokulara çarpıp yansmasıyla oluşan görüntünün incelenmesi esasıyla çalışmaktadır. Mamografide saptanan şüpheli bir kitle, bölgenin veya hastanın fiziksel olarak hissettiği kitlenin sıvı veya katı içerikli olduğunun anlaşılması amacıyla kullanılmaktadır. Sıvı içerikli kitlelerin yani kistlerin kansere sebebiyet vermesi beklenmez. Ancak katı kitleler memenin tümörleridir. Bu tümörlerin iyi huylu mu yoksa kötü huylu mu olduğunun ayrımı, düzenli takipler veya diğer ileri yöntemler gerektirmektedir.
<ul style="list-style-type: none">• Galaktografi: Meme ucuna ilaç enjekte edilerek süt kanallarının filme alınmasıdır. Daha çok meme başı akıntı şikâyeti olanlara uygulanmaktadır.

Bu tür tümörler yayılma özelliği göstermemektedir. Dolayısıyla yaşamsal faaliyetlerde herhangi bir aksaklığa da sebep olmamaktadır. İyi huylu tümörlerin aksine kötü huylu tümörler ise kanserli hücrelere sahiptir. Bu tümörler kendilerine yakın hücrelere yayılarak,

hayati bir tehlike meydana getirmektedir. Dolayısıyla kötü huylu tümörlerin erken teşhis edilip tedavi edilmesiyle hastanın kurtulma şansı artmaktadır.

1.4 TEZ AMACI

Literatür genelindeki çalışmaların Bilgisayar Destekli Sistemler (BDS) ile yapıyor olması, yenilikçi derin öğrenme mimarisi ile bir çalışmanın yapılmasını zorunlu kılmıştır. Derin Öğrenme sayesinde meme kanserinin erken safhasında kesin tanı ile saptanması, tedavi metodunun doğru ve hızlı bir şekilde seçilip hastaya uygulanması ve ilgili çalışmadan elde edilen veri işlenmesinin sistematikleştirilmesi, bu çalışmanın temel ana konusunu oluşturmaktadır. Dolayısıyla çalışmadaki temel prensip; tıp ile bilişim sektörünün entegrasyonunu sağlamaktır. Bu entegrasyon ile pek çok sektörde maliyetten ve zamandan tasarruf elde edilebilir. Bunlara ek olarak, sistemin daha faydalı hâle gelmesi ve erken teşhis ile tedaviye başlanması da bu amacın olumlu etkileri olarak gösterilebilir.

Küresel olarak mortalitesi en yüksek hastalıklardan biri olarak tanımlanabilecek meme kanserini baz alarak Mamografi Görüntü Analizi Derneği (MIAS: Mammography Image Analysis Society) Veri Kümesinden elde edilmiş DICOM [17] formatlı X-Ray meme kanseri görüntü veri setleri işlenip farklı dijital formlara dönüştürülerek düzenlenen, teşhisi yanlış yönlendiren görüntüdeki hatalardan arındırılmış ve hazırlanan veri ambarında tutulmuştur.

1.5 TEZ DÜZENİ

Bölüm 1: Meme kanserine, nodüllerin çeşitlerine ve büyüklüklerine dair temel bilgilerin verildiği bu bölümde; öncelikli olarak kanser teşhis metotlarına ve tetkiki en kısa zamanda ortaya koymanın nasıl mümkün olabileceğine dair öneriler sunulmaktadır. Ek olarak; meme kanseri görüntüleme X-Ray cihazlarını içeren görüntüleme teknikleri ve tüm bu süreçlerde karşılaşılan bazı sorunlarla birlikte, bu sorunların çözümüne de değinen “Derin Öğrenme” yöntemi detaylı bir şekilde açıklanmaktadır. Özetle bu bölümde; problemin tespitinin ardından çalışmada uygulanan yaklaşımlar ile tezin amacı ortaya konularak çalışmanın diğer sektörlere olan olumlu etkileri ve çalışmada kullanılan araştırma yöntemleri irdelenmektedir.

Bölüm 2: Çalışmanın bu bölümünde, literatürde yer alan meme kanseri tanısı ile ilgili çalışmalar ve söz konusu çalışmalardaki eksiklerden bahsedilmektedir.

Bölüm 3: Çalışmanın bu bölümünde; meme dokusuna ait olan X-Ray görüntülerinin veri seti ve bu veri setinden elde edilen bilgiler, incelenen verilerde format değişikliğinin yapılması ve verilerin ön işlemden geçirilmesi ile ilgili detaylı bilgiler yer almaktadır.

Bölüm 4: İhtiyaç analizi geliştirmeye dayalı aşamaların ele alındığı bu bölümde; meme kanserinde tanı yöntemleri geliştirilirken faydalanılan araçlar, Derin Öğrenme mimarisinin nasıl geliştirilebileceği, hangi amaçlar doğrultusunda kullanılabilceği, veriyi nasıl işleyeceği, kaç katman olması gerektiği gibi sorular ile kullanılacak aktivasyon yöntemleri ve kullanılan verilerin anlamlı hâle gelmesi, doğru ve anlamlı sonuçlar ortaya çıkaran modelin geliştirilmesi hususlarında bilgiler ortaya konmaktadır.

Bölüm 5: Bu bölümde sırasıyla; meme kanserine ait X-Ray veri kümesi yardımıyla öznitelik oluşturabilmek açısından derin öğrenme kullanımı, Derin Öğrenme Metodunun oluşturulan öznitelik kümesi üzerinde kullanılması, Derin Öğrenme tekniği kullanarak X-Ray görüntülerinden meme kanseri teşhisinin sahip olduğu çalışma prensibinin değerlendirilmesi ve uygulanan farklı tekniklerin karşılaştırılması, burada yapılan deneylerin sonuçlarına ilişkin karşılaştırmalar ve bu sonuçların belirsizlik ölçümüne göre ne kadar başarılı ve ne kadar başarısız olduğu konuları ele alınmaktadır.

Bölüm 6: Çalışmanın son bölümünde ise çalışmadan elde edilen sonuçlar, sınırlamalar ve bulgular tartışılmaktadır.

2. LİTERATÜR ÇALIŞMASI

Meme kanseri, son yıllarda önemli bir ölüm sebebine dönüşmüş olması nedeniyle tüm dünya kadınları arasında en çok tanınan hastalıklardan biridir. Bu hastalığın dijital görüntüleme tekniklerinin kullanımıyla teşhis edilebilmesi için histopatolojik görüntü işleme alanında pek çok çalışma gerçekleştirilmiştir. Gerçekleştirilen bu çalışmaların çoğu, geleneksel metotlar ve bilgisayar destekli yöntemler ile yapıldıkları için beklentileri karşılama hususunda hem yetersiz kalmış hem de maliyet açısından sıkıntılar yaşanmasına sebep olmuştur. Söz konusu bu çalışmalara ek olarak meme kanserinin teşhisinde BDS ve çeşitli Makine Öğrenimi (MÖ) algoritmaları gibi çalışmalar da kullanılmış fakat bu yöntemler de tıpkı diğerleri gibi beklentileri karşılama hususunda yetersiz kalmıştır. Son otuz yılda bilim insanları tarafından, doğruluğu artıran algoritmalar veya optimize edilmiş BDS sistemlerinin geliştirilmesiyle de tüm tespit aşamalarının tam bütünleşmiş bir sistemi içeren sınırlı çalışmalar yapılmıştır. Tez çalışmasında devamında; ilgili alan yazın kapsamında meme kanseri görüntülerinin sınıflandırılmalarına yönelik olarak bazı yöntemlerin uygulandığı çeşitli araştırmalar yer almaktadır. Histopatolojik görüntülerin sınıflandırılması amacıyla LeNet ve AlexNet modellerinin önerildiği bir çalışma gerçekleştirilmiştir. Çalışmadan elde edilen bulgular neticesinde sırasıyla; AlexNet modelinin histopatolojik görüntüleri sınıflandırmadaki başarısının LeNet modeline göre daha iyi olduğu, AlexNet'e gönderilen görsel boyutlarının 32×32 veya 64×64 piksel olarak tanımlandığı, önerilen modellerde maksimum, çarpım ve toplam gibi basit füzyon kurallarının uygulandığı ve elde edilen sonuçların karşılaştırılmasıyla da ikili meme kanseri görüntü sınıflandırması açısından önerilen AlexNet modeli sayesinde $85,6 \pm 4,8$ ile en yüksek sınıflandırma başarısının elde edildiği yönünde sonuçlara ulaşılmıştır.

İyi huylu ve kötü huylu meme kanseri görüntülerini sınıflandırabilmek amacıyla Sınıf Yapısı Tabanlı Derin Evrişimli Sinir Ağı modelinin kullanıldığı bir araştırma gerçekleştirilmiştir. CNN derin öğrenme modeline girdi veri görüntülerinin boyutları, 256×256 olacak şekilde yeniden boyutlandırılarak evrişim katmanlarında 3×3 , 5×5 veya 7×7 boyutlarında filtreler uygulanmıştır. Çalışmada kullanılan modelin eğitiminde yani sisteme tanıtılmasında, iki farklı yöntem denenmiştir. Denenen yollardan ilki, modelin MİAS veri seti üzerindeki eğitiminin sıfırdan yapılmasıdır. Ancak başarısız sonuçlar alındığının görülmesiyle ikinci yol olarak izlenen ImageNet üzerindeki transfer öğrenme yöntemi ile eğitilmiş olan modelin ağırlıkları ele alınmıştır. Uygun görülen model ile görüntülerin ikili sınıflandırılmasında

%96,9 ± 1,9 ile en yüksek performans elde edilmiştir. Uyarlanabilir Seyrek Destek Vektör Makinesi yaklaşımının kullanıldığı farklı büyütmelerdeki görüntülerde %94,97'ye varan bir sınıflandırma çalışması yapılmıştır. Önerilen yöntemde, özellik çıkarımı için ağırlıklı L1 normu ile birleştirilmiş destek vektör makineleri kullanılmıştır. Ayrıca 50 hastadan elde edilmiş olan 500 imgelik veri setinde çekirdek segmentasyonuna uygun dört farklı kümeleme algoritmasının karşılaştırılmasıyla %96-%100 aralığında sınıflandırma performansı elde edilen bir çalışma gerçekleştirilmiştir.

Meme kanseri histopatolojik imgelerinin iyi huylu ve kötü huylu olarak sınıflandırılabilmesi amacıyla Temel Bileşen Analizi (PCA, Principal Component Analysis) yönteminin önerildiği bir çalışma gerçekleştirilmiştir. Çalışmadan elde edilen veriler neticesinde; önerilen yöntem ile %92 oranında bir sınıflandırma başarısı elde edildiği belirtilmiştir. Aynı araştırmacılar tarafından gerçekleştirilen diğer bir çalışmada ise Cascade (katmanlı) yaklaşımı ile 40x büyütme oranına ait 361 imgeden meydana gelen bir veri serisinde %97 başarı oranı elde edilen bir çalışma gerçekleştirilmiştir [19]. Söz konusu çalışma ile benzerlik gösteren bir başka çalışmada da meme kanseri imgelerinin sınıflandırılabilmesi için 92 imgeden oluşan bir veri seti üzerinde, ANN ve DVM gibi farklı makine öğrenme modellerinin kullanılmasıyla %94 oranında bir sınıflandırma doğruluğunun elde edildiği ifade edilmiştir.

[20] tarafından 737 adet meme kanseri imgesini iyi huylu veya kötü huylu olarak ayırt etmek amacıyla gerçekleştirilen çalışmada, 25 boyutlu bir özellik vektörü ile eğitilmiş dört farklı sınıflandırıcının kullanılması neticesinde %98 oranında bir başarı elde edildiği belirtilmiştir.

[21] tarafından DVM ve En Yakın Komşu Sınıflandırıcısı adlı ayırt edici analiz ve topluluk sınıflandırıcılarına ilişkin makine öğrenmesi yöntemlerinin kullanılmasıyla meme kanseri imgelerinin hasta seviyesinde sınıflandırılabilmesi açısından ortalama %87,53 oranında başarıya ulaşıldığı bir çalışma gerçekleştirilmiştir


Evrişimli Sinir Ağları (ESA)'na ilişkin jeoistatistik fonksiyonlar ve DVM'nin kullanılmasıyla mamogram görüntülerindeki kitlenin tespit edilebildiğini öneren bir çalışma gerçekleştirilmiştir [22]. Gerçekleştirilen çalışmadaki amaç, güçlerin mamogram görüntülerinde yer alan meme kütlelerini tanımasına yardımcı olabilecek bir hesaplama sisteminin gösterilmesidir. Yöntemin birincil dönemi mamogram resmini iyileştirmeyi amaçlamaktadır. MÖ sonucunda elde edilen veriler neticesinde; Bolster vektör makinelerinin aday bölgeleri için %80 doğruluk başarısı sağladığı, her görüntü için 0,84 yanlış pozitif, her

görüntü için 0,2 yanlış negatif ve 0,87'lik alıcı işlem karakteristikleri ROC (Alıcı Çalışma Karakteristikleri) bölgesi ve AUC (ROC Eğrisi altındaki alanın) değerini gösterdiği yönünde sonuçlara ulaşılmıştır.

Mamogram görüntüleri için Histogram Değiştirilmiş Yerel Kontrast İyileştirme üzerinde çalışılarak farklı geliştirme teknikleri kullanılmasıyla da farklı sonuçların elde edildiği bir çalışma gerçekleştirilmiştir. Yapılan çalışmada, mamogram görüntüleri için kontrast değişimi sunularak önerilen yöntem ile üstün bir farklılaştırma güncellemesi ve bilgi korunması sağlandığı belirtilmiştir. Ayrıca çalışmada önerilen yöntemin; yağlı, yağlı glandüler ve kalın glandüler şeklindeki mamogram görüntüleri için daha uygun olduğu ifade edilmiştir

Meme kanseri sınıflandırması için 82 hastadan elde edilen 7,909 histopatolojik meme kanseri görüntüsünden oluşan bir çalışma gerçekleştirilmiştir [22]. Bu amaç doğrultusunda çalışmada, doğrusal sınıflandırıcılara gönderilen manuel olarak tasarlanmış hesaplama özellikleri kullanılmıştır. Çalışmadan elde edilen veriler neticesinde; verilerin yetersiz bulunması nedeniyle %85,6 oranında sınırlı bir başarı elde edildiği ifade edilmiştir.

Wilkins'in ölçek uzay tekniklerinin, bir Gauss filtresi (Bkz: Şekil 2.1) ile kırmızı çözünürlüklü bir görüntü oluşturabilmek amacıyla orijinal görüntü kullanılacağına öne sürüldüğü bir çalışma gerçekleştirilmiştir [23]. Fakat söz konusu yöntemin, zemin ölçeklerinde "anlamsal olarak önemli" sınırları doğru bir şekilde yerleştirebilmek açısından önemli bir dezavantaj bulunmaktadır.



Şekil 2.1: Farklı büyütme faktörlerinde görülen meme malign tümörünün görüntüsü.

Son olarak yine [24] tarafından 737 meme kanseri görüntüsünün kötü huylu veya iyi huylu olarak ayırt edilebilmesi amacıyla 25-boyutlu bir özellik vektörü kullanılarak dört

sınıflandırıcı ile etkinlik hesaplaması yapılmak istenen bir çalışma gerçekleştirilmiştir. Çalışmada kullanılan görüntüler, meme kanseri görüntülerini sınıflandırabilmek amacıyla AlexNet benzeri bir modelin kullanılmasıyla hasta düzeyinde kategorize edilmiştir. Çalışmadan elde edilen veriler neticesinde; maksimum füzyon yöntemi ile farklı füzyon tekniklerinin kullanılmasıyla ortalama %97 oranında bir doğruluk kaydedildiği belirtilmiştir.

3. VERİ VE YÖNTEM

Çalışmanın bu bölümünde deneylerde kullanılacak verilerin güvenilirliği, elde edilmeleri ve kabul edilebilir düzeye getirilmelerine ilişkin bilgiler yer almaktadır.

3.1 DENEYLERDE KULLANILAN VERİ KÜMELERİ VE YÖNETİMİ

Meme kanserine X-Ray görüntüleri ile teşhis koyabilmek için kullanılan DÖ algoritmasının başarımını tabi tutarak ve BDT yöntemine nazaran çok daha iyi olduğunu deneysel olarak ölçebilmek amacıyla MIAS veri tabanında yer alan çeşitli veri kümelerinden faydalanılmıştır. Söz konusu veri tabanı ve veri kümesine ilişkin ayrıntılarına dair bilgiler aşağıda verilmektedir.


İngiliz araştırmacı grupları tarafından kurulan ve çevrim içi bir mamogram veri tabanı olan MIAS; elde edilen sonuçları doğrudan karşılaştırabilmek, araştırmacıları ve onların çalışmalarını araştırabilmek amacıyla kullanılmaktadır. Çalışmada kullanılan veri seti, MIAS aracılığıyla halka açık bir şekilde internet ortamında yayınlanmış olan görüntülerden oluşmaktadır. Bu görüntülerin halka açık olması sebebiyle herhangi bir onay formuna ihtiyaç duyulmamıştır. Kullanılan bu veriler, en az 3 uzmanın kontrolünden geçirilerek işaretlenmiştir.

Çalışmada kullanılan meme görüntüleri, Ağustos 2002 ile Nisan 2004 yılları arasında, yaklaşık 4.050 katılımcıdan alınmıştır. MIAS veri setindeki mikroskobik imgeler 50x, 100x, 200x, 400x ve 600x gibi birbirinden bağımsız büyütme katsayıları ile verilmiştir. Veri setindeki örnekler, 8 bit derinliğinde ve 720×440 boyutunda üç kanallı RGB imgelerinden oluşmaktadır. Şekil 3.1’de MIAS veri setinden farklı oranlarındaki örnek imgeler gösterilmektedir.

3.2 VERİ BÜTÜNLÜĞÜ

Bilgisayar grafik tekniklerinin ilerlemesi, oyunlarda ve film endüstrilerinde devrim yaratmıştır. Tamamen bilgisayar grafik modelleri kullanılarak çok gerçekçi karakterler yaratmak günümüzde mümkündür. Bununla birlikte, bu ilerlemenin büyük bir bedeli vardır: Görüntülerin gerçekçiliği o kadar büyük ki, bilgisayar tarafından oluşturulmuş bir görüntüyü gerçek bir fotoğrafla karşılaştığımızda ayırt etmek oldukça zordur. Bu çalışmada, göz bölgesindeki tutarsızlıkları keşfederek son derece gerçekçi olarak bilgisayar tarafından

oluşturulan görüntülerin tespiti için yeni bir yaklaşım önerilmektedir. Bu tür tutarsızlıklar, VGG19 Derin Sinir Ağı modeliyle, transfer öğrenme yaklaşımıyla çıkarılan özelliklerin ifade gücünü keşfederek yakalanır. Dengesiz ve sınırlı veri boyutu, sağlam BDS sisteminin geliştirilmesindeki en büyük zorluktur. Veri büyütme, sınırlı veri boyutu sorununu hafifletmek amacıyla veri kümesini büyütme için derin modellerde kullanılan bir yaklaşımdır. Çevirme, kırpma, ölçekleme, döndürme, enterpolasyon, öteleme ve gürültü ekleme gibi bazı popüler veri büyütme teknikleri, önceki birçok çalışmada zaten uygulanmıştır [25]. Ancak doğal görüntüler için kullanılan tüm büyütme yaklaşımları, tıbbi görüntüler üzerinde işe yaramamaktadır. Çünkü birçok tıbbi görüntü, doğal görüntüler gibi aşağıdan yukarıya değil, yukarıdan aşağıya çözülmüş bir problemdir. Ayrıca yoğunluklar, doğal görüntülere kıyasla birçok tıbbi görüntüleme modalitesinde çok önemli bir rol oynamaktadır. Bu nedenle, bir veri büyütme yaklaşımının seçimi, veri kümesine dayalı olarak akıllıca yapılmalıdır. Histopatolojik görüntüler dönme ve yansıma simetrisine sahiptir [26]. Bu nedenle ayırt edici özelliklerin veya bilgilerin kaybına neden olabilecek diğer büyütme teknikleri kullanılırsa, görüntüden bazı doğal özellikleri ortadan kaldırma olasılığı her zaman vardır. Sonuç olarak hem tam eğitim hem de transfer öğrenimi için, veri artırma tekniği olarak yalnızca döndürme kullanılır. Görüntülerin merkezleri etrafında üç açıyla döndürülmesi yapılır. Görüntü büyütme işlemi kullanmanın bir başka avantajı, çok daha başarılı sonuçlar elde edebilmesidir. Büyütme faktörü, histolojik görüntülerin analizinde çok önemli bir rol oynar. Büyütmede, bir nesnenin boyutu, nesnenin rahatça görülebilmesi için değiştirilir. Histoloji görüntüleri çeşitli dokulardan oluşur, ancak bu dokuların analizi düşük büyütmede karmaşık hâle gelmektedir. Farklı büyütme oranlarında bir görüntünün elde edilmesi, arka planda çeşitliliği ortaya çıkarmaktadır. Bu nedenle, otomatik bir BDS sisteminin ayırıcı tanı yapmak için farklı büyütme oranlarına sahip görüntülerden farklı özellikler öğrenmesi veya çıkarması zorlaşmaktadır. Aynı büyütme oranına sahip görüntülerin kullanılması, önceki çalışmaların çoğunda tercih edildiği gibi, arka plandaki varyasyonu azaltmanın bir yolu olabilmektedir. Görüntülerin daha net olabilmesi için belli bir seviyeye kadar büyütme işlemi yapılmıştır. Daha önceki bazı çalışmalarda, çoklu büyütme faktörlerine sahip görüntüler de dikkate alınmış ve spesifik büyütme faktörü için farklı sınıflandırıcılar kullanılmıştır. Bu tür yaklaşımların uygulanmasında, büyütme faktörünün ön bilgisi ile bağlantılı olarak birden fazla eğitim aşaması gereklidir. Ayrıca, yeni bir büyütme faktörüne sahip bir görüntü, büyütmeyle ilgili yaklaşımların yürütülmesinde büyük bir zayıflık olan ağın performansına da önemli bir sınır koyar. Bu nedenle, yeni büyütme faktörüne de uyum sağlayabilen, büyütmeden bağımsız bir otomatik teşhis sisteminin geliştirilmesine ihtiyaç vardır.



Şekil 3.1: Eğitim ve test X-Ray görüntüsü

Yukarıda verilen Şekil 3.1'de de görüldüğü üzere meme kanseri verisinden alınmış iki farklı görüntü bulunmaktadır. Eğitim veri seti için ayrılan veri seti ile test için ayrılan veri seti aynı veri kümesinden alınmıştır. Tanısal ve prognostik veri kümeleri, orijinal veri kümesi gibi, meme kitlesinin ince iğne aspirasyonundan elde edilen görüntünün sayısallaştırılmasına dayalı bilgiler içermektedir.

3.3 YÖNTEM VE TEKNİKLER

Çalışmada; ilk olarak kullanılan veri setleri ve performans kriterleri sunulacaktır. Yöntemlerin doğruluk ve hız açısından karşılaştırmaları daha sonra rapor edilecektir. Deneysel olarak ilk olarak Derin Öğrenme (DÖ) tabanlı sınıflandırıcılar birbirleriyle karşılaştırılacak, ardından Evrişimli Sinir Ağları (CNN, Convolutional Neural Network) tabanlı sınıflandırıcılar kıyaslanacaktır. Sınıflandırıcılar, sınıflandırma doğruluğu ve ROC analizi yardımıyla mukayese edilecektir. Daha sonra hız açısından değerlendirmeler yapılacaktır.

Temel amaç, mamografi meme görüntülerinden kanserli ve kanserli olmayan görüntülerin, kullanılan görüntü işleme ve makine öğrenimi stratejilerine göre sınıflandırılmasını yönetebilmektir. Çalışmada Şekil 3.1'de gösterildiği gibi, akış şeması tarafından verilen özelliğin sınıflandırılması ve kanserli ve kanserli olmayan görüntülerin belirlenmesi için görüntü tanıma teknikleri bulunmaktadır. Bu çerçeveyi yürütmek için yazılım programı, Python programlamasında oluşturulmaktadır.

Mamografide tümörlerin tanınması üç ana aşamaya bölünmüştür. Bir geliştirme stratejisini içeren ana adım; görüntü geliştirme stratejileri, bir görüntünün geliştirilmesi, SNR'nin nerede genişletileceği ve değişen renkleri veya parlaklığı değiştirerek belirli bir özelliği elde etmeyi daha kolay hale getirmek için kullanılmaktadır [27]. Test, mamogram ve görüntü işleme bölümlerinden elde edilen görüntülerin geliştirilen model ile denenmesidir. Eğitim ve test aşamaları ile ilgili detaylar Bölüm 3'te tartışılmıştır. Görüntü işleme başlığı altında, görüntü bölümlenme, parlaklık, görüntüyü kırpmaya gibi işlemler uygulanmıştır.

3.3.1 Makine Öğrenmesi

Makine öğrenimi (MÖ); konuşma tanımadan görüntü nesnesi tanımlamaya, arama sonucu filtrelemeye, yayınları ve haber öğelerini kullanıcıların ilgi alanlarıyla (İA) senkronize etmeye kadar değişen uygulamalarla günümüzün dijital çağında her yerde bulunur hâle gelmiştir. MÖ teknolojisi modern topluma büyük ölçüde fayda sağlamıştır ve şimdi çok çeşitli alanlarda ve amaçlarda kullanılmaktadır [28].

Doğal verileri yalnızca ham formlarda işleyebiliyor olmaları sebebiyle geleneksel MÖ tekniklerinin yetenekleri oldukça sınırlıydı. Çünkü bir görüntüye ilişkin çözünürlük gibi ham verileri; uygun dâhili anlamlara dönüştürebilen bir özellik çıkarımı, bir desen veya MÖ tanıma sistemi oluşturmanın bir hayli zor oluşu, özenli bir mühendislik ve önemli bir alan bilgisi gerektirmektedir. Bir makinenin ham veriler sayesinde desteklenmesi, sınıflandırma, kümeleme gibi algılama için gereksinim duyulan illüstrasyonları özdevimsel olarak icadını sağlayan yöntemle “Temsili Öğrenme” adı verilmektedir. Buradan hareketle DÖ yöntemleri de çoklu temsil seviyelerine sahip olan temsili öğrenme yöntemleridir. Öğrenme Aktarımı (ÖA) ham veri girişinden başlayarak her biri, temsili düzeyde daha da yüksek ve biraz daha yalın şekilde simgelere dönüştürülen basit ama lineer olmayan kitler oluşturmaktadır. Buna benzeyen dönüşümlerin yeterli bileşimi ile çok daha kompleks formlar öğrenilebilir. Sınıflandırma görevleri için daha yüksek temsil katmanları, girdi için önemli olan yönleri güçlendirerek ilgisi olmayan varyasyonları bastırmaktadır.

Sınıflandırma sorunları transfer öğrenme yoluyla daha etkin bir şekilde çözülebilir. Evrişimli sinir ağlarını eğitmek için, çok gürültülü ve güçlü bir bilgisayara sahip büyük bir veri kümesine ihtiyaç bulunmaktadır. Etiketli verilerin eksikliği tıbbi görüntü işlemede önemli bir sorundur. Tıbbi verilerin profesyonel doktorlar tarafından etiketlenmesi çok zaman ve para gerektirmektedir. Bu nedenle sıfırdan yeni bir modelle başlamak yerine önceki modelin

deneyimleri eldeki modele aktarılır. Böylece, önceden eğitilmiş modellerin ağırlıkları mevcut olana beslenir, bu şekilde transfer öğrenme yaklaşımı uygulanır. Aktarım öğrenimi yaklaşımı kullanılarak sorunları minimum sayıda veri kümesiyle eğitmek mümkündür. Ek olarak bu yaklaşım diğerlerine göre zaman ve enerji açısından daha maliyetlidir.

British Columbia'da denetimli öğrenme en popüler yöntemdir. Bu yöntemi kullanırken verilerin ne kadar derin olduğu önemli değildir. Bir sınıflandırma sistemi oluşturmak için her resmi ait olduğu kategori ile tanımlamak ve kapsamlı bir görüntü verisi koleksiyonu derlemek gerekir. Sınıf bazında bir çıktı vektörü, verilerin eğitimi boyunca görünen bu resimlerden herhangi birinin makine öğrenimi ile oluşturulur. Bir kategoride daha fazla puana sahip olmak ideal olandır, ancak eğitimden önce bunun gerçekleşmesi pek olası değildir.

Bu nedenle, amaçlanan çıktı puanları ile oluşturulanlar arasındaki farkı değerlendirebilecek bir amaç fonksiyonu oluşturulur. Dâhili ayarlar bu nedenle değiştirilebilir veya güncellenebilir. Bu yüzden bir hata olasılığı daha düşüktür. Ağırlıklar bu faktörler için ortak bir terimdir.

Düzenli bir şekilde ağırlık vektörü ayarlamak için görüntüdeki dolguların doğru bir şekilde 0 değerleri ile doldurulması, uygun havuzlama tekniğinin seçilmesi gibi adımlar bulunmaktadır.

Öğrenme algoritmasında, bir gradyan vektörü hesaplanırken her bir katman ağırlığı için, ağırlık artırıldığında veya azaltıldığında hatanın da bu şekilde ne kadar azalacağı incelenir. Yapılan incelemelerden sonra ağırlık vektörü, gradyan vektörünün tersi yönünde düzenlenir. Amaç fonksiyonunun tüm eğitim örnekleri üzerinden ortalaması alındığında, amaç fonksiyonu ağırlık değerinin yüksek boyutlu uzayında bir tür tepelik manzara olarak görünebilir. Bu hatanın en dik iniş yönü negatif gradyan vektörünü gösterir ve hemen hemen minimum seviyeye ulaştığı gözlenir. Bu sebeple, çıktı hatası ortalaması oldukça düşüktür.

3.3.2 Derin Öğrenme

Derin Öğrenme, MÖ'nün özellikle görüntü işlemede yetersiz kalması sebebiyle ortaya çıkmış bir yöntemdir. MÖ alanında daha yeni olmasına karşın çok büyük başarılar gösteren DÖ'de temel olarak Yapay Sinir Ağlarından (YSA) esinlenilmiştir. Bugün DÖ algoritmaları onlarca insanın yapamayacağı çok karmaşık işleri daha doğru bir şekilde ve zamandan tasarruf ederek yapabilmektedir. DÖ algoritmaları, verilerde öznitelik çıkarma gibi bir zorunluluğu olmaması

sebebiyle DVM'ler ve YSA gibi geleneksel MÖ algoritmalarına göre çok daha avantajlıdır. Bu nedenle de eğitim sürecinde insan müdahalesi bulunmamaktadır [29].

DÖ ile ifade edilen; doğal dil işleme, görsel algılama, konuşma, ses tanıma vb. karmaşık işlemlerin makine tarafından yürütülebilmesidir. Bu gibi proseslere ek olarak kompleks ilaç salım moleküllerinin aktivite olasılıklarının incelenmesi, partikül hızlandırıcı verilerinin analiz edilmesi, pek çok hastalığın erken tanısı ve mutasyonların etkilerinin tahmin edilmesi için de DÖ kullanılmaktadır. Aslında bunlar çok katmanlı bir yapı gerektirmektedir. Yapay Sinir Ağları (YSA) aracılığıyla elde edilmiş çok katmanlı yapı; bilgisayar bilimi, beşerî bilimler, nöroloji, psikoloji ve matematik gibi birçok disiplinin çalışma odağı olmuştur.

Verilen bir veri seti ile sonuçları tahmin eden birden fazla katmandan oluşan bir MÖ yöntemi olan DÖ, verilen bir veri kümesi ile çıktıları tahmin edecek olan modelin eğitilmesine imkân tanımaktadır. Söz konusu modeli eğitmek için hem denetimli hem de denetimsiz öğrenme kullanılabilir. “Denetimli Öğrenme”, girdilere ve beklenen çıktılara sahip etiketli veri setlerini kullanmayı içermektedir. Denetimli öğrenmeyi kullanarak bir modeli eğitirken, ona bir girdi verilerek beklenen çıktı istenmektedir. Modelin ürettiği çıktı doğru değilse hesaplamaların yeniden ayarlanması gerekmektedir. Bu işlem, modelin hata oranını en aza indirgeyene kadar veri seti üzerinden tekrar tekrar yapılmaktadır [30]. “Denetimsiz Öğrenme” ise belirli bir yapıya sahip olmayan veri kümeleri üzerinde işlem yapılmasıdır. Model, verilerin mantıksal sınıflandırmasını yapmaktadır.


Daha önce belirtildiği gibi MÖ, doğrusal olmayan işlem birimlerinin birçok katmanını kullanarak özellik çıkaran ve dönüştürmeyi gerçekleştiren bir yapay zekâ alt alanıdır. Her ardışık katman, bir önceki katmandan çıktıyı alır ve sonraki katmana iletir. Algoritmaları denetlemek veya denetlememek mümkündür. DÖ, çeşitli özellik seviyelerini veya veri temsillerini öğrenmek üzerine inşa edilmiştir. Düşük seviyeli özelliklerden yüksek seviyeli karakteristikleri çıkararak hiyerarşik bir temsil oluşturur. Bu temsil, çeşitli soyutlama derecelerine karşılık gelen sayısız temsil katmanları edinir. DÖ, temelde verilerden elde ettiği öznitelikler yoluyla öğrenen bir modeldir. Bir görüntünün temsilini ifade ederken piksel başına yoğunluk değerinin vektörü, özellikler olarak adlandırılan kenar kümeleri, özel formlar vb. ile temsil edilebilir. Bu özelliklerden bazıları veri aktarımında daha etkilidir. DÖ yaklaşımları faydalıdır çünkü manuel olarak oluşturulmuş özelliklerin aksine verileri en doğru şekilde tanımlayan hiyerarşik özellikleri çıkarmak için otomatikleştirilmiş, verimli algoritmalar kullanılmaktadır [31].

Yapay zekâ teknolojisinin gelişmesiyle birlikte, hastalık teşhisinde önemli gelişmeler olmuştur. Derin öğrenme yöntemlerinin ve genel olarak evrişimli sinir ağlarının gelişmesiyle birlikte yapay zekâda önemli ilerlemeler sağlanmıştır. Bu tür yaklaşımlar, özellik uzayının bir tanımına ihtiyaç duymaz ve insan uzmanların sonuçlarını aşan sınıflandırma sonuçları elde edebilir. Mamogramları kullanarak meme kanseri riskini değerlendirmeye yönelik derin öğrenme yönteminin bulguları cesaret vericidir. Derin öğrenme, çok sayıda gizli katmana sahip sinir ağlarını kullanan denetimli bir modda veya otomatik kodlayıcılar tarafından denetlenmeyen bir modda ham resim verilerinden örüntü tanımlama ve sınıflandırma için yardımcı olan hiyerarşik temsillerin otomatik olarak öğrenilmesini içerir. Ek olarak, büyük veri ve makine öğreniminin entegrasyonu, tarama testlerinin doğruluğunu artırmak ve özellikle görüntü tabanlı tarama için daha iyi doğrudan tarama yöntemleri için yeni beklentiler sunmaktadır. Bu araştırmanın amacı meme kanseri tümörlerini belirlemektir. Meme kanserini teşhis etmek için Inception-ResNet-V2'ye dayalı bir sınıflandırma modeli sunulmuştur. Gerçek veriler kullanılarak önerilen stratejinin performansı incelenmiştir. Önerilen derin öğrenme modeli, Inception ve ResNet modellerinin hibrit bir mimarisidir ve önemli ölçüde geliştirilmiş sınıflandırma ve tanıma performansına sahiptir. Derin öğrenme için önerilen mimari üç aşamadan oluşur: ön işleme, sınıflandırma ve performans değerlendirmesi.

Derin sinir ağları genellikle giriş katmanı ile çıkış katmanı arasında birkaç gizli katmana sahiptir. Bu ağlar, meme kanseri tespiti için el mühendisliği özelliklerini kullanan geleneksel MÖ algoritmalarının aksine, görüntülerden özellikler almak için kullanılır [32]. Yeni bir derin öğrenme türü (DÖ), MÖ yapılarının çoğunlukla optimum ağırlıkları bulmak için bir eğitim aşaması gerektiren makine öğrenimi sinir ağlarıdır. En sık kullanılan öğrenme kuralı, gradyan ve zincir kuralı ile üretim katmanından elde edilen hata oranına bağlı olarak ağırlıkların her geçiş için sistematik olarak güncellendiği geri yayılım algoritmasıdır.

3.3.3 CNN Mimarisi

Geleneksel CNN mimarisinin çoğunlukla 4 ana katmandan oluştuğu görülmektedir. Söz konusu bu 4 ana katman; girdi katmanı, havuzlama katmanı, Tam Bağımlı Katman (FC) ve çıktı katmanı şeklinde adlandırılmaktadır. Bu katmanların farklı dizilişlerinden oluşturulan Inception, VGG19, Resnet50, AlexNet gibi CNN mimarileri, araştırmacıların çalışmalarına destek sağlamaktadır. Aşağıda verilen Şekil 3.2'de örnek CNN yapısı görülmektedir.



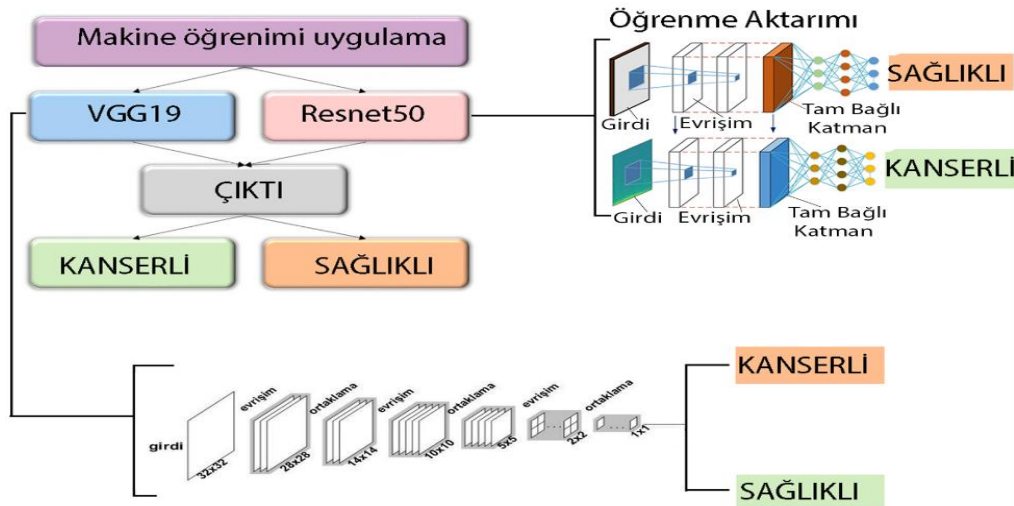
Şekil 3.2: Çalışmasında uygulanan CNN mimarisi

Yukarıda verilen Şekil 3.2’de görüldüğü gibi; bu çalışmada kullanılan meme kanseri imgeleri, açık kaynak MIAS veri setinden sağlanmıştır. Görüntüler ön işleme alınmış ve daha sonra ise görüntülerde bulunan gürültü ve eksiklikler giderilmiştir. Filtreler uygulandıktan sonra kenar belirleme ve öznitelik çıkarma işlemleri yapılmıştır.

Uygulamalarda, bir CNN'yi sıfırdan eğitmek için büyük boyutta veri gerekmektedir. Ancak bazı durumlarda, ilgili problemlerden oluşan büyük bir veri setini düzenlemek çok zordur. İdeal bir durumun aksine, gerçek dünya uygulamalarının çoğunda durum böyle değildir veya eşleşen eğitim ve test verilerini elde etmek karmaşık bir husustur. Bu nedenle transfer öğrenme kavramı ortaya çıkmıştır. Transfer öğrenimi, bir problemi çözmek için uygulanan arka plan bilgisini öğrenen ve diğer ilgili problemlerde yeniden kullanan en iyi bilinen makine öğrenimi yöntemlerinden biridir. Başlangıçta baz ağ, ilgili veri setinde belirli bir görev için eğitilir ve ardından hedef veri seti tarafından eğitilen hedef göreve aktarılır. Transfer öğrenme süreci üç ana adıma ayrılabilir: önceden eğitilmiş modelin seçimi, problem boyutu ve benzerlik. Önceden eğitilmiş modelin seçimi, hedef problemin çözümünde iyi sonuçlar verdiği için zaman ve enerji açısından daha avantajlıdır. Hedef veri setinin boyutu daha küçükse ve kaynak eğitim veri setine benzerse (tıbbi veri setleri, elle yazılmış karakter veri setleri, araç veri setleri veya biyometrik ile ilgili veri setleri vb.) fazla zaman ve enerji maliyetine neden olmaktadır. Benzer şekilde, hedef verinin boyutu daha büyükse ve kaynak veri setlerine benzerse, o zaman aşırı öğrenme şansı düşüktür ve sadece önceden eğitilmiş modelin ince ayarının yapılması gerekir. Önerilen çerçevede, transfer öğrenme ve ince ayar özelliklerini paylaşmak için üç CNN mimarisi (GoogLeNet, VGGNet ve ResNet)

kullanılmıştır. Bu üç CNN mimarisi, ImageNet veri setinden alınan örnek görüntülerle eğitilmiş ve aktarım öğrenmesi benimsenmiştir. Bu, mimarinin yeni eğitime ihtiyaç duymadan diğer veri kümelerinden genel özellikleri öğrenmesini sağlar. İlgili CNN mimarisinden bağımsız olarak çıkarılan özniteliklerin sayısı, ortalama havuzlama sınıflandırması kullanılarak kötü huylu ve iyi huylu hücrenin sınıflandırılması için tam bağlantılı katmanda birleştirilir.

Evrişimli sinir ağları (CNN'ler), görüntü işlemede çok çeşitli uygulamalara sahiptir. Derin evrişimli sinir ağları, daha yüksek seviyelerdeki özelliklerin daha düşük seviyelerdekilerden daha soyut olduğu giriş görüntülerinden hiyerarşik özellikleri otomatik olarak öğrenebilir. Genel olarak evrişimli sinir ağları üç katman içerir: evrişimli katman, havuzlama katmanı ve tam bağlantılı katman [33]. Evrişim katmanı ve havuz katmanı, bir evrişim bloğu oluşturmak için birleştirilir ve bu tür birkaç blok, derin seviyeli bir mimari oluşturmak için istiflenir. Genellikle, sınıflandırma veya regresyon gerçekleştirmek için son katman olarak tam bağlantılı bir katman kullanılır. Şekil 3.3, temsili bir CNN mimarisini göstermektedir. CNN, tipik bir denetimli ileri beslemeli sinir ağıdır. Eğitimin amacı, evrişim çekirdeklerini ve havuzlama işlemlerini değiştirerek ve üst üste bindirerek soyut özellikleri öğrenmektir.



Şekil 3.3: Çalışmada uygulanan makine öğrenme mimarisi

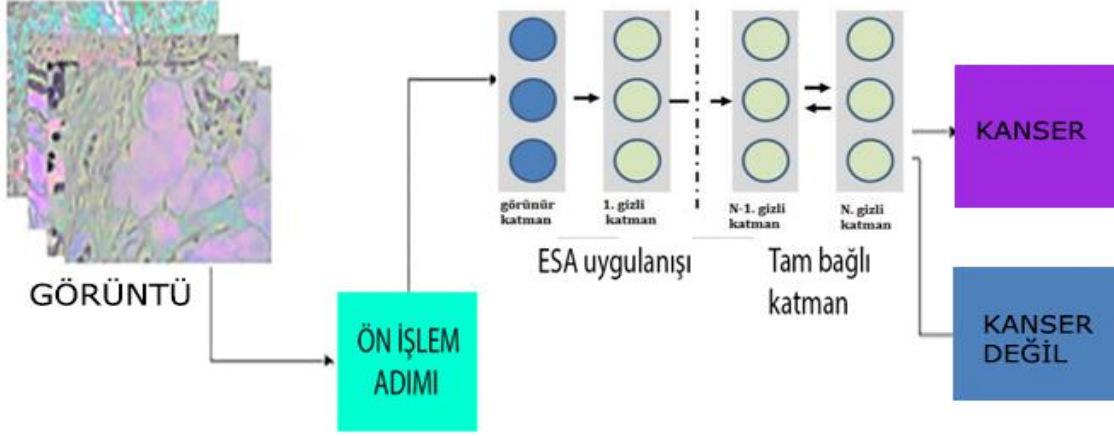
Şekil 3.3'te gösterildiği gibi, DÖ modelinin eğitimi için Python programlama dili destekli PyTorch kitaplıkları kullanılmıştır. PyTorch derin öğrenme kitaplığını oluşturmak için Python programlama dili kullanılmıştır. Güçlü bir GPU mimarisine sahip olan bu kütüphane, dinamik hesaplama grafiklerinin hızlı bir şekilde üretilmesini sağlamaktadır. Tüm testler

Windows 10 işletim sistemi ve 36 GB hafızaya sahip NVIDIA GeForce GTX grafik kartı kullanılarak yapılmıştır.

CNN'ler bir görüntüdeki kalıpları keşfetmek için uygulanır. Bu, bir görüntü üzerinde kivrılarak ve desenler aranarak yapılır [34]. Ağ, CNN'lerin birkaç ön katmanındaki çizgileri ve köşeleri algılayabilir. Ancak sinir ağı aracılığıyla bu kalıplar aşağıya aktarılabilir ve daha derine indikçe daha karmaşık özellikler tanımlanmaya başlanabilir. Bu özellik, CNN'lerin görüntülerdeki nesnelere tespit etmede çok etkili olmasını sağlamaktadır (Alirezazadeh et al., 2018). Önerilen sistem, meme dokusu görüntülerinden meme kanserini tespit etmek için CNN'leri kullanır. Bir CNN mimarisi, yukarıdaki Şekil 3.3'te gösterildiği gibi, evrimsel katman, havuz katmanı ve tam bağlantılı katman olmak üzere 3 ana katmana sahiptir. İlk katman, yerel bölgelerle bağlantılı nöronların çıktısını hesaplar. Her biri, ağırlıkların ve bölgenin bir nokta çarpımı ile hesaplanır. Görüntü girişleri için tipik filtreler, 3×3 , 5×5 veya 8×8 gibi alanlarda küçüktür. Bu filtreler, görüntünün herhangi bir alanında ortaya çıkan tekrarlayan kalıpları öğrenirken, görüntüyü görüntü üzerinde kayan bir pencere ile tarar. Filtreler görüntü üzerinde dolaştırılırken arada kalan boşluklara adım denir. Adım hiperparametresi filtre boyutundan daha küçükse evrişim, örtüşen pencerelere genişletilir.

3.3.4 Evrişim Katmanı

Derin Öğrenme kavramına ait temel mimari CNN mimarisi olarak kabul edilmektedir. Bu mimariye göre ilk birkaç aşama “Konvolüsyon” (convolution) ve “Havuzlama” (ortaklama) katmanlarından oluşmaktadır. Son aşama “Tam Bağlı” katmandan oluşmakta, akabinde “Sınıflandırma” katmanı bulunmaktadır. Özetle CNN'ler art arda yerleştirilmiş birden fazla eğitilebilir bölümden meydana gelmektedir. CNN'de giriş verilerini aldıktan sonra katman katman tüm işlemler yapılarak eğitim süreci gerçekleştirilir. En sonunda doğru sonuç ile karşılaştırma yapmak için bir final çıktısı verilmektedir. Üretilen sonuç ile istenen sonucun farkı kadar bir hata oluşmaktadır. Bu hatanın bütün ağırlıklara aktarılması için geriye yayılım algoritması kullanılmaktadır. Her bir iterasyonla ağırlıkların güncellenmesi yapılarak hatanın azaltılması sağlanmaktadır. CNN'nin anahtar bileşeni olan evrişim katmanı, en az bir katmandan oluşmalıdır. Katmanların amacı, girdi olarak alınan görüntülerde bir dizi özelliğin varlığını tespit etmektir. Tespit CNN ile yapılmaktadır.



Şekil 3.4: Makine öğrenmesinde evrişimli sinir ağlarının uygulaması

Yukarıda Şekil 3.4'te gösterildiği gibi, modelin nasıl çalıştığı tartışılmaktadır. Modelin eğitimindeki ağırlık parametreleri, RMSprop optimizasyon tekniği kullanılarak güncellenmiştir. Modele eklenen damla katmanları için parametre değerleri sırasıyla 0,25 ve 0,50 olarak seçilmiştir. Modelin eğitiminde ResNet-50 mimarisinden transfer öğrenme yaklaşımı kullanılarak elde edilen taban katmanlarının ağırlık değerleri dondurulmuş ve sadece bu tabana eklenen ek katmanlar eğitilmiştir. Eğitimin rastgele 1e-3 ve 10 epok oranında yapılmasına karar verilmiştir. Daha sonra tüm model katmanları eğitilir ve öğrenme oranı [1e-6, 1e-3] aralığında belirlenir. Modelin ilk katmanları önceden eğitilmiş olduğundan, bu adımda öğrenme oranı için küçük bir değer (1e-6) seçilmektedir. Son katmanlardaki öğrenme oranı, önceki katmanlardan (1e-3) daha fazla parametre değişikliğine ihtiyaç duyduğu için daha yüksek ayarlanır. Ara katmanların parametre güncellemelerinde bu iki değer (1e-6, 1e-3) arasından öğrenme oranı seçilmiş ve katman derinliğine bağlı olarak aşamalı eğitim gerçekleştirilmiştir.

1	1	0	0	0
0	1	1	1	0
0	1	1	0	0
0	0	1	1	1
0	0	0	1	1

Evrişim

 \times

1	0	1
0	1	0
1	0	1

Uygulanan Filtre

 $=$

4	3	3
2	4	1
1	2	3

Yeni görüntü

Şekil 3.5: CNN mimarisinde evrişim, çekirdek ve elde edilen yeni görüntü gösterimi

Şekil 3.5'te de görüldüğü üzere; resmi filtrelerken herhangi bir benzerlik olmadığı durumlarda özellik haritasının boşluk ya da benzerlik bulunmayan bölgelerdeki değerleri daha düşük ölçülmektedir. Bu sebeple çekirdeklere "özellik dedektörleri" de denmektedir. Bu düşük değerler dolgu yani sıfır değeri ile doldurulmaktadır.

CNN'lerde evrişim işlemi göz önüne alındığında, üzerine düşünülmesi gereken 3 farklı tasarım sorunu göze çarpmaktadır. Söz konusu bu 3 tasarım sorunu; çekirdek boyutu, çekirdek sayısı ve kaydırma adımından (stride) oluşmaktadır. Modelin inşası için kullanılan bloklarda sırasıyla 128, 256, 512 ve 1024 özellik haritaları kullanılmıştır. Model yaklaşık 9,3 milyon parametre içermektedir. Bu parametreler, çıktı verilerinin şekli ve bellek kullanımı üzerinde oldukça etkilidir.


Üzerine düşünülmesi gereken tasarım sorunlarından ilki olan çekirdek boyutu, evrişim tabakasının çıkışındaki her bir nöronun alıcı alanını belirlemektedir. Çekirdeğin değerleri, modelin ağırlıklarını temsil etmektedir. Örneğin; çekirdek 3x3 boyutuna sahipse çıktısının da giriş katmanında 9 farklı düğümle bağlantısı bulunmaktadır. Genel olarak çekirdek boyutu, giriş veri boyutuyla aynıdır. Girişin sahip olduğu görüntü 1 kanallı gri tonlamalı bir görüntü ise çekirdek de 1 kanala sahip olmaktadır. Girişin sahip olduğu görüntü 3 kanallı bir RGB görüntüsü ise bu kez de çekirdek 3 boyutlu bir yapıda seçilmiş olmaktadır. Eğer çekirdek boyutu fazla küçük olursa da yeterli özellikleri ayıklaması mümkün olmamaktadır.

Küçük çekirdekler büyük ve karmaşık desenleri algılayamamaktadır. Fakat küçük çekirdek boyutlarına sahip kıvrımlar, art arda uygulanırlarsa özellikleri ayıklamaları daha mümkün hâle gelebilmektedir. Öte yandan çekirdek boyutunun büyük olması, hesaplama karmaşıklığının artmasına da sebep olmaktadır. CNN eğitiminde genellikle 3x3 veya 5x5 gibi küçük çekirdek boyutları kullanılmaktadır. Ancak son yayınlarda, ağdaki boyutun azaltılması açısından bazı durumlarda 1x1 filtrelerin yarar sağlayabileceği belirtilmektedir.

Üzerine düşünülmesi gereken tasarım sorunlarından ikincisi olan çekirdek sayısı, odaklanılacak farklı özelliklerin sayısını belirlemesi sebebiyle çok önem verilen bir tasarım parametresidir. Bunun yanı sıra, çekirdek sayısı yinelenen filtrelere neden olacak kadar büyük olmamalıdır. Örneğin; çekirdek boyutu 3x3 ise 64 çekirdeğin kullanılması yinelenen filtreler oluşturmaktadır. Çünkü 3x3 boyutun 64 nitelikli farklı filtre oluşturması mümkün değildir. Yinelenen filtrelere ek olarak; her bir kıvrık görüntü bilgisayarın belleğinde ayrı yer kapladığı için çok fazla filtre, bellek sorunlarını doğuracaktır. Her çekirdek giriş görüntüsünün üzerine kaydırıldığında, bir özellik haritası oluşmaktadır. Bu çıktı görüntüleri,

tüm çekirdekler çıktılarını ürettikten sonra birleştirilmektedir. Giriş görüntüsü 2 boyutlu ise çıktıları, 3 boyutlu tensör olacaktır. Giriş görüntüsü 3 boyutlu hacimsel veri ise çıktıları, 4 boyutlu tensör olacaktır. Bu ekstra boyut, birçok filtre kullanımının etkisiyle ortaya çıkmaktadır. Tensörün derinliği ve çekirdeğin derinliği aynı olmalıdır. Örneğin; 30x30 boyutunda bir giriş tensörü ve 3x3 boyutunda bir çekirdekten yola çıkılırsa ortaya çıkan kıvrım boyutu 28x28'dir. Sonuç olarak, çıkış tensörünün boyutu $K \times 28 \times 28$ olmaktadır. Bir sonraki evrişim işleminde ise çekirdek boyutu, $K \times N \times M$ olarak hesaplanmaktadır.

CNN modeli gösterimlerinde bu boyut, genellikle $K \times N \times M$ olarak temsil edilmektedir. Dolgu (padding) ise burada çok ciddi bir rol oynamaktadır. Genel olarak çekirdeğin giriş görüntüsü bir kerede 1 düğüm adımı boyutunda kaymaktadır. Yine de çıkış tensörü boyutunu kontrol etmek için kaydırma adım sayısında değişiklik yapılabilir. Bu kayma, üzerine düşünülmesi gereken tasarım sorunlarından sonuncusudur. Adım sayısı "2" olarak değiştirilirse çekirdek, 2 düğümü kaydırarak bir sonraki kısma geçmektedir. Örneğin; 64x64 boyutunda bir görüntü ve 3x3 boyutunda bir çekirdek (filtre) için adım 1 ise çıktı görüntüsü iyi veya kötü huylu (0 ya da 1) olacaktır. Aşağıda verilen Şekil 3.6'da dolgu değerleri işlemleri gösterilmektedir.




Şekil 3.6: Dolgu değerleri, filtre ve çıktı

Yukarıda verilen Şekil 3.6'da da görüldüğü üzere; evrişim işleminde, çıkış tensörünün boyutunu giriş hacmiyle aynı tutabilmek amacıyla giriş tensörüne dolgu eklenebilir. Dolgu boyutu genellikle çekirdeğin boyutuna göre ayarlanmaktadır.

3.3.5 Havuzlama Katmanı

Çıktının boyutunu düşürmek amacıyla havuzlama işlemlerinde bazı yöntemler uygulanmaktadır. Alt bölgelerin özetlenmesi için maksimum ya da ortalama değer alma gibi bazı fonksiyonların kullanılması bu yöntemlere örnek olarak gösterilebilir. Havuzlama işleminde, belirlenen alan içerisindeki değerlerin ortalaması alınarak maksimumu hesaplanmakta ve buna göre bir değer çıkarılmaktadır. Havuzlama işlemi, girdide kayan pencere yöntemi kullanılarak uygulanmaktadır. Kayan pencere her defasında havuzlama yöntemine göre denk gelen girdi alanının içerisinde bir değer ortaya çıkararak bu değeri çıktı katmanına ilave etmektedir. Söz konusu girdinin küçük parçaları, CNN'deki havuzlama katmanları sayesinde, tercih edilmiş olan yöntemine uygun olarak sabit bir değere indirgenmiş bulunmaktadır. Buradan yola çıkılarak havuzlama katmanı hesaplamalarının evrişim katmanı hesaplamalarına göre daha az maliyetli olduğu söylenebilir. Havuzlama türlerinin DÖ'de en yaygın kullanılanı, girdinin parçalara ayrıldığı ve her bir parçadaki en yüksek değer alındığı maksimum havuzlama tekniği bu çalışmada kullanılmıştır. Aşağıda Şekil 3.7'de; Maksimum ve ortalama havuzlama katmanı gösterilmektedir.



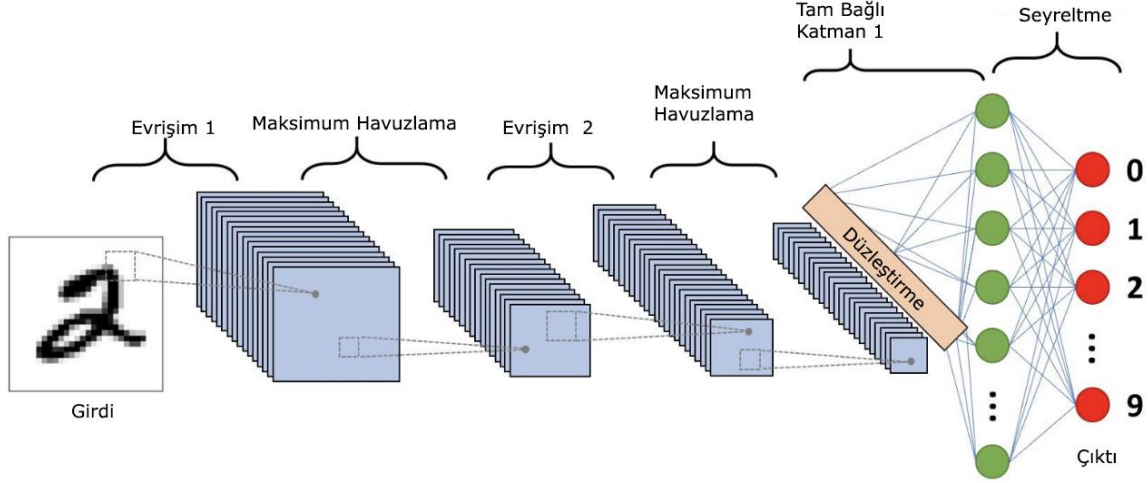
Şekil 3.7: Maksimum ve ortalama havuzlama katmanı

Yukarıda verilen Şekil 3.7'de da görüldüğü üzere; maksimum ve ortalama havuzlama türleri hesaplanmıştır. Eğer bütün değerlerin ortalaması alınırsa bu ortalama havuzlama; her alanda bulunan değerlerin en yüksekini alınırsa bu da maksimum havuzlama olmaktadır.

Aşağı örnekleme katmanı olarak da adlandırılan havuzlama katmanı, ağdaki parametre sayısını ve hesaplamayı azaltmak amacıyla evrişim katmanı çıktısının uzamsal boyutunu azaltmaktadır. Havuzlama katmanı ayrıca aşırı gecikmeyi kontrol altına alabilmek için de kullanılmaktadır. Havuzlama katmanı genellikle iki kıvrım katmanı veya kıvrım ile FC'ler (Tam Bağlantılı Katman) arasına yerleştirilmektedir. Maksimum havuzlama ve ortalama havuzlama, en çok kullanılan havuzlama yöntemlerindedir. Belirli bir pencere bazında düşünüldüğünde, ortalama havuzlamanın o penceredeki değerlerin ortalama değerini aldığı, maksimum havuzlamanın ise o penceredeki maksimum değeri aldığı görülmektedir. Görüntü üzerinde havuzlama işlemi yapmak için pencere boyutu ve adım değeri olan iki önemli hiperparametre bulunmaktadır. Pencere boyutu, odaklanılacak alanın genişliğini ve öte yandan adım, sürgülü pencerenin adım boyutunu belirlemektedir. Havuzlama katmanı, görüntü matrisini üst üste gelmeyen ve 4 dikdörtgen kısımdan oluşan gruplara bölmektedir. 2 havuzlama sınıfı, maksimum ve ortalama maksimum değerdeki görelî matris bölgesinde, maksimum havuzlama ile üretilmektedir. Ortalama havuzlama, görelî matris bölgesindeki ortalama değeri sağlamaktadır. Havuz katmanı bilgisayarın performansını artırarak, fazla gecikme olasılığını düşürmektedir.

3.3.6 Tam Bağlı Katman

Bir sinir ağında, bir katmandaki bütün girdilerin kendinden sonra gelen katmandaki her bir etkinleştirme birimine bağlandığı katmanlara FC (Tam Bağlantılı Katman) adı verilmektedir. FC'ler, modern MÖ modellerinde, son çıktıyı meydana getirebilmek için önceki katmanlar tarafından çıkarılan verileri derleyen son birkaç katman olarak da tanımlanabilir. Konvolüsyon katmanından sonra en çok zaman harcandığı bilinen ikinci katmandır. Bir başka deyişle evrişim ve havuzlama tabakası, dikdörtgen şekilli çıktılar üretmektedir. Bu çıktılar, vektör matrisine dönüştürülerek ağırlık matrisi ile çarpılmaktadır. Örneğin; her biri $5 \times 5 \times 3$ voksel içeren 64 özellik eşleme katmanı varsa FC'de bu hacimler 4800×1 vektörüne ($5 \times 5 \times 3 \times 64 = 4800$) dönüştürülmektedir. Aşağıda verilen Şekil 3.8'de FC katmanının kullanımını gösterilmektedir.



Şekil 3.8: Modelde uygulanan Tam Bağlı Katman

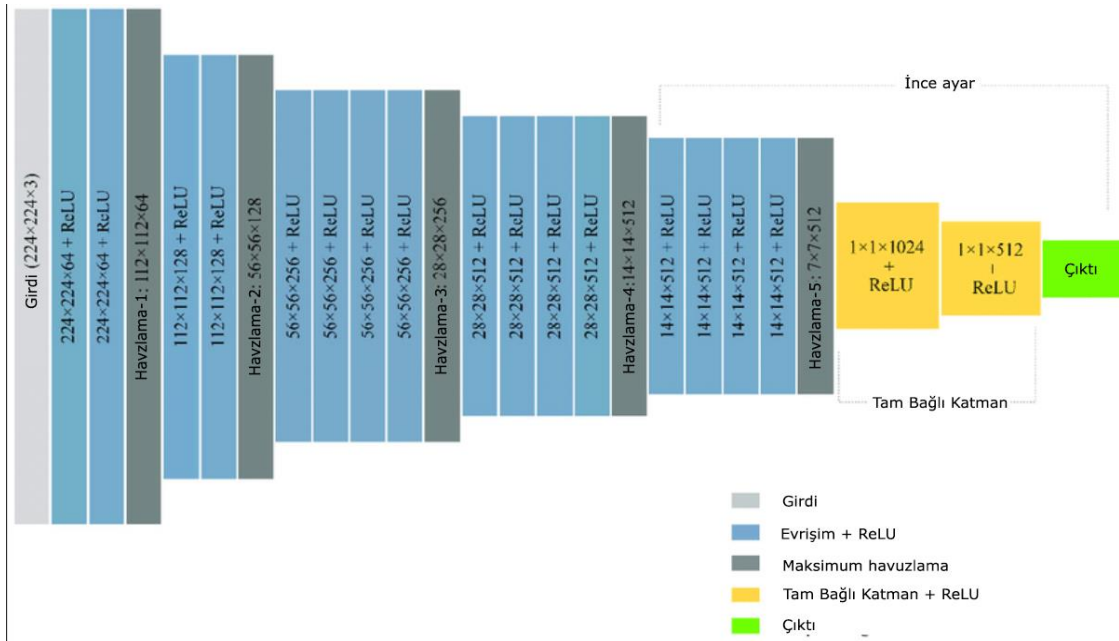
Şekil 3.8’de görüldüğü üzere; FC katmanından önceki katman, üst düzey özellikleri simgelemektedir. Tamamen bağlı bir katmanın yardımıyla bu üst düzey özellikler, gizli katmanların ağırlıkları ile çarpılabilir. Sistemin geri kalanı Çok Katmanlı Perseptron (MLP: Multi- Layer Perceptron) gibi çalışmaktadır. Bu katman YSA (Yapay Sinir Ağları) gibi çalışmaktadır. Havuzlama ve evrişim işlemlerinden sonra ortaya çıkan değerler, birinci katman tarafından girdi olarak alınarak, işleme sokulmakta ve çıkış katmanında sınıf sayısı kadar sonuç üretilmektedir.

3.3.7 VGG19 Ağı

VGG19 Ağı, temelde AlexNet ile aynı prensipler temel alınarak üretilmiştir. Ağın girdisi, RGB renk formatında ve 224x224 boyutlarında bir görüntüdür. Ağa verilmeden önce görüntüdeki her pikselden, eğitim setindeki görüntülerde hesaplanan, ortalama resme ait olan piksel değerleri çıkartılmaktadır. Ağda kullanılabilen evrişimler 3x3 boyutlarındadır ve derinliklerine de farklı olan değerler atanmıştır. Çıktının boyutları değişmeyecek şekilde dolgu değerleri ayarlanmıştır. Bazı evrişim katmanlarının ardından toplam 5 defa, 2x2 boyutlarında ve adım sayısı 2 olan maksimum havuzlama işlemi uygulanmıştır. Evrişim katmanlarından sonra her birinde 4096 adet filtre bulunan FC’ler kullanılmıştır. Son katmanda ise 1000 adet nöron kullanılmıştır. Son katman softmax adı verilen katmandır.

Şekil 3.9’da gösterilen eğitim esnasında VGG19 girdisi, sabit boyutlu 224×224 RGB görüntüden meydana gelmektedir. Görüntü, ön işlemten sonra eğitim setinde hesaplanan ortalama RGB değerini her pikselden olacak şekilde çıkarmaktır. Görüntü, çok küçük bir alıcı

alana sahip filtreler kullanılması sebebiyle bir evrişimli katman yığınının geçirilmektedir. Bu, 3×3 bir filtre olarak varsayılabilir. VGG19 modelinde, giriş kanallarının doğrusal bir dönüşümü olarak görülebilen 1×1 evrişim filtrelerinden yararlanılmaktadır. Evrişim adımı 1 piksele sabitlenmiş, modelde dolgu, çözünürlüğün evrişimden sonra korunacağı şekilde ayarlanmıştır. Yani dolgu, 3×3 dönüşüm için 1 pikseldir. Havuzlama için beş maksimum havuzlama katmanından yarar sağlanmaktadır. Şekil 3.9'da VGG19 ağı mimari yapısı uygulanışı gösterilmektedir.




Şekil 3.9: VGG19 ağı mimari yapısı uygulanışı

Yukarıda verilen Şekil 3.9'da da görüldüğü üzere; maksimum havuzlama, adım 2 ile 2×2 piksellik bir pencere üzerinde meydana getirilmektedir. Evrişim katmanını 3 adet FC katmanı izlemektedir. İlk ikisinde 4096 kanal bulunmaktadır. Üçüncüsünde ise 1000 kanal mevcuttur. Son katman daha önce de bahsedildiği üzere softmax katmanıdır. FC konfigürasyonu tüm ağlarda aynıdır.

3.3.8 Resnet50 Ağı

Derin öğrenme mimarisinde ağın gerçek anlamda derinleşmeye başladığı mimari türü Resnet50 Ağıdır. Bu yönüyle kendinden önceki modellerden daha farklıdır. ResNet şu ana kadarki tüm mimarilerden daha derin olarak tasarlanan bir mimaridir. 50 katmandan oluşmaktadır. Aynı zamanda %3,6 hata oranı ile ImageNet 2015 yarışmasının kazananı olmuştur [10]. Söz konusu durum Resnet50 mimarisini, klasik bir model olmaktan

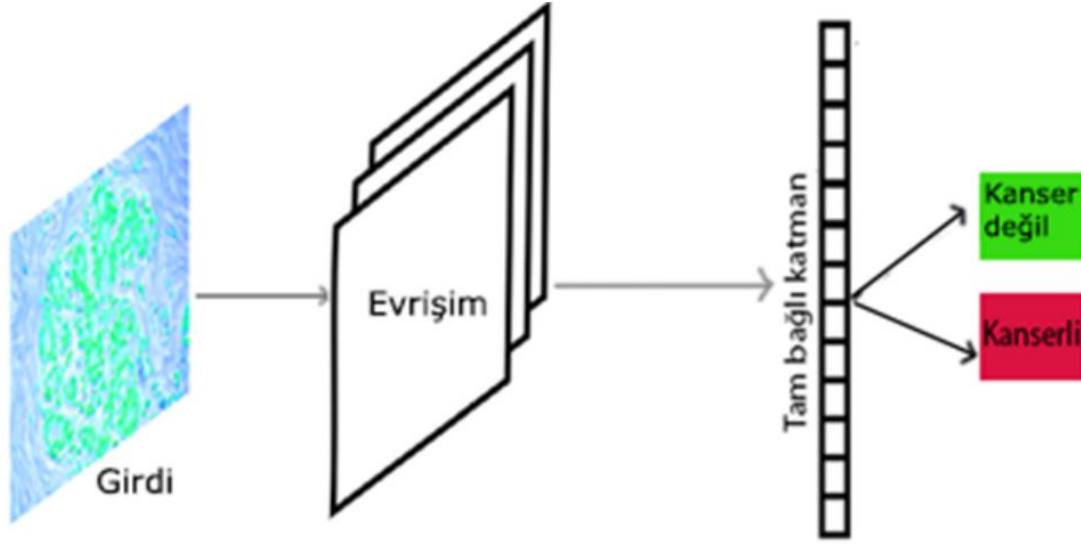
çıkarmaktadır. Resnet50 "residual network" isminden türetilmiştir [11]. Şekil 3.10'da Kalıntı (Residual) öğrenme blokları yapısı gösterilmektedir.



Şekil 3.10: Kalıntı (Residual) öğrenme blok yapısı

Şekil 3.10'da da görüldüğü üzere; ResNet, Microsoft araştırma ekibince çok fazla derin ağlarda gradyanın 0'a yakınsaması problemini ortadan kaldırmak için geliştirilmiştir. Mantığı oldukça basit olan Resnet50 mimarisi, birkaç katman önde yer alan aktivasyon fonksiyonunu şu anki aktivasyon fonksiyonunun girdisiyle toplayıp aktive etmektedir. Böylece üzerinde işlem yapılan katmanın lineer transformunun sonucu 0 olsa bile bir çıktı meydana gelmektedir. Resnet50 sayesinde "kaybolan gradyanlar" problemi meydana gelmeden öğrenme çok daha derin ağlarla gerçekleştirilebilmektedir.

Ağı oluşturan blok diyagramının gösterildiği Şekil 3.11'de klasik ağa, bazı kısa yollar eklenerek oluşturulan Microsoft Resnet50 Ağı, kalıntı bloklardan meydana gelmektedir. Kalıntı blokta x değerinin girdi olarak alınmasıyla evrişim – aktivasyon – evrişim serisinden görüntü geçirilmekte ve bir $f(x)$ fonksiyonu elde edilmektedir. Daha sonra $f(x)$ fonksiyonuna orijinal girdi olan x değeri eklenerek $h(x) = f(x) + x$ üretilmektedir. Klasik evrişim işleminde $h(x)$ fonksiyonu $f(x)$ fonksiyonuna eşittir. Fakat geliştirilen modelde, girdiye evrişim işlemi uygulandıktan sonra orijinal veri de eklenmektedir [21]. Şekil 3.11'de meme verisi üzerine uygulanan temel model çerçevesi gösterilmektedir



Şekil 3.11: Uygulanan temel model çerçevesi

Şekil 3.11’de görüldüğü üzere, model birçok evrişimden ve maksimum havuzlama adımlarından oluşmaktadır. Son katmanda iş, tamamen bağı bir sinir ağı içermektedir. ReLU, bir aktivasyon işlevi görmekte ve katmanların havuzlanmasında maksimum havuzlama kullanılmaktadır [35]. 5x5 ve 3x3 boyutlu filtreler uygulanmadan önce 1x1 boyutlu filtre uygulanmış ve boyut küçültülmüştür. Inception v2 ağına aksine, bu model aynı zamanda paket normalleştirme içermektedir. Kısaca ifade etmek gerekirse her katmanın çıktısındaki ortalama ve standart sapmayı hesaplama ve çıktıyı bu değerlerle normalleştirme işlemine "paket normalleştirme" denmektedir. Bu süreç, tüm sinir ağının sıfır ortalama ile aynı aralıkta sonuç vermesini sağlamaktadır. Ağı derinliği ve genişliği, ağdan maksimum bilgi akışını almak amacıyla optimize edilmiştir. Derinlik arttıkça ağı genişliği sistematik olarak artmaktadır. Bu ağa 5x5 ve 7x7 filtreler değildir, ancak bunları karşılamak için 2 veya 3x3x3 boyutunda filtre kullanılmaktadır.

3.4 PERFORMANS METRİKLERİ

Meme nodüllerini tespit etmek ve sınıflandırmak için geliştirilen DÖ algoritmalarının performansını analiz etmek için farklı ölçütler kullanılmaktadır. Hata Matrisi, MÖ’de kullanılan sınıflandırma modellerinin performansını değerlendirmek için hedef niteliğe ait tahminî değerler ile gerçek değerlerin karşılaştırıldığı özel bir tablo düzenidir. Matrisin her satırı, tahmin edilen bir sınıftaki örnekleri simgelerken her sütun gerçek bir sınıftaki örnekleri temsil etmektedir. Modelin performansı, sistemin iki sınıfı karıştırıp karıştırmadığını

anlamayı kolaylaştırmasından kaynaklanmaktadır. Aşağıda verilen Çizelge 3.1’de DÖ’de meme kanseri tespit literatüründe kullanılan metrikler gösterilmektedir.

Çizelge 3.1: Derin öğrenme meme kanseri tespit literatüründe kullanılan metrikler.

<ul style="list-style-type: none"> Doğru Pozitif: X-Ray görüntüsündeki verinin gerçek sınıfı ve tahmin edilen sınıfın doğruluğu
<ul style="list-style-type: none"> Yanlış Pozitif: X-Ray görüntüsündeki verinin gerçek sınıfı yanlış ve tahmin edilen sınıfın doğruluğu
<ul style="list-style-type: none"> Doğru Negatif: X-Ray görüntüsündeki verinin gerçek sınıfı yanlış ve tahmin edilen sınıfın yanlışlığı
<ul style="list-style-type: none"> Yanlış Negatif: X-Ray görüntüsündeki verinin gerçek sınıfı doğru ve tahmin edilen sınıfın yanlışlığı

Hata matrisi yukarıda verilen Çizelge 3.1’de gösterilmekte olan 4 değerlendirmeden en az birine sahip olmalıdır. Aşağıda verilen Çizelge 3.2’de Doğruluk (Accuracy), Hassasiyet (Sensitivity), Özgünlük (Specificity), Kesinlik (Precision) ve F1 skoru gösterilmektedir.

Çizelge 3.2: Performans ölçümü parametreleri

Metrik	Açıklaması
Hassasiyet (SE)	$SE = \frac{TP}{(TP + FN)}$
Özgünlük (SP)	$SP = \frac{TN}{(TN + FP)}$
Doğruluk (ACC)	$ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)}$

Çizelge 3.2: Performans ölçümü parametreleri (devam)

Metrik	Açıklaması
Kesinlik (PRV)	$PPV = \frac{TP}{(TP + FP)}$
F1-Skoru	$F1 = \frac{2TP}{(2TP + FP + FN)}$
ROC	Özgünlük ve ROC değeri arasındaki ilişkiyi gösteren eğri (Y eksenini gerçek pozitif orandır ve X eksenini yanlış pozitif)
AUC	ROC eğrisinin altındaki toplam alan

Çizelge 3.2’de görüldüğü üzere; doğruluk bir sınıflandırıcının başarısını göstermek için yaygın olarak kullanılan ölçütlerden biridir. Doğru tahminler, toplam örnekleme oranını ifade etmektedir. Hassasiyet ise doğru pozitif orandır. Sınıflandırıcı tarafından bulunan doğru pozitif örneklerin, tüm pozitif örneklere oranını ifade etmektedir. Özgünlük, doğru negatif oranını ifade etmektedir. Sınıflandırıcı tarafından bulunan doğru negatif örneklerin, tüm negatif örneklere oranıdır. Son olarak kesinlik ise sınıflandırıcı tarafından bulunan doğru pozitif sayısının, pozitif olarak sınıflandırılan örneklerin toplamına oranını ifade etmektedir.

3.4.1.1 Sınıflandırmayla ilgili metrikler

Doğruluk (Accuracy) yerine F1 Score değerinin kullanılmasının en temel sebebi eşit dağılmayan veri kümelerinde hatalı bir model seçimi yapmamaktır. Ayrıca sadece yanlış negatif ya da yanlış pozitif değil tüm hata maliyetlerini de içerecek bir ölçme metriğine ihtiyaç duyulduğu içinde F1 Score bizim için çok önemlidir.

Makine öğrenimi sınıflandırması için çeşitli endüstriyel uygulamalar arasında; Twitter’da yüz tanıma, YouTube video kategorizasyonu, içerik denetleme, tıbbi teşhis, metin sınıflandırma ve nefret söylemi tanımlama yer alır. En çok kullanılan sınıflandırma modelleri destek vektör makinesi (DVM), lojistik regresyon, karar ağaçları, rastgele orman, XGBoots, evrişimli sinir

ağı ve tekrarlayan sinir ağıdır. Bir sınıflandırma modelini değerlendirmenin birkaç yöntemi vardır ve en bilinenlerinden bazıları bir sonraki bölümde tartışılacaktır.

Yanlış anlama matrisi

İlk olarak, kategorizasyon sorunlarıyla bağlantılı birkaç temel terimin bilinmesi gereklidir. Hata matrisi, sınıflandırma performansındaki temel kavramlardan biridir. Önemli doğruluk etiketlerine karşı model tahminlerinin tablo şeklinde bir temsilidir. Hata matrisinin her satırında hem öngörülen sınıftan hem de gerçek sınıftan örnekler bulunmaktadır. Aşağıdaki misal üzerinden durum somutlaştırılabilir. Memelerin görüntülerini diğer hayvanların görüntülerinden ayırmak için ikili bir sınıflandırıcı oluşturulduğu varsayılır. Aşağıdaki hata matrisi ile test setinde (1000 doku resmi ve 100 meme resmi) 1100 fotoğraf olduğu varsayılır.

Sınıflandırma Hassasiyeti

Sınıflandırma doğruluğunu belirlemek için, tahmin edilen sayısı doğru tahmin sayısına bölünür ve ardından bölüm 100 ile çarpılır. Bu örnekte, 1100 numuneden 1030'u doğru bir şekilde tahmin edilerek bir sınıflandırma doğruluğu elde edilir.

Duyarlılık

Sınıflandırma doğruluğunun anlamlı bir performans ölçüsü olmadığı çeşitli durumlar vardır. Sınıftaki verilerin dağılımı şu durumlardan birini gösterir: Bir modeldeki verilerin dağılımı diğerine göre daha seyreklerdir. Bu örnekte, tüm örneklerin en sık kullanılan sınıfa ait olduğu tahmin edilse bile anlamsız derecede yüksek bir doğruluk oranı elde edilir (çünkü model hiçbir şey öğrenmemekte ve tüm örneklerin en sık görülen sınıfa ait olduğunu tahmin etmektedir) örneğin, memeler ve dokular kategorizasyonunda model, tüm örneklerin doku olduğunu tahmin ederse, sonuç $1000/1100 = \%90,9$ olur. Bu nedenle, sınıfa özgü performans ölçütleri de dikkate alınmalıdır.

Geri çağırma

Geri çağırma, bir model tarafından doğru bir şekilde tahmin edilen bir sınıfın örneklerinin yüzdesi olarak tanımlanan bir diğer önemli ölçümdür. Bunun ışığında, meme ve doku sınıfları için hatırlama oranı aşağıdaki gibi hesaplanabilir. Uygulamaya bağlı olarak, hatırlama veya doğruluk tercih edilebilir. Ancak hem hafızanın hem de doğruluğun gerekli olduğu sayısız durum vardır. Bu nedenle, bu ikisini tek bir ölçü içinde birleştirmek için bir yöntem düşünülebilir. Kesinlik ve hafızayı birleştirmek için dikkate değer bir istatistik, kesinlik ve hatırlamanın harmonik ortalaması olan F1 puanıdır. Sonuç olarak, hata matrisindeki kullanılan sınıflandırma örneği için F1 puanı aşağıdaki gibi hesaplanabilir:

Aşağıda, genelleştirilmiş versiyonunda F-skorunun bir tanımı yer almaktadır. Görüldüğü gibi, F1-skor, $1=1$ olduğunda F'nin özel bir örneğidir. Bir modelin doğruluğu ve geri çağırılması arasında her zaman bir değiş tokuş olduğuna dikkat edilmelidir; kesinlik aşırı derecede yüksek olursa, geri çağırma oranı düşecektir ve bunun tersi de geçerlidir.

ROC Analizi

Sadece bir duyarlılık ve özgüllük değeri kullanarak tanı koymanın getirdiği sakıncaları ortadan kaldırmak için geliştirilmiş istatistik değerlendirme yöntemidir. Bir ROC eğrisi, farklı eşik değerleri için dikey eksen üzerinde doğru pozitiflik (duyarlılık) ve yatay eksen üzerinde yanlış pozitiflik (1-özgüllük) oranlarının yer aldığı bir eğridir. ROC eğrisi üzerindeki her nokta, farklı eşik değerlerine karşılık gelen duyarlılık ve 1- özgüllük değerlerini ortaya koyar. Genelde düşük yanlış pozitiflik oranlarını veren eşik değerleri, düşük doğru pozitiflik oranına da sahiptir. Doğru pozitiflik oranı arttıkça, yanlış pozitiflik oranı da artar.

ROC Eğrisi

Alıcı işletim karakteristik eğrisi, bir ikili sınıflandırıcının kesme eşiğine karşı performansını gösteren bir grafikdir. Bu grafik, çeşitli eşik değerleri için yanlış pozitif oranı gerçek pozitif oranı ile karşılaştırır. Başka bir deyişle çoğu sınıflandırma modeli olasılıksaldır, yani bir örneğin meme olma olasılığını tahmin eder. Çıktı sonucu 1 ise görüntünün "kötü huylu" olmasına karar verilir.

4. MODEL ÇALIŞMALARINA YÖNELİK VERİ ÖNİŞLEM SÜRECİ

Dijital görüntü işleme, bir video veya fotoğraf çerçevesi gibi bir görüntüyü meydana getiren sinyal işlemenin bir parçasıdır. Öncelikle MİAS meme veri seti görüntüleri girdi olarak alınmakta ve çıktı, görüntüye bağlı olan görüntü veya parametre karakterizasyonları olarak ortaya çıkmaktadır. Maksimum görüntü dönüştürme işlemleri, görüntüyü 2 boyutlu bir sinyal olarak ele almayı ve ona standart sinyal işleme tekniklerinin uygulanmasını içermektedir.

Çalışma kapsamında; görüntü geliştirme, görüntü segmentasyonu ve öznelik çıkarma şeklinde adlandırılan farklı sinyal işleme teknikleri kullanılmıştır. Söz konusu tekniklere ilişkin detaylar takip eden alt başlıklarda ele alınacaktır.

4.1 GÖRÜNTÜ ÖNİŞLEME

Çalışmada; kullanılan görüntü işleme tekniği ile görüntü iyileştirildikten sonra görüntünün alınabilmesi için çalışılmıştır. Bu teknik; geliştirme, kontrastı iyileştirme, bulanıklaştırma ve gürültüyü azaltma gibi görüntü kalitesini iyileştiren durumlar için kullanılan bir tekniktir. Önışlem; görüntü işleme, gürültü olarak adlandırılan kirliliği gidererek görüntüyü iyileştirme anlamına gelmektedir. Bu şekilde görüntü daha anlaşılır hâle gelmektedir. Görüntü işleme, elektronik ortamda kaydedilen herhangi bir resim dosyası üzerinde bilgisayar yardımıyla yapılan tüm işlemleri kapsamaktadır. Görüntü dosyaları üzerinde yapılan işlemler görüntüdeki ışık, renk, zıtlık, keskinlik ya da netlik gibi özellikleri değiştirmek veya resimde yer alan bir gürültüyü, pürüz ya da bozukluğu gidermek de olabilir. Ayrıca bu sayılanlara ek olarak; görüntü dosyalarından anlamlı veriler çıkarmak ve o görüntülerde yer alan nesnelere hakkında farklı bilgiler edinmek de görüntü işleme olarak adlandırılmaktadır.

Görüntünün düzeltilmesinde kullanılan ortalama filtre, bulanık mantık filtresi, gürültünün olup olmadığına karar veren birim filtresi ve Gauss filtresi, görüntünün iyileştirilmesine ilişkin en önemli parametrelerdendir [36]. Gauss filtresi görüntüleri bulanıklaştırmak, özelliği ve gürültüyü temizlemek amacıyla uygulanan iki boyutlu bir evrişim parametresidir. Görüntünün ne kadar homojen olup olmadığı belirlenebilmesi açısından standart sapma, bu parametrede çok önemli bir rol oynamaktadır [37]. Gauss filtresi, veri veya gürültü için bir olasılık dağılımını karakterize etmek, düzeltme operatörü ve matematik araştırma alanlarında sıklıkla kullanılmaktadır. Denklem 1’de Gauss filtreleri için ortalama ve standart sapma değerlerinin alınması gösterilmektedir:

$$f_Z(z) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{z^2}{2}\right\} \quad (1)$$

Formülde yer alan M değeri, ortalamayı; σ değeri ise standart sapmayı ifade etmektedir.

Tuz ve biber filtresi ise görüntü üzerinde yer alan tuz biber gürültülerinin giderilmesi ve görüntüdeki gereksiz ayrıntıların azaltılmasını sağlamaktadır. Kameradan alınan görüntü matrisi üzerinde, 3x3, 5x5 vb. küçük bir çekirdek matrisinin gezdirilmesi sonucunda filtreleme işlemi gerçekleşmektedir.

4.2 GÖRÜNTÜ SEGMENTASYONU

Görüntü segmentasyonu, temelde bir görüntünün bölümü veya bölümlenmesidir. Bir diğer ifadeyle; görüntünün bir veya daha fazla kriterin özelliklerine bağlanabilen çeşitli bölgelere bölünmesine ilişkin prosedürdür. Görüntü segmentasyonu genellikle görüntülerdeki nesnelere ve sınırları bulmak için kullanılmaktadır. Aynı etikete sahip piksellerin belirli özellikleri paylaşacak şekilde bir görüntüdeki her piksele bir etiket atama işlemidir. Segmentasyon sonucunda sadece aranan kısımların tutulması ve gereksiz kısımların görüntüden çıkarılması hedeflenir. İyi parçalanmış bir görüntünün özellikleri; gri ton ya da doku gibi bir özellik açısından segmente edilmiş bir görüntüde düzgün ve homojen bölgelerin elde edilmesi, bölge içlerinin basit olması ve küçük delikler içermesi, birbirine yakın fakat farklı bölgelerin düzgün oldukları özellik açısından farklı değerler alması, bölge sınırlarının basit olması, girinti çıkıntı olmaması ve bölge sınırlarının uzamsal olarak doğru konumda bulunmasıdır. Görüntü bölütleme yöntemlerinden en önemlisi, görselin sadece parlaklık bilgisi dikkate alınarak bölütlemenin gerçekleştirildiği eşikleme işlemidir. Diğer bir bölütleme işlemi, farklı yüzeylerin veya bölgelerin yan yana getirilmesiyle oluşturulan kenar bölgelerinin bulunmasıdır.

4.3 ÖZNETELİK ÇIKARMA

Öznitelik çıkarma, meme kanserini ayırt etmeye yönelik en ideal yaklaşımdır. Bu durum; görüntü işleme teknikleri açısından meme kanserinin tanımlanmasında, tıbbi sürece avantaj sağlayacağı ve tıbbi ilerlemenin geliştirilmesine yardımcı olabileceği anlamına gelmektedir. Bu öznitelikler, görüntü işlemedeki özellik için çeşitli sınıflandırmaları kapsamaktadır. Çip histogram özelliği, dalgacık tabanlı öznitelik çıkarımı gibi birçok öznitelik çıkarma kategorisi bulunmaktadır.

5. UYGULAMA

YSA, insan beyninden ilham alan paralel ve dağıtık bilgi işleme mimarileridir ve ağırlıklı bağlantılar aracılığıyla birbirine bağlanan işlem modüllerinden oluşmaktadır. Öğrenebilen bir yapay zekâ alt kümesidir. Yapay sinir ağları, insan beyninin bir özelliği olan yeni bilgi türetme ve öğrenme yoluyla yeni bilgi üretme ve bulma gibi kapasiteleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek için kurulmuştur.

Bir Yapay Sinir Ağını eğitirken katman sayısı, gizli birim sayısı, öğrenme hızı, aktivasyon fonksiyonu gibi parametrelere karar verilmesi gerekir. Bu parametrelerin davranışı hakkında doğru tahminlerde bulunmak için birçok farklı değerle deney yapmak gerekmektedir. Bu zorluklar nedeniyle, makine öğrenimi uygulaması yinelemeli bir süreç olarak oluşturulmuştur. Bu yaklaşım normalde hedef sorununu çözmek için gereken katman sayısı, gizli birimlerin sayısı ve üzerinde çalışılacak veri kümeleri kavramıyla başlamaktadır. Söz konusu kavram geliştirildikten sonra kodlama yoluyla teste tabi tutulur. Ağın ve çeşitli ayarların ne kadar iyi çalıştığını görmek için kodun yürütülmesi izlenebilir. Performans analiz edildikten ve konsept yenilendikten sonra yeni konfigürasyon ayarları ve optimizasyon parametreleri geliştirilerek prosedür tekrarlanır.

Sınıflandırma Modellerinde Başarı Kriterleri: Performans ölçümü, MÖ'de önemli bir yer tutmaktadır. ROC ve AUC eğrileri bu nedenle bir sınıflandırma algoritmasının doğruluğunu ölçmek için kullanılır [38]. ROC eğrisi, herhangi bir sınıflandırma modelinin performansını yönetmede temel değerlendirme kriterlerinden biri olarak kabul edilmektedir. Sınıflandırma algoritmalarını kullanan araştırmalardaki temel yanlışlardan biri, yalnızca doğruluk oranının bir başarı kriteri olarak değerlendirilmesidir. Özellikle dengesiz veri setlerinde doğruluk oranı güvenilir bilgi sağlayamaz. Dengesiz veri kümesi, sınıflar arasındaki dağılımın yakın olmadığı veri kümelerini temsil eder.

Dünya çapında, bir performans ölçüsü olarak eşik değeri değiştirilerek oluşturulan Gerçek Pozitif Oran-Yanlış Pozitif Oran grafiğinin kullanılması yaygındır. AUC normalde 0'dan 1'e kadar çalışır. Bir karar verme algoritmasının ROC eğrisi çapraz bir çizgi oluşturuyorsa, AUC değeri 0,5'tir. AUC değeri kullanılırsa doğru seçim yapmak daha olasıdır. Özetle, daha iyi bir eğri, her iki ROC eğrisinin AUC'nin 1'den büyük olduğu bir eğridir. Bununla birlikte, uygun bir karşılaştırma için bazı yönler dikkate alınmalıdır. ROC eğrileri oluşturulurken çeşitli veri

kümelerinin zorluk seviyelerinin eşdeğer olduğu varsayılır. Bilgisayarlı bir tıbbi görüntü analiz algoritması tarafından oluşturulan bir ROC eğrisi genellikle 10 veya 100'dür.

AUC genel bir performans ölçüsü olduğundan, birkaç önemli husus ihmal edilebilir. Bu durumda, belirtilen DP aralığı, YP aralığı veya her ikisi için ROC eğrisi altındaki kısmi alan hesaplanmalıdır. Aynı DP veya YP aralığındaki kısmi AUC'leri karşılaştırmaya genellikle izin verilir. Farklı DP aralıkları için hesaplanan AUC'lerin her bir DP aralığındaki minimum sayıda farklı değerde normalleştirilmesi, eğer herhangi bir amaç için karşılaştırılıyorsa önerilir. Çapraz çizgi, kısmi AUC için en düşük değeri alabilir. Bu şekilde ayarlansa bile, çeşitli DP aralıklarındaki AUC'leri karşılaştırmak mantıklı olmayacaktır.

5.1 UYGULANAN ÖĞRENME AKTARIMI TABANLI TEKNİKLER

ESA, X-Ray görüntülerine bir dizi öğrenilebilir filtre uygulamaktadır. ESA'da evrişim katmanı; filtre boyutu, uygulanan filtre sayısı ve evreler ile tanımlanabilir. Evrişimli bir katmanın girişi ve çıkışı, X-Ray görüntüleri ile başlayan üç boyutlu (genişlik, yükseklik, kanal sayısı) bir yapıya sahiptir. Evrişim katmanları derlenirken; çıkışın genişliği ve yüksekliği maksimum havuzlama işlemi ve derinlik ise daha fazla veya daha az filtre kullanılarak elde edilmektedir.

Yapılan çalışmada hız ve modülerlik göz önüne alınarak, 1 TB veri yerine sadece 32.7 GB veri ile çalışılmıştır. Çalışmada kullanılan veri setinin %80'i eğitim, %20'si ise test için ayrılmıştır. Bilgisayar konfigürasyonu Intel Core i7 10750H 16GB 512 GB SSD RTX 2060 ile sistem üzerinde işlem yapılarak model eğitilmiştir. Programlama dili olarak Python kullanılmıştır. Python dilinin yanı sıra Tensorflow ve Keras kütüphanelerinden de yararlanılmıştır. Doğrulama için 10 katlı çapraz doğrulama yaklaşımı kullanılmıştır.


5.1.1 Resnet50 Ağı

Resnet50, yenilikçi bir mimariden ziyade çok çeşitli sınıflandırma görevlerinin kullanılmasıyla mükemmel sonuçlar elde edilmesini sağlayan bir modeldir. Çalışmada, sıfırdan CNN eğitmek yerine hâlihazırda var olan CNN mimarisinden yararlanılmıştır. Resnet50, toplam 50 katmana sahip bir artık sinir ağı varyantıdır. Artık ağların, iyi bir performans ve parametre sayısı kombinasyonu sağlamasıyla model daha hızlı eğitilmektedir. Artık ağ mimarisi kullanılmasının bir başka nedeni ise eğitildikleri boyuttan farklı boyutlara sahip olan görüntüleri de besleyebilme özelliğidir. Resnet50 ağı için önerilen sistem, aynı X-

Ray taramalarına sahip vakaların oluşturduğu bir veri üzerinden oluşturulmuştur. X-Ray görüntü setinin %80'i eğitim, %20'si ise test için kullanılmıştır.

Resnet50 model eğitimi iki aşamadan oluşmaktadır. Birinci aşamada; X-Ray görüntüleri MİAS veri kümesinde 224 x 224 x 3 olarak boyutlandırılmakta ve daha sonra 128 x 128 x 3, 224 x 224 x 3 ve 299 x 299 x 3 olarak yeniden ölçeklendirilmektedir. Farklı eğitim aşamalarında farklı boyutlar kullanılmaktadır. Bir X-Ray veri seti için ImageNet ağırlıkları 5 Epok boyunca öğrenme hızı 1e-3 olacak şekilde ayarlanmaktadır. İkinci aşamada, tüm ağ daha önce olduğu gibi ayırt edici bir öğrenme oranıyla 5 Epok için daha da ince ayarlamalara tabi tutulmaktadır. Daha sonra tüm ağ, 40 Epok için 229 x 229 x 3 boyutunda girdi görüntüleriyle daha da ince hâle getirilmektedir. Böylece ilk katmanın 1e-6 öğrenme oranıyla; son katmanınsa 1e-3 öğrenme oranıyla eğitildiği öğrenme oranları kullanılmaktadır.

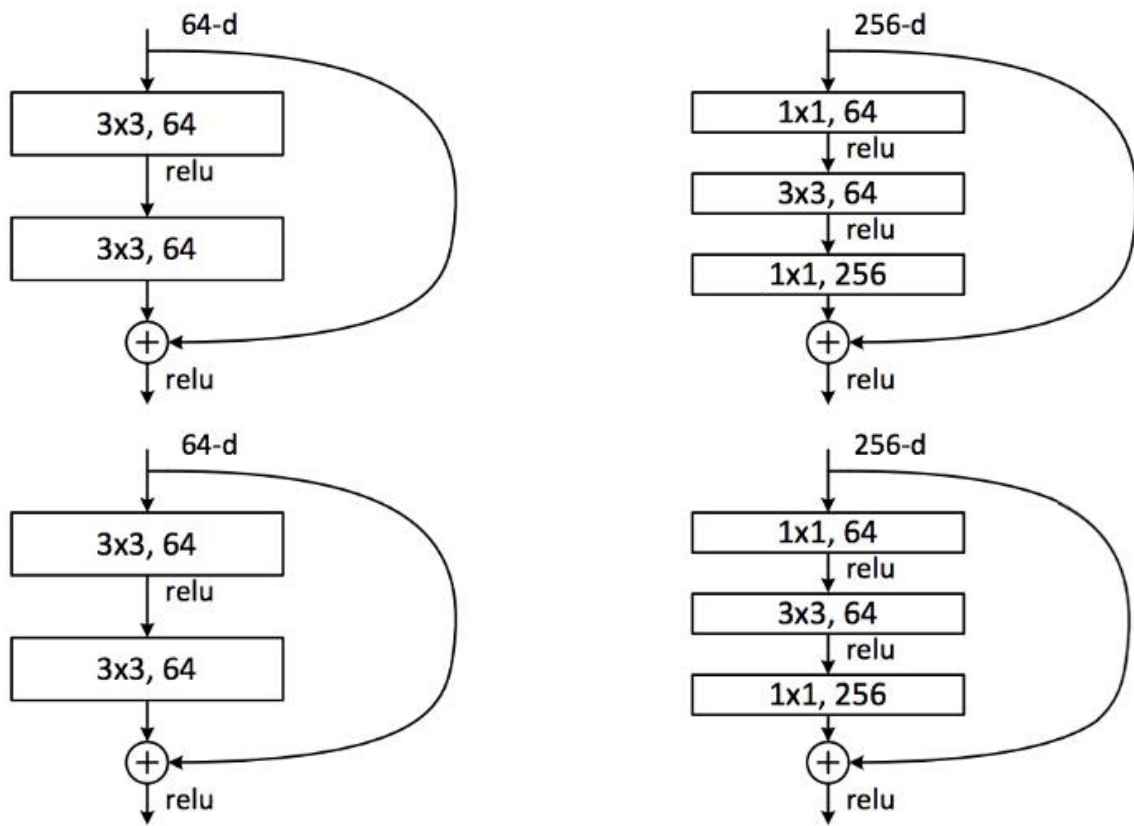
Kısaca; Resnet50 modelinde 50 Epok, 0.001 öğrenme katsayısı ve Adam optimizeden yararlanılmıştır. Resnet50'de kullanılan ağırlıklar ImageNet veri seti ile önceden eğitilmiş, modelin tekrar eğitilmesine gerek kalmadan zaman kaybı önlenmiştir. Aşağıda verilen Şekil 5.1'de, Resnet50'nin kullanılmasıyla bulunan en iyi dört sonuç gösterilmektedir.



Şekil 5.1: Resnet50 ile elde edilmiş en iyi sonuçlar

Yukarıda verilen Şekil 5.1'de de görüldüğü üzere; az sayıda veriye sahip sınıflandırma problemlerinin çözümünde, transfer öğrenme yöntemi büyük önem taşımaktadır. Evrişimli sinir ağlarını eğitmek için büyük miktarda etiketlenmiş veri kümesi ve yüksek hesaplamalı

grafik kartları gerekmektedir. Tıbbi görüntü işlemedeki temel sorunlardan biri, etiketli verilerin azlığıdır. Tıbbi verilerin uzman doktorlar tarafından etiketlenmesi pahalı ve zaman alan bir işlemdir [39]. Bu nedenle CNN modelini sıfırdan eğitmek yerine, daha önce farklı bir veri kümesi üzerinde eğitilen modelin deneyimleri eldeki modele aktarılmaktadır. Başka bir deyişle, transfer öğrenme yöntemi kullanılarak önceden eğitilmiş modellerin ağırlıkları mevcut modele aktarılmaktadır. Birkaç veri seti ile problemler, transfer öğrenme yöntemi kullanılarak başarılı bir şekilde eğitilebilir. Aşağıda verilen Şekil 5.2’de uygulanan Resnet50 mimarisi gösterilmektedir.



Şekil 5.2: Uygulanan Resnet50 Mimarisi

Şekil 5.2’de de görüldüğü üzere; ÖA için eğitilen modelin bazı parametreleri (maksimum havuzlama, paket normalizasyonu) değiştirilerek model, MİAS veri setine uyarlanmıştır. Öncelikle X-Ray veri seti alınıp paket normalizasyonuna tabi tutulmuş ve daha sonra evrişim 2D katmanı ve bu adımların tekrarından oluşan bir seriden geçirilmiştir. Son adım olarak da düzleştirme uygulanmıştır.


Aşamalı yeniden boyutlandırma kullanan Resnet50 modeli, farklı girdi görüntüsü boyutlarıyla birden çok eğitim aşamasında daha iyi bir sınıflandırma yapma eğilimindedir. Bu, aynı zamanda bir girdi görüntü boyutundan diğerine aktarım yapmayı öğrenmenin bir yoludur. Çizelge 5.1’de Resnet50 model sonuçları gösterilmektedir.

Çizelge 5.1: Resnet50 model Sonuçları

ÇAPRAZ	Doğruluk	Kesinlik	Hassasiyet	Özgünlük	Duyarlılık	F1-skor
Fold 1	0.986	0.913	0.977	0.894	0.988	0.903
Fold 2	0.984	0.851	0.968	0.973	0.944	0.915
Fold 3	0.982	0.858	0.986	0.952	0.988	0.827
Fold 4	0.958	0.827	0.974	0.931	0.832	0.963
Fold 5	0.976	0.803	0.965	0.979	0.912	0.911
Fold 6	0.972	0.924	0.926	0.940	0.908	0.983
Fold 7	0.968	0.855	0.902	0.905	0.996	0.811
Fold 8	0.952	0.983	0.912	0.097	0.964	0.983
Fold 9	0.836	0.911	0.866	0.948	0.971	0.923
Fold 10	0.988	0.993	0.981	0.991	0.964	0.983

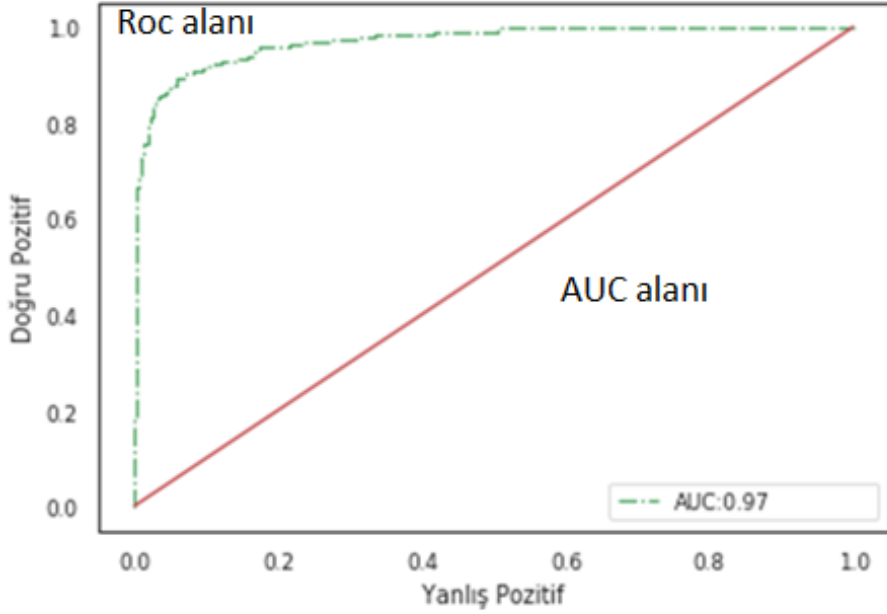
Dikkat edilmesi gereken husus, eğitimin sonraki aşamalarına geçerken öğrenme oranlarında düşüş sağlanmış olmasıdır. Bu durum, ağırlıkların bir aşamadan sonraki aşamaya kadar çok fazla değiştirilmediğini göstermektedir.

Bu bölümde, Resnet50 ağı performansının sonuçları ve kullanılan nicel ölçümler gösterilmektedir. Sağlıklı / iyi huylu tümör / kötü huylu tümör vakaların yanı sıra her enfeksiyon türü duyarlılık, kesinlik, doğruluk, özgünlük, hassasiyet, metrikleri ve F1 skoru verilmektedir. Model doğruluğu için 10 katlı çapraz doğrulama kullanılmıştır. Yukarıda verilen Çizelge 5.1'de de görüldüğü üzere; doğruluk oranı %98,8 gibi bir değerle başarıya ulaşmıştır. Ayrıca hata matrisi de bunu ispatlayacak şekildedir. Aşağıda verilen Şekil 5.3’te Resnet50 hata matrisi gösterimi bulunmaktadır.



Şekil 5.3: Resnet50 hata matrisi gösterimi

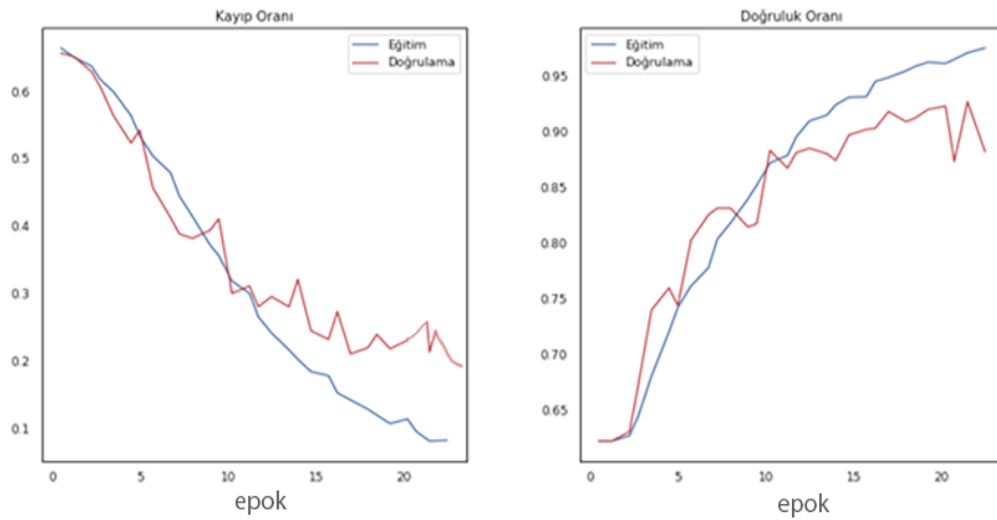
Yukarıda verilen Şekil 5.3'te görüldüğü üzere; normalize edilmiş ve normalize edilmemiş hâli ile Resnet50 mimarisinin sonuçları tartışılmaktadır. Aşağıda verilen Şekil 5.4'te ise Resnet50 modelinin eğitim ve test seti için ROC eğrisi gösterilmektedir.



Şekil 5.4: Resnet50 ağı ROC eğrisi sonuçları

Şekil 5.4'te de görüldüğü üzere; Resnet50 modelinin performans için gösterilen ROC eğrisinde AUC'si 0,97 olarak ölçülmüştür. Bu durum, Resnet50 mimarisinde modelin başarılı olduğu anlamına gelmektedir. Yapılan deneyler sonucunda ortaya çıkan tek problem,

doğrulama sonucunun istenilen düzeye ulaşamamış olmasıdır. Şekil 5.5'te Resnet50 doğruluk ve kayıp oranları gösterilmektedir.




Şekil 5.5: Resnet50 doğruluk ve kayıp oranları

Şekil 5.5'te de görüldüğü üzere Resnet50 mimarisi için kayıp oranı düşmüş, doğruluk oranı ise artmıştır.

5.1.2 VGG19 Ağı

VGG19 modelinde veri eğitimi için VGG19 kullanılmıştır. X-Ray görüntüleri eğitim ve test için iki sete ayrılmıştır. Bir CNN mimarisi olan VGG19'un 16 katmanı bulunmaktadır [39]. Katmanlar; evrişimli katmanlar, maksimum havuzlama katmanları, aktivasyon katmanları ve FC'lerden oluşmaktadır. VGG19'un; 13 evrişimli, 5 maksimum havuzlama ve 3 yoğun katman olmak üzere toplam 21 katmandan oluşmasına rağmen sadece 16 ağırlık katmanı vardır. Evrişim 1'de 64 filtre bulunurken evrişim 2'de 128, evrişim 3'te 256, evrişim 4 ve 5'te ise 512 filtre bulunmaktadır. Şekil 5.6'da uygulanan VGG19 şeması gösterilmektedir.



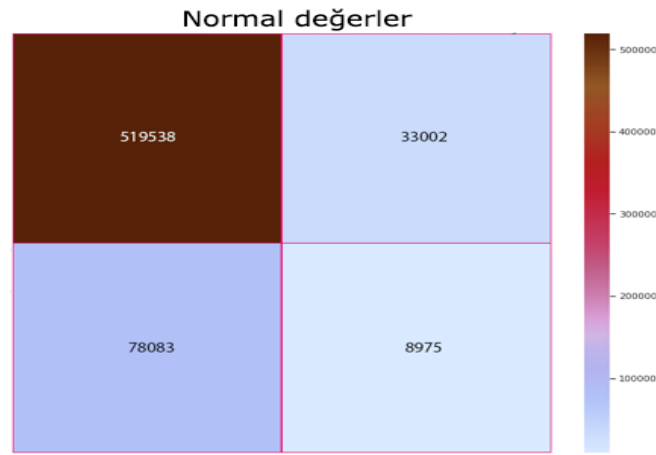
Şekil 5.6: Uygulanan VGG19 şeması gösterimi

Yukarıda verilen Şekil 5.6'da görüldüğü üzere; VGG19 ağı performansının sonuçları ve kullanılan nicel ölçümler sunulmaktadır. Sağlıklı / iyi huylu tümör / kötü huylu tümör vakaların yanı sıra her enfeksiyon türü duyarlılık, kesinlik, doğruluk, özgünlük, hassasiyet, metrikleri ve F1 skoru verilmektedir. Aşağıda verilen Çizelge 5.2'de VGG19 ağının toplam Epok sayısı ve modelin doğruluğu gösterilmektedir.

Çizelge 5.2: VGG19 model Sonuçları


ÇAPRAZ	Doğruluk	Kesinlik	Hassasiyet	Özgünlük	Duyarlılık	F1-skor
Fold 1	0.813	0.712	0.869	0.705	0.823	0.893
Fold 2	0.842	0.812	0.857	0.845	0.883	0.842
Fold 3	0.911	0.822	0.870	0.802	0.835	0.869
Fold 4	0.824	0.897	0.869	0.825	0.925	0.874
Fold 5	0.819	0.842	0.857	0.714	0.709	0.901
Fold 6	0.917	0.914	0.889	0.871	0.915	0.896
Fold 7	0.815	0.832	0.841	0.818	0.675	0.886
Fold 8	0.913	0.877	0.899	0.877	0.682	0.843
Fold 9	0.881	0.812	0.857	0.781	0.899	0.895
Fold 10	0.899	0.799	0.869	0.761	0.859	0.884

Çizelge 5.2’de görüldüğü üzere; doğruluk oranında %91,7 gibi bir değerle başarıya ulaşmıştır. Şekil 5.7’de VGG19 hata matrisi gösterilmedi.



Şekil 5.7: VGG19 hata matrisi gösterimi

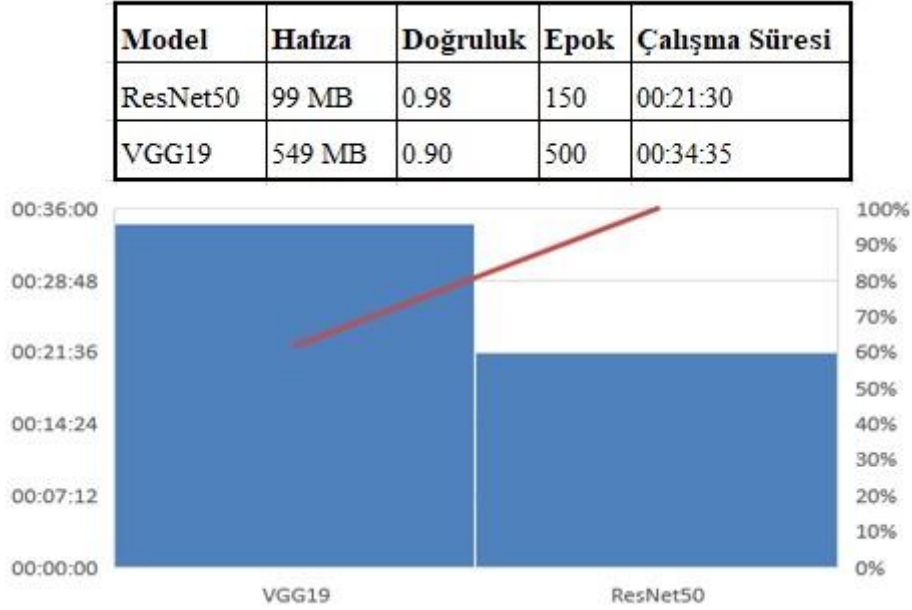
Şekil 5.7’de de görüldüğü üzere, VGG19 modeli için hata matrisinde gerçek değerler ve tahmin edilen değerler tartışılmaktadır. Hata matrisi normalize edilmiş ve edilmemiş durumlar açısından ele alınmıştır. Aşağıda verilen Şekil 5.8’de VGG19 hata matrisi gösterilmektedir.



Şekil 5.8: VGG19 ROC sonuç gösterimi

Şekil 5.8’de görüldüğü üzere; ROC için en iyi AUC değeri 0,87 olarak hesaplanmıştır. VGG19 performansında ise yanlış teşhis oranı düşük olmakla birlikte yanlış pozitif oranı ve

yanlış negatif oranı yüksek bir şekilde görülmektedir. Şekil 5.9'da VGG19 ile Resnet50'in çalışma ve başarı grafiği gösterilmektedir.




Şekil 5.9: GG19 ile Resnet50 çalışma ve başarı grafiği

Yukarıda verilen Şekil 5.9'da da görüldüğü üzere; VGG19 modeline kıyasla hem başarı hem de çalışma süresi açısından Resnet50 modeli daha iyi bir performans sergilemiştir.

ResNet50 ve VGG19 Performans Karşılaştırması

Model karşılaştırma sonuçları, ResNet50'nin VGG19'dan daha iyi performans gösterdiğini ve meme kanseri modelinin daha yüksek bir puan elde etmesini sağladığını göstermektedir. Ayrıca sonuçlar ResNet50'nin modelin VGG19 daha başarılı olduğu ortaya koymaktadır. Bunun başlıca nedeni VGG19'da 19 katman varken, ResNet50'de 50 katman ve derin filtreler bulunmaktadır. Çalışmada açık kaynaklı yüksek çözünürlüklü normal meme röntgeni görüntülerinden pnömoni görüntülerini ayırt etmek için önceden eğitilmiş modeller olan VGG19 ve ResNet50 kullanarak deneyler yapılmıştır. Standart bir teknik olarak, görüntü daha küçük boyutlara indirgenmiş ve daha sonra sınıflandırma için ESA'ya aktarılmıştır. Modelin doğruluğu, önceden eğitilmiş modelleri kullanmanın etkinliği nedeniyle diğer geleneksel yaklaşımlarla karşılaştırıldığında daha yüksek çıkmaktadır. Şekil 5.9'da görüldüğü gibi ResNet50 derin filtreleri sayesinde hem yüksek başarı göstermiş hem de çok kısa zamanda işlemi gerçekleştirmiştir.

Ayrıca çalışmada iki deney analizinden oluşmuştur. Yapılan deneyde VGG19 mimarileri özellik seçim yöntemleri kullanılmadan MÖ ile sınıflandırılmıştır. Analiz sonuçları Çizelge 5.1 ve 5.2’de gösterilmiştir. Analiz sonuçlarında en iyi sınıflandırma doğruluğu Resnet50 mimarisiyle sağlanmıştır (Bkz: Çizelge 5.1). Elde edilen sınıflandırma başarısı %98,80’dir. CNN mimarilerinin öğrenim başarı ve çalışma süreleri ise Şekil 5.10’da gösterilmiştir. Şekil 5.10’da meme görüntülerinin yüksek ve düşük risk görüntüleri verilmiştir



Şekil 5.10: a) iyi huylu görüntü ve b) kötü huylu görüntü gösterimi

Şekil 5.10’da farklı meme yoğunluğu ve Hibrit DÖ riski kombinasyonlarına sahip muayeneler için bir karışıklık matrisi hesaplanmıştır. Test setindeki her muayene, meme yoğunluğuna (sıra) ve Hibrit DÖ riskine (sütun) göre bir hücreye yerleştirilmiştir. Satırlar, yoğun olmayan memelere ve sütunlar ise Hibrit DÖ tarafından sıralanan en düşük ve en yüksek %50 risk muayenelerine karşılık gelmektedir. Her hücrede, 5 yıl içinde kanser geliştiren incelemelerin oranı bildirilmiştir. Sıraların düşük, orta ve yüksek riskli üçlüleri temsil ettiği ve sütunların Hibrit DÖ ile düşük, orta ve yüksek riskli üçlüleri temsil ettiği karşılaştırma için benzer bir analiz tekrarlanmıştır. Son olarak, karışıklık matrislerindeki her hücrenin örnek bir mamografisi sunulmaktadır.

Tarihsel olarak, doku biyobelirteçleri için bilgisayar destekli tanı kullanmanın yararı, klinik olarak ilgili alanlarını otomatik olarak tanımak için görüntü analizinin eksiklikleri nedeniyle zayıflamıştır. Giderek artan sayıdaki metodolojik çalışma, derin öğrenmenin karmaşık örüntü

tanıma görevlerini başarma yeteneğinin yeni nesil bilgisayar destekli teşhis araçlarına yol açabileceğini öne sürmektedir. Bununla birlikte, derin öğrenme algoritmalarının onkolojide klinik karar vermeye yardımcı olabileceğine dair bir kanıt yoktur. Bu çalışma, meme dokusu örneklerinin derin öğrenmeye dayalı analizinin bir doku biyobelirteçlerinin otomatik ve doğru bir şekilde puanlanmasını sağladığına dair bir kavram kanıtı oluşturmaktadır. Ayrıca, bilgisayar destekli tanının, tanısal olarak net olmayan ve yanlış tanı riski taşıyan zorlu vakalardan ayırt edilmesinde araçsal olabileceğini öne sürmektedir.

Otomatik tümör biyobelirteç puanlaması ilk olarak CNN genellikle göğüs tümörü örneklerinde bulunan çeşitli hücre fenotiplerini tanıma yeteneği değerlendirilerek ele alınmıştır. CNN, iki son teknoloji klasik makine öğrenimi algoritmalarına kıyasla önemli ölçüde daha yüksek doğruluk elde etmiştir. CNN örüntü tanıma doğruluğu, genellikle eğitim verilerinden soyut temsilleri öğrenme kapasiteleriyle açıklanır. Göğüs kanseri hücrelerinin pleomorfisi³⁹ nedeniyle CNN, her bir belirli fenotip içindeki hücre çeşitliliğine karşı sağlam olan ayırmacı özellikleri ortaya çıkarmak için özellikle yararlıdır. Ancak dikkate değer bir istisna, yalnızca membran boyama yoğunluğuna göre ayırt edilebilen 2+ tümör hücresi ve 3+ tümör hücresi ile ortaya çıkar. CNN, bu iki fenotip için klasik makine öğrenimi yaklaşımlarından daha iyi performans göstermemiştir. Çünkü klasik makine öğrenimi, bir özellik olarak zar boyama yoğunluğunun açık kullanımından yararlanabilir. Bu nedenle, MIAS puanlaması için CNN performansını güçlendirmeye yönelik bir yaklaşım, ConvNet model yerleştirme sırasında eğitilebilir özelliklere ek olarak membran boyama yoğunluğunu açıkça tanıtmak olabilir. Bu çalışmanın bir uzantısı, eğitim setinin CNN performansı üzerindeki etkisini değerlendirmek olacaktır. Özellikle, eğitim seti boyutunun etkisi ve eğitim setine açıklama ekleyen operatörün deneyim derinliğinin CNN performansı üzerindeki etkisi burada değerlendirilmemiştir ve hücre sınıflandırmasının doğruluğunu optimize etmek için değerli bilgiler sağlayabilir.

Otomatik puanlama ile burada bildirilen ilk patolog puanlaması arasındaki anlaşma düzeyi, eğitim gerçekleştirildikten sonra önerilen yaklaşımın tam otomatik bir şekilde geçerli MIAS puanları üretebileceğini göstermektedir. Özellikle bu çalışma, çeşitli laboratuvarlardan çıkan numunelere genellenebilirliği araştırmamıştır. Otomatik teşhis sistemlerinin kullanımı nedeniyle BDS teknikleri giderek daha standart hâle gelmesine rağmen, analitik öncesi faktörler (doku toplama ve işleme) nedeniyle laboratuvarlar arasında boyama yoğunluğunda farklılıklar ortaya çıkabilir. Ek olarak, slayt tarayıcı satıcıları ve slayt tarayıcı kalibrasyonu arasındaki farklılıklar, görüntü yoğunluğu seviyelerini etkileyebilir. Bu nedenle, farklı

laboratuvarlardan oluşturulan slayt görüntülerini puanlamak için bir laboratuvarında eğitilmiş bir CNN modelinin uygulanıp uygulanmayacağı ve hangi koşullar altında uygulanabileceği veya eğitim ve doğrulamanın her laboratuvarında ayrı ayrı yapılması gerekip gerekmediği henüz belirlenmemiştir.

6. TARTIŞMA

Meme kanseri, kadınlar arasında en yaygın görülen kanser türüdür ve dünya çapında yaşam alan bir hastalıktır. Histopatolojik görüntüleme, patologların doku hücrelerini farklı mikroskopik standartlar altında inceledikleri ancak nihai karar üzerinde anlayamadıkları kanser teşhisi yöntemlerinden biridir. Bu yorucu bir iştir ve bu nedenle denetimli sınıflandırma için Derin Öğrenme kullanılmaktadır.

MIAS veri seti için değerlendirme süreci, 10 kat çapraz doğrulama kullanılarak gerçekleştirilmektedir. Her katlama için kalan örnekler, rastgele bir şekilde eğitim (%80) ve doğrulama (%20) kümelerine bölünür. Bu veri kümesi için sağlanan sonuçlar, on çalışmanın ortalaması olarak hesaplanır. MIAS veri kümesi için rastgele yeni bir eğitim kümesine ve bir doğrulama kümesine bölünen orijinal eğitim bölümlenmesi kullanılmıştır.

Mamogramlardan IA'ların çıkarılması, tüm lezyonlar için kitle etrafında ortalanmış sabit boyutta (1024x1024) bir pencere kırılarak gerçekleştirilmiştir. Görüntü boyutu, veri setindeki tüm kütleler için yeterli olacak şekilde seçilmiştir. Bu şekilde, daha büyük ölçeklerde öğrenme özellikleri için yeterli bitişik doku dâhil edilirken yeniden boyutlandırma kaynaklı bozulma önlenmektedir.

Veri büyütme, CNN eğitim sürecinin önemli bir parçasıdır. Veri büyütme sayesinde, mevcut görüntüler dönüştürülerek yapay eğitim örnekleri oluşturulmaktadır. Eğitimde kullanılan dönüşümler döndürme ve çevirmedir. Bu şekilde, öğrenilen özellikler için rotasyon değişmezliğini ifade eden anlamlı örnekler üretilmektedir. Veri büyütme işlemi çevrim içi olarak gerçekleştirilmekte, yani her eğitim örneği için rastgele döndürme ve çevirme uygulanmaktadır.

Her iki veri setinde transfer öğrenme ince ayar kullanılarak maksimum performans elde edilmiştir. Bu, ILSVCR yarışmasında da bildirilen sonuçlarla örtüşmektedir. Bunun olası bir nedeni, incelenen diğer ağlardan daha derin bir büyüklük sırası olduğu için ResNet'in artan karmaşıklığıdır. CNN derinleştikçe, yani daha fazla sayıda katmanla birlikte, doğrusal olmayanların sayısı da artar. Sıfırdan eğitim durumunda, test edilen daha basit ve sığ ağ olan VGG19 ile maksimum performans elde edilir. Bu, tıbbi uygulamalar ve özellikle mamografi için mevcut olanlar gibi sınırlı sayıda örnek içeren veri kümeleri söz konusu olduğunda, daha büyük ve karmaşık ağların etkili eğitiminin sağlanamayacağı hipotezini doğrular. Hemen

hemen bütün metotlar benzer sonuçlar göstermiştir. ResNet diğer metotlara kıyasen biraz daha başarı oranı yüksek çıkmıştır.

Çizelge 6.1 meme kanseri teşhisi için kullanılan metotların performansını göstermektedir. En iyi performans gösteren ağlar, AUC açısından aynı veri kümesi üzerinde değerlendirildiğinde diğer tüm çalışmalardan marjinal olarak daha yüksek performans elde eder ve bunları geride bırakmaktadır. Bununla birlikte, geliştirilen mimari özellikleri ve şekil özelliklerini çıkarmak için girdi olarak sağlanan ayrıntılı bir lezyon segmentasyonu kullanılır. Sonuç olarak, sistemin performansı büyük ölçüde sağlanan segmentasyonun kalitesine bağlıdır, bu da kullanıcıdan önemli ölçüde zaman ve çaba harcamayı gerektiren bir görev olabilir. Buna karşılık, CNN'de herhangi bir bağımlılığın olmaması, teşhisin tamamen otomatikleştirilebildiği daha somut bir uçtan uca sınıflandırma sistemi ile sonuçlanır.

Çizelge 6.1: Geliştirilen modelin literatür ile karşılaştırması

Çalışma	Metotlar	Veri Seti	Başarı Oranı
Yala, Adam, et al.(2019) [40]	Yarı otomatik segmentasyon	Meme Tomografi Merkezi	0.71
Shen et al. (2019) [41]	Resnet50	Kanser Arşivi Merkez	0.96 (180 epok)
Qi et al. (2010) [42]	Kenar tabanlı segmentasyon, Hough dönüşümü	Breast DWI	0.77
EtehadTavakol et al. (2009) [43]	Fuzzy C-means	Breast Cancer Wisconsin	0.68
Jin-Yu et al. (2010) [44]	Otsu Metodu ile Genetik Algoritma	NuCLS	0.71
Kapoor and Prasad (2014) [45]	Canny kenar dedektörü ve Hough dönüşümü kullanılarak otomatik segmentasyon	Baseline Anket yoluyla	0.91

Çizelge 6.1: Geliştirilen modelin literatür ile karşılaştırması (devam)

Çalışma	Metotlar	Veri Seti	Başarı Oranı
Suganthi et al. (2017) [46]	Anizotropik difüzyon filtreli seviye seti yöntemi	Uci breast	0.88
Golestani et al. (2019) [47]	Seviye seti yöntemi	Wisconsin Breast Cancer	0.87
Sathish et al. (2020) [48]	Yatay Projeksiyon Profilinin Uygulanması	UCI Makine Öğrenimi Deposu	0.94
Devi et al. (2020) [49]	Çatallanma noktası uydurma	Kanser arşivi Merkezi	0.89
Pramanik et al. (2020) [50]	Meme kan perfüzyonu, Uyarlanabilir üçgen histogram tabanlı eşikleme	Wisconsin Breast Cancer	0.85
Geliştirilen Model	VGG19, Resnet50	MIAS	0.988 (500 epok)

Aşağıda verilen Çizelge 6.1’de VGG19 çalışma kodları gösterilerek uygulama için kullanılan kodlar ve yapılan ince ayarlar sunulmuştur.

Çizelge 6.1: VGG19 uygulama kodlar

Çağır numpy as np
Çağır pandas as pd
Çağır matplotlib.pyplot as plt
Çağır seaborn as sns
Çağır keras
From keras.layers çağır FC, Conv2D , MaxPooling2D ,
Düzleştir, Seyreltme , BatchNormalization
From keras.preprocessing.image çağır ImageDataGenerator
From sklearn.model_selection çağır eğitim_test_split

Çizelge 6.1: VGG19 uygulama kodlar (devam)

Etiketler = ['KANSER', 'SAĞLIKLI']
Imaj_boyut = 184
Def veri_fonk(veri_dir):
Veri = []
For etiket in etiketler:
Path = os.path.join(veri_dir, etiket)
Sınıf_num = etiketler.index(etiket)
For imaj in os.listdir(path):
Try:
imaj_arr = cv2.cvtColor(imaj_arr,cv2.COLOR_GRAY2RGB)
reboyutd_arr = cv2.reboyut(imaj_arr, (imaj_boyut, imaj_boyut))
veri.append([reboyutd_arr, sınıf_num])
except Exception as e:
print(e)
return np.array(veri)
eğitim = veri_fonk('meme_xray/eğitim')
test = veri_fonk('meme_xray/test')
val = veri_fonk('meme_xray/val')
eğitimetiket = []
for imaj in eğitim:
if(imaj[1] == 0):
eğitimetiket.append("KANSER")
else:
eğitimetiket.append("SAĞLIKLI")

Çizelge 6.1: VGG19 uygulama kodlar (devam)

<code>sns.countplot(eğitimetiket)</code>
<code>plt.figure(figsize = (5,5))</code>
<code>plt.imshow(eğitim[0][0], cmap='gray')</code>
<code>plt.title(etiketler[eğitim[0][1]])</code>
<code>plt.figure(figsize = (5,5))</code>
<code>plt.imshow(eğitim[-1][0], cmap='gray')</code>
<code>plt.title(etiketler[eğitim[-1][1]])</code>
<code>x_eğitim = []</code>
<code>y_eğitim = []</code>
<code>x_val = []</code>
<code>y_val = []</code>
<code>x_test = []</code>
<code>y_test = []</code>
<code>for ozellik, etiket in eğitim:</code>
<code> x_eğitim.append(ozellik)</code>
<code> y_eğitim.append(etiket)</code>
<code>for ozellik, etiket in test:</code>
<code> x_test.append(ozellik)</code>
<code> y_test.append(etiket)</code>
<code>for ozellik, etiket in val:</code>
<code> x_val.append(ozellik)</code>
<code> y_val.append(etiket)</code>
<code>x_eğitim = np.array(x_eğitim)/255.0</code>
<code>x_test = np.array(x_test)/255.0</code>

Çizelge 6.1: VGG19 uygulama kodlar (devam)

x_val = np.array(x_val)/255.0
x_eğitim = (x_eğitim.reshape(-1,imaj_boyut,imaj_boyut,3))
x_test = (x_test.reshape(-1,imaj_boyut,imaj_boyut,3))
x_val = (x_val.reshape(-1,imaj_boyut,imaj_boyut,3))
x_eğitim.shape
y_eğitim=np.array(y_eğitim)
y_test=np.array(y_test)
y_val=np.array(y_val)
from keras.models çağır Sequential
from keras.models çağır Model
from keras.callbacks çağır ModelCheckpoint, LearningRateScheduler, EarlyStopping, ReduceLROnPlateau, TensorBoard
from keras çağır optimizers, kayıpes, activations, models
from keras.katmans çağır Convolution2D, FC, Input, Düzleştir, Seyreltme, MaxHavuzlama2D, BatchNormalization, GlobalAverageHavuzlama2D, Concatenate
from keras çağır applications
input_shape = (184,184,3)
base_model = keras.applications.VGG19(weights='imagenet', include_top=False, input_shape=(184,184,3))
base_model.eğitimbable = False
x = base_model.output
x= Düzleştir()(x)

Çizelge 6.1: VGG19 uygulama kodlar (devam)

x = FC(4096, activation='relu')(x)
x= BatchNormalization()(x)
x=Seyreltme(0.5)(x)
x= FC(4096,activation='relu')(x)
x= BatchNormalization()(x)
x=Seyreltme(0.5)(x)
tahmin = FC(2, activation='softmax')(x)
for katman in base_model.katmans:
katman.eğitilebilir = False
model=Sequential()
model = Model(inputs=base_model.input, outputs=tahmin)
model.compile(kayıp='sparse_categorical_crossentropy',
optimizer=optimizers.SGD(lr=1e-3, momentum=0.9),
metrics=[Doğruluk])
model.summary()
verigen= ImageVeriGenerator(zoom_range=0.2)
verigen.fit(x_ēğitim)
from keras.callbacks çağır ModelCheckpoint, EarlyStopping
history = model.fit(verigen.flow(x_ēğitim,y_ēğitim,
batch_boyut = 32) ,epochs = 5 , validation_veri = verigen.flow(x_test, y_test))
for i, katman in enumerate(base_model.katmans):
print(i, katman.name)
for katman in model.katmans[:12]:
katman.eğitilebilir = False

Çizelge 6.1: VGG19 uygulama kodlar (devam)

for katman in model.katmans[12:]:
katman.eğitilebilir = True
model.compile(kayıp='sparse_categorical_crossentropy', optimizer=optimizers.SGD(lr=1e-3, momentum=0.9),metrics=[Doğruluk])
from keras.callbacks import ModelCheckpoint, EarlyStopping
checkpoint = ModelCheckpoint("vgg19.h5", monitor='val_acc', verbose=1, save_best_only=True, save_weights_only=False, mode='auto', period=1)
early = EarlyStopping(monitor='val_acc', min_delta=0, patience=3, verbose=1, mode='auto')
history = model.fit(veri_gen.flow(x_ēğitim,y_ēğitim, batch_boyut = 32) , epochs = 8 , validation_veri = veri_gen.flow(x_test, y_test),callbacks=[checkpoint,early])
print("Kayıp of the model is - " , model.evaluate(x_test,y_test)[0])
print("Accuracy of the model is - " , model.evaluate(x_test,y_test)[1]*100 , "%")
print(history.history.keys())
"Doğruluk"
plt.plot(history.history[Doğruluk])
plt.plot(history.history['val_accuracy'])
plt.title('model accuracy')
plt.yticks(Doğruluk)
plt.xticks('epoch')
plt.legend(['ēğitim', doğrulama'], loc='upper left')
plt.show()
"Kayıp"
plt.plot(history.history['kayıp'])

Çizelge 6.1: VGG19 uygulama kodlar (devam)

<code>plt.plot(history.history['val_kayıp'])</code>
<code>plt.title('model kayıp')</code>
<code>plt.yetiket('kayıp')</code>
<code>plt.xetiket('epoch')</code>
<code>plt.legend(['eğitim', doğrulama'], loc='upper left')</code>
<code>plt.show()</code>
<code>tahmin = model.predict(x_test)</code>
<code>tahmin = tahmin[:0]</code>
<code>i=0</code>
<code>for i in range(len(tahmin)):</code>
<code>if tahmin[i]>0.65:</code>
<code> tahmin[i]=0</code>
<code>else:</code>
<code> tahmin[i]=1</code>
<code>cm = confusion_matrix(y_test,tahmin)</code>
<code>sns.heatmap(cm, annot=True)</code>
<code>Cm</code>
<code>(cm[0][0]+cm[1][1])/624</code>
<code>from sklearn.metrics çağır precision_score , recall_score</code>
<code>print(precision_score(y_test,tahmin,average=None))</code>
<code>print(recall_score(y_test,tahmin,average=None))</code>
<code>from sklearn.metrics çağır roc_curve,roc_auc_score</code>
<code>fpr , tpr , thresholds = roc_curve (y_test , tahmin)</code>

Çizelge 6.1: VGG19 uygulama kodlar (devam)

def plot_roc_curve(fpr,tpr):
plt.plot(fpr,tpr)
plt.axis([0,1,0,1])
plt.xetiket('False Positive Rate')
plt.yetiket('True Positive Rate')
plt.show()
plot_roc_curve (fpr,tpr)
auc_score=roc_auc_score(y_test , tahmin)
print(auc_score)
çağır os
çağır numpy as np
çağır pandas as pd
çağır random
from skimage.io çağır imread
çağır matplotlib.pyplot as plt
%matplotlib inline
from tensorflow.python.keras.applications çağır Resnet50
from tensorflow.python.keras.applications.Resnet50 çağır preprocess_input, decode_tahmin
from tensorflow.python.keras.models çağır Sequential
num_sınıfes = 2
resnet_weights_path ='Resnet50'

Aşağıda verilen Çizelge 6.'de Resnet50 çalışma kodlarını gösterilerek, uygulama için kullanılan kodlar ve yapılan ince ayarlar sunulmuştur.

Çizelge 6.2: Resnet50 uygulama kodları

<code>orneklem_saglikli = load_orneklem(saglikli_vaka_dir + orneklem_isim)</code>
<code>print('SAGLIKLI')</code>
<code>plt.imshow(orneklem_saglikli)</code>
<code>plt.show()</code>
<code>orneklem_isim = 'meme_kanser_1.png'</code>
<code>orneklem_kanserli = load_orneklem(kanserli_vaka_dir + orneklem_isim)</code>
<code>print(kanserli')</code>
<code>plt.imshow(orneklem_kanserli)</code>
<code>plt.show()</code>
<code>saglikli_vaka = glob(saglikli_vaka_dir+'/*.png')</code>
<code>kanserli_vaka = glob(kanserli_vaka_dir+'/*.png')</code>
<code>egitim_veri = []</code>
<code>for orneklem in saglikli_vaka:</code>
<code>egitim_veri.append((orneklem,0))</code>
<code>for orneklem in kanserli_vaka:</code>
<code>egitim_veri.append((orneklem, 1))</code>
<code>egitim_veri = pd.DataFrame(egitim_veri, columns=['image', 'label'],index=None)</code>
<code>egitim_veri = egitim_veri.sample(frac=1.).reset_index(drop=True)</code>
<code>kanserli_orneklem = (egitim_veri[egitim_veri['label']==1]['image'].iloc[:5]).tolist()</code>
<code>saglikli_orneklem = (egitim_veri[egitim_veri['label']==0]['image'].iloc[:5]).tolist()</code>

Çizelge 6.2: Resnet50 uygulama kodları (devam)

<code>orneklem = kanserli_orneklem + saglikli_orneklem</code>
<code>del kanserli_orneklem, saglikli_orneklem</code>
<code>f, ax = plt.subplots(2,5, figboyut=(30,10))</code>
<code>orneklem = imread(orneklem[i])</code>
<code>ax[i//5, i%5].imshow(orneklem, cmap='gray')</code>
<code>if i<5:</code>
<code>ax[i//5, i%5].set_title("Kanserli")</code>
<code>else:</code>
<code>ax[i//5, i%5].set_title("Saglikli")</code>
<code>ax[i//5, i%5].axis('off')</code>
<code>ax[i//5, i%5].set_aspect('auto')</code>
<code>plt.show()</code>
<code>image_boyut = 150</code>
<code>nb_egitim_orneklem = 5216 # egitim seti</code>
<code>paket_boyut = 16</code>
<code>EPOCHS = 6</code>
<code>STEPS = nb_egitim_orneklem / paket_boyut</code>
<code>veri_generator_with_aug</code> <code>= ImageVeriGenerator(preprocessing_function=preprocess_input,</code>

Çizelge 6.2: Resnet50 uygulama kodları (devam)

horizontal_flip = True,
width_shift_range = 0.2,
height_shift_range = 0.2,
shear_range = 0.2,
zoom_range = 0.2
)
veri_generator_no_aug
= ImageVeriGenerator(preprocessing_function=preprocess_input
egitim_generator = veri_generator_with_aug.flow_from_directory(directory = 'chest_xray/egitim/', target_boyut = (image_boyut, image_boyut), paket_boyut = paket_boyut, sınıf_mode = 'categorical')
validation_generator = veri_generator_no_aug.flow_from_directory(directory = 'chest_xray/val/', target_boyut = (image_boyut, image_boyut), sınıf_mode = 'categorical')
test_generator = veri_generator_no_aug.flow_from_directory(directory = 'chest_xray/test/', target_boyut = (image_boyut, image_boyut),

Çizelge 6.2: Resnet50 uygulama kodları (devam)

<code>paket_boyut = paket_boyut,</code>
<code>sınıf_mode = 'categorical')</code>
<code>model.fit_generator(egitim_generator, epochs = EPOCHS, steps_per_epoch=STEPS, validation_veri=validation_generator)</code>
<code>scores = model.evaluate_generator(test_generator)</code>
<code>print("\n%s: %.2f%%" % (model.metrics_names[1], scores[1]*100))</code>
<code>from tensorflow.python.keras.models import load_model</code>
<code>model.save('xray_model.h5') plt.plot(model.history.history['acc'])</code>
<code>plt.plot(model.history.history['val_acc']) plt.title('Model Accuracy')</code>
<code>plt.ylabel('Doğruluk') plt.xlabel('Epoch')</code>
<code>plt.legend(['Egitim set', 'doğrulama set'], loc='upper left')</code>
<code>plt.plot(model.history.history['kayıp'])</code>
<code>plt.plot(model.history.history['val_kayıp'])</code>
<code>plt.title('Model Kayıp')</code>
<code>plt.ylabel('Kayıp')</code>
<code>plt.xlabel('Epoch')</code>
<code>plt.legend(['Egitim set', 'Test set'], loc='upper left')</code>

Çizelge 6.2: Resnet50 uygulama kodları (devam)

<code>plt.show()</code>
<code>def choose_image_and_predict():</code>
<code> saglikli_or_kanserli = ['SAGLIKLI', kanserli']</code>
<code> folder_choice = (random.choice(saglikli_or_kanserli))</code>
<code> kanserli_images = glob('chest_xray/val/'+folder_choice+'/*')</code>
<code> orneklem_choice = (random.choice(kanserli_images))</code>
<code> orneklem = load_orneklem(orneklem_choice, target_boyut=(150, 150))</code>
<code> orneklem = orneklem_to_array(orneklem)</code>
<code> plt.imshow(orneklem / 255.)</code>
<code> x = preprocess_input(np.expand_dims(orneklem.copy(), axis=0))</code>
<code> pred_sınıf = model.predict_sınıfes(x)</code>
<code> pred = model.predict(x)</code>
<code> print("Actual sınıf:", folder_choice)</code>
<code> if pred_sınıf[0] == 0:</code>
<code> print("Tahmin edilen sınıf: Saglikli")</code>
<code> print("Likelihood:", pred[0][0].round(4))</code>
<code> if pred[0][0].round(4) < 0.8:</code>
<code> print("UYARI, low confidence") else:</code>
<code> print("Tahmin edilen sınıf: Kanserli")</code>
<code> print('Likelihood:', pred[0][1].round(4))</code>

7. SONUÇLAR

Çalışmada, meme kanserinin sebep olduğu ölümlerin oranının azaltılabilmesi amacıyla meme kanserinin tespiti ve sınıflandırması kapsamında önerilen son modeller karşılaştırılmaktadır. Önerilen söz konusu modellere ilişkin veri kümeleri arasındaki farklar; boyut, içerdiği görünüm, görüntü formatının içerdiği sınıflar vb. birçok açıdan tartışılmıştır. Bu farkların tartışılmasının ardından yakın zamanda yayımlanan çeşitli makine öğrenimi tabanlı algılama ve sınıflandırma yöntemleri arasında genel bir karşılaştırmalı çalışma yapılmıştır.

Çalışma kapsamında, meme kanseri hastalarından alınan X-Ray görüntülerindeki metastaz bölgelerinin otomatik olarak tespit ve lokalize edilebilmesi amacıyla CNN tabanlı bir sistem geliştirilmiştir. Önerilen bu sistem, ön işleme, sınıflandırma ve son işleme şeklinde adlandırılan üç temel adımdan oluşmaktadır. Ön işleme adımında, tüm X-Ray görüntülerine ait lenf düğümü bölümleri arka plandan çıkarılarak sınıflandırma aşamasının denetimli eğitim veri seti yapımında kullanılmak üzere hazırlanmaktadır. Girdi görüntülerini sınıflandırmak için evrişimli bir sinir ağı yapısı tasarlanarak, geliştirilen ağı denetimli bir şekilde eğitmek için kullanılan bir veri seti oluşturulmuştur. Ağın tasarımı ve eğitiminden sonra, X-Ray görüntülerine ait lenf düğümü bölümlerinden çıkarılan tüm yamaların ağa beslenmesiyle sınıflandırma aşamasında sınıf etiketleri elde edilmektedir. Son aşama, karar birleştirme amacıyla kullanılan işlem sonrası aşamadır. Çalışmada, metastaz bölgesi seviyesi ve dilim seviyesi performans ölçüm değerlerinin elde edilmesi amacıyla tüm X-Ray görüntüsü üzerindeki yamaların etiket verilerinin birleştirilmesi açısından kayan pencere tabanlı bir filtreleme sistemi önerilmiştir. Önerilen bu çözümün sınıflandırma aşamasında kullanılması için çalışma kapsamında farklı ağ mimarilerinin performans analizleri incelenmiştir. Ayrıca, daha iyi performans değerleri elde etmek için ön işlem sonrası veri bütünleştirme, kenar bulma gibi farklı filtre yapıları kullanılmaktadır. Böylece çalışmada, ağ yapıları ve filtre performanslarının karşılaştırılması yapılmıştır.

Çalışmada önerilen çözümün performansı, diğer çözümlerle karşılaştırıldığında gelecekteki gelişmeler açısından oldukça umut vericidir. Önerilen çözümde, sınıflandırma aşaması CNN mimarilerine ilişkin eğitim veri seti, neredeyse eşit sayıdaki “normal” ve “tümör” numunesi ile normal ve tümör sonuçlarından oluşturulmuştur. Gelecekteki çalışmalarda daha farklı yöntemler denenebilir. Ayrıca çalışmada, yalnızca tümör bölgelerinin metastaz bölgelerinden gelen görüntü örnekleri 'tümör' numuneleri olarak kullanılmıştır. Normal tümör sınır örnekleri eğitim veri kümesine dâhil edilmemiştir. Çünkü bu, modelin veri kümesindeki sınır

örneklerinin yanlış sınıflandırılmasına neden olabilir. Diğer BDS tarafından önerilen çözümler, meme görüntülerini “tümör” örnekleri olarak içermekte ve modelin genelleme kabiliyetine katkıda bulunabileceği için mantıklı kabul edilmektedir. Dolayısıyla bu durum, gelecekteki çalışmalar açısından dikkate alınması gereken bir diğer önemli konudur.

Düşük çözünürlüklü kalite pahasına küçük boyutlu görüntülerle çalışmanın kısa eğitim ve işlem süresi avantajlarından yararlanmak için önerilen çözümün işlemleri sırasında, Katman 7 ve Katman 2 görüntüleri kullanılmıştır. Modelin eğitiminde Katman 2’den 64x64 görüntüleri kullanılmıştır. Ancak çalışmada Katman 0’dan 256x256 görüntü kullanılmıştır. Her iki seçenekte de karşılık gelen fiziksel boyutlar aynı olsa da Katman 2’deki çözünürlük kısıtlamaları nedeniyle bazı ayrıntılar kaybedilebilir. Gelecekteki çalışmalarda, Katman 0 görüntü örnekleri kullanılabilir. Ayrıca bu, modeli tek geçişte eğitmek açısından en iyi seçim olmayabilir. Bir başka deyişle başlangıçta bir eğitim veri seti oluşturularak, bu veri seti modeli eğitmek için kullanılmıştır. Bu, modelden en iyi performansı elde edebilmek açısından yeterli ve başarılı sonuçlar göstermiştir. Eğitimli modelin performansını doğrulamak için eğitim setinden bir dizi örnek ayrılmıştır (hold-out cross-validation). Bu küme sınıflandırılırken bazı örnekler yanlış sınıflandırılma olasılığını ortadan kaldırmaktadır. Bu örnekleri eğitim veri kümesine ekleyerek ve modeli yeni bir genişletilmiş veri kümesiyle daha da eğiterek modelin performansına katkıda bulunulmalıdır. Bu yaklaşım literatürde ve zorluklardaki bazı çalışmalarda da kullanılmaktadır. Örneğin maksimum olasılık teorisinden yararlanılmıştır. Bu çalışmamada ise sıfırdan eğitmek ve zaman kaybını önleyebilmek amacıyla Aslan (2020) çalışmalarından farklı olarak önceden eğitilmiş modeller kullanılmıştır. Böylece bu çalışmadaki maksimum olasılık ihtiyacı ortadan kalkmıştır.

Çizelge 5.1 ve 5.2’de elde edilen sonuçlara göre; Resnet50 mimarisinin daha yüksek doğruluk ve F1 skoru ile diğer CNN mimarilerinden daha iyi performans gösterdiği açıkça ortaya konulmaktadır. Makine öğrenme “pipeline” geliştirme sırasında kullanılan VGG19 mimarisi, diğer geleneksel modellerden daha verimli görünse de Resnet50’ye kıyasla daha başarısız bir performans sergilemiştir. Bu sonuçlar, Resnet50’nin VGG19’dan daha iyi performans gösterdiğini, MİAS veri kümesindeki sonuçlarda da ortaya koymaktadır.

Çalışmada, sınıflandırma aşaması için 2 farklı CNN modeli olan VGG19 ve ResNet50 eğitilmiştir. Filtre boyutları, evrişim katmanlarının sayısı, normalizasyon katmanlarının etkisi gibi farklı mimari elemanların etkileri analiz edilmiştir. İki evrişim katmanı kullanırken 5x5 filtrelerin 3x3 filtrelere göre daha iyi sonuçlar verdiği gözlemlenmiştir. Bunun temel nedeni,

5x5 filtrelerdeki büyük alıcı alanların, sığ olduğu söylenebilecek iki katmanlı bir yapıda daha küçük alıcı alanlı 3x3 filtrelerden daha ayırt edici özellikler yakalayabilmesidir. Ancak, 3x3 filtreler ile dört evrişim katmanı çalıştırıldığında ve giriş görüntüsü üzerinde aynı etkin alıcı alanı elde edildiğinde, sistemin performansı hemen hemen aynıdır. Ayrıca, geliştirilen model daha fazla eğitim ile öğrenebilir, bu nedenle derin mimarilerdeki 3x3 filtreler (küçük boyutlu filtreler) daha basit bir mimari ve daha doğrusal olmayan dönüşümler kullanarak daha karmaşık özellikleri yakalayabildikleri için CNN yapılarında daha iyidir. Ek olarak, evrişim katmanlarının sayısını bir noktaya kadar arttırmanın sistem performansına katkı sağlayabileceği ancak bir noktadan sonra sistemin doygunluğa ulaştığı gözlemlenmiştir. 4 ve 6 konvolüsyonel katmanlarla daha iyi sonuçlar elde edilmiş ve bu ikisinin performansının birbirlerine yakın olduğu görülmüştür. Evrişim katmanlarının sayısını 9'a çıkarmak performansı arttırmamış, aksine azaltmıştır. Bu, son üç evrişim katmanı ile birlikte gelen ek bir havuz katmanından kaynaklanabilir. Adım 2 ile bir havuzlama katmanının daha eklenmesi, tam bağlı katmana beslenen öznitelik vektör boyutunu dörde düşürmektedir. Bu nedenle bazı öznitelikler kaybedilebilir. Ek katmanlar, öznitelik vektörü boyutundaki azalmayı telafi etmek için filtre sayısını 4 kat arttırmak gibi ağı yapısında bazı ilave değişiklikler gerektirebilir.

Bu çalışma sırasında elde edilen en önemli verilerden biri, ağ ağırlıklarının başlatılmasının önemli ve kritik bir konu olduğudur. Tüm modeller aynı ağırlıklarla başlatıldığında bazı modellerin hiçbir şey öğrenmediği gözlemlenmiştir. Modellerdeki ağırlıkların veri ve yapıya bağlı olarak başlatılması, bu durumu tamamen değiştirmektedir. Model 1'den Model 5'e kadar olan modellerin ağırlıkları benzer şekilde başlatılır. Ağların veriye bağlı ağırlıklar ile başlatılmasına ilişkin bazı yeni yayınlar son zamanlarda ortaya çıkmıştır. Son olarak, önerilen çözümün sınıflandırma aşaması evrişimli bir sinir ağına dayanmaktadır. Bu nedenle gelecekte ağı hem yapısında hem de eğitiminde daha fazla gelişim sağlanabilir. Ayrıca, daha iyi füzyon sonuçları elde etmek için işlem sonrası aşamada iyileştirme ve performans da mümkündür. Bununla birlikte, iki aşamayı ayrı ayrı geliştirmekten daha umut verici olan hem sınıflandırma hem de karar birleştirmenin aynı ağ mimarisinde ele alınmasıdır. Literatürde bu tür mimarilerin örnekleri son zamanlarda ortaya çıkmıştır. Tüm bir X-Ray görüntüsü üzerinde metastaz bölgelerinin hem sınıflandırılması hem de lokalizasyonu tek bir evrişimli sinir ağında yapılabilir.

Daha sonraki aşamalarda iyileştirilmesi gereken ana çalışma alanı X-Ray için ön işlemdir. Çünkü bu genellikle global kontrast normalleştirme, lokal kontrast normalleştirme ve Otsu

eşik segmentasyonu gibi tekniklerin kullanılmasıyla önemli performans kazanımlarının sağlanabileceği bir alandır. CNN'nin ilgili olmayan kısımları, öğrenmeyi zor bir sürece sürüklemesini önlemek için röntgen ve siyah arka plan üzerindeki etiketler gibi yapay nesnelerin tümü bilgisayarla görme teknikleri kullanılarak kaldırılmalıdır. İyileştirmelerin yapılabileceği diğer bir alan, veri kümelerinde daha iyi performans elde etmek ve ezberciliği önlemek için yapılan ince ayarlamalardır. Yukarıda bahsedilen veri ön işleme ile görüntüler daha küçük olacak ve bu da daha hızlı çalıştırma sürelerine izin verecektir. Böylece daha iyi çözümler sağlayabilmek açısından daha fazla konfigürasyon kombinasyonunun keşfedilmesi için ince ayar algoritmalarına izin verilecektir.

REFERANSLAR

- [1] Puigpinós-Riera, R., Graells-Sans, A., Serral, G., Contente, X., Bargalló, X., Doménech, M., ... & Pla, M. (2018). Anxiety and depression in women with breast cancer: Social and clinical determinants and influence of the social network and social support (DAMA cohort). *Cancer epidemiology*, 55, 123-129.
- [2] Mattiuzzi, C., & Lippi, G. (2019). Current cancer epidemiology. *Journal of epidemiology and global health*, 9(4), 217-222.
- [3] Miller, K. D., Goding Sauer, A., Ortiz, A. P., Fedewa, S. A., Pinheiro, P. S., Tortolero-Luna, G., ... & Siegel, R. L. (2018). Cancer statistics for hispanics/latinos, 2018. *CA: A Cancer Journal for Clinicians*, 68(6), 425-445.
- [4] Zhao, S., Dong, H., Qin, J., Liu, H., Li, Y., Chen, Y., ... & Yang, L. (2019). Breast cancer mortality in Chinese women: does migrant status play a. *Annals of Epidemiology*, 40, 28-34.
- [5] Goldsbury, D. E., Yap, S., Weber, M. F., Veerman, L., Rankin, N., Banks, E., ... & O'Connell, D. L. (2018). Health services costs for cancer care in Australia: Estimates from the 45 and Up Study. *PloS one*, 13(7), e0201552.
- [6] Yu, C., Chen, H., Li, Y., Peng, Y., Li, J., & Yang, F. (2019). Breast cancer classification in pathological images based on hybrid features. *Multimedia Tools and Applications*, 78(15), 21325-21345.
- [7] Kareem, Zeinab Shaban Ali, Ekbal Abdel reheem Emam, and Hoda Abd-Elazim Mohamed. "Effectiveness of Teaching Program on Knowledge Regarding the Breast Feeding Problems among Postnatal Mothers."
- [8] Araújo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., ... & Campilho, A. (2017). Classification of breast cancer histology images using convolutional neural networks. *PloS one*, 12(6), e0177544.
- [9] Pavithra, M., Rajmohan, R., Kumar, T. A., & Ramya, R. (2021). Prediction and Classification of Breast Cancer Using Discriminative Learning Models and Techniques. *Machine Vision Inspection Systems, Volume 2: Machine Learning- Based Approaches*, 241-262.
- [10] Zhou, Y., Chen, H., Li, Y., Liu, Q., Xu, X., Wang, S., ... & Shen, D. (2021). Multi-task learning for segmentation and classification of tumors in 3D automated breast ultrasound images. *Medical Image Analysis*, 70, 101918.

- [11] Hai, J., Qiao, K., Chen, J., Tan, H., Xu, J., Zeng, L., ... & Yan, B. (2019). Fully convolutional densenet with multiscale context for automated breast tumor segmentation. *Journal of healthcare engineering*, 2019.
- [12] Hamidinekoo, A., Denton, E., Rampun, A., Honnor, K., & Zwiggelaar, R. (2018). Deep learning in mammography and breast histology, an overview and future trends. *Medical image analysis*, 47, 45-67.
- [13] Zadeh, H. G., Fayazi, A., Binazir, B., & Yargholi, M. (2020). Breast Cancer Diagnosis Based on Feature Extraction Using Dynamic Models of Thermal Imaging and Deep Autoencoder Neural Networks. *Journal of Testing and Evaluation*, 49(3).
- [14] George, M. J., & Sankar, S. P. (2017, December). Efficient preprocessing filters and mass segmentation techniques for mammogram images. In *2017 IEEE International Conference on Circuits and Systems (ICCS)* (pp. 408-413). IEEE.
- [15] Kaur, N., & Sharma, A. S. (2018, September). Detection of Breast Cancer on Mammograms using Neural Network Approach. In *2018 International Conference on Computing, Power and Communication Technologies (GUCON)* (pp. 544-547). IEEE.
- [16] Mejbri, S., Franchet, C., Reshma, I. A., Mothe, J., Brousset, P., & Faure, E. (2019, February). Deep analysis of CNN settings for new cancer whole-slide histological images segmentation: the case of small training sets. In *6th International conference on BioImaging (BIOIMAGING 2019)* (pp. 120-128).
- [17] Grinet, M. A., Garcia, N. M., Gouveia, A. I., Moutinho, J. A., & Gomes, A. J. (2020). Reduction of Surgical Risk Through the Evaluation of Medical Imaging Diagnostics. *arXiv preprint arXiv:2003.08748*.
- [18] Hussain, L., Almarashi, M. S., Aziz, W., Habib, N., & Saif Abbasi, S. U. R. (2021). Machine learning-based lungs cancer detection using reconstruction independent component analysis and sparse filter features. *Waves in Random and Complex Media*, 1-26.
- [19] El Bakrawy, L. M., Cifci, M. A., Kausar, S., Hussain, S., Islam, M. A., Alatas, B., & Desuky, A. S. (2022). A Modified Ant Lion Optimization Method and Its Application for Instance Reduction Problem in Balanced and Imbalanced Data. *Axioms* 2022, 11, 95.
- [20] Pardamean, B., Cenggoro, T. W., Rahutomo, R., Budiarto, A., & Karuppiyah, E. K. (2018). Transfer learning from chest X-ray pre-trained convolutional neural network for learning mammogram veri. *Procedia Computer Science*, 135, 400-407.
- [21] Cong, W., Shan, H., Zhang, X., Liu, S., Ning, R., & Wang, G. (2019, September). Deep-learning-based breast CT for radiation dose reduction. In *Developments in x-ray tomography XII* (Vol. 11113, p. 111131L). International Society for Optics and Photonics.

- [22] Abidin, A. Z., Deng, B., DSouza, A. M., Nagarajan, M. B., Coan, P., & Wismüller, A. (2018). Deep transfer learning for characterizing chondrocyte patterns in phase contrast X-Ray computed tomography images of the human patellar cartilage. *Computers in biology and medicine*, 95, 24-33.
- [23] Cifci, M. A., & Aslan, Z. (2020, July). Deep Learning Algorithms for Diagnosis of Breast Cancer with Maximum Likelihood Estimation. In *International Conference on Computational Science and Its Applications* (pp. 486-502). Springer, Cham.
- [24] Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156(3), 312-322.
- [25] Desuky, A. S., Akif, M., Kausar, S., Hussain, S., & El Bakrawy, L. M. (2022). Mud Ring Algorithm: A new meta-heuristic optimization algorithm for solving mathematical and engineering challenges. *IEEE Access*.
- [26] Alirezazadeh, P., Hejrati, B., Monsef-Esfahani, A., & Fathi, A. (2018). Representation learning-based unsupervised domain adaptation for classification of breast cancer histopathology images. *Biocybernetics and Biomedical Engineering*, 38(3), 671-683.
- [27] Parashar, J., & Rai, M. (2020). Breast cancer images classification by clustering of ROI and mapping of features by CNN with XGBOOST learning. *Materials Today: Proceedings*.
- [28] Cifci, M. A. SegChaNet: A Novel Model for Lung Cancer Segmentation in CT scans. *Applied Bionics and Biomechanics*, 2022.
- [29] Kumar, R., Wang, W., Kumar, J., Yang, T., Khan, A., Ali, W., & Ali, I. (2020). An Integration of Blockchain and AI for Secure Data Sharing and Detection of CT images for the Hospitals. *Computerized Medical Imaging and Graphics*, 101812.
- [30] Cifci, M. A. (2020). Deep learning model for diagnosis of corona virus disease from CT images. *Int. J. Sci. Eng. Res*, 11(4), 273-278.
- [31] Chougrad, H., Zouaki, H., & Alheyane, O. (2020). Multi-label transfer learning for the early diagnosis of breast cancer. *Neurocomputing*, 392, 168-180.
- [32] Horwath, J. P., Zakharov, D. N., Mégret, R., & Stach, E. A. (2020). Understanding important features of deep learning models for segmentation of high-resolution transmission electron microscopy images. *npj Computational Materials*, 6(1), 1-9.
- [33] Alzubaidi, L., Fadhel, M. A., Al-Shamma, O., Zhang, J., Santamaría, J., Duan, Y., & Oleiwi, S. R. (2020). Towards a better understanding of transfer learning for medical imaging: a case study. *Applied Sciences*, 10(13), 4523.
- [34] Jaworek-Korjakowska, J., Kleczek, P., & Gorgon, M. (2019). Melanoma Thickness Prediction Based on Convolutional Neural Network with VGG-19 Model Transfer Learning.

In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 0-0).

[35] Wang, F., Jiang, M., Qian, C., Yang, S., Li, C., Zhang, H., ... & Tang, X. (2017). Residual attention network for image classification. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3156-3164).

[36] Cao, X., Chen, H., Li, Y., Peng, Y., Wang, S., & Cheng, L. (2020). Uncertainty Aware Temporal-Ensembling Model for Semi-supervised ABUS Mass Segmentation. *IEEE Transactions on Medical Imaging*.

[37] Zhang, D. (2020). Deep Reinforcement Learning in Medical Object Detection and Segmentation.

[38] Li, W. J., Hsu, M. C., & Huang, S. M. (2020). Machine learning on the electron–boson mechanism in superconductors. *New Journal of Physics*, 22(12), 123014.

[39] Kingston, A. M., Fullagar, W. K., Myers, G. R., Adams, D., Pelliccia, D., & Paganin, D. M. (2021). Inherent dose-reduction potential of classical ghost imaging. *Physical Review A*, 103(3), 033503.

[40] A deep learning mammography-based model for improved breast cancer risk prediction." *Radiology* 292.1 (2019): 60-66. N. Scales, C. Kerry, and M. Prize, "Automated image segmentation for breast analysis using infrared images," in Proc. 26th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc., Sep. 2004, pp. 1737_1740.

[41] P. T. Kuruganti and T. Phani, "Detecting breast cancer from thermal infrared images by asymmetry analysis," *Med. Med. Res.*, Feb. 2003. M. EtehadTavakol, S. Sadri, and E. Y. K. Ng, "Application of K- and fuzzy C-means for color segmentation of thermal infrared breast images," *J. Med. Syst.*, vol. 34, no. 1, pp. 35_42, Feb. 2010.

[42] Z. Jin-Yu, C. Yan, and H. Xian-Xiang, "IR thermal image segmentation based on enhanced genetic algorithms and two-dimensional classes square error," in Proc. 2nd Int. Conf. Inf. Comput. Sci., vol. 2, 2009, pp. 309_312.

[43] P. Kapoor and S. V. A. V. Prasad, "Image processing for early diagnosis of breast cancer using infrared images," in Proc. 2nd Int. Conf. Comput. Automat. Eng. (ICCAE), Feb. 2010, pp. 564_566.

[44] S. S. Suganthi and S. Ramakrishnan, "Anisotropic diffusion _lter based edge enhancement for segmentation of breast thermogram using level sets," *Biomed. Signal Process. Control*, vol. 10, pp. 128_136, Mar. 2014. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1746809414000093>

- [45] D. Sathish, S. Kamath, K. Prasad, R. Kadavigere, and R. J. Martis, "Asymmetry analysis of breast thermograms using automated segmentation and texture features," *Signal, Image Video Process.*, vol. 11, no. 4, pp. 745_752, May 2017.
- [46] R. R. Devi and G. S. Anandhamala, "Analysis of breast thermograms using asymmetry in infra-mammary curves," *J. Med. Syst.*, vol. 43, no. 6, p. 146, Apr. 2019.
- [47] S. Pramanik, D. Bhattacharjee, and M. Nasipuri, "MSPSF: A multiscale local intensity measurement function for segmentation of breast thermogram," *IEEE Trans. Instrum. Meas.*, vol. 69, no. 6, pp. 2722_2733, Jun. 2020.
- [48] A. S. Koshki, M. Zekri, M. R. Ahmadzadeh, S. Sadri, and E. Mahmoudzadeh, "Extending contour level set model for multiclass image segmentation with application to breast thermography images," *Infr. Phys. Technol.*, vol. 105, Mar. 2020, Art. no. 103174.
- [49] Yala, A., Lehman, C., Schuster, T., Portnoi, T., & Barzilay, R. (2019). A deep learning mammography-based model for improved breast cancer risk prediction. *Radiology*, 292(1), 60-66.
- [50] Yala, A., Schuster, T., Miles, R., Barzilay, R., & Lehman, C. (2019). A deep learning model to triage screening mammograms: a simulation study. *Radiology*, 293(1), 38-46.