



T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü



# MAMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME İLE BI-RADS SINIFLANDIRMASI

Yüksek Lisans Tezi

Başak KATUK

Bilgisayar Mühendisliği Anabilim Dalı

İzmir  
2022

T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü

# MAMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME İLE BI-RADS SINIFLANDIRMASI

Başak KATUK

Danışman : Doç. Dr. Rıza Cenk ERDUR

Bilgisayar Mühendisliği Anabilim Dalı  
Bilgisayar Mühendisliği Yüksek Lisans Programı

İzmir  
2022

Başak KATUK tarafından Yüksek Lisans tezi olarak sunulan “Mamografi Görüntüleri Üzerinde Derin Öğrenme ile BI-RADS Sınıflandırması” başlıklı bu çalışma EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliği ile EÜ Fen Bilimleri Enstitüsü Eğitim ve Öğretim Yönergesi'nin ilgili hükümleri uyarınca tarafımızdan değerlendirilerek savunmaya değer bulunmuş ve .....tarhinde yapılan tez savunma sınavında aday oybirliđi/oyçokluđu ile başarılı bulunmuştur.

**Jüri Üyeleri:**

**İmza**

**Jüri Başkanı :**

**Raportör Üye:**

**Üye :**



# EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

## ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “Mamografi Görüntüleri Üzerinde Derin Öğrenme ile BI-RADS Sınıflandırması” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

... / ... / 2022

İmzası

Başak KATUK



**ÖZET****MAMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDE  
DERİN ÖĞRENME İLE BI-RADS SINIFLANDIRMASI**

KATUK, Başak

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Rıza Cenk ERDUR

Ağustos 2022, 46 sayfa

Meme kanseri kadınlarda kanserden ölümlerin ikinci en sık nedenidir. Bu kadar yaygın görülen bir hastalığın tedavi edilebilir bir dönemde saptanması oldukça önemlidir. Günümüzde siber güvenlik, dil çevirileri ve sağlık hizmetleri gibi birçok uygulama alanında yapay zeka yöntemleri kullanılmaktadır. Bu uygulamalara mamografi görüntüleri üzerinde kanser tespiti, risk seviyesi tespiti ve kuşkulu bölgelerin bulunması gibi konularda geliştirilen yapay zeka modelleri dahildir.

Amerikan Radyoloji Koleji tarafından geliştirilen BI-RADS sistemi mamografi görüntülerinde kanser seviyesinin belirlenmesinde radyologlar tarafından bir standart olarak kullanılmaktadır. 6 adet seviye içeren BI-RADS seviyelerinden 3. ve 4. seviyeler, sırasıyla iyi huylu ve kötü huylu meme kanseri ihtimali olan hastaları temsil etmektedir. Literatürde BI-RADS 3 ve BI-RADS 4 olarak etiketlenen görüntülerin sınıflandırılmasında bir belirsizlik bulunmaktadır. Bu tezde CBIS-DDSM adlı açık veri setinde bulunan mamografi çekimleri kullanılarak görüntüleri BI-RADS 3 ve BI-RADS 4 sınıflarından birine sınıflandıran bir yapay zeka modeli geliştirilmiştir. Bu amaçla evrişimli sinir ağları ile bir sınıflandırma modeli eğitilip, veri artırımı ve transfer öğrenme yöntemleri ile başarılı bir derin öğrenme modeli geliştirilmesi amaçlanmıştır.

**Anahtar sözcükler:** Derin öğrenme, sınıflandırma, transfer öğrenme, evrişimli sinir ağları, mamografi

**ABSTRACT**

**BI-RADS CLASSIFICATION ON  
MAMMOGRAPHY IMAGES USING DEEP LEARNING**

KATUK, Başak

MSc in Computer Eng.

Supervisor: Assoc. Prof. Dr. Rıza Cenk ERDUR

August 2022, 46 pages

Breast cancer is the second most common cause of cancer death in women. It is very important to detect such a common disease in a treatable period. Today, artificial intelligence methods are used in many application areas such as cyber security, language translations and health services. These applications include artificial intelligence models developed on subjects such as cancer detection, risk level detection and finding suspicious areas on mammography images.

The BI-RADS system, developed by the American College of Radiology, is used as a standard by radiologists in determining the level of cancer in mammography images. Levels 3 and 4 of the 6 levels of BI-RADS represent patients with a probability of benign and malignant breast cancer, respectively. There is an uncertainty in the classification of images labeled as BI-RADS 3 and BI-RADS 4 in the literature. In this thesis, an artificial intelligence model has been developed that classifies images into one of BI-RADS 3 and BI-RADS 4 classes by using mammography images in the CBIS-DDSM open dataset. For this purpose, it is aimed to train a classification model with convolutional neural networks and develop a successful deep learning model with data augmentation and transfer learning methods.

**Keywords:** Deep learning, classification, transfer learning, convolutional neural networks, mammography



## ÖNSÖZ

Danışman Hocam Doç. Dr. Cenk Erdur'un yönlendirmesiyle, yapay zeka yöntemlerinin sağlık sektöründe çeşitli uygulamalarını araştırma ve öğrenme fırsatı elde ettim. Yapmış olduğum literatür taraması sonucunda radyoloji alanında mamografi görüntüleri kullanılarak geliştirilen birçok yapay zeka uygulaması olduğunu fakat tez konuma ait çok az çalışma bulunduğunu fark ettim. Ayrıca, tezimle ilgili yapmış olduğum tüm ön işleme ve derin öğrenme çalışmalarında yeni bilgiler ve yetenekler öğrenme fırsatı elde ettim. Tüm bu süreçte yanımda olan başta danışmanım Doç. Dr. Cenk Erdur olmak üzere, öğrenim hayatımın ilk gününden bugüne kadar maddi-manevi desteklerini esirgemeyen aileme teşekkürlerimi ve şükranlarımı sunarım.

İZMİR

... / ... / 2022

Başak KATUK



**İÇİNDEKİLER**

	<u>Sayfa</u>
İÇ KAPAK .....	ii
KABUL ONAY SAYFASI .....	iii
ETİK KURALLARA UYGUNLUK BEYANI .....	iv
ÖZET .....	i
ABSTRACT .....	ii
ÖNSÖZ .....	iv
İÇİNDEKİLER DİZİNİ .....	vi
ŞEKİLLER DİZİNİ .....	ix
TABLolar DİZİNİ .....	xii
KISALTMALAR DİZİNİ .....	xiv
1.GİRİŞ .....	1
2.GENEL BİLGİLER .....	10
2.1 Derin Öğrenme Kütüphaneleri ve Araçları .....	10
2.2 Açık Mamografi Veri Setleri .....	10
2.3 Mamografi Görüntülerine Uygulanan Ön İşleme Çalışmaları .....	12

**İÇİNDEKİLER (devam)**

	<u>Sayfa</u>
2.4 Derin Öğrenme ve CNN .....	14
2.5 Dengesiz Veri Setleri .....	16
2.6 Sınıflandırma Metrikleri .....	18
3.GEREÇ VE YÖNTEM .....	21
3.1 Kullanılan Veri Seti .....	21
3.2 Kullanılan Teknolojiler .....	22
3.3 Veri Setinin İndirilmesi .....	23
3.4 CSV Dosyaları Üzerinde Yapılan Ön İşleme Çalışmaları .....	24
3.5 Görüntü İşleme .....	26
3.6 Veri Setinin Düzenlenmesi .....	29
3.7 Derin Öğrenme Modeli .....	30
4. SONUÇ .....	33
5. ÖNERİLER .....	38
KAYNAKLAR DİZİNİ .....	39
TEŞEKKÜR .....	45
ÖZGEÇMİŞ .....	46
EKLER .....	



## ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1 Karmaşıklık matrisi ve elemanları .....	18
3.1a CBIS-DDSM BI-RADS 3 örnek görüntüsü: tam mamografi.....	25
3.1b CBIS-DDSM BI-RADS 3 örnek görüntüsü: maske .....	25
3.1c CBIS-DDSM BI-RADS 3 örnek görüntüsü: ROI .....	25
3.2a CBIS-DDSM kalsifikasyon örnek görüntüsü üzerinde ön işleme: orijinal PNG.....	28
3.2b CBIS-DDSM kalsifikasyon örnek görüntüsü üzerinde ön işleme: CLAHE kafes boyutu 8 .....	28
3.2c CBIS-DDSM kalsifikasyon örnek görüntüsü üzerinde ön işleme: CLAHE kafes boyutu 4 .....	28
3.2d CBIS-DDSM kalsifikasyon örnek görüntüsü üzerinde ön işleme: CLAHE kafes boyutu 2 .....	28
3.3a CBIS-DDSM kitle örnek görüntüsü üzerinde ön işleme: orijinal PNG .....	29
3.3b CBIS-DDSM kitle örnek görüntüsü üzerinde ön işleme: CLAHE kafes boyutu 8.....	29
3.3c CBIS-DDSM kitle örnek görüntüsü üzerinde ön işleme: CLAHE kafes boyutu 4.....	29

**ŞEKİLLER DİZİNİ (devam)**

<u>Şekil</u>	<u>Sayfa</u>
3.3d CBIS-DDSM kitle örnek görüntüsü üzerinde ön işleme: CLAHE kafes boyutu 2.....	29
3.4 Düzenlenmiş veri seti klasör şeması.....	30
4.1 Öznitelik çıkartma yöntemi ile eğitim sonucu oluşan eğriler.....	33
4.2 Öznitelik çıkartma yöntemi ile eğitim sonucu oluşan karmaşıklık matrisi ..	34
4.3 Öznitelik çıkartma yöntemi ile eğitim sonucu oluşan ayrıntılı sınıflandırma raporu .....	34
4.4 İnce ayar yöntemi ile eğitim sonucu oluşan eğriler .....	36
4.5 İnce ayar yöntemi ile eğitim sonucu oluşan karmaşıklık matrisi .....	36
4.6 İnce ayar yöntemi ile eğitim sonucu oluşan ayrıntılı sınıflandırma raporu..	37



**TABLolar DİZİNİ**

<u>Tablo</u>	<u>Sayfa</u>
2.1 Literatürdeki açık mamografi veri setleri .....	11
2.2 Sınıflandırma metrikleri ve metriklerin formülleri. (DP = doğru pozitif, DN = doğru negatif, YP = yanlış pozitif, YN = yanlış negatif) .....	19
3.1 CBIS-DDSM veri setine ait CSV dosyaları ve açıklamaları .....	23
3.2 CBIS-DDSM eğitim ve test veri setinde bulunan BI-RADS örnek sayıları ve toplamları .....	24



**KISALTMALAR DİZİNİ**

<u>Kısaltmalar</u>	<u>Açıklama</u>
VGG	Visual Geometry Group (Görsel Geometri Grubu)
ZF-Net	Zeiler Fergus Net (Zeiler Fergus Ağı)
MIAS	Mammographic Image Analysis Society (Mamografik Görüntü Analizi Derneği)
KAU-BCMD	King Abdulaziz University Breast Cancer Mammogram Dataset (Kral Abdülaziz Üniversitesi Meme Kanseri Mamografi Veri Seti)
VICTRE	Virtual Imaging Clinical Trial for Regulatory Evaluation (Düzenleyici Değerlendirme için Sanal Görüntüleme Klinik Denemesi)
BCDR	Breast Cancer Digital Repository (Meme Kanseri Dijital Deposu)



## 1. GİRİŞ

Dünya Sağlık Örgütü, 2020'de yaklaşık 10 milyon ölümün (yaklaşık altı ölümden birinin) sorumlusunun kanser olduğunu belirtmiştir. Bu sebepten dolayı kanser dünya çapında önde gelen bir ölüm nedenidir. Dünyada en sık rastlanan kanser tipleri meme, akciğer, kolon, rektum ve prostat kanseridir (World Health Organization, 2022).

Kanser vücuttaki hücrelerin kontrolsüz ve düzensiz bir şekilde büyüyüp yayılmasıyla gerçekleşen bir hastalık türüdür. Kanser birçok türü olmakla beraber her kanserin kendine has özellikleri vardır. Fakat tüm kanser türlerinde ortak olarak, vücuttaki hücre çoğalması ile ilgili kontrollerin takip edilmemesi durumu bulunmaktadır. Ayrıca kanserli hücreler başladıkları dokulardan göç etme, yakındaki dokuları istila etme ve vücudun uzak bölgelerinde kitleler oluşturma yeteneğine sahiptir. Bu tür zararlı hücrelerin bir araya gelmesiyle oluşan tümörler, organizmanın hayatta kalması için gerekli doku ve organların işleyişini bozduklarında, ölümcül bir hastalığa dönüşürler (Weinberg, 1996).

Meme kanseri kadınlarda en sık tespit edilen kanserlerden biri olmakla beraber kadınlarda kanserden ölümlerin ikinci en sık nedenidir (Fahad Ullah, 2019). Kadın nüfusu dünya nüfusunun %49,5'ünü oluşturmaktadır. Meme kanseri vaka sayılarında ülkelerin gelişmişlikleri ya da gelir düzeylerinden bağımsız olarak, nüfus artışı ve nüfusun yaşlanmasından dolayı artış görülmektedir. Fakat, meme kanseri erken teşhis edildiği durumda hastaların %70-80'inde tedavi edilebilmektedir. (Harbeck et al., 2019). Bu sebepten dolayı, meme kanserinin erken teşhisi, kesin tanı (düşük yanlış pozitif ve yanlış negatif oranı) yapılmasını gerektirir.

Erken meme kanseri, kanser hücrelerinin sadece meme dokularında veya koltuk altı lenf bezlerinde bulunduğu aşamadır ve tedavi edilebilir olarak kabul edilir. Buna karşılık ileri meme kanseri, mevcut tedavi yöntemleri kullanılarak tedavi edilememektedir. Meme kanseri teşhisinde mamografi, ultrasonografi, manyetik rezonans görüntüleme ve histoloji görüntüleme gibi çeşitli görüntüleme yöntemleri kullanılmaktadır (Harbeck et al., 2019).

Mamografi çekimleri, memenin düşük dozlu X-ışını ile görüntülenmesi yöntemiyle yapılmaktadır. Mamografi, meme kanseri için popülasyon taramasında en sık kullanılan, ikincil bir önleme stratejisidir (Harbeck et al.,

2019). Mamografi taraması, radyologların meme kanseriyle alakalı anormallikleri tespit etmek amacıyla, 20 yılı aşkın süredir kullandığı bir yöntemdir. Ultrason ile çekilen görüntüler ise yüksek frekanslı ses dalgaları yardımıyla oluşturulur. Bu yüzden, mamografi ya da manyetik rezonans görüntüleme yöntemlerinde olduğu gibi radyasyon kullanımını gerektirmez. Manyetik rezonans görüntüleme yönteminde, manyetik rezonans makinesi vücudun belirli bir bölgesinin birden çok görüntüsünü alır ve bunları birleştirerek ayrıntılı bir görüntü elde eder. Histoloji görüntüleri ise anomali tespiti yapıldıktan sonra, anormallik içeren bölgeden toplanan dokuların patoloj tarafından incelenip görüntüsünün alınması ile üretilir. Histoloji görüntülerinde, dijital görüntü elde edilmeden önce bir kimyasal ile dokulara boyama işlemi yapılır (Murtaza et al., 2019).

Mamografi taramasında şüpheli bir durum görülürse hastanın ultrason ya da manyetik rezonans görüntüsünün de alınması gibi tamamlayıcı testler radyolog tarafından istenebilir. Fakat manyetik rezonans görüntüsü genellikle kanser teşhisi konulduktan sonra, doktor hastalığın kapsamı hakkında ayrıntılı bilgi almak istediği zaman çekilmektedir. Ultrason görüntüleri tek başına kullanıldığında kanserli kitlelerin kalsifikasyonlardan ayırt edilmesi zordur (Murtaza et al., 2019). Ultrason görüntüleri çoğunlukla mamografi görüntüsünde çok miktarda glandüler doku bulunan (meme dokusu yoğunluğu yüksek) kadınları taramak için kullanılır. Ultrasonografi, manyetik rezonans görüntüleme gibi yardımcı görüntüleme yöntemlerinin kullanılması meme kanseri tespitini artırmaktadır (Harbeck et al., 2019).

Radyologlar, mamografi görüntülerinde meme kanseriyle ilişkili olarak kitle, küçük kalsiyum birikintileri, asimetri ya da yapısal bozukluklar gibi anormallikleri aramaktadır (Murtaza et al., 2019; Abdelrahman et al., 2021). Kitleler kist veya yumru şeklinde bulunabilmektedir. Kalsiyum birikintileri ise düzensiz şekillerde bulunup benekler şeklinde görülmektedir. Bu tarz kalsiyum birikintileri literatürde mikro kalsifikasyon ya da mikro kireçlenmeler şeklinde de adlandırılabilir (Murtaza et al., 2019).

Mamografi görüntülerinin üç çeşidi vardır. Bunlar sırasıyla ekran filmi mamografisi, dijital mamografi ve dijital meme tomografisidir. Ekran filmi mamografisi görüntüleri doğrudan (dijital olmayan) bir film tabakasına basılmaktadır. Buna karşılık dijital mamografi görüntüleri, dijital olarak elde edilip saklanmaktadır. Dijital meme tomografisi yöntemi ise, en gelişmiş mamografi yöntemi olmakla beraber 3-boyutlu olarak mamografi alma yöntemidir

(Murtaza et al., 2019). Mamografi çekimi sırasında iki açıdan görüntü alınmaktadır. Bu açılardan ilki baştan ayağadır ve Kranyokaudal (Craniocaudal – CC) olarak adlandırılır. İkinci açı ise yan görünümdür ve Mediolateral Oblik (Mediolateral Oblique – MLO) olarak adlandırılmaktadır (Wikipedia, 2022). Dijital tıbbi görüntülerin saklanması sürecinde Tıpta Dijital Görüntüleme ve İletişim (Digital Imaging and Communications in Medicine – DICOM) (National Electrical Manufacturers Association, 2022) gibi standartlar kullanılabilir.

Mamografi raporlarında radyologlar arasında bir standart elde etmek için Amerikan Radyoloji Koleji, 1993 yılında Meme Görüntüleme Raporlama ve Veri Sistemi (Breast Imaging Reporting and Data System – BI-RADS) sözlüğünü geliştirmiştir. BI-RADS sözlüğünde kitlelerin ve kalsifikasyonların özelliklerini ve ilişkili bulgularını tanımlayan, ayrıca mamografi taraması sonucu nihai değerlendirme kategorilerini belirleyen terimler bulunmaktadır (Lieberman and Menell, 2002).

Bu terimlerden ilki meme yoğunluğudur. 4 adet sınıf içermektedir. BI-RADS 1 sınıfı, neredeyse tamamen yağ; BI-RADS 2, dağınık fibroglandüler yoğunluklar; BI-RADS 3, heterojen yoğun ve BI-RADS 4 sınıfı, yoğun anlamına gelmektedir (Lieberman and Menell, 2002).

Nihai değerlendirme sonucu sınıfları ise, kötücül hastalık seviyesinin belirlenmesine yardımcı olmaktadır. Bu kategoride 0'dan 6'ya kadar, 7 adet sınıf bulunmaktadır (Balleyguier et al., 2007). BI-RADS 0 şeklinde adlandırılan ilk sınıf, değerlendirmenin eksik olduğunu ve ek görüntüleme ile değerlendirme gerektiğini belirtmektedir. BI-RADS 1 sınıfı, negatif durumu (kansere bulunmaması durumu) belirtmektedir. Bu sınıfa ait hastalara 1 yıl içerisinde rutin mamografi taraması önerilmektedir. BI-RADS 2 sınıfı ise, iyi huylu bulguları belirtir. Benzer şekilde BI-RADS 2 hastalarına da 1 yıl içinde rutin mamografi önerilir. BI-RADS 5 kategorisine sınıflandırılan hastalarda yüksek derecede kötücül hastalık bulunduğu düşünülmektedir. BI-RADS 5 hastalarına da biyopsi veya uygun görülen ilgili operasyon uygulanmaktadır. BI-RADS 3 ve BI-RADS 4 sınıfları ise iyi huylu kanser ile kötü huylu kanser arasında belirsizlik olduğunda kullanılan nihai değerlendirme sonuçlarıdır. BI-RADS 3 sınıfı, muhtemelen iyi huylu bulguları gösterir ve hastalarına kısa aralıklarla (6 aylık) takip önerilir. BI-RADS 4 sınıfı ise şüpheli bulguları belirtir ve hastalarında biyopsi yapılması düşünülmelidir. (Lieberman and Menell, 2002). Son olarak BI-RADS 6 kategorisi ise histolojik olarak kanıtlanmış kötücül hastalık bulduran

hastaları temsil etmektedir. Bu kategoriye sınıflandırılan hastalara kemoterapi sonrasında kanserin gidişatını izleyebilmek için görüntüleme yapılmaktadır (Balleyguier et al., 2007).

Literatürde yayınlanan bir çalışmada, biyopsi yapılan hastaların yaklaşık %10'luk bir kısmının aslında BI-RADS 3 kategorisine sınıflandırılması gerektiği ve biyopsi uygulanmaması gerektiği tespit edilmiştir (Lieberman and Menell, 2002). İstatistiklere göre, biyopsi önerilen hastaların %67'lik kısmının yanlış pozitif vaka olduğu ve hastalarda meme kanseri bulunmadığı ortaya çıkmıştır (Abdelrahman et al., 2021). Gerçekleşen yanlış pozitif ve yanlış negatif vakaların çoğunluğu BI-RADS 3 ve BI-RADS 4 kategorilerine sınıflandırılan hastalardan kaynaklanmaktadır (Medeiros et al., 2020). Biyopsi işleminde, cerrahi olarak doku alınması ve dokunun histolojik olarak incelenmesi yöntemleri uygulanmaktadır (Lyman et al., 2005). Kısa aralıklı takip uygulanması gereken BI-RADS 3 hastalarına biyopsi uygulanması hastaya gereksiz bir işlem uygulanması anlamına gelmektedir.

Yakın zaman önce gerçekleşen donanım ve yazılımdaki gelişmeler yapay zekanın derin öğrenme gibi çeşitli konuları üzerindeki çalışmalara büyük bir ivme kazandırmıştır. Bu gelişmeler, daha büyük boyutlarda verilerin daha gelişmiş algoritmalar ve donanımlar, özellikle Grafik İşleme Ünitesi (Graphics Processing Unit – GPU) ve Tensör İşleme Ünitesi (Tensor Processing Unit- TPU), kullanılarak işlenebilmesine olanak sağlamıştır (Burt et al. 2018).

Bilgisayar donanımında ve geliştirilen algoritmalarındaki ilerlemeler, Bilgisayar Destekli Tanı (Computer Aided Diagnosis – CAD) sistemlerinin gelişmesine olanak sağlamıştır. CAD sistemleri 30 yılı aşkın süredir onkoloji alanında tespit ve teşhise yardımcı olması amacıyla klinik olarak kullanılmaktadır. Bu sistemler radyoloji görüntüleri üzerinde teşhis yapabilmek için çeşitli yapay zeka algoritmalarından faydalanmaktadır (Burt et al. 2018). Bu sistemlerin kullanılması insana bağımlılığı azaltmaktadır. Ayrıca yanlış pozitif ve yanlış negatif olarak tespit edilen vakaları azaltarak meme kanseri tespit oranını iyileştirmektedir (Ramadhani, 2021).

Belirtilen CAD sistemleri genellikle 2 adet yapay zeka yaklaşımı kullanmaktadır. Bu yaklaşımlardan ilki, bölütlenmiş görüntülerden manuel olarak elde edilen özniteliklerin geleneksel makine öğrenmesi algoritmaları ile kullanılmasıdır. İkincisi ise makine öğrenmesinin özel bir alt konusu olan derin

öğrenme algoritmalarının kullanılmasıdır. Derin öğrenme algoritmaları, manuel olarak elde edilen özniteliklere ihtiyaç duymayıp, ilgili öznitelikleri otomatik olarak çıkartabilmektedir (Castiglioni et al., 2021). Derin öğrenme yapay sinir ağlarını kullanmaktadır ve "derin" terimi genellikle sinir ağlarındaki gizli katmanların sayısını belirtmektedir. Gizli katman sayısı arttıkça derinlik artmaktadır (Murtaza et al., 2019).

İlgili yapay zeka modelleri geliştirilirken meme kanseriyle ilgili hangi görüntülerin kullanıldığı ve hangi veri seti kullanıldığı çalışmadan çalışmaya değişebilmektedir. Literatürdeki çalışmalar veri seti olarak özel veri setleri veya açık veri setlerini kullanmaktadır (Burt et al. 2018). Fakat açık veri setleri kullanılarak yapılan çoğu çalışmada mamografi görüntüleri kullanılmaktadır. Bunun sebebi var olan çoğu açık veri setinin mamografi görüntüleri üzerine oluşturulmuş olmasıdır (Murtaza et al., 2019).

Meme kanseri görüntüleri kullanılarak geliştirilen bu uygulamaların geneli, yapay zekanın başlıca problemlerinden olan sınıflandırma, bölütleme, görüntü kaydı, algılama, lokalizasyon veya derecelendirme problemlerini çözme amacıyla geliştirilmiştir. Literatürde, bu problemleri çözmek amacıyla geleneksel makine öğrenmesi ve derin öğrenme algoritmalarını kullanan birçok çalışma vardır. Fakat yakın zamanda yayınlanmış olan makalelerde derin öğrenme yaklaşımlarının daha sık kullanıldığı görülmektedir (Murtaza et al., 2019). Özellikle radyolojide derin öğrenme modellerinin kullanılması, sınıflandırma ve tümörlerin lokalizasyonu problemleri konusunda insan performansını geçebilen derin öğrenme modellerin elde edilmesine olanak sağlamıştır (Kwong and Mazaheri, 2021).

Görüntüler üzerinde oldukça başarılı sonuçlar veren bir derin öğrenme algoritması olan Evrişimsel Sinir Ağının (Convolutional Neural Network – CNN) geliştirilmesinden sonra araştırmacılar mamografi analizi için birçok CNN tabanlı uygulama geliştirmiştir. Bu uygulamaların bir kısmı Amerika Birleşik Devletleri Gıda ve İlaç Dairesi (Food and Drug Administration – FDA) tarafından onaylanmıştır (Abdelrahman et al., 2021). 2010 yılından beri 5 yıl boyunca her yıl düzenlenen ImageNet adlı yarışma görüntü sınıflandırma ve lokalizasyon problemleri konusunda CNN model mimarileri için bir kıyaslama kriteri olmuştur. Yarışmada kullanılan ImageNet veri seti 14 Milyon üzerinde 1000 adet obje sınıfına ait görüntüleri içermektedir (Russakovsky et al., 2015). Yarışmaya yönelik geliştirilen AlexNet, ZF-Net, GoogLeNet, VGG-Net ve ResNet gibi

mimariler aldıkları sonuçlarla CNN algoritmalarının güçlü performansını bir kez daha kanıtlamıştır (Murtaza et al., 2019).

Makine öğrenmesi algoritmalarında kullanılmak üzere veri seti oluşturulması zaman alıcı ve maliyetli bir iştir. Bu sebeple yeterli veri içermeyen problemler bulunmaktadır. Transfer öğrenme, veri miktarının az olduğu durumlarda etki alanları arasında bilgi aktarımı yaparak az olan veride daha iyi genelleme yapabilen modellerin elde edilmesini sağlamaktadır (Zhuang et al., 2020). Transfer öğrenme 4 adet kategori altında gruplandırılabilir. Bunlar örnek tabanlı, haritalama tabanlı, ağ tabanlı ve çekişme tabanlı transfer öğrenmedir (Tan et al., 2018).

ImageNet üzerinde eğitilmiş başarılı CNN'lerin üretilmesi ile bu ağları mamografi görüntüleri üzerinde ağ tabanlı transfer öğrenme ile kullanan birçok araştırma yayınlanmıştır. Literatürde bu yöntemle mamografi görüntülerini eğiten makalelerin çoğunluğu Alex-Net, VGG16, ResNet50 ve GoogleLeNet adlı CNN modellerini kullanmaktadır. Bu modellerin baştan eğitilmesi modern ekran kartlarında bile günler veya haftalar alabilmektedir (Abdelhafiz et al., 2019). Bu yüzden transfer öğrenme yöntemi ile kullanılabilmesi avantajlı bir durumdur. Ayrıca bu çalışmaların, sınırlı veri sorununu çözmek amacıyla transfer öğrenmeye ek olarak sentetik veri artırımı yöntemleri kullandığı da görülmektedir. Görüntüler üzerinde uygulanan veri artırımı yöntemleri ile veri seti büyüklüğü 1000 katına kadar çıkartılabilmektedir (Burt et al. 2018).

Belirtilen CNN modelleri ağ tabanlı transfer öğrenmeyle kullanılırken iki adet yaklaşım izlenmektedir. Bu yöntemler sırasıyla öznitelik çıkartma ve ince ayardır. Öznitelik çıkartma yönteminde kaynak etki alanında eğitilmiş CNN mimarisinin sonunda bulunan sınıflandırıcı katmanlar çıkartılır. Geri kalan katmanlar kaynak etki alanını için öğrenilmiş parametreler ile transfer edilir. Çıkarılan katmanlar yerine yeni probleme özel sınıflandırıcı katman ya da bir geleneksel makine öğrenmesi modeli bağlanır. Bu yöntem ile kullanılan derin öğrenme modelinde, transfer edilen CNN'e ait katmanlar eğitime katılmaz (katmanlar dondurulur). Sadece sona eklenen katmanlar yeni veri seti üzerinde eğitime katılır. İnce ayar yönteminde ise transfer edilen CNN'e ait bir veya birden fazla katmanın da eğitime katılması sağlanır (Falconi et al., 2020a). Fakat kaç adet katmanın eğitime katılması gerektiği uygulamadan uygulamaya değişmektedir (Abdelhafiz et al., 2019). Öznitelik çıkarma yöntemi yaygın bir transfer öğrenme yöntemidir. CNN'in öznitelik çıkarma yöntemi ile kullanılmasının ardından ince

ayar yöntemi ile kullanılması modelin performansını arttırabilmektedir (Google Brain, 2022a).

Mamografi görüntüleri ile CNN'ler genel olarak BI-RADS meme yoğunluğu sınıflandırması, asimetri sınıflandırması ve lokalizasyonu, kalsifikasyon sınıflandırması ve lokalizasyonu, kitle sınıflandırması ve lokalizasyonu problemlerini çözmek amacıyla kullanılmaktadır (Abdelrahman et al., 2021). Literatürdeki çalışmaların mamografi lezyon sınıflandırmasını 2 ya da 3 adet sınıfa ayırarak yaptığı görülmektedir. Bu sınıflar iyi huylu-kötü huylu veya normal (tümör içermeyen)-iyi huylu-kötü huylu şeklinde olabilmektedir (Abdelhafiz et al., 2019).

Veri setinde bulunan veriler normal, iyi huylu ve kötü huylu şeklinde bir etikete sahip değilse, sınıfların belirlenmesinde nihai BI-RADS değerlendirme sonucundan yararlanan çalışmalar bulunmaktadır. Örneğin literatürde sıklıkla kullanılan bir açık mamografi veri seti olan INbreast'e (Moreira et al., 2011) ait verilerde iyi huylu veya kötü huylu etiketi bulunmamaktadır. Bir çalışma (Calderon-Ramirez et al., 2021) INbreast görüntülerini iyi huylu ve kötü huylu olarak sınıflamıştır. Sınıflama algoritması olarak popüler CNN mimarilerinden VGG19, ResNet-152 ve EfficientNet-b0'ı, ImageNet ağırlıklarıyla transfer öğrenme yöntemi ile kullanmıştır. Yazarlar, BI-RADS 1, BI-RADS 2 verilerini iyi huylu sınıf olarak ve BI-RADS 4, BI-RADS 5, BI-RADS 6 verilerini kötü huylu sınıf olarak kabul etmiştir. Tüm BI-RADS 3 verileri çalışma dışı bırakılmıştır. Benzer şekilde başka çalışmalar (Shen et al., 2019; Kumar et al., 2017) da INbreast veri seti üzerinde sınıfları ayırırken BI-RADS 3'ü çalışmaya dahil etmemiştir. Fakat Gao et al. (2018) etiketleme yaparken hem BI-RADS 3'ü hem de BI-RADS 4'ü dahil etmemiştir.

INbreast görüntüleri sınıflandırılırken tüm BI-RADS sınıflarının dahil edildiği oldukça az sayıda çalışma vardır (Domingues et al., 2018; Falconi et al. 2020b). Falconi et al. (2020b) BI-RADS sınıflarının iyi huylu- kötü huylu şeklinde etiketlenmesinde literatürde bir ortak karar olmadığını vurgulamıştır. Örneğin Carneiro et al. (2015) ve Cortez et al. (2021) BI-RADS 3 görüntülerini iyi huylu olarak etiketlerken Akselrod-Ballin et al. (2019) ise kötü huylu olarak etiketlemiştir.

Wong et al. (2020) ve Akselrod-Ballin et al. (2019), CNN modellerinin BI-RADS 3 kategorisine sahip görüntüleri ayırt etmede zorlandığını belirtilmiştir. Wong et al. (2020), BI-RADS 3 kategorisindeki görüntülerin çalışmada kullanılan veri setinden çıkartılması sonucunda Eğrinin Altında Kalan Alan (Area under the Curve – AUC) skorunda %12’lik bir artış ile model başarısının arttığını göstermiştir.

Sonuç olarak BI-RADS 3 ve BI-RADS 4 sınıftaki görüntülerin kullanımında literatürde farklı yaklaşımlar gözlemlenmiştir. Belirsizliğe sebep olan bu sınıflar, düşük yanlış pozitif ve düşük yanlış negatif oranlarının yakalanabilmesi için büyük bir öneme sahiptir. Fakat literatürdeki ilgili çalışmalar incelendiğinde BI-RADS 3 ve BI-RADS 4 grubuna odaklanan sadece bir çalışma bulunabilmiştir.

Bu çalışmada (Medeiros et al., 2020) Küratörlü Meme Görüntüleme Alt Kümesi DDSM (Curated Breast Imaging Subset DDSM Dataset- CBIS-DDSM) açık mamografi veri setinde bulunan BI-RADS 3 ve BI-RADS 4 görüntülerini sınıflandırmak üzere yapay zeka modelleri geliştirilmiştir. Görüntülere ait öznitelikler çıkartılırken 11 adet farklı, ImageNet veri tabanında eğitilmiş CNN mimari model, transfer öğrenme yöntemiyle öznitelik çıkartma amacıyla kullanılmıştır. Ardından, çıkarılan öznitelikler 4 adet geleneksel makine öğrenmesi algoritmasına girdi olarak verilmiş ve bu algoritmalar ikili sınıflandırma yapma amacıyla eğitilmiştir. 11 adet CNN mimarisinin 4 adet makine öğrenmesi algoritması ile kombinasyonları arasından BI-RADS 3 ve BI-RADS 4 görüntülerini sınıflandırmada en başarılı olan model seçilmiştir. En başarılı model DenseNet201 CNN modeli ve Çok Katmanlı Algılayıcı (Multilayer Perceptron – MLP) algoritması ile elde edilmiştir. Sınıflandırma modellerinin performansları ölçülürken accuracy (doğruluk), precision (hassasiyet), recall (hatırlama), ve F1 skoru metrikleri kullanılmıştır. DenseNet201 ve MLP kombinasyonu ile eğitilen modelde 0.634 doğruluk skoru elde etmiştir. F1 skorunda 0.631 değeri ile en başarılı model ise MobileNet CNN modeli ve Destek Vektör Makinesi (Support Vector Machine – SVM) algoritması ile elde edilmiştir. Sonuç olarak geliştirilen model ile BI-RADS 3 ve BI-RADS 4 görüntülerini sınıflamada uzman insan performansına ait doğruluk skoru, yapay zeka yöntemleri ile %9 oranında geçilmiştir.

Tez kapsamına en benzer bulunan bu çalışmada (Medeiros et al., 2020) transfer öğrenme yöntemlerinden sadece öznitelik çıkartma kullanılmıştır. Fakat

bu yaklaşımda önceden eğitilmiş CNN modelinin arkasına tam bağlı sınıflandırıcı katmanlar eklenmesi yerine geleneksel makine öğrenmesi algoritmalarının koyulması tercih edilmiştir. Tez kapsamında aynı veri seti üzerinde aynı problemi çözmek amacıyla diğer transfer öğrenme yaklaşımlarının da incelenmesi, özellikle CNN üzerinde ince ayar yapılarak 0.63 doğruluk skorundan daha yüksek bir skor elde edilmesi amaçlanmıştır. Ayrıca yayınlanan çalışmada (Medeiros et al., 2020) veri seti üzerinde hangi görüntü işleme yöntemlerinin kullanıldığı bilgisi verilmemektedir. Benzer şekilde, literatürde transfer öğrenme yöntemleri ile sıklıkla birlikte kullanılan veri artırımı yöntemleri kullanılmamıştır. Tez kapsamında görüntü işleme ve veri artırımı yöntemlerinin de kullanılması amaçlanmıştır.



## 2. GENEL BİLGİLER

### 2.1 Derin Öğrenme Kütüphaneleri ve Araçları

Günümüzde derin öğrenme algoritmalarının daha kolay kullanılabilmesi için çeşitli yazılım kütüphaneleri geliştirilmiştir. Kullanılacak kütüphanenin seçimde kütüphanenin hangi programlama dili için yazıldığı, yeterli belgelendirmeye sahip olup olmadığı ve algoritmalarının kullanımında GPU desteği sağlayıp sağlamadığı çok önemlidir (Abdelhafiz et al., 2019). Derin öğrenme algoritmaları görüntülerin her bir pikseli için binlerce hesaplama yapmaktadır. Daha büyük veri setlerinin kullanılması ve daha karmaşık derin öğrenme model mimarilerinin seçilmesi gibi etkenler eğitim zamanını etkilemektedir. Bu sebeple günlerce sürebilecek eğitim süresini kısaltan GPU donanımından yararlanabilmek oldukça önemlidir.

Literatürde CNN ile sınıflandırma algoritmaları geliştirilirken Tensorflow, Keras, Caffe, Pytorch ve MatConvNet kütüphanelerinin sıklıkla kullanıldığı görülmüştür (Abdelhafiz et al., 2019).

Kişilerde yeterli GPU donanımı bulunmaması durumunda ise çeşitli alternatifler vardır. Kullanılacak kütüphane tarafından desteklenen GPU'nun satın alınması ya da Google gibi büyük şirketlerin sunmuş olduğu GPU'ların kullanılması tercih edilebilir. İkinci seçenekteki GPU'lar kişisel kullanım, akademik araştırma ya da ticari amaçlarla kullanılabilir. Özellikle Kaggle (Kaggle Inc., 2022) ve Google Colab (Google LLC, 2022) ortamları belirli bir saat limitiyle kullanıcılarına ücretsiz GPU erişim imkânı sağlamaktadır.

Tez kapsamında Tensorflow'un üzerinde çalışabilen daha yüksek seviyeli bir kütüphane olan Keras'ın (Keras, 2022) kullanılması tercih edilmiştir. Keras'ın sunduğu algoritmaların Python programlama dili aracılığı ile kullanılması amaçlanmıştır. GPU kullanımı için ise Kaggle ortamı seçilmiştir.

### 2.2 Açık Mamografi Veri Setleri

Meme kanseri tespitinde daha başarılı algoritmaların geliştirilmesine olanak sağlamak için çeşitli kurum ve kuruluşlar bu konuyla alakalı açık veri setleri oluşturmuştur. Bu şekilde araştırmacılar aynı veri seti üzerinde çalıştırılan algoritmaların performanslarını karşılaştırabilecektir. Bu veri setlerinin

büyüklikleri, hangi meme kanseri görüntüleme yöntemine ait görüntüleri içerdiği ve görüntülerinin saklanma formatları birbirinden farklı olabilmektedir.

Tez kapsamında mamografi görüntüleri ile çalışılması amaçlandığı için literatürde en çok kullanılan açık mamografi veri setleri araştırılmıştır. Bu veri setleri Çizelge 2.1’de özetlenmiştir.

**Çizelge 2.1.** Literatürdeki açık mamografi veri setleri.

Veri Seti İsmi	Yıl	Görüntü Sayısı	Mamografi Görüntü Tipi	Görüntü Formatı
DDSM	1999	10480	MLO, CC	.LJPEG
mini-MIAS	2003	322	MLO	.PGM
BancoWeb LAPIMO	2010	1400	MLO, CC	.TIFF
InBreast	2011	410	MLO, CC	.DICOM
BCDR	2012	7315	MLO, CC	.TIFF
CBIS-DDSM	2017	4067	MLO, CC	.DICOM
VICTRE	2018	217.913	MLO, CC	.DICOM
OPTIMAM	2020	2.5 Milyon üzeri	MLO, CC	.DICOM
KAU-BCMD	2021	5662	MLO, CC	.DICOM

Tarama Mamografisi için Dijital Veritabanı (Digital Database for Screening Mammography – DDSM) (Heath et al., 1998), mini-MIAS (Suckling et al., 2015), BancoWeb LAPIMO (Matheus and Schiabel, 2011), Inbreast (Moreira et al., 2011), BCDR (Lopez et al., 2012), CBIS-DDSM (Lee et al., 2017), VICTRE (Badano et al., 2018), OPTIMAM (Halling-Brown et al., 2021), KAU-BCMD (Alsolami et al., 2021) adlı veri setleri arasında karşılaştırma yapılabilmesi için her bir veri setinin hangi yılda oluşturulduğu, kaç adet görüntü içerdiği ve görüntülerinin saklama formatı bilgileri de belirtilmiştir (Bkz. Çizelge 2.1).

Tez kapsamında BI-RADS 3 sınıfı ve BI-RADS 4 sınıfına ait görüntüleri sınıflandıran bir derin öğrenme modeli geliştirilmesi planlanmıştır. Tez çalışmasına ait sonuçların literatürdeki en alakalı çalışmayla (Medeiros et al., 2020) karşılaştırılabilmesi için çalışmadaki aynı veri seti kullanılmıştır. Tez kapsamında CBIS-DDSM veri setine ait BI-RADS 3 ve BI-RADS 4 görüntülerini

içeren veri seti kullanılarak transfer öğrenme yöntemi ile ikili sınıflandırma modeli geliştirilmesi amaçlanmıştır.

### 2.3 Mamografi Görüntülerine Uygulanan Ön İşleme Çalışmaları

Mamografi görüntülerinin ön işlemeye alınması modelin başarısının artmasında oldukça önemli bir yere sahiptir. Mamografi görüntülerinde ön işleme yöntemleri olarak kontrast artırma, gürültü azaltma ve bölütleme işlemleri yapılmaktadır (Abdelhafiz et al., 2019).

Mamografi görüntülerinde, meme dokusunun dışında kalan alanda boşluk alan ve görüntüyle ilgili çeşitli etiketler bulunmaktadır. Mamografi görüntüsü incelenirken arka planda yer alan pikseller ile ilgilenilmediğinden dolayı, bölütleme işlemiyle arka plan görüntüsü ortadan kaldırılır. Yapay zeka modelleri eğitim sırasında görüntü içerisindeki her bir piksel üzerinde binlerce hesaplama yapmaktadır. Bu yüzden tam görüntü üzerinde eğitim gerçekleştirmek daha fazla piksel üzerinde hesaplama yapmak anlamına gelmektedir. Bu sebepten dolayı arka planı çıkartılmış tam meme görüntülerini kullanmak yerine, İlgi Bölgesi (Region of Interest- ROI) görüntülerini kullanan birçok araştırmacı vardır. Meme dokusu içerisindeki şüpheli bölgeleri temsil eden ROI görüntülerinin kullanılması CNN'lerin işlem yükünün azaltmaktadır (Abdelhafiz et al., 2019).

Mamografi görüntülerinde gürültü azaltma ve görüntü iyileştirme amacıyla ortalama filtresi, medyan filtresi ve Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization- CLAHE) algoritmalarının kullanımı öne çıkmaktadır (Abdelhafiz et al., 2019).

CLAHE algoritması, Uyarlanabilir Histogram Eşitleme (Adaptive Histogram Equalization – AHE) algoritmasının geliştirilmiş halidir. Görüntü iyileştirme amacıyla AHE kullanılması, görüntünün kontrastını aşırı yükselterek gürültüyü azaltmak yerine artırabilmektedir. Ayrıca CLAHE algoritmasının kullanılması mamografi görüntülerindeki kitle ve mikro kalsifikasyonlarda daha iyi sonuç vermektedir (Lu et al., 2019).

CLAHE algoritmasında görüntü matrisi birbiriyle örtüşmeyen alt matrislere bölünür. Ardından her bir matrisin içerdiği piksel değerleri yardımıyla matrislerin histogramı hesaplanır. Daha sonra, bu histogramlar belirlenen kırılma değerine

göre kırpılır. Son olarak histogramları kırpılmış komşu matrisler, bilineer enterpolasyon kullanılarak birbiriyle birleştirilir (Lu et al., 2019).

Radzi et al. (2020) mamografi görüntüleri üzerinde yapılan ön işleme çalışmalarında AHE ve CLAHE algoritmalarını karşılaştırmıştır. Yazarlar, ön işleme sonucu oluşan görüntülerin tümör içeren kısımlarını bölütlenmiştir. Ayrıca ön işleme yöntemine göre bölütlemeye alınan sonuçlar karşılaştırıldığında CLAHE ile oluşturulan görüntülerin AHE'ye göre daha başarılı bir performans gösterdiğini kanıtlamıştır. Huang and Lin, (2020) ise INBreast veri setine ait görüntüler üzerinde öncelikle CLAHE uygulanmış, ardından oluşan yeni görüntülerle orijinal görüntüleri bir araya getirerek veri seti boyutunu 2 katına çıkartmıştır.

Falconi et al. (2020b), veri artırımı aşamasında CLAHE ve çeşitli dönüşümleri (sentetik veri artırımı yöntemleri) birlikte kullanmıştır. Dönüşümler için çeşitli açılarda döndürme, yatay eksende çevirme ve parlaklık değişimleri uygulamıştır.

Yetersiz miktarda veri kullanılması derin öğrenme modelinin yakınsamasını zorlaştırmaktadır. Görüntü sayısı az olan veri setlerinin boyutlarının büyütülmesi için çeşitli veri artırımı yöntemleri kullanılmaktadır. Özellikle radyolojik görüntülerde rotasyon, farklı seviyelerde gürültü ekleme, görüntünün kesilmesi ve geometrik transformasyon yöntemleri kullanılmaktadır. Tüm bu işlemler asıl görüntünün yapısı bozulmadan yapılmaktadır (Burt et al. 2018).

Tez çalışmaları kapsamında görüntü iyileştirme ve veri artırımı amacıyla CLAHE algoritmasının kullanılması amaçlanmıştır. 3 farklı CLAHE parametresi ile oluşturulan görüntülerin orijinal görüntülere eklenmesi ile veri setinin boyutunun 4 katına çıkartılması amaçlanmıştır. CLAHE algoritmasına ek olarak, veri artırımı yöntemlerinden yatay ve dikey eksende çevirmenin kullanılması amaçlanmıştır. CBIS-DDSM veri seti, araştırmacılara hazır ROI görüntülerini sunmaktadır. Her bir ROI görüntüsüne ait nihai BI-RADS sonucu bulunmaktadır. Tez kapsamında kullanılacak evrişimli sinir ağının işlem yükünün azaltılması için BI-RADS 3 ve BI-RADS 4 görüntülerine ait tam mamografi görüntülerinin kullanılması yerine ROI görüntülerinin kullanılmasına karar verilmiştir. Tez kapsamında incelenen literatürdeki en alakalı çalışma (Medeiros et al., 2020) da ROI görüntülerini kullanarak BI-RADS 3 ve BI-RADS 4 sınıflandırması gerçekleştirmiştir.

## 2.4 Derin Öğrenme ve CNN

Makine öğrenmesi algoritmaları kullanılırken veri seti genellikle eğitim, doğrulama ve test olmak üzere 3 parçaya bölünür. Aynı bir test veri seti olmadığı durumlarda ise eğitim ve doğrulama olmak üzere 2 grup kullanılabilir. Bu durumda doğrulama veri seti, test veri seti olarak da adlandırılabilir. Eğitim veri seti ile makine öğrenmesi model eğitimi yapılır. Modele ait ağırlıklar eğitim veri setindeki desenler öğrenilerek güncellenir. Doğrulama seti ise modelin öğrenme işlemi esnasında görmediği verileri içerir ve modelin eğitim esnasında ne kadar genelleme yapabildiğini (performansını) ölçmek için kullanılır. Test veri seti ise doğrulama setine benzer olarak modelin görmediği verileri içerir fakat doğrulama setinden farklı olarak eğitim işlemi sonlandıktan sonra performans ölçümünde kullanılır (Castiglioni et al., 2021). CBIS-DDSM veri seti, eğitim ve test setlerini sağlamaktadır (Lee et al., 2017).

Görüntülerin yapay zeka modelleri ile kullanılmasında çeşitli yaklaşımlar vardır. Bu yaklaşımlar gözetimli eğitim, gözetimsiz eğitim ve yarı gözetimli eğitimidir. Görüntülerin sınıflandırılması problemi düşünüldüğünde, gözetimli eğitim gerçekleştiren yapay zeka modelleri önceden sınıfı (etiketi) belirlenmiş görüntüleri kullanarak eğitim gerçekleştirir. Model eğitimi tamamlandığında modelin tahmin ettiği sınıflar ile verilerinin gerçek sınıfları karşılaştırılarak performans ölçümü yapılır. Gözetimsiz eğitimde, eğitim verilerinin sınıfları belli değildir. Kullanılan yapay zeka algoritması eğitim esnasında veri üzerindeki benzer desenleri keşfederek verileri ilgili sınıflara ayırır. Tüm eğitim verilerinin etiketlenmesinin mümkün olmadığı durumlarda yarı gözetimli eğitim kullanılabilir. Bu yöntemde eğitim verisinin sadece küçük bir kısmında sınıf bilgisi bulunmaktadır (Castiglioni et al., 2021).

CNN'lerin mimarisi diğer yapay sinir ağları gibi katmanlardan oluşmaktadır. Basit bir CNN mimarisi birbiri ardına yerleştirilmiş evrişim katmanı, örneğin Rektifiye Lineer Birim (Rectified Linear Unit – RELU) gibi bir doğrusal olmayan katman, havuzlama katmanı ve sonda bulunan tam bağlı katmandaki aktivasyon fonksiyonundan (örneğin sigmoid ya da softmax) oluşmaktadır (Murtaza et al., 2019). Tam bağlı katmandan önce veri çok boyutludur. Tam bağlı katmana geçilmeden önce veri düzleştirilir ve tek boyutlu bir matris haline gelir (Yamashita et al., 2018). Düzleştirme için sıklıkla kullanılan 2 adet alternatif vardır. Bunlar düzleştirme (flatten) katmanı ve küresel ortalama havuzlama katmanıdır (global average pooling). Maisano et al. (2018)

küresel ortalama havuzlama katmanının belleği daha etkili kullanmaya yardımcı olduğunu vurgulamıştır.

Sigmoid ve softmax aktivasyon fonksiyonları mamografi görüntüleri üzerinde geliştirilmiş arařtırmalarda sıklıkla kullanılmaktadır. Özellikle ikili sınıflandırma durumunda sigmoid, sayıca ikinin üzerinde sınıf bulunduğu durumda ise softmax fonksiyonu sınıflandırıcı olarak kullanılmaktadır (Abdelrahman et al., 2021).

Yapay sinir ağıları model eğitimi sırasında kayıp fonksiyonunun değerini azaltarak doğruluğu arttırmaya çalışmaktadır. Görüntü sınıflandırma problemi için CNN modelleri eğitim esnasında model ağırlıklarını eğitim verisindeki doğru sınıfları tahmin edebilmek amacıyla günceller. Model ağırlıklarının en optimize değerine ulaşabilmesi için çeşitli optimizasyon algoritmaları kullanılır. Bu optimize edicilere SGD, AdaGrad, Adam gibi algoritmalar örnek verilebilir. Günümüzde Adam algoritması daha sık kullanılan bir algoritmadır (Abdelrahman et al., 2021).

CNN mimarisinin tasarımı modelin gereksinimlerine ve veri setinin büyüklüğüne bağlıdır. Katman sayısı arttırıldığında daha soyut şekillerin algılanmasının kolaylaşacağı için sınıflar daha doğru tahmin edilir. Fakat bu durum optimize edilmesi gereken parametre artışına da sebep olacaktır. Sonuç olarak ezberleme problemi daha olası olarak ortaya çıkacaktır. Bu durum ile küçük boyutlu veri setlerinde daha sık karşılaşılmaktadır. Bu yüzden katman sayısı, öğrenme oranı büyüklüğü, optimize edici seçimi yapılırken deneme yanılma yöntemine ve deneyimlere dayanarak karar verilmektedir (Abdelhafiz et al., 2019).

CNN'lerin performansının arttırılması için bırakma (dropout), grup (batch) normalleştirme ve transfer öğrenme gibi yaklaşımlar kullanılmaktadır. Bu yöntemler ile ezberlemenin önüne geçilmeye çalışılmaktadır. Bırakma yönteminde rastgele seçilen nöronlar eğitime katılmaz (Abdelhafiz et al., 2019). Ezberleme durumunda model sadece eğitim verilerindeki desenleri çok iyi öğrenir ve doğrulama ya da test seti gibi görmediği veriler üzerinde iyi bir genelleme yapamaz. Ezberleme, istenmeyen bir durumdur (Johnson and Khoshgoftaar, 2019).

Falconi et al. (2020b) mamografi görüntülerini sınıflandırırken VGG modeli kullanmıştır. VGG'ye ait sınıflandırıcı katmanlar çıkartıldıktan sonra küresel ortalama havuzlama katmanı ve ardından tam bağlı katman eklenmiştir. Tam bağlı katmandan sonra ise bırakma katmanı kullanılmıştır. Bırakma değeri olarak 0.2 değeri seçilmiştir.

Öğrenme oranı büyüklüğü kararı da önem arz etmektedir. Eğer çok küçükse eğitim çok yavaş sürecektir. Çok büyükse model lokal optimalde takılma sorunu ile karşılaşabilecektir (Abdelhafiz et al., 2019). Ağ tabanlı transfer öğrenme kullanılırken ince ayar aşamasında öznitelik çıkartma aşamasından daha küçük bir öğrenme oranı kullanılmalıdır. Bunun sebebi ince ayarda öznitelik çıkartmaya göre daha büyük bir model kullanılmasıdır. Aksi taktirde model ezberleme sorunu ile karşılaşabilmektedir (Google Brain, 2022b).

## 2.5 Dengesiz Veri Setleri

İkili sınıflandırma probleminde iki adet sınıf vardır. Bu sınıflardan biri diğerine göre daha az veri içerdiğinde sınıf dengesizliği elde edilmiş olur. Sınıf dengesizliği dolandırıcılık tespiti ve kanser tespiti gibi birçok gerçek dünya uygulamasında doğal olarak bulunmaktadır. Örneğin kanser tespiti ile ilgili veriler düşünüldüğünde doğal olarak sağlıklı verilerin sayısı kanser içeren verilerden fazla olacaktır (Johnson and Khoshgoftaar, 2019). Veri setinde bulunan sınıfların dağılımı dengesizse bu durum modelin tahmin yapmasında bir önyargıya sebep olabilir. Çünkü çoğu sınıflandırıcı model dengesiz sınıflar ile eğitildiğinde çoğunluk sınıfına karşı bir önyargı sergilemektedir. Bunun için mamografi görüntülerinin analizinde dengeli bir veri setinin kullanılması önerilmektedir (Abdelhafiz et al., 2019).

Modelin çoğunluk sınıf için öğrendiği ön yargıyı azaltmak için çeşitli yöntemler vardır. Bu yöntemler 3 grup altında incelenebilir. İlk grup verinin kendi üzerinde yapılan işlemleri içerir. İkinci grup öğrenme algoritmasında yapılan işlemleri içerir. Son olarak üçüncü grupta ise ilk iki grubun kombinasyon olarak kullanıldığı yöntemler bulunmaktadır (Johnson and Khoshgoftaar, 2019).

Veri üzerinde kullanılan yöntemler, veri setinde her bir sınıfa ait veriden yaklaşık olarak eşit sayıda bulunmasını sağlamaya çalışır ve sınıfları dengeler. Bu amaçla veriler yeniden örneklenir. Örnekleme amacıyla kullanılan iki yöntem vardır (Johnson and Khoshgoftaar, 2019).

Bunlardan ilki eksik örneklemedir. Eksik örneklemede sayıca fazla olan sınıfa ait verilerin belirli bir kısmı veri setinden çıkartılır. Bu şekilde sınıflar sayıca daha yakın örnek sayısına sahip olur. Fakat bu yöntem modelin öğrenmesi gereken toplam bilgiden de kayıp verilmesine sebep olur (Johnson and Khoshgoftaar, 2019). Bu durum tez kapsamında kullanılan veriler için sorun oluşturabilmektedir. Çünkü bu yöntemin kullanılmasıyla test veri setinde bulunabilecek benzer bir mamografi görüntüsünün model tarafından hiç görülme olasılığı bulunmaktadır.

Veri üzerinde kullanılan ikinci yöntem ise aşırı örneklemedir. Bu yöntemde azınlıkta olan sınıfa ait veriler çoğaltılır ve veri setinde eşit sayıda sınıf oranları elde edilir. Fakat bu yöntemin kullanılmasıyla veri sayısı artacağı için modelin eğitim süresi de artacaktır. Ayrıca aşırı örnekleme kullanıldığında modelin eğitim verisini ezberlediği ve test verisinde genelleştirme yapamadığı belirtilmiştir (Johnson and Khoshgoftaar, 2019). Tez kapsamında yapılan çalışmalarda ezberlemenin önüne geçebilmek için aşırı örnekleme yöntemi tercih edilmemiştir.

Sınıf dengesizliğinin çözümü için öğrenme algoritması üzerinde kullanılan yöntemlerde ise ağırlık veya maliyet şeması kullanılmaktadır. Bu yöntemler, verinin dağılımını değiştirmek yerine temelde kullanılan öğrenme algoritmasını ya da çıktıyı değiştirerek çoğunluk sınıfa ait ön yargıyı azaltmaktadır (Johnson and Khoshgoftaar, 2019). Sınıf ağırlıklarının kullanılması ile, azınlıkta olan sınıfa daha büyük bir ağırlık değeri verilir. Bu şekilde model, azınlık sınıfa ait verileri daha çok dikkate alır (Google Brain, 2022b). Maliyet ile eğitim gerçekleştirildiğinde ise bir maliyet matrisi kullanılmalıdır. Fakat üzerinde çalışılan problem için en uygun maliyet matrisinin bulunması zor olabilmektedir. Çünkü maliyet matrisleri genellikle geçmiş deneyime ve probleme yönelik alan bilgisine bağlı olarak oluşturulmaktadır (Johnson and Khoshgoftaar, 2019).

Tez kapsamında kullanılan veri setine ait sınıflardan BI-RADS 3 sınıfı BI-RADS 4 sınıfına göre sayıca daha azdır ve bu durum bir dengesizlik oluşturmaktadır. Literatürde bu tarz veri setleri için kullanılan yöntemler incelendiğinde sınıf ağırlıklarının kullanılmasına karar verilmiştir. Benzer şekilde, bu tezin konusuna en yakın çalışma (Medeiros et al., 2020) da ilgili sonuçları hesaplarken sınıf ağırlıklarını kullanmıştır.

Sınıf ağırlıkları kullanılırken hangi optimizasyon algoritmasının kullanıldığına dikkat edilmelidir. Çünkü sınıf ağırlıklarını kullanmak, kayıp

fonksiyonunun hesapladığı kaybın aralığını değiştirir. Bu da optimize ediciye bağlı olarak eğitimin kararlılığını etkileyebilir. Stokastik Gradyan İnişi (Stochastic gradient descent – SGD) gibi optimizasyon algoritmaları sınıf ağırlıkları ile başarısız olabilmektedir. Fakat Adam optimizasyon algoritması sınıf ağırlıkları ile uygun bir şekilde kullanılabilir (Google Brain, 2022b). Bu yüzden tez çalışmalarında Adam optimizasyon algoritması seçilmiştir.

## 2.6 Sınıflandırma Metrikleri

Sınıflandırma amacıyla eğitilen derin öğrenme modellerinin performansı çeşitli metrikler aracılığıyla ölçülmektedir. Literatürde bu amaçla kullanılan metrikler accuracy (doğruluk), AUC, precision, (hassasiyet), specificity (özgüllük), recall (geri çağırma) ya da diğer adıyla sensitivity (duyarlılık) ve son olarak F-skoru'dur (Debelee et al., 2019).

Bahsedilen metriklerin hesaplanması için karmaşıklık matrisine ihtiyaç vardır. Karmaşıklık matrisi tek başına kullanıldığında bir performans belirleyicisi değildir. İki adet sınıfın bulunduğu bir karmaşıklık matrisi düşünüldüğünde karmaşıklık matrisinin elemanları sırasıyla yanlış negatif, doğru negatif, doğru pozitif ve yanlış pozitifdir. Şekil 2.1'de bir karmaşıklık matrisi görüntüsü verilmiştir.

		Tahminlenen	
		Negatif Sınıf	Pozitif Sınıf
Gerçek	Negatif Sınıf	Doğru Negatif	Yanlış Pozitif
	Pozitif Sınıf	Yanlış Negatif	Doğru Pozitif

Şekil 2.1. Karmaşıklık matrisi ve elemanları.

Pozitif ve negatif iki adet sınıfın olduğu düşünülürse, doğru negatif değer negatif örneklerden kaçının negatif olarak yani doğru tahmin edildiğini belirtir. Yanlış pozitif değer ise gerçek değeri negatif olan örneklerden kaçının pozitif olarak tahmin edildiğini belirtir. Benzer şekilde doğru pozitif değer gerçek değeri pozitif olan örneklerden kaçının pozitif olarak tahmin edildiğini ve yanlış negatif değer ise kaçının negatif olarak tahmin edildiğini belirtir. Doğru negatif ve yanlış pozitif örneklerin toplamı negatif örneklerin sayısına eşittir. Benzer şekilde yanlış negatif ve doğru pozitif örneklerin toplamı da pozitif örneklerin sayısına eşittir.

Karmaşıklık matrisi yardımıyla hesaplanan metrikler ve hesaplanma formülleri Çizelge 2.2’de verilmiştir.

**Çizelge 2.2.** Sınıflandırma metrikleri ve metriklerin formülleri. (DP = doğru pozitif, DN = doğru negatif, YP = yanlış pozitif, YN = yanlış negatif).

Metrik İsmi	Formül
Accuracy (doğruluk)	$(DP + DN) / (DP + DN + YP + YN)$
Precision (hassasiyet)	$DP / (DP + YP)$
Recall (Hatırlama = doğru pozitif oranı)	$DP / (DP + YN)$
Specifity (doğru negatif oranı)	$DN / (DN + YP)$
F1 skoru	$2 * Hassasiyet * Hatırlama / (Hassasiyet + Hatırlama)$

Doğruluk skoru, doğru tahmin sayısının toplam tahmin sayısına bölünmesi ile hesaplanmaktadır. Bu skorun sonucu 100 ile çarpılarak yüzde kaç doğru tahminleme yapıldığı bilgisi elde edilebilir.

Kullanılan veri setinin dengesiz olması durumunda doğruluk skoru, modelin performansını uygun olarak yorumlayamamaktadır. Bu nedenle sadece doğruluk skoru yerine F1 skoru kullanılması daha doğru sonuç vermektedir (Abdelhafiz et al., 2019). Dengesiz veri setlerinde bir sınıfa ait örnekler diğer sınıftan çok fazladır. Bu durumda, tüm örnekler en sık kullanılan sınıf olarak tahmin edilse

bile, yüksek bir doğruluk skoru elde edilir. Aslında modelin öğrenme başarısı düşüktür. Çünkü azınlık sınıfın örnekleri doğru olarak tahmin edilmemiştir. Bu sebepten dolayı her bir sınıfa ait hassasiyet ve hatırlama skorları hesaplanmalıdır.

Hatırlama skoru ise, model tarafından doğru şekilde tahmin edilen bir sınıftan numunelerin kesri olarak tanımlanır.

Üzerinde çalışılan sınıflandırma problemine göre, hatırlama veya hassasiyet skorlarına daha yüksek öncelik verilmek istenebilir. Fakat hem hatırlama skoru hem de hassasiyet skorunun önemli olduğu birçok uygulama vardır. Bu nedenle, bu ikisini tek bir ölçümde birleştirdiği F1 skoru kullanılabilir. F1 skoru hassasiyet ve hatırlama skorlarının harmonik ortalaması ile hesaplanır.

Yapay zeka sınıflandırma modellerinin çoğu olasılık çıkararak tahminleme yapmaktadır. Yani modeller örneklerin bir sınıfa ait olma olasılığını tahmin etmektedir. Model, bir veri örneği için tahmin etmiş olduğu olasılık değerini belirlenen kesme eşiğiyle karşılaştırır. Eğer olasılık değeri eşikten büyük eşitse etiketini pozitif sınıf olarak, aksi takdirde negatif sınıf olarak tahmin eder. İkili sınıflandırma problemi için genellikle 0.5 eşik değeri kullanılmaktadır (Freeman and Moisen, 2008). Tez kapsamında da karmaşıklık matrisi oluşturulması aşamasında 0.5 eşik değerinin kullanılması amaçlanmıştır.

AUC skoru Alıcı Çalışma Karakteristiği Eğrisi (Receiver Operating Characteristic Curve – ROC Curve) yardımıyla hesaplanmaktadır. ROC eğrisi, bir ikili sınıflandırıcının performansını kesme eşiğinin bir fonksiyonu olarak gösteren bir grafikdir. Çeşitli eşik değerleri için yanlış pozitif karşı gerçek pozitif oranını göstermektedir. AUC skoru, ROC eğrisinin altındaki alanı hesaplar ve bu nedenle 0 ile 1 arasındadır. Genellikle AUC skoru 1'e ne kadar yakın olursa başarı o kadar yüksektir.

Tez kapsamında, bahsedilen ilgili metrikler kullanılarak modelin performansı hakkında daha ayrıntılı yorum yapılması amaçlanmıştır.

### 3. GEREÇ VE YÖNTEM

#### 3.1 Kullanılan Veri Seti

Tez çalışmasında CBIS-DDSM veri seti kullanılmıştır. Bu veri seti, esasen bilgisayar destekli tespit ve teşhis sistemleri ile kullanılarak, radyologların mamografi görüntülerini yorumlamasına yardımcı olmak amacıyla oluşturulmuştur.

CBIS-DDSM veri seti, diğer mamografi veri setlerinde bulunan küçük veri seti boyutu ve tutarsız veri kaynakları sorunlarını çözmek amacıyla geliştirilmiştir. Bu amaç doğrultusunda, literatürde birçok çalışmada kullanılmış olan DDSM adlı veri setinin çeşitli sorunları çözülerek, daha güncel bir veri seti yaratılmıştır (Lee et al., 2017).

Orijinal DDSM veri setinde 2620 adet taranmış film mamografi görüntüsü bulunmaktadır. Bu veri seti doğrulanmış patoloji bilgisine sahip normal, iyi huylu ve kötü huylu vakalar içermektedir. Veri setindeki mamografi görüntüleri Massachusetts General Hospital, Wake Forest University School of Medicine, Sacred Heart Hospital ve Washington University of St. Louis School of Medicine kurumlarından elde edilen görüntülerinin birleştirilmesi ile elde edilmiştir (Heath et al., 1998).

Fakat DDSM veri setinde özellikle ROI ek açıklamaları gibi bazı bilgiler tam ve doğru değildir. Ayrıca görüntülere ait belirli bilgilere erişmek zordur. CBIS-DDSM veri seti ise, DDSM'in bu sorunlarını çözerek, veri setini daha erişilebilir kılmaktadır (Lee et al., 2017).

CBIS-DDSM veri seti, DDSM görüntülerine ait ROI bölütlemelerini güncellemiş ve meta verileri daha erişilebilir olması için yeni bir format haline getirerek düzenlemiştir. Ayrıca DDSM veri setindeki ROI ek açıklamaları doğru olmayan 339 adet görüntü çalışma dışı bırakılmıştır. Düzenleme işlemi yapılırken tüm görüntüler, medikal görüntülerde bir standart olarak kullanılan DICOM formatına dönüştürülmüştür (Lee et al., 2017). Tez metninde önceden bahsedildiği üzere çoğu çalışma, mamografi görüntülerinin tamamını kullanmak yerine sadece anormalliğin bulunduğu bölgeyi (ROI görüntülerini) kullanmaktadır. CBIS-DDSM bu durumu değerlendirerek, mamografi görüntüsünden kesilerek oluşturulmuş ROI görüntülerini hazır bir şekilde, ilgili mamografi görüntüleri ile

ilişkilendirerek, sunmaktadır. İlgili bölgenin kesilme (kırpma) işlemi, anormalliğin bulunduğu sınırlayıcı dikdörtgen dikkate alınarak yapılmıştır. Ayrıca tüm veri seti eğitim ve test olmak üzere iki alt veri setine bölünmüştür. Eğitim ve test seti bölümlenmesi yapılırken görüntülerin BI-RADS kategorisi, hangi rutin tarama görüntüsü tipinde olduğu (MLO ya da CC) bilgileri dikkate alınmıştır (Lee et al., 2017). Bu şekilde, literatürdeki yapay zeka uygulamalarında alınan sonuçlarda benzer veri seti ayrımı kullanılarak daha rahat karşılaştırma yapılabilecektir.

Bu teze en benzer çalışmada (Medeiros et al., 2020) CBIS-DDSM veri setine ait BI-RADS 3 ve BI-RADS 4 görüntülerini kullanırken eğitim veri seti boyutu tüm veri setinin %80'i ve test veri seti boyutu kalan %20'lik kısım olarak belirlenmiştir. Fakat çalışmada CBIS-DDSM'e ait orijinal eğitim ve test veri seti ayrımının kullanıldığı bilgisi bulunmamaktadır. Petrini et al. (2021), CBIS-DDSM veri setinin rastgele eğitim-test seti ayrımıyla kullanılmasının ön yargıya bağlı sonuçlar oluşturacağı vurgulanmıştır. Yazarlar, CBIS-DDSM'e ait orijinal ayrım kullanılmadığında, 5 farklı rastgele eğitim-test ayrımı için sınıflandırma AUC skorunun 0.90'dan 0.99'a kadar değiştiğini gözlemlemiştir. Ayrıca CBIS-DDSM veri setine ait orijinal ayrımın kullanılması durumunda AUC skorunda büyük bir düşüş yaşandığını belirtilmiştir. Ayrıma bağlı bir sonuç elde edilmemesi adına tez çalışması kapsamında orijinal veri seti ayrımının kullanılması amaçlanmıştır.

Sonuç olarak, CBIS-DDSM veri setinde toplam 10.239 adet görüntü bulunmaktadır. Ayrıca, toplamda 753 adet kalsifikasyon ve 891 adet kitle anormalliği içermektedir (Lee et al., 2017).

### 3.2 Kullanılan Teknolojiler

Tez kapsamında programlama dili olarak Python (versiyonu 3.8) ve Python'a ait hazır kütüphaneler kullanılmıştır. Kullanılan hazır kütüphanelerin isimleri pandas, cv2 (open cv), os, numpy, matplotlib, pydicom, shutil, tensorflow.keras, sklearn (scikit learn)'dir.

Veri setinin indirilmesinde Ulusal Biyomedikal Görüntüleme Arşivi (National Biomedical Imaging Archive – NBIA) Data Retriever adlı yazılım ve derin öğrenme modelinin eğitilmesinde kaggle.com sitesi tarafından sunulan GPU kaynakları kullanılmıştır.

Tüm kütüphanelerin ve yazılımların hangi aşamada, nasıl kullanıldığı bilgisi tez metninin ilerleyen bölümlerinde açıkça anlatılmıştır.

### 3.3 Veri Setinin İndirilmesi

CBIS-DDSM veri seti, resmi sitesi (The Cancer Imaging Archive, 2022) üzerinden indirilmiştir. İndirme işleminde resmi sitede bulunan “.tcia” uzantılı bir dosya ve resmi site tarafından önerilen “NBIA Data Retriever” adlı bir yazılım kullanılmıştır. Ayrıca resmi sitede görüntülere ait tıbbi bilgileri içeren 4 adet Virgülle Ayrılmış Değerler (Comma Separated Values – CSV) dosyası bulunmaktadır. Bu dosyaların isimleri ve açıklamaları aşağıdaki Çizelge 3.1’te yer almaktadır.

Çizelge 3.1. CBIS-DDSM veri setine ait CSV dosyaları ve açıklamaları.

Dosya İsmi	Açıklama
Mass-Training-Description.csv	Anormallik tipi kitle olan ve eğitim veri setinde bulunan görüntülere ait bilgiler içerir.
Calc-Training-Description.csv	Anormallik tipi kalsifikasyon olan ve eğitim veri setinde bulunan görüntülere ait bilgiler içerir.
Mass-Test-Description.csv	Anormallik tipi kitle olan ve test veri setinde bulunan görüntülere ait bilgiler içerir.
Calc-Test-Description.csv	Anormallik tipi kalsifikasyon olan ve test veri setinde bulunan görüntülere ait bilgiler içerir.

Her bir CSV dosyasının içerdiği kolonlar ve bu kolonların anlamları hakkında ayrıntılı bilgi, CBIS-DDSM veri setine ait orijinal makalede (Lee et al., 2017) yer almaktadır.

İndirme yazılımı iki adet indirme seçeneği sunmaktadır. Bu seçeneklerden ilki açıklayıcı dizin adları, ikincisi ise sınıf dizin adı seçeneğidir

Tez çalışması kapsamında ROI görüntüleri ile bir sınıflandırma modeli eğitildiği için, CSV dosyalarındaki ROI görüntülerine ait dosya yollarını belirten

“cropped image file path” adlı kolon içeriği incelenmiştir. Bu inceleme sonucunda indirme yazılımındaki seçeneklerden, “cropped image file path” kolonu içeriğine benzer bir dosya dizini oluşturan seçeneğin sadece “sınıf dizin adı” olduğu fark edilmiştir. Fakat orijinal indirme yazılımının bu seçenekle kullanılması durumunda bile, belirtilen kolon içerisindeki dosya (dizin) yolları ile inen görüntülerin dosya yolları örtüşmemektedir. Bu yüzden tez kapsamında, CSV dosyaları üzerinde bir ön işleme çalışması yapılarak dosya yolları uygun hale getirilmiştir.

### 3.4 CSV Dosyaları Üzerinde Yapılan Ön İşleme Çalışmaları

CSV dosyaları üzerinde yapılan ön işleme çalışmalarında öncelikle “Mass-Training-Description.csv” adlı dosya ile “Calc-Training-Description.csv” adlı dosya birleştirilip, anormallik tipinden bağımsız olarak tek bir eğitim veri setinin oluşturulması amaçlanmıştır. Aynı işlem, “Mass-Test-Description.csv” ve “Calc-Test-Description.csv” adlı dosyalara da uygulanarak tek bir test veri setinin oluşturulması amaçlanmıştır.

Ardından yeni oluşan eğitim ve test veri setlerini belirten CSV dosyaları üzerinde, görüntülere ait BI-RADS sınıfını belirten kolon olan “assessment” kolonu aracılığı ile “BI-RADS 3” ve “BI-RADS 4” görüntüleri filtrelenmiştir. Bu şekilde iki adet dosyada da sadece BI-RADS sınıfı 3 veya 4 olan görüntülere ait bilgilerin bulunması amaçlanmıştır. Filtreleme sonucunda her bir veri setinde bulunan görüntü sayıları ve veri setlerinin ilgili BI-RADS sınıfına ait kaç adet görüntü içerdiği bilgisi Çizelge 3.2’te yer almaktadır.


**Çizelge 3.2.** CBIS-DDSM eğitim ve test veri setinde bulunan BI-RADS örnek sayıları ve toplamları.

	Test Veri Seti	Eğitim Veri Seti	Toplam
<b>BI-RADS 3 Görüntü Sayısı:</b>	109	368	<b>477</b>
<b>BI-RADS 4 Görüntü Sayısı:</b>	347	1286	<b>1633</b>
<b>Toplam</b>	<b>456</b>	<b>1654</b>	

Eđitim ve test veri setlerindeki BI-RADS 4 sınıfına ait veri sayısı BI-RADS 3'ten neredeyse 3,5 kat fazladır (Bkz. Çizelge 3.2). Bu durum tez kapsamında kullanılacak veri setinin dengesiz bir veri seti olduđunu belirtmektedir. Bu yüzden, derin öğrenme modeli eğitimi aşamasında dengesiz veri setleri ile ilgili yöntemlerden sınıf ağırlıklarının kullanılmasına karar verilmiştir.

Filtreleme işlemi sonrasında “cropped image file path” kolonundaki dosya yolu bilgilerinin düzenleme işlemi yapılmıştır. CSV dosyalarında bulunan bu kolondaki dosya yolları, indirilen dosyalarda görüntünün adına kadar doğru olarak eşleşmektedir. Fakat DICOM görüntülerine ait dosya adları resmi sitede önerilen yazılım ile indirildiğinde farklı gelmektedir. CSV dosyalarında görüntü adları “000001.dcm” ve “000000.dcm” şeklinde iken, indirilen dosyaların adları “1-1.dcm” veya “1-2.dcm” şeklindedir. Bu dosyalardaki “.dcm” uzantısı, dosya tipinin DICOM dosyası olduğunu belirtmektedir.

Ayrıca, indirilen veri setinde bulunan diđer bir sorun ise, “1-1.dcm” ya da “1-2.dcm” dosyalarından hangi dosyada ROI görüntüsünün olduğunu bilinmemesidir. Bu durumda belirli görüntüler için CSV dosyalarındaki dosya yolları yanlıştır. “1-1.dcm” ve “1-2.dcm” adlı görüntülerden birinde ROI görüntüsü bulunurken diđer görüntüde ise maske görüntüsü bulunmaktadır. Şekil 3.1’de “Calc-Training\_P\_00005\_RIGHT\_CC” adlı BI-RADS 3 olarak etiketlenmiş mamografi görüntüsüne ait ROI görüntüsü ve maske görüntüleri örnek olarak gösterilmiştir.



Şekil 3.1. CBIS-DDSM BI-RADS 3 örnek görüntüsü a) Tam mamografi, b) Maske, c) ROI.

Maske görüntüsü tam mamografi boyutu ile eşit büyüklüktedir. Kırılmamış görüntü olan maske görüntülerinde anormallik içeren bölgeye ait piksel değerleri 255 (beyaz), geri kalan piksellerin değeri ise 0 (siyah) olarak ayarlanmıştır. Bu bilgi, dosya yolları düzenlenirken hangi görüntünün ROI görüntüsü olduğunu öğrenmek amacıyla kullanılmıştır.

Öncelikle CSV dosyalarındaki tüm hatalı görüntü adları “1-1.dcm” olarak değiştirilmiştir. Ardından tüm “1-1.dcm” adlı DICOM görüntüleri, pydicom kütüphanesi yardımı ile okunmuş ve numpy kütüphanesi yardımı ile maske görüntüsü olup olmadığı kontrol edilmiştir.

Bu kontrol yapılırken, pydicom kütüphanesi ile okunan dosya içerisindeki görüntü bir numpy dizisine dönüştürülmüştür. Dicom görüntülerinde piksellerin değeri 0 ile  $2^{16}-1$  değerleri arasında değişmektedir. Öncelikle tüm piksellerin 0 ile 255 ( $2^8-1$ ) arasına yeniden ölçeklendirilmesi sağlanmıştır. Ardından her bir piksel değerinin frekansı (görüntü içerisinde kaç adet yer aldığı) bulunmuştur ve bir numpy dizisi değişkenine atılmıştır. Maske görüntülerinde 0 ile 255 değerine sahip pikseller haricinde başka bir değer bulunmamaktadır. Bu yüzden örneğin 5 değerine sahip piksel değerinin frekansı 0 olarak gelecektir. Kontrol aşamasında ise, frekans dizisi değişkeninin ilk ve sonuncu (0. ve 255.) indeksteki elemanları haricindeki elemanları alınıp, tamamı 0 olan bir numpy dizisi ile eşitliği kontrol edilmiştir. Eşit ise maske görüntüsü olduğu, eşit değil ise ROI görüntüsü olduğu bulunmuştur. Eğer maske görüntüsü ise, dosya yolundaki görüntü ismi “1-2.dcm” olacak şekilde değiştirilmiştir.

Sonuç olarak, tüm dosya yollarının ROI görüntülerini belirtecek şekilde düzenlenmesi başarıyla yapılmıştır.

### 3.5 Görüntü İşleme

Görüntüler matrisler ile temsil edilmektedir. Her bir matris elemanı da bir piksele karşılık gelmektedir. Normalde 3 çeşit görüntü tipi vardır. İlki siyah beyaz (ikili) görüntüdür. Bir kenarının büyüklüğü N boyutunda, diğer kenarının büyüklüğü ise M boyutunda bir matris düşünülürse, bu tip görüntülerde N x M'lik matrisin elemanları 0 ve 1'lerden oluşmaktadır. 0 siyahı 1 ise beyazı temsil etmektedir. Bir diğer görüntü tipi olan gri tonlamalı görüntülerde genellikle 0-255 arası değerler vardır. Fakat DICOM görüntülerinde yoğunluklar daha büyük bir aralıkta bulunabilmektedir. Burada 0 siyahı 255 ise beyazı temsil etmektedir.

Aradaki deęerler grinin tonlarını temsil etmektedir. Üçüncü tip olan renkli görüntülerde ise görüntünün kırmızı, yeşil ve mavi renklerinin yoğunluklarını temsil eden 3 kanaldan oluştuęu düşünülür. Sonuç olarak 3 adet  $N \times M$ 'lik matris arka arkaya eklendięi için  $N \times M \times 3$  boyutunda bir matris oluşmuş olur. Burada her bir piksel 3 kanaldaki yoğunluklar ile belirlenir. Yani kırmızı kanaldaki yoğunluk deęeri 120, yeşil kanaldaki yoğunluk deęeri 215 ve mavi kanaldaki yoğunluk deęeri 0 olan bir piksel (120, 215, 0) ile temsil edilir.

Tüm dosya yolları düzeltildikten sonra, iki CSV dosyasındaki (eęitim ve test) “cropped image file path” kolonunda belirtilen görüntüler üzerinde ön işleme adımları uygulanmıştır. Test verilerine ait DICOM dosyalarının okunup Taşınabilir Ağ Grafikleri (Portable Network Graphics – PNG) formatına dönüştürülmesi sağlanmıştır. Eęitim verilerinde ise test verilerindeki işlemin yanı sıra CLAHE ile veri iyileştirme ve veri artırımı yapılmıştır.

Görüntü ön işleme adımlarında tek bir görüntü için sırasıyla belirli adımlar izlenmiştir. Bu adımların ilkinde, görüntünün indirilmiş olduęu konumdaki DICOM dosyası pydicom kütüphanesi yardımıyla açılıp, dosya bir python deęişkenine atanmıştır. Ardından DICOM deęişkeninin “pixel\_array” özellięi yardımı ile görüntünün numpy dizisi hali elde edilmiştir. Bu numpy dizisi bir gri tonlamalı görüntüyü temsil etmektedir. Bu numpy dizisinin her bir elemanının deęeri, 0 ile  $2^{16}-1$  arasında deęişmektedir (her bir eleman uint16 tipinde veri içermektedir). Öncelikle bu numpy dizisi uint8 tipinde veri tutacak hale dönüştürülmüştür.

Transfer öğrenme aşamasında renkli görüntülere ihtiyaç duyulmaktadır. Çünkü kullanılacak CNN modeli ImageNet veri tabanındaki renkli görüntüler ile eğitilmiştir ve dolayısıyla model renkli görüntüleri alacak şekilde inşa edilmiştir. Bu nedenden dolayı tüm görüntüler (numy dizileri) renkli görüntü formatına dönüştürülmüştür. Renkli görüntüye dönüştürme aşamasında üç renk kanalından (kırmızı, yeşil, mavi) her birine gri tonlamalı görüntü konulmuştur. Bu işlem, gri tonlamalı görüntünün 3 kez art arda eklenmesi ile aynı anlamı taşımaktadır. Bu işlemin yapılmasında numpy kütüphanesinden yararlanılmıştır.


Sadece eęitim verilerinde bulunan görüntülere (numpy dizilerine) renkli görüntüye dönüştürülmeden önce CLAHE uygulanmıştır. CLAHE uygulamak için cv2 kütüphanesindeki “createCLAHE” metodu ile bir deęişken oluşturulup deęişken üzerinde “apply” metodu çağırılmış ve bu metoda ilgili görüntü

parametre olarak verilmiştir. Bir CLAHE değişkeni oluşturulması aşamasında 2 adet parametre belirlenmelidir. Bunlardan ilki olan “clipLimit” parametresi için “2.0” değeri belirlenmiştir. İkinci parametre olan “tileGridSize” için ise 3 farklı değer belirlenmiştir. 3 farklı değer sırasıyla “(2,2)”, “(4,4)” ve “(8,8)” olarak seçilmiştir. 3 farklı değer kullanılmasıyla, yani aynı görüntüye 3 farklı CLAHE değişkeni uygulanması ile, 3 adet farklı kontrastta görüntü elde edilmiştir. Bu üç görüntüden en yüksek kontrasta sahip görüntü, kafes (grid) boyutu 2 ( yani “tileGridSize” parametresi “(2,2)”) olan görüntüdür. En düşük kontrasta sahip görüntü ise kafes boyutu 8 olan görüntüdür. Ardından renkli görüntüye dönüştürme işlemi yapılmıştır.


CLAHE işleminin uygulanması sonucunda toplamda 4 adet farklı görüntü oluşmuştur. Bu görüntülerden ilki belirli dosya yolundaki DICOM dosyasının okunması ile elde edilen orijinal görüntü, diğer üçü ise CLAHE yöntemi kullanılarak görüntü iyileştirilmesi ile elde edilen görüntülerdir.

Ardından artık renkli görüntü formatında olan tüm görüntüler cv2 kütüphanesi yardımıyla PNG görüntüsü olarak kaydedilmiştir. PNG dosyasına kaydetme işlemi, her bir pikselin değeri 0 ile 255 değerlerinden 0 ile 1 arasına çekilmiştir. Bu işlem ile her bir görüntünün normalleştirilmesi de sağlamıştır. Bu şekilde, derin öğrenme modeli eğitimi öncesinde görüntülerin piksellerini 255’e bölerek ayrı bir normalleştirme işlemi uygulamaya gerek kalmayacaktır.

Şekil 3.2’te kalsifikasyon anormallik tipi için, Şekil 3.3’te ise kitle anormallik tipi için oluşan 4 adet PNG dosyalarından örnekler gösterilmiştir



**Şekil 3.2.** CBIS-DDSM kalsifikasyon örnek görüntüsü üzerinde ön işleme a) orijinal PNG, b) CLAHE kafes boyutu 8, c) CLAHE kafes boyutu 4, d) CLAHE kafes boyutu 2.



**Şekil 3.3.** CBIS-DDSM kitle örnek görüntüsü üzerinde ön işleme a) orijinal PNG, b) CLAHE kafes boyutu 8, c) CLAHE kafes boyutu 4, d) CLAHE kafes boyutu 2.

CLAHE ile veri setindeki görüntüler üzerinde kontrastı daha yüksek ve net görüntüler elde edilmiştir. CLAHE yardımıyla kalsifikasyon ve kitleler daha net görülmektedir.

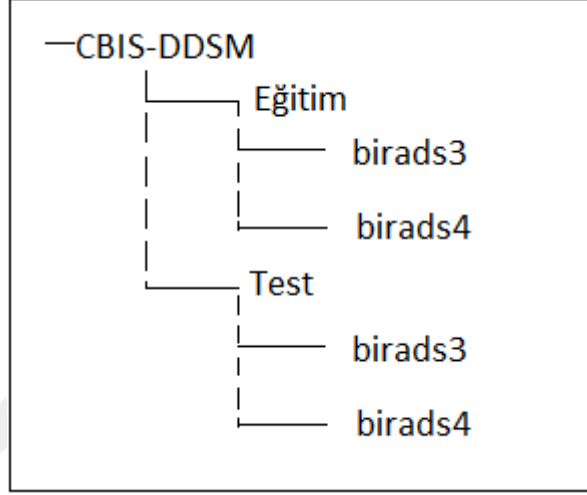
### 3.6 Veri Setinin Düzenlenmesi

Görüntü ön işleme sonucunda oluşan yeni dosyaların adları yardımıyla eğitim ya da test setine aitlikleri kontrol edilerek uygun klasörlere yerleştirilmesi sağlanmıştır. Sonuç olarak orijinal ve işlenmiş verilerle eğitim ve test setleri oluşturulmuştur.

Eğitim veri seti boyutu, CLAHE uygulanmamış (orijinal) görüntü ve CLAHE uygulanmış görüntüler ile 4 katına çıkmıştır. Bu durum CLAHE ile veri artırımı gerçekleşmesini sağlamıştır. Dolayısıyla eğitim veri seti 1654 görüntü yerine 6616 adet görüntü içermektedir. Test veri seti boyutu 456 adet görüntü ile aynı kalmıştır.

Derin öğrenme modeli eğitimi aşamasında görüntülerin model tarafından okunmasında “tensorflow.keras.preprocessing.image” kütüphanesinin içerisinde bulunan “ImageDataGenerator” sınıfı kullanılmasına karar verilmiştir. Bu sınıf yardımıyla görüntülerin bir klasörden okunması ve veri artırımı yöntemleri uygulanabilmektedir. Görüntülerin klasörden okunmasında bu sınıfın içerisindeki “flow\_from\_directory” metodu kullanılmıştır. Bu metot görüntülere ait dosya yollarının belirli bir formatta düzenlenmesini zorunlu kılar. Dolayısıyla görüntüler okuma işleminden önce, formata uymak adına düzenlenmiştir. Formata göre, görüntüler eğitim ve test klasörlerine ayrılmalıdır. Bu iki klasörün altında ise sınıf

sayısı kadar klasör bulunmalı ve ilgili sınıfa ait görüntüler bu alt klasörlere yerleştirilmelidir. Tez kapsamında iki adet sınıf bulunduğu için eğitim ve test klasörlerinin altında “birads3” ve “birads4” adında iki alt klasör oluşturulup, ilgili görüntüler filtrelenerek shutil kütüphanesi yardımıyla bu klasörlere taşınmıştır. Şekil 2.5 veri setinin son haline ait klasör şeması gösterilmiştir.



Şekil 3.4. Düzenlenmiş veri seti klasör şeması.

### 3.7 Derin Öğrenme Modeli

Derin öğrenme modellerinin eğitimi uzun süreler aldığı için GPU kullanımı oldukça önemli bir yer tutmaktadır. Bu sebeple tez çalışmalarını gerçekleştirmek amacıyla Google şirketi tarafından desteklenen, “www.kaggle.com” sitesi kullanılmıştır. Kaggle (Kaggle Inc., 2022), veri bilimi ve makine öğrenmesi konularında çalışan kişilere GPU ve TPU hizmeti haricinde, bünyesinde bulundurduğu açık veri setlerini kullanma gibi birçok imkân sağlamaktadır. Ayrıca ilgili modellerin geliştirilmesi için python ve R adlı programlama dillerini çalıştıran uygun ortamları sağlamaktadır.

Tez çalışmalarında derin öğrenme modelinin geliştirilmesi için python programlama dili kullanılmıştır. Veri setinin düzenlenmesi tamamlandıktan sonra, tüm görüntüleri içeren CBIS-DDSM adlı ana klasör (Bkz. Şekil 3.4) Roşal Arşivi (Roshal Archive- RAR) formatında sıkıştırılıp Kaggle sitesine yüklenmiştir. Ardından teze ait kodların çalıştırılabilmesi için Kaggle üzerinde “.ipynb” uzantılı bir adet interaktif python dosyası oluşturulmuştur. Son olarak, yüklenen veri seti

bu python dosyasına girdi olacak şekilde ayarlanmıştır. Bu şekilde yazılan kodlar aracılığı ile görüntülere erişim sağlanabilecektir.

Verilerin okunmasında “tensorflow.keras.preprocessing.image” kütüphanesinin içerisinde bulunan “ImageDataGenerator” sınıfı kullanılmıştır. Öncelikle hem eğitim veri seti için hem de test veri seti için bir ImageDataGenerator nesnesi oluşturulmuştur. Eğitim seti için kullanılacak nesne yaratılırken hangi veri artırımı yöntemlerinin kullanılacağı belirlenmiştir. Veri artırımı yöntemlerinden yatay ve dikey ekseninde çevirme yöntemleri kullanılmıştır. Nesne oluşturulması aşamasında genellikle eğitim ve test verilerin normalleştirilmesi de yapılabilmektedir. Fakat görüntülerin normalleştirilmesi önceki aşamalarda yapıldığı için sadece veri artırımı yöntemleri kullanılmıştır. Daha sonra ise görüntüler 512x512 boyutunda, renkli görüntü formatında, eğitim ve test veri setlerine ait dosya yolları aracılığı ile okunmuştur.

Veri setinde bir dengesizlik bulunduğu için model eğitiminde ağırlıklı eğitim yapılmasına karar verilmiştir. Bu amaçla sklearn kütüphanesi yardımıyla veri setine ait sınıf ağırlıkları hesaplanmıştır. Hesaplama sonucu BI-RADS 3 sınıfının ağırlığı 2.247, BI-RADS 4 sınıfının ağırlığı ise 0.643 olarak belirlenmiştir.

Ardından transfer öğrenme ile model eğitimi gerçekleştirmek amacıyla VGG16 (Simonyan and Zisserman, 2014) modeli, modelin en sonunda bulunan sınıflandırıcı katmanlar dahil edilmeden ImageNet (Russakovsky et al., 2015) veri setinde eğitilmiş ağırlıkları ile indirilmiştir. Ek 1.1’de indirilen VGG16 modeline ait özet yer almaktadır. İndirme işleminde modelin, tez çalışmasındaki görüntüler ile aynı boyutlarda görüntü kullanabilmesi için girdi boyutu (512, 512, 3) olarak ayarlanmıştır. Bu durum “input\_1” adlı katmanda görülebilmektedir. 3 sayısı renkli görüntülerdeki kanal sayısını temsil etmektedir. Sınıflandırma katmanı bulunmuyorken VGG16 modeline ait parametre sayısı 14.714.688 adettir (Bkz. Ek 1.1.). Ve bu parametrelerden (ağırlıklardan) hiçbirinin eğitime katılmayacağı bilgisi, eğitilebilir parametre sayısını belirten “Trainable params”ın yanında 0 olması ile belirtilmektedir.

Model eğitiminin ilk aşamasında öznetelik çıkartımı yöntemi izlenmiştir. Bu amaçla transfer edilen modelin, yani VGG16’nın tüm katmanları eğitime kapalı olarak bırakılmış ardından ise eğitime katılacak yeni katmanlar modele eklenmiştir. Ek 1.2’de bu yöntem ile oluşturulan modele ait özet yer almaktadır.

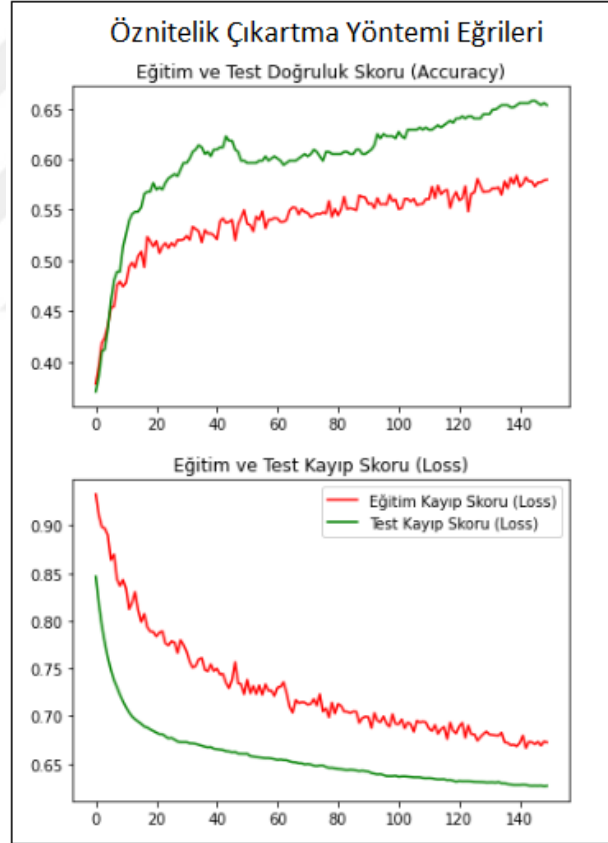
Model eğitimi sırasında kayıp fonksiyonu olarak “binary crossentropy”, grup boyutu olarak 64, optimizasyon algoritması olarak Adam, öğrenme oranı değeri için  $1e-6$ , bırakma katmanı oranı için 0.2, ve devir (epoch) sayısı 150 olarak seçilmiştir. Model eğitimi tamamlandıktan sonra ilgili grafiklerin ve raporların ekrana yazdırılabilmesi amacıyla takip edilen metrikler ise doğru pozitif, yanlış pozitif, doğru negatif, yanlış negatif, doğruluk skoru ve AUC olarak belirlenmiştir. Öznitelik çıkartma yöntemiyle eğitilecek, yeni katmanlardan kaynaklanan, parametre sayısı 147.841’dir.

Öznitelik çıkartma aşaması tamamlandıktan sonra ince ayar yöntemi ile transfer öğrenme yapılmıştır. Bu amaçla transfer edilen VGG16 modelindeki son 6 katman eğitime açılmıştır. Ek 1.3’te ince ayar yöntemi ile oluşturulan modele ait özet görülmektedir. VGG16’ya ait son 6 katmanın açılması ile eğitilebilen parametrelerin sayısı 147.841’den 9.587.073’e çıkmıştır.

İnce ayar aşamasında öznitelik çıkartımı aşamasında farklı olarak, öğrenme oranı parametresi  $1e-7$  olarak değiştirilmiş (küçültülmüş) ve 300 devir daha eğitim gerçekleştirilmiştir.

#### 4. SONUÇ

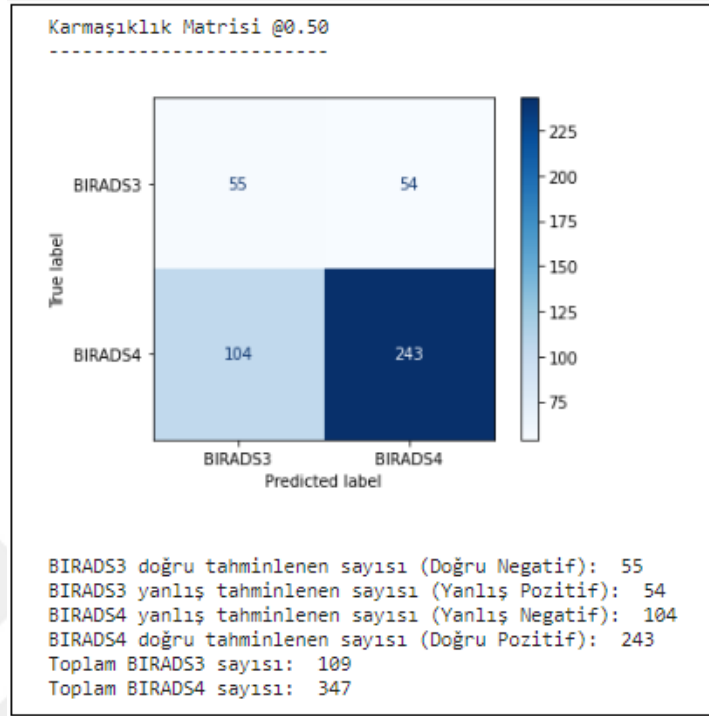
150 devir boyunca, öznitelik çıkartma yöntemi ile eğitilen model eğitimin sonuna doğru yakınsamıştır. Bu durum eğitimin sonuna yaklaşıldığında eğrilerde gerçekleşen düzleşmeden (hızlı artış ya da azalış olmaması durumundan) anlaşılmaktadır. Eğitim ve test verileri için doğruluk skoru ve kayba ait eğrileri gösteren grafikler Şekil 4.1’de gösterilmiştir. Bu grafiklerde kırmızı renkteki eğriler eğitim verileri ile alınan sonuçları gösterirken yeşil renktekiler ise test verileri ile alınan sonuçları göstermektedir. Ayrıca grafiklerdeki x eksenleri devir sayısını, y eksenleri de doğruluk skoru ve kayıp değerini belirtmektedir. 150 devir sonucu test doğruluk skoru 0.6535, test kayıp değeri 0.6267 ve test AUC skoru 0.6696 değerinde sabitlenmiştir.



Şekil 4.1. Öznitelik çıkartma yöntemi ile eğitim sonucu oluşan eğriler.

Şekil 4.2’de test verilerine ait karmaşıklık matrisi görülmektedir. İkili sınıflandırma işlemi varsayılan olarak 0.5 eşik değeri kullanılarak yapılmıştır. 150 devir sonucunda model, 109 adet BI-RADS3 test verisinden 55 adedini doğru

sınıflandırmıştır. Ayrıca 357 adet BI-RADS4 test verisinden 243 adedini doğru sınıflandırmıştır.



Şekil 4.2. Öznitelik çıkartma yöntemi ile eğitim sonucu oluşan karmaşıklık matrisi.

Karmaşıklık matrisi yardımı ile hesaplanan diğer sınıflandırma metrikleri ise Şekil 4.3'te yer almaktadır.

Ayrıntılı Sınıflandırma Raporu

	precision (hassasiyet)	recall (hatırlama)	f1-score (f1 skoru)	support (örnek sayısı)
BIRADS3	0.35	0.50	0.41	109
BIRADS4	0.82	0.70	0.75	347
Doğruluk Skoru (Accuracy)	0.65			
AUC Skoru	0.67			

Şekil 4.3. Öznitelik çıkartma yöntemi ile eğitim sonucu oluşan ayrıntılı sınıflandırma raporu.

Metrikler virgülden sonra 2 rakam yazdırılacak şekilde basılmıştır. Sınıflar özelinde performansı gösteren diğer metrikler ise “hassasiyet”, “hatırlama” ve “f1 skoru” başlıkları altında yer almaktadır. “örnek sayısı” başlığı altında ise ilgili

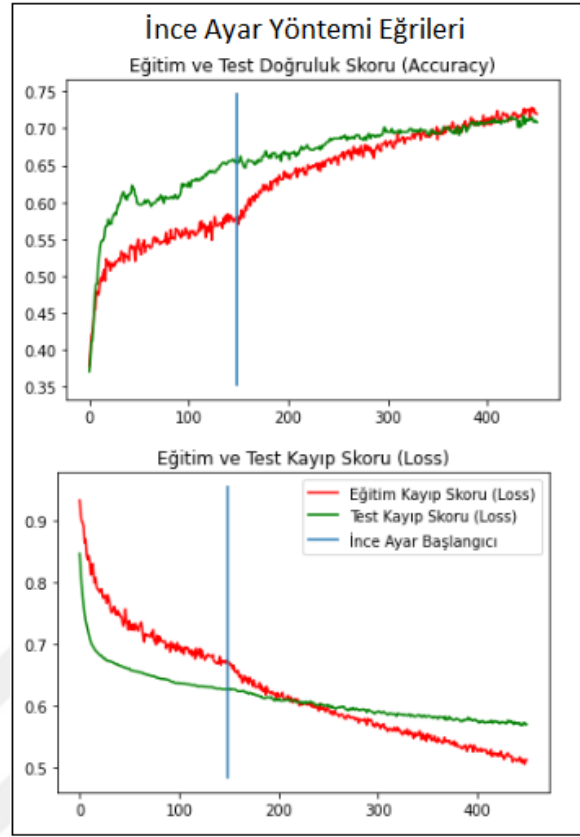
sınıftan kaç adet veri olduğu bilgisi bulunmaktadır. Tez kapsamında kullanılan veri seti dengeli bir veri seti olmadığı için her iki sınıf için de f1 skorunun 1'e yakın olması önem taşımaktadır. Öznitelik çıkartma yöntemi sonucunda BI-RADS3 sınıfı için f1-skoru 0.41, BI-RADS4 sınıfı için ise 0.75 olarak elde edilmiştir.

Öznitelik çıkartmada modelin yakınsamasının ardından aynı model üzerinde 300 devir boyunca ince ayar yöntemi ile eğitim gerçekleştirilmiştir. İnce ayar eğitimi sonrasında alınan test doğruluk skoru 0.6535'ten 0.7083'e çıkmıştır. Toplam 450 devir sonucunda test kayıp değeri 0.5697, test AUC skoru ise 0.7239 olarak elde edilmiştir.

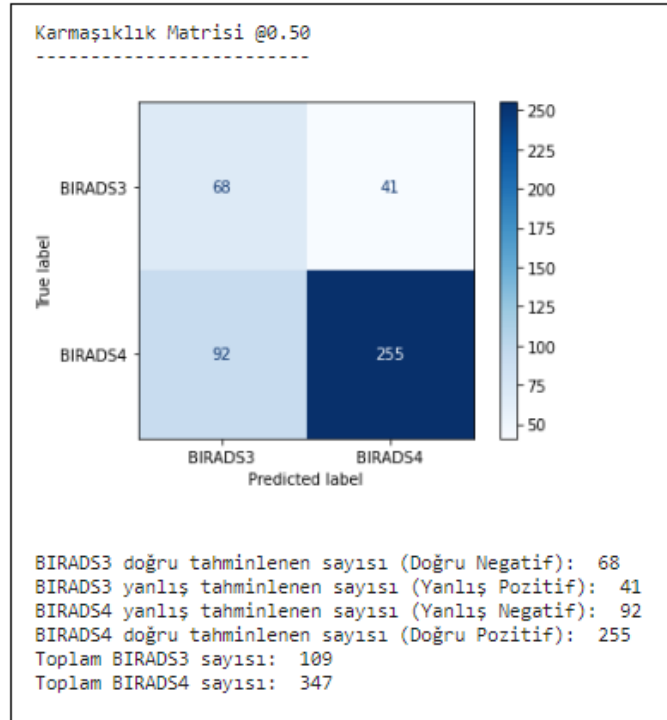
İnce ayar yöntemi ile eğitim esnasında, eğitim ve test verileri için doğruluk skoru ve kayba ait değişimi gösteren grafikler Şekil 4.4'te verilmiştir. Bu grafiklerde, test ve eğitim setleri için öznitelik çıkartma yöntemi ile aynı renkler ve aynı anlamdaki eksenler kullanılmıştır. Grafiklerde bulunan mavi dikey çizgi ince ayar yönteminin başlatıldığı devir sayısını belirtmektedir. Dikey çizginin solunda kalan eğriler ilk 150 devri belirtmektedir. Bu sebeple öznitelik çıkartma yöntemdeki grafikler ile aynıdır. Dikey çizginin sağında kalan eğriler ise ince ayar ile eğitimdeki eğrileri belirtmektedir.

Toplamda 450 devir süren eğitim sonucunda eğitim seti doğruluk skoru, test seti doğruluk skorunu geçmiştir. Ayrıca eğitim kaybını belirten eğride düzenli bir iniş olmasına rağmen test kaybını belirten eğri düzleşmiştir. Bu da daha fazla eğitim gerçekleşmesi dahilinde ezberlemenin başlayacağını belirtmektedir. Fakat ince ayar için 300 devir sayısının seçilmesi sonucu belirgin bir ezberleme gerçekleşmemiştir.

Şekil 4.5'te test verilerine ait ince ayar sonucu oluşan karmaşıklık matrisi görülmektedir. Öznitelik çıkartma yöntemine benzer şekilde ikili sınıflandırma işlemi varsayılan olarak 0.5 eşik değeri kullanılarak yapılmıştır. 300 devir sonucunda model, 109 adet BI-RADS3 test verisinden 68 adedini doğru sınıflandırmıştır. Ayrıca 357 adet BI-RADS4 test verisinden 255 adedini doğru sınıflandırmıştır.



Şekil 4.4. İnce ayar yöntemi ile eğitim sonucu oluşan eğriler.



Şekil 4.5. İnce ayar yöntemi ile eğitim sonucu oluşan karmaşıklık matrisi.

İnce ayar sonucu oluşan karmaşıklık matrisi yardımı ile hesaplanan diğer sınıflandırma metrikleri ise Şekil 4.6’da yer almaktadır.

Ayrıntılı Sınıflandırma Raporu				
	precision (hassasiyet)	recall (hatırlama)	f1-score (f1 skoru)	support (örnek sayısı)
BIRADS3	0.42	0.62	0.51	109
BIRADS4	0.86	0.73	0.79	347
Doğruluk Skoru (Accuracy)			0.71	
AUC Skoru			0.72	

Şekil 4.6. İnce ayar yöntemi ile eğitim sonucu oluşan ayrıntılı sınıflandırma raporu.

Sonuç olarak bu tez kapsamında CBIS-DDSM veri setinde bulunan BI-RADS 3 ve BI-RADS 4 sınıfına ait ROI görüntüleri ile sınıflandırma yapan bir CNN modeli eğitilmiştir. ROI görüntülerine CLAHE ile görüntü iyileştirme ve veri artırımı çalışması yapılmıştır. Model eğitimi aşamasında ise VGG16 modeli ImageNet veri tabanı ağırlıkları ile indirilip ardına küresel ortalama havuzlama katmanı, tam bağlı katmanlar ve bırakma katmanları bağlanmıştır. En sonda bulunan tam bağlı katmanda ise sigmoid fonksiyonu kullanılarak bir ikili sınıflandırma problemi çözülmüştür.

Tez çalışması ile literatürdeki en alakalı çalışma (Medeiros et al., 2020) karşılaştırıldığında, öznelik çıkartma yöntemi sonucunda elde edilen 0.65 doğruluk skoru ile, Medeiros et al.’ın (2020) öznelik çıkartma yöntemi ile elde etmiş olduğu 0.63 doğruluk skoru geçilmiştir. Doğruluk skorundaki yaklaşık 0.02’lik farkın VGG16 modelinin sonuna geleneksel bir makine öğrenmesi modeli bağlamak yerine tam bağlı katmanlar bağlanmasından ve yapılan görüntü ön işleme çalışmalarından kaynaklandığı düşünülmektedir. VGG16 modelinin öznelik çıkartma yöntemi ile eğitimi sonucunda ince ayar yöntemi ile eğitilmesiyle bu fark artarak modelin doğruluk skoru 0.71’e çıkmıştır.

## 5. ÖNERİLER

Bu tez çalışmasında CBIS-DDSM görüntüleri üzerinde transfer öğrenme yaklaşımları incelenirken meşhur CNN modellerinden VGG16 modeli, ImageNet veri seti ile eğitilmiş ağırlıklarıyla kullanılmıştır. Sentetik veri artırımı yöntemlerinden sadece yatay ve dikey ekseninde çevirme kullanılmıştır.

ImageNet veri seti köpek, kuş, araba ve bisiklet gibi doğal canlılara ve nesnelere ait görüntüleri içeren bir veri setidir. Transfer öğrenme yaklaşımının başarılı olabilmesi için kaynak ve hedef etki alanlarının oldukça benzer olması gerekmektedir. Mamografi görüntülerini içeren CBIS-DDSM veri seti ile ImageNet veri setindeki görüntülerin etki alanları çok benzememektedir. Tez çalışması kapsamında alınan sonuçlardan daha başarılı sonuçların elde edilebilmesi için tıp etki alanında hazırlanmış, CBIS-DDSM'e ait kullanılan toplam görüntü sayısından daha büyük boyuttaki bir veri setinde eğitilmiş modelin transfer edilmesi düşünülebilir. Özellikle mamografi görüntüleri, meme dokusu üzerine yoğunlaşmış röntgen görüntüleridir. Mamografi veya vücudun başka bölümleri için çekilmiş röntgen görüntülerini barındıran daha büyük bir veri seti aracılığı ile transfer öğrenme yapmak BI-RADS 3 ve BI-RADS 4 sınıflandırma problemi için daha başarılı bir model elde edilmesini sağlayabilir.

Tez kapsamında kullanılan transfer öğrenme yöntemleri, VGG16 dışındaki diğer meşhur CNN mimarileri ile kullanılabilir. Kullanılacak ilgili modeller farklı hiper parametreler ile optimize edilebilir. Ayrıca ilgili modellerin eğitimi sırasında sentetik veri artırımı yöntemlerinden yatay ve dikey ekseninde çevirme haricindeki diğer yöntemlerin de kullanımı sağlanarak daha büyük boyutta bir eğitim veri seti elde edilebilir. Bu şekilde daha başarılı sınıflandırma sonuçları elde edilebilir.

## KAYNAKLAR DİZİNİ

- Abdelhafiz, D., Yang, C., Ammar, R. and Nabavi, S.**, 2019, Deep convolutional neural networks for mammography: advances, challenges and applications, *BMC Bioinformatics*, 20(S11), 20p.
- Abdelrahman, L., Al Ghamdi, M., Collado-Mesa, F. and Abdel-Mottaleb, M.**, 2021, Convolutional neural networks for breast cancer detection in mammography: A survey, *Computers in Biology and Medicine*, 131 (104248), 16p.
- Akselrod-Ballin, A., Karlinsky, L., Alpert, S., Hashoul, S., Ben-Ari, R. and Barkan, E.**, 2019, A CNN based method for automatic mass detection and classification in mammograms, *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 7(3), 8p.
- Alsolami, A. S., Shalash, W., Alsaggaf, W., Ashoor, S., Refaat, H. and Elmogy, M.**, 2021, King Abdulaziz University Breast Cancer Mammogram Dataset (KAU-BCMD), *Data*, 6(11), 15p.
- Badano, A., Graff, C. G., Badal, A., Sharma, D., Zeng, R., Samuelson, F. W. and Myers, K. J.**, 2018, Evaluation of digital breast tomosynthesis as replacement of full-field digital mammography using an in silico imaging trial, *JAMA Network Open*, 1(7), 12p.
- Balleyguier, C., Ayadi, S., Van Nguyen, K., Vanel, D., Dromain, C. and Sigal, R.**, 2007, BIRADS™ classification in mammography, *European Journal of Radiology*, 61(2), 3p.
- Burt, J. R., Torosdagli, N., Khosravan, N., RaviPrakash, H., Mortazi, A., Tissavirasingham, F., Hussein, S. and Bagci, U.**, 2018, Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks, *The British Journal of Radiology*, 20170545, 11p.
- Calderon-Ramirez, S., Murillo-Hernandez, D., Rojas-Salazar, K., Elizondo, D., Yang, S. and Molina-Cabello, M.**, 2021, A real use case of semi-supervised learning for mammogram classification in a local clinic of costa rica, *ArXiv:2107.11696*, 17p.

**KAYNAKLAR DİZİNİ (devam)**

- Carneiro, G., Nascimento, J. and Bradley, A. P.**, 2015, Unregistered multiview mammogram analysis with pre-trained deep learning models, International Conference on Medical Image Computing and Computer-Assisted Intervention, 9p.
- Castiglioni, I., Rundo, L., Codari, M., Di Leo, G., Salvatore, C., Interlenghi, M. and Sardanelli, F.**, 2021, AI applications to medical images: From machine learning to deep learning, *Physica Medica*, 83, 16p.
- Cortez, D. L., Santiago, C. and Nascimento, J.**, 2021, Fully-Automated Multi-View Classification for Lesion Interpretation in Mammography, *MIDL 2021*, 11p.
- Debelee, T. G., Schwenker, F., Ibenthal, A. and Yohannes, D.**, 2019, Survey of deep learning in breast cancer image analysis, *Evolving Systems*, 11(1), 21p.
- Domingues, I., Abreu, P. H. and Santos, J.**, 2018, Bi-rads classification of breast cancer: a new pre-processing pipeline for deep models training, 2018 25th IEEE International Conference on Image Processing (ICIP), 5p.
- Fahad Ullah, M.**, 2019, Breast cancer: current perspectives on the disease status, *Breast Cancer Metastasis and Drug Resistance*, 14p.
- Falconi, L. G., Perez, M., Aguilar, W. G. and Conci, A.**, 2020a, Transfer learning and fine tuning in breast mammogram abnormalities classification on CBIS-DDSM database, *Adv. Sci. Technol. Eng. Syst. J*, 5, 12p.
- Falconí, L., Pérez, M., Aguilar, W. and Conci, A.**, 2020b, Transfer learning and fine tuning in mammogram bi-rads classification, 2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS), 6p.
- Freeman, E. A. and Moisen, G. G.**, 2008, A comparison of the performance of threshold criteria for binary classification in terms of predicted prevalence and kappa, *Ecological Modelling*, 217(1-2), 11p.

## KAYNAKLAR DİZİNİ (devam)

- Gao, F., Wu, T., Li, J., Zheng, B., Ruan, L., Shang, D. and Patel, B., 2018,** SD-CNN: A shallow-deep CNN for improved breast cancer diagnosis, *Computerized Medical Imaging and Graphics*, 70, 10p.
- Google Brain,** 2022a, "Transfer learning and fine-tuning", [https://www.tensorflow.org/tutorials/images/transfer\\_learning](https://www.tensorflow.org/tutorials/images/transfer_learning) (Erişim tarihi: 26 Haziran 2022)
- Google Brain,** 2022b, "Classification on imbalanced data", [https://www.tensorflow.org/tutorials/structured\\_data/imbalanced\\_data](https://www.tensorflow.org/tutorials/structured_data/imbalanced_data) (Erişim tarihi: 26 Haziran 2022)
- Google LLC,** "Colaboratory'ye Hoş Geldiniz", <https://colab.research.google.com/> (Erişim tarihi: 26 Haziran 2022)
- Halling-Brown, M. D., Warren, L. M., Ward, D., Lewis, E., Mackenzie, A., Wallis, M. G. and Young, K. C., 2021,** OPTIMAM Mammography image database: a large-scale resource of mammography images and clinical data, *Radiology: Artificial Intelligence*, 3(1), 6p.
- Harbeck, N., Penault-Llorca, F., Cortes, J., Gnant, M., Houssami, N., Poortmans, P. and Cardoso, F., 2019,** Breast cancer, *Nature Reviews Disease Primers*, 5(1), 31p.
- Heath, M., Bowyer, K., Kopans, D., Kegelmeyer, P., Moore, R., Chang, K. and Munishkumar, S., 1998,** Current status of the digital database for screening mammography, *Digital Mammography*, 10p.
- Huang, M. L. and Lin, T. Y., 2020,** Dataset of breast mammography images with masses, *Data in Brief*, 31 (105928), 6p.
- Johnson, J. M. and Khoshgoftaar, T. M., 2019,** Survey on deep learning with class imbalance, *Journal of Big Data*, 6(1), 54p.
- Kaggle Inc., "Kaggle",** <https://www.kaggle.com/> (Erişim tarihi: 26 Haziran 2022)
- Keras, "About Keras",** <https://keras.io/about/> (Erişim tarihi: 26 Haziran 2022)

## KAYNAKLAR DİZİNİ (devam)

- Kumar, D., Kumar, C. and Shao, M.**, 2017, Cross-database mammographic image analysis through unsupervised domain adaptation, 2017 IEEE International Conference on Big Data (Big Data), 8p.
- Kwong, T. and Mazaheri, S.**, 2021, A survey on deep learning approaches for breast cancer diagnosis, ArXiv:2109.08853, 10p.
- Lee, R. S., Gimenez, F., Hoogi, A., Miyake, K. K., Gorovoy, M., and Rubin, D. L.**, 2017, A curated mammography data set for use in computer-aided detection and diagnosis research, Scientific Data, 4(1), 9p.
- Liberman, L. and Menell, J. H.**, 2002, Breast imaging reporting and data system (BI-RADS), Radiologic Clinics, 40(3), 22p.
- Lopez, M. G., Posada, N., Moura, D. C., Pollán, R. R., Valiente, J. M. F., Ortega, C. S. and Araújo, B. M. F.**, 2012, BCDR: a breast cancer digital repository, 15th International Conference on Experimental Mechanics, 1215, 5p.
- Lu, H. C., Loh, E. W. and Huang, S. C.**, 2019, The classification of mammogram using convolutional neural network with specific image preprocessing for breast cancer detection, 2019 2nd International Conference on Artificial Intelligence and Big Data (ICAIBD), 4p.
- Lyman, G. H., Giuliano, A. E., Somerfield, M. R., Benson, A. B., Bodurka, D. C., Burstein, H. J. and Winer, E. P.**, 2005, American Society of Clinical Oncology guideline recommendations for sentinel lymph node biopsy in early-stage breast cancer, Journal of Clinical Oncology, 23(30), 17p.
- Maisano, R., Tomaselli, V., Capra, A., Longo, F. and Puliafito, A.**, 2018, Reducing complexity of 3D indoor object detection, 2018 IEEE 4th International Forum on Research and Technology for Society and Industry (RTSI), 6p.
- Matheus, B. R. N. and Schiabel, H.**, 2011, Online mammographic images database for development and comparison of CAD schemes, Journal of Digital Imaging, 24(3), 7p.

## KAYNAKLAR DİZİNİ (devam)

- Medeiros, A., Ohata, E. F., Silva, F. H., Rego, P. A. and Reboucas Filho, P. P.**, 2020, An approach to BI-RADS uncertainty levels classification via deep learning with transfer learning technique, 2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS), 6p.
- Moreira, I. C., Amaral, I., Domingues, I., Cardoso, A., Cardoso, M. J. and Cardoso, J. S.**, 2012, Inbreast: toward a full-field digital mammographic database, *Academic radiology*, 19(2), 13p.
- Murtaza, G., Shuib, L., Abdul Wahab, A. W., Mujtaba, G., Mujtaba, G., Nweke, H. F. and Azmi, N. A.**, 2019, Deep learning-based breast cancer classification through medical imaging modalities: state of the art and research challenges. *Artificial Intelligence Review*, 53(3), 66p.
- National Electrical Manufacturers Association**, "DICOM", <https://www.dicomstandard.org/> (Erişim tarihi: 26 Haziran 2022)
- Petrini, D. G., Shimizu, C., Roela, R. A., Valente, G. V., Folgueira, M. A. and Kim, H. Y.**, 2021, Breast Cancer Diagnosis in Two-View Mammography Using End-to-End Trained EfficientNet-Based Convolutional Network, *ArXiv:2110.01606*, 15p.
- Radzi, S. F. M., Karim, M. K. A., Saripan, M. I., Abd Rahman, M. A., Osman, N. H., Dalah, E. Z. and Noor, N. M.**, 2020, Impact of Image Contrast Enhancement on Stability of Radiomics Feature Quantification on a 2D Mammogram Radiograph, *IEEE Access*, 8, 12p.
- Ramadhani, S.**, 2021, A Review Comparative Mammography Image Analysis on Modified CNN Deep Learning Method, *Indonesian Journal of Artificial Intelligence and Data Mining*, 4(1): 1-2p.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S. and Fei-Fei, L.**, 2015, Imagenet large scale visual recognition challenge, *International Journal of Computer Vision*, 115(3), 42p.

## KAYNAKLAR DİZİNİ (devam)

- Shen, L., Margolies, L. R., Rothstein, J. H., Fluder, E., McBride, R. and Sieh, W.**, 2019, Deep learning to improve breast cancer detection on screening mammography, Scientific Reports, 9(1), 12p.
- Simonyan, K. and Zisserman, A.**, 2014, Very deep convolutional networks for large-scale image recognition, ArXiv:1409.1556, 14p.
- Suckling, J., Parker, J., Dance, D., Astley, S., Hutt, I., Boggis, C. and Savage, J.**, 2015, Mammographic image analysis society (mias) database v1. 21, International Congress Series 1069, 4p.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C. and Liu, C.**, 2018, A survey on deep transfer learning, ArXiv:1808.01974, 10p.
- The Cancer Imaging Archive**, "CBIS-DDSM", <https://wiki.cancerimagingarchive.net/display/Public/CBIS-DDSM> (Erişim tarihi: 26 Haziran 2022)
- Weinberg, R. A.**, 1996, How Cancer Arises, Scientific American, 275(3): 2-3p
- Wikipedia**, 2022, "Mammography", <https://en.wikipedia.org/wiki/Mammography> (Erişim tarihi 30 Haziran 2022)
- Wong, D. J., Gandomkar, Z., Wu, W. J., Zhang, G., Gao, W., He, X. and Reed, W.**, 2020, Artificial intelligence and convolution neural networks assessing mammographic images: A narrative literature review, Journal of Medical Radiation Sciences, 67(2), 9p.
- World Health Organization**, 2022, "Cancer", <https://www.who.int/en/news-room/fact-sheets/detail/cancer> (Erişim tarihi: 26 Haziran 2022)
- Yamashita, R., Nishio, M., Do, R. K. G. and Togashi, K.**, 2018, Convolutional neural networks: an overview and application in radiology, Insights Into Imaging, 9(4), 19p.
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H. and He, Q.**, 2020, A comprehensive survey on transfer learning, ArXiv:1911.02685, 34p.

## TEŐEKKÖR

Bu alıŐma sűresince, tezin biimlenmesinde kıymetli gűrűŐlerinden ve bilgilerinden yararlandıĐım, yakın ilgisini esirgemeyen hocalarım Do. Dr. Rıza Cenk Erdur'a ve Prof. Dr. OĐuz Dikenelli'ye, ayrıca meme kanseri konusunda kıymetli bilgi ve gűrűŐlerinden yararlandıĐım hocam ŐĐr. Gűr. Uzm. Dr. Őzge Aslan'a ve aileme teŐekkűrű bir bor bilirim.

... / ... / 2022

İmzası

BaŐak KATUK

## ÖZGEÇMİŞ

### A. KİŞİSEL BİLGİLER

- **Adı soyadı:** Başak Katuk
- **Doğum yeri:**
- **Doğum tarihi:**
- **Vatandaşlık:**
- **Yabancı dil bilgisi:**
- **E-posta adresi:**

### B. EĞİTİM BİLGİLERİ

### C. İŞ TECRÜBESİ

### D. YAYINLAR

- **Aslan, Ö., Oktay, A., Katuk, B., Erdur, R. C., Dikenelli, O., Yeniay, L., Zekioğlu O. and Özbek, S. S., 2022, Breast Imaging Prediction of malignancy upgrade rate in high-risk breast lesions by an artificial intelligence model: A retrospective study, Diagnostic and Interventional Radiology, 17p.**

## EKLER

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 512, 512, 3)]	0
block1_conv1 (Conv2D)	(None, 512, 512, 64)	1792
block1_conv2 (Conv2D)	(None, 512, 512, 64)	36928
block1_pool (MaxPooling2D)	(None, 256, 256, 64)	0
block2_conv1 (Conv2D)	(None, 256, 256, 128)	73856
block2_conv2 (Conv2D)	(None, 256, 256, 128)	147584
block2_pool (MaxPooling2D)	(None, 128, 128, 128)	0
block3_conv1 (Conv2D)	(None, 128, 128, 256)	295168
block3_conv2 (Conv2D)	(None, 128, 128, 256)	590080
block3_conv3 (Conv2D)	(None, 128, 128, 256)	590080
block3_pool (MaxPooling2D)	(None, 64, 64, 256)	0
block4_conv1 (Conv2D)	(None, 64, 64, 512)	1180160
block4_conv2 (Conv2D)	(None, 64, 64, 512)	2359808
block4_conv3 (Conv2D)	(None, 64, 64, 512)	2359808
block4_pool (MaxPooling2D)	(None, 32, 32, 512)	0
block5_conv1 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv2 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv3 (Conv2D)	(None, 32, 32, 512)	2359808
block5_pool (MaxPooling2D)	(None, 16, 16, 512)	0
Total params: 14,714,688		
Trainable params: 0		
Non-trainable params: 14,714,688		

**EK 1.1.** Sınıflandırıcı katmanları çıkartılmış VGG16 modeline ait özet

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 512, 512, 3)]	0
block1_conv1 (Conv2D)	(None, 512, 512, 64)	1792
block1_conv2 (Conv2D)	(None, 512, 512, 64)	36928
block1_pool (MaxPooling2D)	(None, 256, 256, 64)	0
block2_conv1 (Conv2D)	(None, 256, 256, 128)	73856
block2_conv2 (Conv2D)	(None, 256, 256, 128)	147584
block2_pool (MaxPooling2D)	(None, 128, 128, 128)	0
block3_conv1 (Conv2D)	(None, 128, 128, 256)	295168
block3_conv2 (Conv2D)	(None, 128, 128, 256)	590080
block3_conv3 (Conv2D)	(None, 128, 128, 256)	590080
block3_pool (MaxPooling2D)	(None, 64, 64, 256)	0
block4_conv1 (Conv2D)	(None, 64, 64, 512)	1180160
block4_conv2 (Conv2D)	(None, 64, 64, 512)	2359808
block4_conv3 (Conv2D)	(None, 64, 64, 512)	2359808
block4_pool (MaxPooling2D)	(None, 32, 32, 512)	0
block5_conv1 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv2 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv3 (Conv2D)	(None, 32, 32, 512)	2359808
block5_pool (MaxPooling2D)	(None, 16, 16, 512)	0
global_average_pooling2d (G1	(None, 512)	0
dense (Dense)	(None, 256)	131328
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 64)	16448
dropout_1 (Dropout)	(None, 64)	0
dense_2 (Dense)	(None, 1)	65
=====		
Total params: 14,862,529		
Trainable params: 147,841		
Non-trainable params: 14,714,688		
=====		

**EK 1.2.** Öznetelik çıkartma yönteminde kullanılan model mimarisi özeti

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 512, 512, 3)]	0
block1_conv1 (Conv2D)	(None, 512, 512, 64)	1792
block1_conv2 (Conv2D)	(None, 512, 512, 64)	36928
block1_pool (MaxPooling2D)	(None, 256, 256, 64)	0
block2_conv1 (Conv2D)	(None, 256, 256, 128)	73856
block2_conv2 (Conv2D)	(None, 256, 256, 128)	147584
block2_pool (MaxPooling2D)	(None, 128, 128, 128)	0
block3_conv1 (Conv2D)	(None, 128, 128, 256)	295168
block3_conv2 (Conv2D)	(None, 128, 128, 256)	590080
block3_conv3 (Conv2D)	(None, 128, 128, 256)	590080
block3_pool (MaxPooling2D)	(None, 64, 64, 256)	0
block4_conv1 (Conv2D)	(None, 64, 64, 512)	1180160
block4_conv2 (Conv2D)	(None, 64, 64, 512)	2359808
block4_conv3 (Conv2D)	(None, 64, 64, 512)	2359808
block4_pool (MaxPooling2D)	(None, 32, 32, 512)	0
block5_conv1 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv2 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv3 (Conv2D)	(None, 32, 32, 512)	2359808
block5_pool (MaxPooling2D)	(None, 16, 16, 512)	0
global_average_pooling2d (GlobalAveragePooling2D)	(None, 512)	0
dense (Dense)	(None, 256)	131328
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 64)	16448
dropout_1 (Dropout)	(None, 64)	0
dense_2 (Dense)	(None, 1)	65
Total params: 14,862,529		
Trainable params: 9,587,073		
Non-trainable params: 5,275,456		

**EK 1.3.** İnce ayar yönteminde kullanılan model mimarisi özeti