

T. C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME İLE MAMMOGRAM GÖRÜNTÜLERİNDEKİ LEZYONLARIN
TESPİTİ VE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

YAVUZ BİÇİCİ

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ SALİM CEYHAN

İKİNCİ TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ SÜLEYMAN UZUN

BİLECİK, 2023
10564020

T. C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME İLE MAMMOGRAM GÖRÜNTÜLERİNDEKİ LEZYONLARIN
TESPİTİ VE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

YAVUZ BİÇİCİ

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ SALİM CEYHAN

İKİNCİ TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ SÜLEYMAN UZUN

BİLECİK, 2023
10564020

BEYAN

“Derin Öğrenme İle Mammogram Görüntülerindeki Lezyonların Tespiti ve Sınıflandırılması” adlı yüksek lisans yeterlik tezi hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.	
DESTEK ALINMIŞTIR	DESTEK ALINMAMIŞTIR
Destek alındı ise;	
Destekleyen kurum;	
Desteğin Türü	Proje Numarası
1- BAP (Bilimsel Araştırma Projesi)	
2- TÜBİTAK	
Diğer;.....	
ETİK KURUL onayı var ise;	
ETİK KURUL karar tarih/sayı:	/.....

Yavuz BİÇİCİ

....../....../2023

İmza

ÖN SÖZ

Tez çalışmamın her aşamasında yardımlarını ve desteklerini hiçbir zaman esirgemeyen danışmanım çok değerli hocam sayın Dr. Öğr. Üyesi Salim CEYAN' a ve değerli hocam sayın Dr. Öğr. Üyesi Süleyman UZUN' a teşekkürlerimi ve saygılarımı sunarım.

Tez süreci boyunca her zaman desteklerini hissettiren hayattaki en değerli varlıklarım olan fedakarlıklarını hiçbir zaman esirgemeyen hayat arkadaşım Aynur BİÇİCİ ve oğlum Emir Alparslan' a sonsuz teşekkürlerimi sunarım.

Yavuz BİÇİCİ

2023



ÖZET

DERİN ÖĞRENME İLE MAMMOGRAM GÖRÜNTÜLERİNDEKİ LEZYONLARIN TESPİTİ VE SINIFLANDIRILMASI

İnsan yaşamında sık görülen kanser türlerinden biri olan meme kanseri erkeklere göre kadınlarda daha sık görülmektedir. Bu kansere neyin sebep olduğu tam olarak bilinmese de kişinin beslenme şekli, regl durumu, doğum ve doğum kontrol hapları gibi birçok nedenlerin olabileceği düşünülmektedir. Meme kanserinin erken teşhisi tedavisinde oldukça önemlidir. Çok farklı meme kanseri tespit yöntemleri vardır. Bunlardan biri de Manyetik Rezonans (MR) ile görüntüleme teknikleridir. Bu çalışmada, Mammogram görüntüleri üzerinde lezyon tespiti ve sınıflandırmasında Faster R-CNN derin öğrenme yöntemi ile birlikte önceden eğitilmiş üç farklı CNN modeli Inception V2, Resnet101 ve Resnet-50 kullanılmıştır. Mammografi taraması görüntüleri içeren “The Digital Database for Screening Mammography – DDSM” açık kaynaklı sayısal veri tabanının kanserli ve normal görüntülerden oluşan toplamda 500 adeti alınarak oluşturulmuştur. Alınan bu görüntülerin 400 adedi radyologlar tarafından işaretlenmiş 100 adedi ise işaretlenmemiş vakalara ait mammogram görüntüsüdür. İşaretlenmiş 400 adet kanserli görüntüdeki lezyon bölgeleri LabelImg etiketleme aracı kullanılarak XML dosyası olarak etiketlendi. Daha sonra bu etiketlenen görüntüler eğitim veri seti olarak kullanıldı. Lezyon tespitinde kullanılan Faster R-CNN derin öğrenme yöntemi ile birlikte kullanılan üç adet CNN modelin her birinin eğitimi 300.000 adımda ve batchsize=1 olarak gerçekleştirildi. Bu deneyler sonucunda Inception V2 modeli için %97,16 doğruluk başarıımı ve ResNet101 modeli için %94,74 doğruluk başarıımı elde edilirken en iyi sonucu veren ResNet-50 modeli için ise %99,63 doğruluk başarıımı elde edilmiştir. Elde edilen sonuçlar bu alanda çalışan uzmanlara erken teşhis koymada destek olabilecektir.

Ayrıca tezde ele alınan ön eğitimli CNN modelleri MIAS veri seti kullanılarak sadece iyi huylu ve kötü huylu tümör sınıflandırması yapılmıştır. 2016 adet iyi huylu eğitim ve 4088 adet kötü huylu eğitim seti ve 504 adet iyi huylu ve 1024 adet kötü huylu görüntü doğrulama veri seti olarak kullanılmıştır. Tezde ele alınan ön eğitimli modellerle gerçekleştirilen eğitim sonucunda yine yüksek başarılar elde edildiği görülmüştür.

Anahtar Kelimeler: Meme kanseri, Derin Öğrenme, Faster-RCNN, ResNet, Inception

ABSTRACT

DETECTION AND CLASSIFICATION OF LESIONS IN MAMMOGRAM IMAGES USING DEEP LEARNING

Breast cancer, one of the commonly occurring cancer types in human life, is more prevalent in women compared to men. Although the exact causes of this cancer are not fully understood, various factors such as dietary habits, menstrual status, childbirth, and the use of birth control pills are believed to contribute to its development. Early detection of breast cancer is crucial for effective treatment. There are various methods for detecting breast cancer, one of which involves Magnetic Resonance (MR) imaging techniques. In this study, three different pre-trained CNN models, namely Inception V2, Resnet101, and Resnet-50, were used in conjunction with the Faster R-CNN deep learning method for lesion detection and classification in Mammogram images. A total of 500 mammography screening images, consisting of cancerous and normal images, were obtained from "The Digital Database for Screening Mammography - DDSM," an open-source digital database. Out of these images, 400 were annotated by radiologists, while 100 were unmarked mammogram images of unrelated cases. The lesion regions in the annotated 400 cancerous images were labeled using the LabelImg annotation tool and stored as XML files. Subsequently, these labeled images were used as the training dataset. The training of each of the three CNN models used in lesion detection was performed with 300,000 steps and a batch size of 1, in conjunction with the Faster R-CNN deep learning method. As a result of these experiments, the Inception V2 model achieved an accuracy of 97.16%, the ResNet101 model achieved an accuracy of 94.74%, and the best-performing ResNet-50 model achieved an accuracy of 99.63%. These results can provide valuable support for early diagnosis by medical experts in this field.

Furthermore, in the thesis, pre-trained CNN models were also used for benign and malignant tumor classification using the MIAS dataset. The training set consisted of 2016 benign and 4088 malignant images, while the validation set comprised 504 benign and 1024 malignant images. The training using the pre-trained models showed high success rates, as observed in the results of this study.

Keywords: Breast cancer, Deep Learning, Faster-RCNN, ResNet, Inception

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
KISALTMALAR LİSTESİ	ix
1. GİRİŞ.....	1
1.1. Literatür Araştırması.....	1
1.2. Tezin Amacı	4
1.3. Araştırmanın Kapsamı	4
1.4. Genel Bilgiler	5
1.4.1. Kanser	5
1.4.2. Meme Kanseri	5
1.4.3. Meme Kanseri Tipleri	6
2. MATERYAL VE YÖNTEM	7
2.1. Kullanılan Derin Öğrenme Algoritmaları.....	8
2.2. Veri Seti	8
2.3. Derin Öğrenme (DL)	11
2.4. Evrişimli Sinir Ağı (CNN).....	12
2.5. Derin Sinir Ağı Modelleri (DNN)	13
2.6. Bölge Tabanlı Evrişimli Sinir Ağları (R-CNN).....	13
2.6.1. Faster R-CNN	13
2.7. Aktarım Öğrenimi	14

3. ÇALIŞMADA KULLANILAN CNN MODELLERİ.....	16
3.1. Inception V2.....	16
3.2. ResNet101.....	17
3.3. ResNet-50.....	19
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	20
4.1. Veri Kümesinin Hazırlanması.....	20
4.2. Meme Kanseri Lezyon Tespiti.....	23
4.3. Meme Kanseri Sınıflandırması	31
5. SONUÇLAR.....	41
KAYNAKÇA	42

TABLÖLER LİSTESİ

	Sayfa
Tablo 1.1. Dünya sağlık örgütüne göre meme kanseri belirtileri	5
Tablo 2.1. DDSM veri setindeki vakalar ve içerikleri hakkındaki bilgiler	10
Tablo 4.1. Inception V2, ResNet101 ve ResNet-50 ön eğitilmiş modellerin performans ölçümleri.....	30
Tablo 4.2. DDSM veri seti kullanılarak yapılan çalışmalar, algoritmalar ve doğruluk değerleri	30
Tablo 4.3. Doğruluk hesaplama parametreleri	32
Tablo 4.4. Modellerin performans değerleri.....	39
Tablo 4.5. BreakHis veri seti kullanılarak yapılan çalışmalar, algoritmalar ve doğruluk değerleri.....	40

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Derin öğrenme süreci	7
Şekil 2.2. Önerilen lezyon tespiti ve sınıflandırma yöntemi	7
Şekil 2.3. DDSM veri setine ait işaretlenmiş kötü huylu görüntüler	9
Şekil 2.4. DDSM veri setine ait işaretlenmiş sağlıklı görüntüler	10
Şekil 2.5. CNN mimarisi	12
Şekil 2.6. Faster R-CNN mimarisi	14
Şekil 2.7. Aktarım Öğrenimi şeması	15
Şekil 3.1. ResNet101 mimarisi	18
Şekil 3.2. ResNet-50 mimarisi	19
Şekil 4.1. Görüntü seçme işlemi	21
Şekil 4.2. Görüntü etiketleme işlemi	21
Şekil 4.3. Görüntü etiketleme işleminin isimlendirilmesi	21
Şekil 4.4. Görüntü etiketleme işlemini kaydetme	22
Şekil 4.5. Oluşturulan XML uzantılı örnek dosya içeriği	22
Şekil 4.6. Inception V2 modeli başarı oranı	24
Şekil 4.7. Inception V2 modelinin bazı test görüntüleri sonuçları	24
Şekil 4.8. Inception V2 modeli kayıp (loss) değerleri	25
Şekil 4.9. ResNet101 modeli başarı oranı	26
Şekil 4.10. ResNet101 modelinin bazı test görüntüleri sonuçları	26
Şekil 4.11. ResNet101 modeli kayıp (loss) değerleri	27
Şekil 4.12. ResNet-50 modeli başarı oranı	28
Şekil 4.13. ResNet-50 modelinin bazı test görüntüleri sonuçları	28
Şekil 4.14. ResNet-50 modeli kayıp (loss) değerleri	29
Şekil 4.15. MIAS veri setine ait arttırılmış görüntüler ve etiket değerleri	32

Şekil 4.16. Inception V2 modeli başarı oranı.....	33
Şekil 4.17 Inception V2 modelinin tahmin edilen ve gerçek sonuçları	34
Şekil 4.18 Inception V2 modeli kayıp (loss) değerleri	34
Şekil 4.19 ResNet101 modeli başarı oranı.....	35
Şekil 4.20 ResNet101 modelinin tahmin edilen ve gerçek sonuçları	35
Şekil 4.21 ResNet101 modeli kayıp (loss) değerleri.....	36
Şekil 4.22 ResNet-50 modeli başarı oranı	36
Şekil 4.23 ResNet-50 modelinin tahmin edilen ve gerçek sonuçları	37
Şekil 4.24 ResNet-50 modeli kayıp (loss) değerleri	37
Şekil 4.25 Eğitimde kullanılan ağların karmaşıklık matrisleri	38
Şekil 4.26 Modellere ait ROC eğrileri	39

KISALTMALAR LİSTESİ

Kısaltmalar:

DDSM	: Mammografi Taraması için Sayısal Veritabanı (The Digital Database for Screening Mammography)
MIAS	: Mamografik Görüntü Analizi Derneği (Mammographic Image Analysis Society)
WHO	: Dünya Sağlık Örgütü
MÖ	: Makine Öğrenimi
DL	: Derin Öğren
CNN	: Evrişimli Sinir Ağı
R-CNN	: Bölge Tabanlı Evrişimli Sinir Ağları (Region Based Convolutional Neural Networks)
Faster R-CNN	: Faster Region Convolutional Neural Networks
BCD	: Breast Cancer Digital (Meme Kanseri Dijital Deposu)
CAD	: Bilgisayar Destekli Tespit (Computer Aided Detection)
DCNN	: Deep convolutional neural network (Derin Evrişimli Sinir Ağı)
CBIS	: The Curated Breast Imaging Subset
DAA	: Doğrusal ayırma analizi
IRMA	: Image Retrieval in Medical Application
YSA	: Yapay Sinir Ağı
SVM	: Destek Vektör Makinesi
DT	: Karar Ağacı
KNN	: K-En Yakın Komşular
NB	: Naive Bayes
DTL-BCDC	: Derin Transfer Öğrenme Özellikli Meme Kanseri Saptama ve Sınıflandırma
ADCNN	: Uyarlanabilir Derin Konvolüsyon Sinir Ağı
CBIS-DDSM	: Curated Breast Imaging Subset of Digital Database for Screening Mammography
BREKHis	: Breast Cancer Histopathological Database
ROC	: Receiver Operating Characteristic
TL	: Transfer Learning

1. GİRİŞ

Meme kanseri dünya genelinde sık görülen üç kanser türünden biridir. Dünyada kadınlar arasında on kadından sekizinde en sık görülen ve kötü huylu kanser sayılabilecek ölüm oranının yüksek olduğu tümör türlerinden biridir. Az gelişmiş ülkelerde en yaygın kanser türü olurken gelişmiş ülkelerde akciğer kanserinden sonra ikinci sırada yer almaktadır. 2012 yılında yapılan bir çalışmaya göre dünya genelinde yaklaşık 1,7 milyon kişiye meme kanseri teşhis konmuş ve bu hastalardan yaklaşık yarım milyonu ölmüştür (Harbeck ve Gnant, 2017).

Mamografi günümüzde meme kanseri tedavisini erken teşhis etmek ve ölüm oranı düşürmek için kullanılan önemli yöntemlerden biridir. Dünya Sağlık Örgütü'ne (WHO) göre 2025 yılında tahmin edilen vaka sayısı 19,3 milyon vaka olması beklenmektedir (Mechria vd, 2019).

İstatistikler, kadınlarda görülen meme kanserinin ciddiyetini ve yaşamları üzerindeki etkisini göstermektedir. 1960 yılından itibaren meme kanseri için düzenli kanser taramalar yapılarak, bu hastalıktan etkilenen kadınların ölüm oranını azaltabilecek çalışmalar yapılmaktadır. Bu taramalar arasında birincil olan X-ray taramalarıdır. Yapılan bu çalışmaların en önemli sonucu meme kanserinin erken teşhisi sonrasında tedavi sürecini hızlandırması ve hastalığın iyileştirme hızını artırdığı gözlemlenmiştir (Hassan ve El-Shenawee, 2011).

Meme kanserinde kanser hücreleri insan vücudunda iki farklı şekilde yayılmaktadır. Birincisi meme dokularında, genellikle anne sütünü meme ucuna ileten kanallarda, diğeri ise süt yapan bezlerde oluşmaktadır. Meme kanseri Invasive (yayılan) ve non-Invasive (yayılmayan) olmak üzere iki şekilde oluşur. Invasive kanserde, kanser hücreleri süt yapan bezlerden yola çıkar ve yakınındaki dokuya yayılır. Non-Invasive kanser ise kanser hücreleri oluşmaya başladığı bölgede kalır ve yayılım göstermeyen kanserlerdir (Surya Gowri ve Amudha, 2014).

Makine öğrenmesi ve derin öğrenme teknikleri gün geçtikçe ilerleme kaydederek kötü huylu kanserli bölgeyi teşhis etmede önemli rol oynamaktadır. Derin öğrenme, yapay sinir ağları ve benzeri öğrenme algoritmaları kapsayan insan beyni gibi çalışacak şekilde modellenen algoritmalar (Hosny vd , 2018).

1.1. Literatür Araştırması

Meme kanseri tespiti ve tedavisiyle ilgili birçok çalışma mevcuttur, bu çalışmaların çoğu bilgisayar destekli yöntemler ve çeşitli makine öğrenmesi (MÖ) algoritmalarıyla gerçekleştirilmiştir. Bunlardan bazı örnekler aşağıda verilmiştir.

(Erdem, 2021) tarafından yapılan bir çalışmada meme kanseri tespitinde derin öğrenme yaklaşımları ve BreakHist veri seti kullanılmıştır. Çalışmada daha önceden makine öğrenimi ile eğitilmiş CNN mimarilerinden, VGG16, Inception v3 ve bu iki mimarinin birleşiminden meydana gelen (VGG16+Inception v3) mimarisi kullanılarak ikili sınıflandırma yapılmıştır.

(Ben-Ari vd, 2017) tarafından yapılan bir çalışmada, DDSM veri seti üzerinde klinik gözlemciler tarafından önceden eğitilmiş bir R-CNN modeli kullanılmıştır. Bu model, normal ve kanserli verileri lezyon bölgeleriyle birlikte %83 doğruluk oranıyla ikili sınıflandırma yapmaktadır.

(Zhang vd, 2019) tarafından gerçekleştirilen bir başka çalışmada, DDSM veri seti üzerinde ResNet101, Inception V2, Inception v3, Mobilenet ve ResNet modelleri kullanılarak iyi huylu ve kötü huylu meme kanserlerinin tespiti karşılaştırılmıştır.

(Cao vd, 2019) Shenzhen Halk Hastanesi'nden temin edilen veri setleri (DDSM, INbreast ve BCD) kullanılarak meme kanserinde kitle ve kireçlenmeyi tespit etmek için Konvolüsyonel Sinir Ağları (CNN) tabanlı Faster Region Convolutional Neural Networks (Faster R-CNN) modeli önermiştir. Bu çalışmada kanserli bölge tanıma için ortalama 0,804 ve kireçleme kitle bölgesi tanımlama için 0,975 oranları bulunmuştur.

(Wei vd, 2020) tarafından yapılan bir çalışmada ise ultrasonik görüntüler kullanılarak meme kanserlerinde lezyon saptama ve sınıflandırma amaçlanmıştır. Çalışmanın sonunda %95'in üzerinde başarı elde edilmiştir.

(Mechria vd, 2019) tarafından gerçekleştirilen bir çalışmada meme kanserlerinde iyi huylu ve kötü huylu kitle tümörlerini sınıflandırmak için bilgisayar destekli tespit (CAD) sistemi kullanılmıştır. Bu çalışmada AlexNet adında bir DCNN mimarisi kullanılmış ve DDSM ve CBIS-DDSM veri setleri kullanılmıştır. Elde edilen sonuçlar başarılı bulunmuştur.

(Chiao vd, 2019) tarafından yapılan bir diğer çalışmada ultrason görüntülerinden oluşan veri setinde meme lezyonlarının tespiti, vücuttaki enfeksiyon varlığı ve sınıflandırılması amaçlanmıştır. Evrişimli sinir ağı ile maske bölgeleri kullanılarak iyi huylu ve kötü huylu sınıflandırma yapılmış ve %85 oranında başarı elde edilmiştir.

(I. Domingues vd, 2012) tarafından gerçekleştirilen bir başka çalışmada mamografi görüntülerinde meme kanserlerinin iyi veya kötü huylu özelliklerinin tespiti için doğrusal ayırma analizi (DAA) kullanılmıştır. Doğruluk, duyarlılık ve özgüllük ölçütleri kullanılarak yapılan değerlendirmelerde %100 duyarlılık ve %79 özgüllük ile %89 doğruluk elde edilmiştir.

(Reiazi vd, 2018) tarafından yapılan çalışmada MIAS veri seti üzerinde derin evrişimli ağları (DCN) kullanarak meme kanseri sınıflandırması yapılmıştır. R-CNN modellemesi kullanılarak başarılı lezyon tespitleri sağlanmıştır.

(Shen vd, 2019) tarafından yapılan bir çalışmada CBIS-DDSM veri seti kullanılarak "uçtan uca" bir eğitim yaklaşımıyla tarama mamogramlarında meme kanserini doğru bir şekilde tespit edebilen bir derin öğrenme algoritması geliştirmişlerdir. Derin evrişimli ağlar yöntemi kullanılarak yapılan sınıflandırmada %86,1 duyarlılık, %80 özgüllük ve yüksek bir doğruluk elde edilmiştir.

(Lotter vd, 2021) tarafından yapılan bir çalışmada meme kanseri için sınıflandırmalar yapılarak bir derin sinir öğrenme yaklaşımı önerilmiştir. Kanserli hastaların klinik olarak negatif önceki mamogramlarında düşük tarama oranlarını %14'lük bir artışla başarılı sonuçlar elde edilmiştir.

(Ismail ve Sovuthy, 2019) tarafından gerçekleştirilen bir çalışmada, IRMA veri seti üzerinde VGG16 ve ResNet-50 derin öğrenme modeli ağları kullanılarak iyi huylu ve kötü huylu tümörler arasında sınıflandırma yapılmıştır. Elde edilen sonuçlara göre ResNet-50 %91,7 ve VGG16 ise %94 doğruluk oranıyla sonuç göstermiştir.

(Kulkarni vd, 2021) tarafından yapılan bir çalışmada, derin öğrenme ve makine öğrenimi teknikleri kullanılarak meme kanserinin sınıflandırılması için çeşitli algoritmalar (Yapay Sinir Ağları, Destek Vektör Makinesi, Karar Ağacı, k-En Yakın Komşular, Naive Bayes) önerilmiştir.

(Soumik, Aziz ve Hossain, 2021) tarafından gerçekleştirilen bir çalışmada BreakHis veri seti üzerinde histopatolojik görüntülerden özellikler çıkararak iyi huylu ve kötü huylu tümörlerin sınıflandırılması için bir Inception v3 modeli eğitilmiştir ve başarılı bir sonuç elde edilmiştir.

(Tezcan vd, 2022) tarafından yapılan bir çalışmada BACH ve Bioimaging veri seti üzerinde dört farklı kanser hücre tiplerine (iyi huylu, kötü huylu, yerinde karsinom ve invaziv karsinom) çeşitli yöntemler ile sınıflandırma yapılmıştır. VGG16, DenseNet121, ResNet-50 ve MobileNetV2 ön-eğitilmiş ağlar kullanılarak başarılı sonuçlar elde edilmiştir.

(Remya ve Hema Rajini, 2022) tarafından yapılan bir çalışmada ise 2022 yılında meme kanseri sınıflandırması için mamogram görüntülerini kullanarak bir derin sinir ağı modeli olan DenseNet-169 kullanılmıştır. Elde edilen sonuçlara göre, başarı oranı yüksek bulunmuştur.

(Manishkumar ve Saranya, 2022) tarafından gerçekleştirilen bir çalışmada 2022 yılında meme kanseri tespiti için Uyarlanabilir Derin Konvolüsyon Sinir Ağı (ADCNN) önerilmiştir. Meme kanseri iyi huylu ve kötü huylu olarak sınıflandırılmıştır.

(Thomas vd, 2022) tarafından yapılan bir çalışmada ise 2022 yılında histopatolojik görüntülerden meme kanseri sınıflandırması yapabilen bir görüntü işleme ve derin öğrenme modeli önerilmiştir.

(Afaq ve Jain, 2022) tarafından gerçekleştirilen bir çalışmada ise 2022 yılında mamografik veri seti CBIS-DDSM üzerinde evrişimli Sinir Ağı (MAMMO-Net) modeli önerilmiştir. Gabor filtresi uygulayarak mamografik görüntülerde işlemler gerçekleştirilmiş ve %98 doğruluk oranı elde edilmiştir.

(Cruz vd, 2022) tarafından yapılan bir çalışmada 2022 yılında meme kanserleri varlığının tespit, iyi huylu ve kötü huylu tümörlerinin seviyesinin sınıflandırılması için çeşitli makine öğrenimi teknikleri değerlendirilmiştir. VGG-16, VGG-19, MobilNet-V2 ve DenseNet-121 kullanılarak yapılan değerlendirmelerde en iyi sınıflandırıcı olarak DenseNet-121 bulunmuştur.

(Bhise vd, 2022) tarafından yapılan bir çalışmada 2022 yılında BreaK-Hist veri seti üzerinde Destek Vektör Makinesi, Naive Bayes sınıflandırıcısı, K-En Yakın Komşuluk ve Lojistik Regresyon ile Makine Öğrenmesi algoritmalarının özellik çıkarımı da gerçekleştiren Konvolüsyonel Sinir Ağı modeli kullanılmıştır. Yapılan denemelerde yüksek oranda doğruluk elde edilmiştir.

1.2. Tezin Amacı

Bu tez çalışması, meme kanserinin erken safhasında kesin tanı ve tespit edilen lezyonların kanserli ve normal olarak sınıflandırılması ile iyi huylu, kötü huylu tümörlerin sınıflandırma için derin öğrenme yöntemlerinin kullanıldığı bir araştırmayı amaçlamaktadır. Bu çalışma derin öğrenme ile mammogram görüntülerindeki lezyonların tespiti ve sınıflandırılması hedeflemektedir. Bu kapsamda çalışma, kanserli bölgenin belirlenme doğruluğunu artırmak ve meme kanserinin erken teşhisini sağlamayı amaçlamaktadır.

1.3. Araştırmanın Kapsamı

Meme kanserinin erken dönemde tespit edilmesi, hastalık tedavi sürecine etkisi olmasından dolayı, araştırmada, bilgisayar destekli tespit ve teşhis sistemlerinin (derin öğrenme metotları) meme kanseri sınıflandırmasına odaklanmaktadır. Özellikle Inception V2, ResNet101 ve ResNet-50 modelleri kullanılarak meme kanserinin iyi huylu ve kötü huylu

olarak sınıflandırılmasında ve lezyon bölgelerinin tespit edilmesinde yüksek başarı elde edilebileceği öngörülmektedir.

1.4. Genel Bilgiler

1.4.1. Kanser

Kanser, organ veya dokudaki hücre fizyolojisinde meydana gelen anormal bölünme ve çoğalma sonucunda iyi huylu veya kötü huylu tümörlere yol açan bir hastalıktır. Kanserli durumda, hücrelerin normal büyüme düzeni bozulur ve kontrolsüz bir şekilde çoğalırlar. İyi huylu tümörler genellikle lokal ve çevre dokulara yayılmazken, kötü huylu tümörler invazi (yayılımcı) ve çevre dokulara yayılarak metastaz yapabilirler (Seyfried ve Shelton, 2010).

Erkeklerde en yaygın görülen kanser türü olan prostat kanseri, erkek üreme sistemindeki prostat bezinde ortaya çıkar. Kadınlarda ise en yaygın kanser türü meme kanseridir, bu kanser türü meme dokusunda meydana gelir. Bu nedenle prostat kanseri erkeklerde, meme kanseri ise kadınlarda en sık görülen kanser türleridir (Jemal ve diğerleri, 2005).

1.4.2. Meme Kanseri

Meme kanseri, meme dokusundaki hücrelerin anormal bir şekilde büyümesiyle karakterize edilen bir hastalıktır. Genellikle, meme içindeki kanallar veya süt bezleri olarak bilinen glandüler dokudan veya diğer meme dokularından kaynaklanır. Meme kanserinin belirtileri arasında şişlik, cilt tahrişi ve meme içinde oluşan kitleler bulunabilir. Bu belirtiler, hastalığın erken tanısını sağlamak ve uygun tedavi sürecini başlatmak açısından önemlidir (Nair vd, 2022).

Dünya Sağlık Örgütünde meme kanserlerine ait belirtiler Tablo 1.1’de verilmiştir.

Tablo 1.1. Dünya sağlık örgütüne göre meme kanseri belirtileri

Meme Kanseri Belirti ve Bulguları
Göğüs bölgesinde yumru şeklinde kitle olması
Memenin boyutunda, şeklinde veya görünümünde değişiklik olması
Ciltte çukurlaşma, kızarıklık olması
Meme ucu görünümünde değişiklik veya meme ucunu çevreleyen deride değişiklik olması
Anormal meme başı akıntısı olması


1.4.3. Meme Kanseri Tipleri

Meme kanseri, hücrelerin anormal bir şekilde bölünmesinden kaynaklanan ve iyi huylu veya kötü huylu kanser oluşumuna yol açan bir hastalıktır. İyi huylu tümör hücreleri, normalden farklı bir şekilde büyüyerek ve bir kitle oluşturarak kendini gösterebilir. Ancak iyi huylu tümör hücreleri, vücudun diğer bölgelerine yayılmaz ve kanserli hücreler oluşturmazlar. Kötü huylu kanser ise vücudun herhangi bir bölgesinde oluşan bir hastalığın başka bir bölgeye sıçraması ve yayılması sonucunda oluşan bir tümördür (Divya vd, 2022).




2. MATERYAL VE YÖNTEM

Derin öğrenme, yapay sinir ağları ve diğer derin öğrenme modellerinin entegre edildiği, karmaşık veri yapılarını analiz etmek ve karmaşık görevleri yerine getirmek amacıyla kullanılan etkili bir makine öğrenme yöntemidir. Bu süreç Şekil 2.1’de gösterilmiştir.



Şekil 2.1. Derin öğrenme süreci

Önerilen lezyon tespiti ve sınıflandırma yöntemine dair ilgili bilgiler Şekil 2.2’de gösterilmiştir.



Şekil 2.2. Önerilen lezyon tespiti ve sınıflandırma yöntemi

Kaynak: (Zhang vd, 2019)

İlk aşamada, önceden işlenmiş görüntüler üç farklı özellik haritası çıkarıcıya, yani Inception V2, ResNet101 ve ResNet-50'ye yönlendirilir. Bu özellik haritaları, meme kitlelerinin bölgesel tespitinde Faster R-CNN ağının temel bileşenleri olarak kullanılmaktadır. Daha sonra, Bölgesel Öneri Ağı (RPN) vasıtasıyla tespit edilecek nesneleri içeren birçok dikdörtgen bölge elde edilir. İkinci aşamada, aday bölgelerin konum bilgisine başvurularak, orijinal görüntüdeki bu bölgelerden öznelik vektörleri çıkarılır. Bu aşamada, ROI (Bölgesel İzleme) havuzlama katmanı kullanılarak, bu özellik vektörleri, tek tip bir boyuta sabitlenen ROI özellik vektörleri olarak adlandırılır. Son olarak, bu ROI özellik vektörleri, tespit sürecini tamamlamak için bir sınıflandırıcıya yönlendirilir.

Makine öğrenmesi, bilgisayar sistemlerinin insanlar gibi düşünmeleri için eğitildikleri ve önceki deneyimlerden öğrenerek bu deneyimleri genişletebildikleri bir yapay zeka yöntemidir (Sah, 2020).

Derin öğrenme ise bir makine öğrenimi tekniği olarak, sistemin çok sayıda girdi verisi katmanını işleyerek sınıflandırma için gerekli özellikleri otomatik olarak öğrendiği ve keşfettiği temsil öğrenmeye dayalı bir yöntemdir (Zhou vd, 2020).

Bu tez çalışmasında, meme kanserinin lezyon tespiti ve sınıflandırılması için derin öğrenme tekniklerini kullanarak meme kanseri lezyon bölgesinin belirlenmesi ve sınıflandırılması yapılmıştır. İlk olarak olayın anlaşılabilmesi için sınıf bilgisinin yer aldığı eğitim verileri kullanılarak bir derin öğrenme modelleri ile eğitim işlemi gerçekleştirilir. Daha sonra modelin daha önce hiç görmediği test veriyle karşılaştığında modelin bu verileri doğru sınıflandırması beklenmektedir.

2.1. Kullanılan Derin Öğrenme Algoritmaları

Derin öğrenme, çeşitli görüntü işleme algoritmaları arasında, görüntü sınıflandırma görevlerinde etkileyici performans sergileyen birçok uygulama sunmaktadır. İyi bir sınıflandırmaya ulaşmak için Inception-V2, ResNet101, ResNet-50 gibi evrişimli sinir ağı (CNN) tasarımları gibi yöntemler yaygın bir şekilde kullanılmaktadır (Urabinahatti ve Jayadevappa, 2023).


2.2. Veri Seti

Bu çalışmada mammogram görüntüleri üzerindeki lezyon bölgelerinin tespiti ve kötü huylu tümör (kanserli) veya sağlıklı sınıflandırma için DDSM veri setinden yararlanılmıştır. DDSM, Güney Florida Üniversitesindeki mamografik görüntü analizi araştırma topluluğu tarafından geliştirilen ve açık bir kaynak olarak kullanılan bir veri tabanıdır. DDSM veri seti,


mamografik görüntü analizi için geniş bir veri kaynağı sağlayan ve meme kanseri lezyon tespiti ve sınıflandırması için sıklıkla kullanılan bir kaynaktır.

Bu veri tabanının temel amacı, bilgisayar algoritmalarının geliştirilmesinde yardımcı olmak ve ilgili hedeflere katkı sağlamaktır. Veri setinde bulunan yaklaşık 2.500 çalışmada, hasta bilgileri, meme yoğunluğu derecesi, anormallikleri için incelik derecesi ve görüntü bilgileri bulunmaktadır. DDSM veri setindeki görüntüler, radyologlar tarafından tümörlü bölgelerin işaretlenmesi ve sınıflandırma yapılması amacıyla kullanılmıştır (Rana vd ,2007).

Bu çalışmada, DDSM veri setinden toplamda 500 adet görüntü kullanılmıştır. Bu görüntülerden 400 adedi radyologlar tarafından işaretlenmiş ve 100 adedi kanserli ve normal işaretlenmemiş vakalara aittir. DDSM veri setinden alınan kanserli ve normal görüntülerden bazı örnekler Şekil 2.3 ve Şekil 2.4'te gösterilmiştir.



Şekil 2.3. DDSM veri setine ait işaretlenmiş kötü huylu görüntüler



Şekil 2.4. DDSM veri setine ait işaretli sağlıklı görüntüler

<http://www.eng.usf.edu/cvprg/mammography/database.html> sitesinden alınan DDSM veri setine ait mamogram görüntüleri ve içerikleri hakkındaki bilgiler Tablo 2.1’de verilmiştir.

Tablo 2.1. DDSM veri setindeki vakalar ve içerikleri hakkındaki bilgiler

Klasör	Görüntü Sayısı	Boyut
normal_01	111	5,8 GB
normal_02	117	6,6 GB
normal_03	38	4,1 GB
normal_04	57	5,1 GB
normal_05	47	4,3 GB
normal_06	60	5,5 GB
normal_07	78	6,2 GB
normal_08	27	2,8 GB
normal_09	59	4,9 GB
normal_10	23	2,1 GB
normal_11	58	6,1 GB
normal_12	20	2,2 GB
kanser_01	69	3,9 GB
kanser_02	88	5,7 GB
kanser_03	66	6,0 GB
kanser_04	31	2,8 GB
kanser_05	83	6,6 GB
kanser_06	56	6,3 GB

Tablo 2.2. (Devamı)

Klasör	Görüntü Sayısı	Boyut
kanser_07	52	6.1 GB
kanser_08	55	6.0 GB
kanser_09	81	6,5 GB
kanser_10	59	6,6 GB
kanser_11	59	5,9 GB
kanser_12	80	6,8 GB
kanser_13	21	2.0 GB
kanser_14	42	4,6 GB
kanser_15	72	6.0 GB
iyi huylu_01	80	6,5 GB
iyi huylu_02	69	6,9 GB
iyi huylu_03	64	6,7 GB
iyi huylu_04	81	6,5 GB
iyi huylu_05	62	6,5 GB
iyi huylu_06	74	6.1 GB
iyi huylu_07	61	6.1 GB
iyi huylu_08	64	6,5 GB
iyi huylu_09	75	6.1 GB
iyi huylu_10	21	2,1 GB
iyi huylu_11	62	6,5 GB
iyi huylu_12	64	6,4 GB
iyi huylu_13	72	6.1 GB
iyi huylu_14	21	2,1 GB

2.3. Derin Öğrenme (DL)

Derin öğrenme, makine öğrenimi alanının bir alt kümesidir ve sinir ağı tabanlı modeller kullanarak öğrenme sürecini gerçekleştirir. Derin öğrenme, büyük ve karmaşık veri kümelerinden yüksek düzeyde temsil öğrenme yapabilme yeteneğine sahiptir. Derin öğrenme modelleri, yapay sinir ağlarının çok katmanlı yapılarından oluşur ve bu yapılar sayesinde otomatik olarak daha karmaşık özellikler ve desenler öğrenebilirler.

Derin öğrenme, sağlık alanında hastalıkların tespitinde önemli bir rol oynamaktadır. Özellikle meme kanseri gibi hastalıkların semptomlarının tespit edilmesinde daha etkili bir yöntem sunmaktadır (Kulkarni vd, 2021).


İnsan beyninin bilgileri filtreleme biçiminden ilham alan bir tekniktir. Örneklerden öğrenme ile ilişkilidir. DL sistemleri, bilgileri tahmin etmek ve sınıflandırmak için bir

bilgisayar modelinin girdi verilerini katmanlar aracılığıyla filtrelemesine yardımcı olur. Derin Öğrenme, bilgiyi insan beyniyle aynı şekilde işler. Sürücüsüz arabalar gibi teknolojilerde kullanılır. DL ağ mimarileri Evrişimli Sinir Ağları, Tekrarlayan Sinir Ağları ve Tekrarlı Sinir Ağları olarak sınıflandırılır.

DL, kanser tahmini de dahil olmak üzere birçok makine öğrenimi görevinde tercih edilen sınıflandırıcı haline gelmiştir (Zhou vd, 2020).

2.4. Evrişimli Sinir Ağı (CNN)

Evrişimli Sinir Ağları (CNN) derin öğrenme modelleri içerisinde insan beyninden esinlenen bir yaklaşımdır. Bu yöntem, ilk olarak 1980 yılında Kunihiro Fukushima tarafından ortaya atılmış ve daha sonra 1998'de Yann LeCun ve ekibi tarafından geliştirilmiştir (Boudouh ve Bouakkaz, 2022). CNN, genellikle sınıflandırma problemleri için kullanılan etkili bir derin öğrenme yöntemidir (Benmabrouk vd, 2022). CNN mimarisi Şekil 2.5'te gösterilmiştir.



Şekil 2.5. CNN mimarisi

Kaynak : (Boudouh ve Bouakkaz, 2022)

CNN mamogram görüntülerinin ön işleme adımlarını gerçekleştirerek, bir insanın görsel görüntüsünü bilgisayar görsel görüntüsüne dönüştürme ve CNN sınıflandırıcısı için uygun parametreleri ayarlama amacıyla kullanılırlar. Bu amaç doğrultusunda, mamogram görüntülerine çeşitli ön işleme adımları uygulanır ve elde edilen modifiye edilmiş görüntüler, CNN sınıflandırıcısının eğitim veri kaynağı olarak kullanılır (Tan vd, 2018).

2.5. Derin Sinir Ağı Modelleri (DNN)

Derin sinir ağları, günümüzde sınıflandırma, görüntü tanıma, konuşma tanıma, duygu analizi ve dil çevirisi gibi çeşitli alanlardaki problemlerde olağanüstü doğruluk sağlama yeteneğiyle, güncel teknolojiyi önemli ölçüde geliştirmiştir. Bu sinir ağları, karmaşık ve zorlu modelleme problemlerine uygun çözümler sunarak, sık sinir ağlarının kapasitesini aşan yüksek boyutlu ve geniş kapsamlı modellemeyi başarıyla gerçekleştirir (Na vd, 2020).

DNN 'ler, veri sınıfları veya nesne kategorileri hakkındaki ön bilgileri kullanma yetenekleri sayesinde, yeni verilerin veya nesnelerin etkin bir şekilde sınıflandırılmasını sağlarken önceki bilgilerini de korur. DNN 'ler, farklı ağ türlerini içeren yapılarıyla birlikte uçtan uca mimariler olarak da uygulanabilir ve sinyalleri, görüntüleri, metinleri ve diğer girdileri analiz etmek için eğitilebilirler. Bu sayede, DNN 'ler, çeşitli alanlarda veri sınıflandırma ve nesne tanıma gibi görevleri başarıyla yerine getirebilirken, önceki bilgilere dayanarak yeni verileri etkili bir şekilde işleyebilir (Kollias vd, 2018).


2.6. Bölge Tabanlı Evrişimli Sinir Ağları (R-CNN)

R-CNN'ler, bilgisayarlı görü alanında en gelişmiş nesne tespiti ve sınıflandırma için kullanılan bir derin öğrenme yöntemidir. Bu yöntem, önceden belirlenmiş nesne benzeri bölgeleri tespit ederek başlar ve her bir bölgeden ayrıntılı ve ayırt edici özellikler çıkarmak için CNN kullanır. Ardından, her bölgeyi kategoriye özgü sınıflandırıcılar kullanarak sınıflandırır. R-CNN modeli, tüm görüntü üzerinde kayan pencere tabanlı tarama yerine yüzlerce önerilen nesne benzeri bölgeyi kullanarak arama alanını azaltır. Bu sayede, daha hızlı çalışır. R-CNN modeli, bilgisayar görüşü alanında önemli bir başarıya ulaşmış olmasına rağmen, havadan elde edilen görüntülerde çeşitli zorluklarla karşılaşabilir. Özellikle araç algılama gibi uygulamalarda bazı sınırlamalar ortaya çıkabilir (Deng vd, 2017).

2.6.1. Faster R-CNN

Faster R-CNN, nesne tespiti ve sınıflandırma alanında kullanılan bir z yöntemidir. R-CNN hızlı ve doğru nesne tespiti yapma yeteneğiyle öne çıkar. Faster R-CNN'nin çalışma prensibi şu şekildedir: İlk adımda, giriş görüntü üzerinde evrişim tabanlı özellik haritası


oluşturulur. Bu adımda, bir evrişim tabanlı sinir ağı (CNN) kullanılır ve görüntünün farklı ölçeklerde ve konumlarda özelliklerini çıkarmak için evrişim işlemleri gerçekleştirilir. Daha sonra, RPN (Region Proposal Network) adı verilen bir ağ kullanılarak öneri bölgeleri oluşturulur. RPN, evrişim tabanlı özellik haritasını kullanarak görüntü üzerinde potansiyel nesne bölgelerini belirler. Bu bölgeler, nesne olabilecek olası kare veya dikdörtgen alanlarıdır (Li vd, 2022). Faster R-CNN mimarisini gösteren şema Şekil 2.6'da verilmiştir.



Şekil 2.6. Faster R-CNN mimarisi

2.7. Aktarım Öğrenimi

Aktarım Öğrenimi (TL), araştırmacıların yeni ve daha karmaşık hedef görevlerde öğrenme hızını artırmak için daha önce öğrenilmiş kaynak görevlerde edinilen bilgileri kullanmayı amaçlayan bir tekniktir. TL'nin bilgi aktarımını gösteren şemaya Şekil 2.7'de yer verilmiştir (H. vd, 2022).



Şekil 2.7. Aktarım Öğrenimi şeması

3. ÇALIŞMADA KULLANILAN CNN MODELLERİ

CNN modelleri, görüntü işleme ve sınıflandırma alanında yaygın olarak kullanılan etkili bir derin öğrenme yaklaşımıdır. Meme kanseri görüntülerinin sınıflandırılması çalışmasında, meme görüntülerindeki lezyon bölgelerine göre kanserli ve sağlıklı görüntüler arasında ayırım yapılması hedeflenmiştir. Bu amaçla, önceden eğitilmiş CNN modelleri, mammogram görüntülerinden özellik haritaları çıkarmak ve daha sonra bu özellik haritaları yardımıyla lezyon bölgesi önerileri oluşturmakta kullanılmıştır. Yüksek başarılar altında bu yöntem, meme kanserinin tanı ve tarama süreçlerinde önemli bir rol oynayabilir ve doğru sınıflandırma sonuçları elde etmek için önemli bir araç olabilir. Çalışmada kullanılan ön eğitilmiş CNN modellerini kısaca verelim.

3.1. Inception V2

Google tarafından geliştirilen Inception V2 modeli, görüntü sınıflandırma ve nesne tanıma gibi görevlerde etkileyici başarılar elde etmiştir. Inception V2 modelinin temel çalışma prensipleri:

Giriş Katmanı: Inception V2 modeli, giriş katmanında temel özellik çıkarma işlemlerini gerçekleştirir. Giriş görüntüleri, önceden belirlenmiş boyutlara yeniden boyutlandırılır ve daha sonra özellik haritalarına dönüştürülür.

Inception Modülleri: Inception V2 modelinin en dikkat çekici özelliklerinden biri, Inception modülleridir. Bu modüller, farklı boyutlarda filtreleri birleştirerek daha karmaşık özelliklerin temsili mümkün kılar. Her Inception modülü, çeşitli paralel konvolüsyon katmanlarından oluşur ve bu katmanlardaki filtrelerin boyutları farklıdır. Bu yapı, hem hesaplama gücünü etkin bir şekilde kullanmayı sağlar hem de farklı düzeylerdeki özelliklerin yakalanmasını destekler.


Azaltma Katmanları: Inception V2 modeli, veri boyutunu azaltmak için azaltma katmanları kullanır. Azaltma katmanları, özellik haritalarını küçültmek ve bilgiyi yoğunlaştırmak amacıyla konvolüsyon işlemlerini uygular. Bu sayede, daha yüksek seviyede temsil edilebilecek özelliklerin elde edilmesi sağlanır.

İzlemeli Bağlantılar: Inception V2 modelinde, önceki katmanlardan gelen bilgilerin sonraki katmanlara doğrudan aktarılmasını sağlayan izlemeli bağlantılar kullanılır. Bu bağlantılar, derin ağ yapısında bilgi kaybını azaltır ve modelin daha iyi öğrenme yeteneğine sahip olmasını sağlar.

Inception V2 modeli, görüntü sınıflandırma ve nesne tanıma gibi görevlerde yüksek performans sergileyen başarılı bir derin öğrenme modelidir. Inception modülleri, azaltma katmanları ve izlemeli bağlantılar gibi temel özellikleri sayesinde daha karmaşık ve derin özelliklerin etkin bir şekilde temsil edilmesine olanak tanır (Szegedy, Ioffe, Vanhoucke ve Alemi, 2016).

3.2. ResNet101

ResNet-101, görsel olarak Şekil 3.1'de tasvir edilen bir evrişimli sinir ağıdır ve toplamda 101 katman içermektedir. Bu ağ, ImageNet veri tabanında bulunan bir milyondan fazla görüntüyle önceden eğitilmiştir. Eğitim sürecinde, bilgisayarlar, yazıcılar ve çeşitli hayvan türleri de dahil olmak üzere 1.000'den fazla sınıfı tanıma yeteneği için bu veri seti üzerinde eğitilmiştir. Ağ, 224 x 224 piksel çözünürlüğe sahip görüntüleri giriş olarak kabul etmektedir (Al-Rubaye ve Ayvaz, 2022).




Şekil 3.1. ResNet101 mimarisi

3.3. ResNet-50

ResNet-50, Kaiming He ve ekibi tarafından 2016 yılında geliştirilen 50 katmanlı bir evrişimli sinir ağıdır. Bu ağ, beş farklı aşamadan oluşmaktadır. Her aşamada bir evrişim bloğu ve bir kimlik bloğu bulunmaktadır. Her evrişim bloğunda üç evrişim katmanı ve her kimlik bloğunda üç evrişim katmanı yer almaktadır. ResNet-50'nin mimarisi Şekil 3.2'de gösterilmiştir ve toplamda 23 milyon eğitilebilir parametreye sahiptir. Bu mimari, daha derin ve karmaşık modellerin eğitiminde başarılı sonuçlar elde etmek için kullanılan önemli bir yapıya sahiptir (Al-Rubaye ve Ayvaz, 2022).

ResNet-50'nin mimarisi ile ilgili bilgiler Şekil 3.2'de gösterilmektedir.



Şekil 3.2. ResNet-50 mimarisi

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada DDSM veri setinden alınan meme kanseri görüntüleri üzerindeki lezyon bölgelerini belirlemek ve görüntüleri sınıflandırmak için kullanılan Faster R-CNN yöntemi ile birlikte Inception V2, ResNet101 ve ResNet-50 olmak üzere 3 farklı ön eğitilmiş CNN modeli kullanılmış ve bu modellerin performansları karşılaştırılmıştır. Elde edilen sonuçlara göre, ResNet101 ağ modelinin diğer modellere göre daha başarılı olduğu gözlenmiştir. Diğer modellerde lezyon tespiti ve sınıflandırmasında oldukça başarılı sonuçlar vermiştir, ancak ResNet101 ağ modeli en yüksek başarı oranlarına sahip olmuştur. Ayrıca diğer bir açık kaynak meme kanseri görüntü seti olan MIAS veri setinde, iyi huylu ve kötü huylu tümör sınıflandırma problemi, çalışmada ele alınan ön eğitilmiş CNN modelleri üzerinde eğitilmiştir. Elde edilen sonuçlar grafikler ve tablolarla verilmiştir.


4.1. Veri Kümesinin Hazırlanması

Bu çalışma kapsamında, öncelikle DDSM veri setinden alınan işaretlenmiş 400 adet kötü huylu görüntüdeki lezyon bölgelerine ait bilgiler XML dosya formatına dönüştürülmüştür. Görüntülerin etiketlenmesi sürecinde, her bir görüntüde yer alan nesnelerin (lezyon) veya bölgelerin tanımlanması yapılmıştır. Bu sayede, belirli nesnelerin konumu, boyutu veya yoğunluğu gibi özellikler etiketlenerek kaydedilmiştir. Görüntülerin etiketlenmesi ve XML dosya formatının oluşturulması için LabelImg etiketleme aracı kullanılmıştır. Bu etiketleme aracı, kullanıcının istenilen nesneleri görüntüler üzerinde tek tek seçerek etiketleme işlemini gerçekleştirilmesine izin verir ve etiketlenen her bir görüntü için bir XML dosyası oluşturur. DDSM veri setinden alınan her bir kanserli görüntüye ait bu XML dosyaları, görüntülerdeki lezyon bölgelerin konum bilgilerini, sınıflandırma etiketlerini ve diğer ilgili meta verilerini içerir.


LabelImg etiketleme aracı kullanılarak görüntülerin etiketlenmesi ve diğer işlemler, Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5'te gösterilmiştir.




Şekil 4.1. Görüntü seçme işlemi



Şekil 4.2. Görüntü etiketleme işlemi



Şekil 4.3. Görüntü etiketleme işleminin isimlendirilmesi



Ad	Değiştirme tarihi	Tür	Boyut
Goruntu1.xml	13.7.2023 01:12	XML Dosyası	1 KB

Şekil 4.4. Görüntü etiketleme işlemini kaydetme

```

<annotation>
  <folder>cancer tüm - Kopya</folder>
  <filename>12.jpg</filename>
  <path>C:/Users/TOSHIBA/Desktop/tez/hazırlıklar/Resim toplama/cancer tüm - Kopya/12.jpg</path>
  <source>
    <database>Unknown</database>
  </source>
  <size>
    <width>231</width>
    <height>357</height>
    <depth>3</depth>
  </size>
  <segmented>0</segmented>
  <object>
    <name>cancer</name>
    <pose>Unspecified</pose>
    <truncated>0</truncated>
    <difficult>0</difficult>
    <bndbox>
      <xmin>96</xmin>
      <ymin>133</ymin>
      <xmax>150</xmax>
      <ymax>174</ymax>
    </bndbox>
  </object>
</annotation>

```

Şekil 4.5. Oluşturulan XML uzantılı örnek dosya içeriği

Oluşturulan XML dosyaları kodlamada kullanılan TensorFlow kütüphanesinin bir veri seti formatı olan tfrecords formatına dönüştürüldü. XML dosyalarının tfrecords formatına çevrilmesi ile veri setinin daha etkili bir şekilde kullanılabilmesi ve derin öğrenme modellerine

uygun hale getirilmesi amaçlanmıştır. Tfrecords formatı, veri setinin depolanması, okunması ve işlenmesi için optimize edilmiş bir yapıya sahiptir.

XML dosyası olarak etiketlenmiş 400 adet kanserli görüntü eğitim seti ve etiketlenmemiş 100 adet görüntü test seti olarak ayrılmıştır.

4.2. Meme Kanseri Lezyon Tespiti


Derin öğrenme alanında, model geliştirme ve araştırmaları devam ettikçe, mevcut modellerde iyileştirmeler ve yenilikler ortaya çıkar. Bu iyileştirmeler, modelin performansını artırmak, daha iyi sonuçlar elde etmek veya daha etkin bir şekilde çalışmasını sağlamak amacıyla yapılır. Bu kapsamda, Faster R-CNN yönteminde kullanılan Inception ve ResNet ön eğitilmiş modellerin güncel versiyonları kullanılarak doğruluk oranlarının daha önce literatürde yapılan çalışmalara göre artırılması hedeflenmiştir.

Ön eğitilmiş modeller, genellikle büyük veri setleri üzerinde önceden eğitilerek genel özellikleri öğrenirler. Ancak, bu modellerin performansı zamanla geliştirilir ve daha yeni versiyonları çıkar. Bu güncellemeler, genellikle ağırlık derinliği, mimarisi, aktivasyon fonksiyonları veya optimizasyon algoritmaları gibi unsurları kapsar. Bu nedenle, Inception V2, ResNet101 ve ResNet-50 gibi ön eğitilmiş modellerin güncel versiyonları kullanılarak doğruluk oranlarının artması beklenmiştir.

Meme görüntüleri üzerindeki lezyon tespiti ve sınıflandırmasında kullanılan modellerin eğitimi, AMD FX-8350 2.80 GHz işlemci, 32 GB DDR3 RAM ve 4 GB GDDR5 128 Bit NVIDIA GeForce GTX 960 OEM grafik kartı olan bir bilgisayar ile yapılmıştır. Çalışmada, açık kaynak kodlu Python dili ve bu dilin makine öğrenmesi ve derin öğrenmede yaygın olarak kullanılan Keras ve TensorFlow kütüphaneleri kullanılmıştır.


Çalışmada kullanılan Inception V2, ResNet101 ve ResNet-50 modellerinin eğitimi 300.000 adımda gerçekleştirilmiştir. Eğitim sürecinin her bir adımında tek bir örnek görüntü (batch_size=1) kullanılmıştır. Batch_size'in 1 olarak belirlenmesi, her bir adımda sadece tek bir örnek görüntünün kullanılmasını sağlamıştır. Ancak, bu eğitim sürecinin daha uzun sürmesine neden olmuştur. Adım sayısı ve batch_size parametreleri, modellerin daha iyi genelleştirme yapması ve başarılı doğruluk oranları elde edilmesini sağlamaktadır. Eğitim sonucunda oluşturulan modeli test etmek için modelin daha önce görmediği etiketlenmemiş 100 adet kanserli ve sağlıklı test görüntüleri kullanılmıştır. Bu test görüntülerinin 80 adeti kanserli ve 20 adeti sağlıklı görüntülerden oluşmaktadır. Çalışmada eğitilen her bir model için test verilerinin başarımlar oranları ve kayıp grafikleri aşağıda verilmiştir.

Inception V2 modelinin 80 adet kanserli görüntü üzerindeki lezyon bölgesinin belirlenmesi ve sınıflandırılmasının ortalama başarı oranı %97,16 olarak hesaplanmıştır ve Şekil 4.6’da gösterilmiştir.




Şekil 4.6. Inception V2 modeli başarı oranı

Inception V2 modelinin bazı test görüntüleri üzerindeki sonuçları Şekil 4.7’de verilmiştir.



Şekil 4.7. Inception V2 modelinin bazı test görüntüleri sonuçları

Inception V2 modelinin kayıp (loss) değerleri Şekil 4.8’de verilmiştir.




Şekil 4.8. Inception V2 modeli kayıp (loss) değerleri

ResNet101 modelinin 80 adet kanserli görüntü üzerindeki lezyon bölgesinin belirlenmesi ve sınıflandırılmasının ortalama başarımlar oranı %94,74 olarak hesaplanmıştır ve Şekil 4.9’da gösterilmiştir.








Şekil 4.9. ResNet101 modeli başarı oranı

ResNet101 modelinin test görüntüleri üzerindeki sonuçları Şekil 4.10’da verilmiştir.



Şekil 4.10. ResNet101 modelinin bazı test görüntüleri sonuçları

ResNet101 modelinin kayıp (loss) değerleri Şekil 4.11’de gösterilmiştir.




Şekil 4.11. ResNet101 modeli kayıp (loss) değerleri

ResNet-50 modelinin 80 adet kanserli görüntü üzerindeki lezyon bölgesinin belirlenmesi ve sınıflandırılmasının ortalama başarı oranı %99,63 olarak hesaplanmıştır ve Şekil 4.12’de gösterilmiştir.




Şekil 4.12. ResNet-50 modeli başarı oranı

ResNet-50 modelinin test görüntüleri üzerindeki sonuçlar Şekil 4.13'te verilmiştir.



Şekil 4.13. ResNet-50 modelinin bazı test görüntüleri sonuçları

ResNet-50 modelinin kayıp (loss) değerleri Şekil 4.14'te verilmiştir.



Şekil 4.14. ResNet-50 modeli kayıp (loss) değerleri

Çalışmalarda Inception V2, ResNet101 ve ResNet-50 gibi ön eğitilmiş modellerin performans ölçümleri Tablo 4.1’de sunulmuştur.

Tablo 4.1. Inception V2, ResNet101 ve ResNet-50 ön eğitimli modellerin performans ölçümleri

Model	Inception V2	ResNet101	Resnet-50
Doğruluk	%97,16	%94,74	%99,63

Inception V2 modeli test veri setindeki 80 adet kanserli görüntüdeki lezyon bölgelerinden 59 tanesini %100, 14 tanesini %99, 3 tanesini %98, 1 tanesini %97, 1 tanesini %96 oranla doğru ve 2 tanesini sağlıklı olarak tahmin etmiş ve 20 adet sağlıklı test görüntüsünün tamamını doğru olarak tahmin etmiştir. ResNet101 modeli 80 tane kanserli görüntülerin 56 tanesini %100 oranla, 19 tanesini %99 oranla, 1 tanesini %98 oranla doğru ve 4 tanesini sağlıklı olarak tahmin etmiş ve 20 adet sağlıklı test görüntüsünün tamamını doğru olarak tahmin etmiştir. ResNet-50 modeli 80 tane kanserli görüntülerin 57 tanesini %100 oranla, 21 tanesini %99 oranla, 1 tanesini %98 oranla ve 1 tanesini %93 oranla doğru tahmin etmiş ve 20 adet sağlıklı test görüntüsünün tamamını doğru olarak tahmin etmiştir. Bu eğitimler sonucu elde edilen başarımlar arasında ResNet-50 modelinin daha çok başarılı olduğu görülmektedir. Bu veri setiyle daha önce yapılan sınıflandırma çalışmaları, kullanılan algoritmalar ve doğruluk değerleri Tablo 4.2’de gösterilmiştir.

Tablo 4.2. DDSM veri seti kullanılarak yapılan çalışmalar, algoritmalar ve doğruluk değerleri


	Sınıflandırma Çalışması	Kullanılan Algoritma	Doğruluk
(Cao vd, 2019)	Lezyon Tespiti	Faster R-CNN	%97,50
(Mechria vd, 2019)	Lezyon Tespiti	DCNN	%89,23
(Hassan vd, 2015)	Lezyon Tespiti	Bölge Büyütme Algoritması	%83
(Duque vd, 2015)	Lezyon Tespiti	Bir bölge büyütme tekniği ve böl ve birleştirme tekniği	%85
(N. vd, 2012)	Lezyon Tespiti	Görüntü işleme teknikleri	%86
(L. vd, 2018)	Lezyon Tespiti	Global eşikleme ve K-means algoritması	%91,30
(Domínguez vd, 2007)	Lezyon Tespiti	Görüntü işleme algoritmaları	%80
Önerilen Çalışma	Lezyon Tespiti	ResNet-50	%99,63

4.3. Meme Kanseri Sınıflandırması

Bölüm 4.1’de verilen çalışmada Faster R-CNN yönteminde Inception V2, ResNet101 ve ResNet-50 CNN modelleri kullanılarak DDSM veri seti üzerinde lezyon tespiti sağlandı. Şimdi, aynı CNN modelleri MIAS (Mammographic Image Analysis Society) veri seti üzerinde farklı parametrelerle sadece iyi huylu ve kötü huylu tümör sınıflandırma probleminde kullanılacak ve başarımlarına bakılacaktır.

MIAS veri seti, meme kanserinin tarama ve teşhisinde kullanılan dijital meme mamografisi görüntülerini içeren 330 adet dijital meme mamografisi görüntüsünden oluşmaktadır. Bu veri setinde 208 normal, 68 iyi huylu ve 54 kötü huylu tümör görüntüsü bulunmaktadır. Her bir görüntü 1024x1024 piksel boyutunda olup, piksel başına 200 mikron kenar uzunluğuna sahiptir. Görüntüler, yüksek kalitede mamografi verileri sağlamak amacıyla İngiltere merkezli bir araştırma grubu tarafından elde edilmiştir. Tüm görüntüler 8 bitlik gri düzeyine (0-255) sahip olup, 256 farklı gri tonunu temsil etmektedir. Görüntüler Portable Gray Map (PGM) formatında sunulmaktadır (Shah ve Kalita, 2022).

MIAS veri setinin çeşitliliğini artırmak veya modelin genelleştirme yeteneğini iyileştirmek için veri setine uygulanmış veri arttırma (data augmentation) işlemlerinden elde edilmiş görüntülerle çalışılmıştır. Veri arttırma işlemleri, yansıtma, ölçeklendirme, yer değiştirme, parlaklık değişimi, gürültü ekleme, vb. olarak sayılabilir. MIAS veri setine ait bazı görüntü ve etiket değerleri Şekil 4.15’te verilmiştir.



Şekil 4.15. MIAS veri setine ait arttırılmış görüntüler ve etiket değerleri

Veri seti modelin eğitimi için 2016 adet iyi huylu ve 4088 adet kötü huylu eğitim veri setine ve 504 adet iyi huylu ve 1024 adet kötü huylu doğrulama veri setine ayrılmıştır. batch_size bu çalışmada 16 olarak belirlenmiştir. MIAS veri seti için oluşturulan model sonuçlarının değerlendirilmesinde kullanılan karmaşıklık matrisindeki parametreler Tablo 4.3'te sunulmuştur.

Tablo 4.3. Doğruluk hesaplama parametreleri

Doğru Pozitif (TP)	Yanlış Pozitif (FP)
Görüntünün gerçek niteliği "kötü huylu" olarak belirlenmiştir. Model tarafından yapılan tahmin de "kötü huylu" olarak gerçekleşmiştir.	Görüntünün gerçek niteliği "iyi huylu" olarak belirlenmiştir. Ancak, model tarafından yapılan tahmin "kötü huylu" olarak gerçekleşmiştir.
Yanlış Negatif (FN)	Doğru Negatif (TN)
Görüntünün gerçek niteliği "kötü huylu" olarak tespit edilmiştir. Ancak, model tarafından yapılan tahmin "iyi huylu" olarak gerçekleşmiştir	Görüntünün gerçek niteliği "iyi huylu" olarak tespit edilmiştir ve model tarafından yapılan tahmin de "iyi huylu" olarak gerçekleşmiştir.

Eğitimde kullanılan modellerin sonuç değerlendirilmesinde kullanılan doğruluk hesaplama eşitliği aşağıda gösterilmiştir.


$$\text{Doğruluk} = \frac{TP+TN}{(TP+TN+FP+FN)} \quad (4.1)$$

$$\text{Hassasiyet} = \frac{TP}{(TP+FP)} \quad (4.2)$$

$$\text{Özgüllük} = \frac{TP}{(TP+FN)} \quad (4.3)$$


$$\text{F1 Skor} = \frac{2 * (\text{Hassasiyet} * \text{Özgüllük})}{(\text{Hassasiyet} + \text{Hatırlama})} \quad (4.4)$$

Her bir model için test verilerinin başarı oranları ve eğitim kayıp grafikleri aşağıdaki gibi verilmiştir. Inception V2 modeli için ortalama başarı oranı %99,41 olarak elde edilmiş ve Şekil 4.16’da gösterilmiştir.




Şekil 4.16. Inception V2 modeli başarı oranı

Inception V2 modelinin eğitimi sonucunda tahmin edilen ve gerçek sonucu gösteren görüntüler Şekil 4.17’de verilmiştir.




Şekil 4.17. Inception V2 modelinin tahmin edilen ve gerçek sonuçları

Inception V2 modelinin kayıp (loss) değerleri Şekil 4.18’de verilmiştir.




Şekil 4.18. Inception V2 modeli kayıp (loss) değerleri

ResNet101 modeli için ortalama başarı oranı %99,21 olarak elde edilmiş ve Şekil 4.19’da gösterilmiştir.




Şekil 4.19. ResNet101 modeli başarı oranı

ResNet101 modelinin eğitimi sonucunda tahmin edilen ve gerçek sonucu gösteren görüntüler Şekil 4.20’de verilmiştir.




Şekil 4.20. ResNet101 modelinin tahmin edilen ve gerçek sonuçları

ResNet101 modelinin kayıp (loss) değerleri Şekil 4.21’de verilmiştir.




Şekil 4.21. ResNet101 modeli kayıp (loss) değerleri

ResNet-50 modeli için ortalama başarı oranı %99,34 olarak elde edilmiş ve Şekil 4.22’de gösterilmiştir.




Şekil 4.22. ResNet-50 modeli başarı oranı

ResNet-50 modelinin eğitimi sonucunda tahmin edilen ve gerçek sonucu gösteren görüntüler Şekil 4.23’te verilmiştir.




Şekil 4.23. ResNet-50 modelinin tahmin edilen ve gerçek sonuçları

ResNet-50 modelinin kayıp (loss) değerleri Şekil 4.24’te verilmiştir.




Şekil 4.24. ResNet-50 modeli kayıp (loss) değerleri

Çalışmada kullanılan Inception V2, ResNet101 ve ResNet-50 modellerin her birinin karmaşıklık matrisleri Şekil 4.25 ’te görselleştirilmiştir.



Şekil 4.25. Eğitimde kullanılan ağların karmaşıklık matrisleri

Makine öğrenmesi ve derin öğrenme çalışmalarında başarıyı değerlendirmesi için en yaygın olarak kullanılan yöntemlerden birisi de ROC (Receiver Operating Characteristic) eğrisidir. ROC eğrisi, sınıflandırma modellerinin performansını analiz etmek için kullanılan grafiksel bir araçtır (Dandıl ve Serin, 2020). Modellere ait ROC eğrileri Şekil 4.26'da gösterilmiştir.



Şekil 4.26. Modellere ait ROC eğrileri

MIAS veri setinde kullanılan modellerin performans değerleri Tablo 4.4'te sunulmuştur.

Tablo 4.4. Modellerin performans değerleri

Ölçüm	Inception V2	ResNet101	ResNet-50
Doğruluk (Accuracy)	%99,41	%99,21	%99,34
Özgüllük (Recall)	%99,51	%99,41	%99,31
Hassasiyet (Precision)	%99,60	%99,41	%99,70
F1 Skor (F1 Score)	%99,56	%99,41	%99,51

Meme kanseri sınıflandırılmasında kullanılan diğer bir veri seti olan BreakHis için yapılan çalışmalara ait bilgiler Tablo 4.5'te tezdeki çalışmanın sonuçlarıyla karşılaştırma yapılabilmesi amacıyla sunulmuştur (Dandil ve Serin, 2020).

Tablo 4. 5 BreakHis veri seti kullanılarak yapılan çalışmalar, algoritmalar ve doğruluk değerleri

Yöntem	Algoritma	Doğruluk
Çok sınıflı tümör sınıflandırma	Fraktal boyut + Destek Vektör Makineleri (SVM)	%55.60
Tümör sınıflandırma	CNN + Uzun Kısa Süreli Hafıza (LSTM) + Softmax + Destek Vektör Makineleri (SVM)	%91.00
Tümör sınıflandırma	Derin Evrişimli Sinir Ağı (DCNN) + TensorFlow + Düzleştirilmiş Doğrusal Birim Katmanı (ReLU)	%91.50
Tümör sınıflandırma	DenseNet161	%91.57
Çok sınıflı tümör sınıflandırma	Yapılandırılmış Derin Öğrenme Modeli (SDLM)	%93.2
Tümör derecelendirmesi	Yerel Olarak Toplanmış Tanımlayıcıların Vektörü (VLAD)	%95.8
Tümör sınıflandırma	Derin Evrişimli Sinir Ağlarına Dayalı Histopatolojik Görüntülerde Meme Kanseri Sınıflandırması (BiCNN)	%97.89
Tümör sınıflandırma	Xception	%98.01

5. SONUÇLAR

Meme kanserinin neden olduğu ölüm oranlarını azaltmak ve iyileştirilmek amacıyla Mammogram görüntüleri üzerinde meme kanserinin doğru bir şekilde bölgesel tespiti ve sınıflandırmasında Faster R-CNN derin öğrenme yöntemi kullanılmıştır. Çalışma kapsamında, önceden eğitilmiş üç farklı CNN modeli Inception V2, Resnet101 ve Resnet-50 DDSM veri seti üzerinde tekrar eğitilmiştir. Modellerin eğitim süreci tamamlandıktan sonra performansları karşılaştırılmış ve sonuçların birbirine oldukça yakın doğrulukta olduğu gözlemlenmiştir. Sonuçlara bakıldığında eğitilen modellerin test görüntüleri üzerindeki lezyon bölgelerinin konumunu belirlemede ve sınıflandırmasında başarı oranı, %99,63 değerine ulaşılmıştır. Bu sonuca göre Faster R-CNN yöntemi ve kullanılan güncel modellerin bu problem için uygun olduğu sonucuna varılabilir.

Literatürde yapılan çalışmalar, Faster R-CNN yönteminin diğer derin öğrenme yöntemlerine kıyasla nesnenin sınıf etiketini ve konumunu birlikte tahmin etme de daha hızlı ve daha yüksek bir sınıflandırma doğruluğuna sahip olduğunu kanıtlamıştır. Bu özellikler, tümörlü görüntülerde lezyon bölgesinin tespiti gibi problemlerin çözümünde tümörün konumunun doğru bir şekilde tespit edilmesinin önemli olmasından dolayı Faster R-CNN yönteminin uygun olduğunu göstermektedir.

Ayrıca tez çalışmasında, meme kanserine ait iyi ve kötü huylu tümörlerin olduğu MIAS veri seti alınarak ön eğitimli Inception V2, Resnet101 ve Resnet-50 derin öğrenme ağları ikili sınıflandırma için kullanılmıştır. Veri seti için elde edilen modellerin performansları karşılaştırılmış ve sonuçların oldukça yakın ve yüksek doğruluklarda olduğu gözlemlenmiştir. Eğitime sokulmayan test görüntülerine karşılık iyi huylu ve kötü huylu tümör görüntülerinin sınıflandırma doğruluk değeri en iyi Inception V2 modelinde %99,41 olarak elde edilmiştir.

KAYNAKÇA

- Afaq, S. ve Jain, A.** (2022). *MAMMO-Net: An Approach for Classification of Breast Cancer using CNN with Gabor Filter in Mammographic Images*. Proceedings of International Conference on Computational Intelligence and Sustainable Engineering Solution, CISES 2022, 177–182. doi:10.1109/CISES54857.2022.9844320
- Al-Rubaye, D. ve Ayvaz, S.** (2022). *Deep Transfer Learning and Data Augmentation for Food Image Classification*. 2022 Iraqi International Conference on Communication and Information Technologies, IICCIT 2022 içinde (ss. 125–130). Institute of Electrical and Electronics Engineers (IEEE).
- Ben-Ari, R., Akselrod-Ballin, A., Karlinsky, L. ve Hashoul, S.** (2017). Domain specific convolutional neural nets for detection of architectural distortion in mammograms. *Proceedings - International Symposium on Biomedical Imaging*, 552–556.
- Benmabrouk, Y., Gasmi, M., Bendjenna, H. ve Nadjah, A.** (2022). *Semantic segmentation of breast cancer histopathology images using deep learning*. 4th International Conference on Pattern Analysis and Intelligent Systems, PAIS 2022 - Proceedings.
- Bhise, S., Gadekar, S., Gaur, A. S., Bepari, S., Kale, D. ve Aswale, S.** (2022). Detection of Breast Cancer Using Machine Learning and Deep Learning Methods. Proceedings of 3rd International Conference on Intelligent Engineering and Management, ICIEM 2022, 1–6.
- Boudouh, S. S. ve Bouakkaz, M.** (2022). *Breast Cancer: Using Deep Transfer Learning Techniques AlexNet Convolutional Neural Network For Breast Tumor Detection in Mammography Images*. 2022 7th International Conference on Image and Signal Processing and their Applications, ISPA 2022 - Proceedings.
- Cao, Z., Yang, Z., Liu, X., Zhang, Y., Wu, S., Lin, R. S., ... Ma, J.** (2019). *Deep learning based lesion detection for mammograms*. 2019 IEEE International Conference on Healthcare Informatics, ICHI 2019.
- Chiao, J. Y., Chen, K. Y., Ken Ying-Kai Liao, Hsieh, P. H., Zhang, G. ve Huang, T. C.** (2019). Detection and classification the breast tumors using mask R-CNN on sonograms. *Medicine (United States)*, 98(19).
- Cruz, A. La, Díaz Santacruz, C. A., Polo, L. ve Severeyn, E.** (2022). Breast Cancer Screening Using Deep Learning, 1–6. doi:10.1109/ETCM56276.2022.9935747

- Dandil, E. ve Serin, Z.** (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 451–463.
- Deng, Z., Sun, H., Zhou, S., Zhao, J. ve Zou, H.** (2017). Toward Fast and Accurate Vehicle Detection in Aerial Images Using Coupled Region-Based Convolutional Neural Networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8), 3652–3664.
- Divya, P., Rajan, D. P., Suguna, R. ve Velliangiri, S.** (2022). *Machine Learning Techniques for Prediction and Analysis of Benign and Malignant in Breast Cancer*. 2022 International Conference on Computer Communication and Informatics, ICCCI 2022.
- Erdem, E.** (2021). Göğüs Kanseri Histopatolojik Görüntü Sınıflandırması. *Bilişim Teknolojileri Dergisi*, 87–94.
- Harbeck, N. ve Gnant, M.** (2017, 8 Mart). Breast cancer. *The Lancet*. Elsevier. doi:10.1016/S0140-6736(16)31891-8
- Hassan, A. M. ve El-Shenawee, M.** (2011). Review of electromagnetic techniques for breast cancer detection. *IEEE Reviews in Biomedical Engineering*, 4, 103–118.
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H. ve Aerts, H. J. W. L.** (2018). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500–510.
- Huang, B., Chen, X., Sun, Y. ve He, W.** (2022). *Multi-agent cooperative strategy learning method based on transfer Learning*. ASCC 2022 - 2022 13th Asian Control Conference, Proceedings, 1095–1100.
- I. Domingues, E. Sales, J. S. C. and W. C. A. P.** (2012). INBreast-database masses characterization. 1 Ocak 2012 tarihinde https://www.researchgate.net/publication/232274438_INBreast-database_masses_characterization adresinden erişildi.
- Ismail, N. S. ve Sovuthy, C.** (2019). *Breast Cancer Detection Based on Deep Learning Technique*. 2019 International UNIMAS STEM 12th Engineering Conference, EnCon 2019 - Proceedings, 89–92.
- Jemal, A., Murray, T., Ward, E., Samuels, A., Tiwari, R. C., Ghafoor, A., ... Thun, M. J.** (2005). Cancer statistics, *CA: a cancer journal for clinicians*, 55(1), 10–30.

- Kollias, D., Yu, M., Tagaris, A., Leontidis, G., Stafylopatis, A. ve Kollias, S.** (2018). *Adaptation and contextualization of deep neural network models*. 2017 IEEE Symposium Series on Computational Intelligence, SSCI 2017 - Proceedings, 2018-Janua, 1–8.
- Kulkarni, N., Patanwadia, B. ve Kulkarni, V.** (2021). *A Survey on Machine Learning Techniques for Breast Cancer Diagnosis and Detection*. Proceedings - 2021 3rd International Conference on Advances in Computing, Communication Control and Networking, ICAC3N 2021 içinde (ss. 425–427). Institute of Electrical and Electronics Engineers Inc.
- Li, Y., Zhang, S. ve Wang, W. Q.** (2022). A Lightweight Faster R-CNN for Ship Detection in SAR Images. IEEE Geoscience and Remote Sensing Letters, 19.
- Lotter, W., Diab, A. R., Haslam, B., Kim, J. G., Grisot, G., Wu, E., ... Gregory Sorensen, A.** (2021). Robust breast cancer detection in mammography and digital breast tomosynthesis using an annotation-efficient deep learning approach. *Nature Medicine*, 27(2), 244–249.
- Manishkumar, S. H. ve Saranya, P.** (2022). *Detection and Classification of Breast Cancer from Mammogram Images Using Adaptive Deep Learning Technique*. ICDCS 2022 - 2022 6th International Conference on Devices, Circuits and Systems, 327–331.
- Mechria, H., Gouider, M. S. ve Hassine, K.** (2019). *Breast cancer detection using deep convolutional neural network*. ICAART 2019 - Proceedings of the 11th International Conference on Agents and Artificial Intelligence içinde (C. 2, ss. 655–660). PeerJ Inc.
- Na, W., Liu, K., Zhang, W., Xie, H. ve Jin, D.** (2020). *Deep Neural Network with Batch Normalization for Automated Modeling of Microwave Components*. 2020 IEEE MTT-S International Conference on Numerical Electromagnetic and Multiphysics Modeling and Optimization, NEMO 2020 içinde . Institute of Electrical and Electronics Engineers Inc.
- Nair, N. B., Singh, T., Thakur, A. ve Duraisamy, P.** (2022). *Deployment of Breast Cancer Hybrid Net using Deep Learning*. 2022 13th International Conference on Computing Communication and Networking Technologies, ICCCNT 2022.
- Rana, R. S., Jiang, Y., Schmidt, R. A., Nishikawa, R. M. ve Liu, B.** (2007). Independent Evaluation of Computer Classification of Malignant and Benign Calcifications in Full-Field Digital Mammograms. *Academic radiology*, 14(3), 363.

- Reiazi, R., Paydar, R., Ardakani, A. A. ve Etedadialiabadi, M.** (2018). Mammography Lesion Detection Using Faster R-CNN Detector, 111–115. doi:10.5121/CSIT.2018.80212
- Remya, R. ve Hema Rajini, N.** (2022). *Transfer Learning Based Breast Cancer Detection and Classification using Mammogram Images*. Proceedings of the International Conference on Electronics and Renewable Systems, ICEARS 2022, 1060–1065.
- Sah, S.** (2020). Machine Learning: A Review of Learning Types. doi:10.20944/PREPRINTS202007.0230.V1
- Seyfried, T. N. ve Shelton, L. M.** (2010). Cancer as a metabolic disease. *Nutrition & Metabolism*, 7(1), 1–22.
- Shah, F. ve Kalita, D.** (2022). *Design and Analysis of Early Detection System of Breast Cancer Based on Mammogram Images using Neural Network*. 2022 IEEE 7th International conference for Convergence in Technology, I2CT 2022.
- Shen, L., Margolies, L. R., Rothstein, J. H., Fluder, E., McBride, R. ve Sieh, W.** (2019). Deep Learning to Improve Breast Cancer Detection on Screening Mammography. *Scientific Reports*, 9(1), 1–12.
- Soumik, M. F. I., Aziz, A. Z. Bin ve Hossain, M. A.** (2021). *Improved transfer learning based deep learning model for breast cancer histopathological image classification*. 2021 International Conference on Automation, Control and Mechatronics for Industry 4.0, ACMI 2021.
- Surya Gowri, D. ve Amudha, T.** (2014). *A review on mammogram image enhancement techniques for breast cancer detection*. Proceedings - 2014 International Conference on Intelligent Computing Applications, ICICA 2014, 47–51.
- Szegedy, C., Ioffe, S., Vanhoucke, V. ve Alemi, A. A.** (2016). *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning*. 31st AAAI Conference on Artificial Intelligence, AAAI 2017, 4278–4284.
- Tan, Y. J., Sim, K. S. ve Ting, F. F.** (2018). *Breast cancer detection using convolutional neural networks for mammogram imaging system*. Proceeding of 2017 International Conference on Robotics, Automation and Sciences, ICORAS 2017, 2018-March, 1–5.

- Tezcan, C. E., Kiras, B. ve Bilgin, G.** (2022). *Classification of Breast Cancer Histopathological Images with Deep Transfer Learning Methods*. 2022 30th Signal Processing and Communications Applications Conference, SIU 2022.
- Thomas, A. M., Adithya, G., Arunselvan, A. S. ve Karthik, R.** (2022). *Detection of Breast Cancer from Histopathological Images using Image Processing and Deep-Learning*. Proceedings of the 2022 3rd International Conference on Intelligent Computing, Instrumentation and Control Technologies: Computational Intelligence for Smart Systems, ICICICT 2022, 1008–1015.
- Urabinahatti, S. ve Jayadevappa, D.** (2023). *Breast Cancer Detection Using Deep Learning Technique* (ss. 1–5). Institute of Electrical and Electronics Engineers (IEEE).
- Wei, K., Wang, B. ve Saniie, J.** (2020). *Faster Region Convolutional Neural Networks Applied to Ultrasonic Images for Breast Lesion Detection and Classification*. IEEE International Conference on Electro Information Technology içinde (C. 2020-July, ss. 171–174). IEEE Computer Society.
- Zhang, Z., Wang, Y., Zhang, J. ve Mu, X.** (2019). *Comparison of multiple feature extractors on Faster RCNN for breast tumor detection*. Institute of Electrical and Electronics Engineers Inc.
- Zhou, X., Li, Y., Gururajan, R., Bargshady, G., Tao, X., Venkataraman, R., ... Kondalsamy-Chennakesavan, S.** (2020). *A New Deep Convolutional Neural Network Model for Automated Breast Cancer Detection*. Proceedings of 2020 7th IEEE International Conference on Behavioural and Social Computing, BESC 2020.