



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MÜHENDİSLİK ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI

**DERİN ÖĞRENME YÖNTEMİ İLE MLO VE CC GÖRÜNTÜLERİ
KULLANILARAK MEME KANSERİNİN SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

İlyas KAYA

Danışman

Dr. Öğr. Üyesi Kadir SARIKAYA

TOKAT- 2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Dr. Öğretim Üyesi Kadir SARIKAYA danışmanlığında hazırlamış olduğum “Derin Öğrenme Yöntemi ile MLO ve CC Görüntüleri Kullanılarak Meme Kanserinin Sınıflandırılması” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

14/08/2025

İlyas KAYA

JÜRİ KABUL VE ONAY SAYFASI

İlyas KAYA tarafından hazırlanan “**Derin Öğrenme Yöntemi ile MLO ve CC Görüntüleri Kullanılarak Meme Kanserinin Sınıflandırılması**” adlı tez çalışmasının savunma sınavı 25/06/2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Çokluğu ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Mühendislik Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan):

.....

Üye :

.....

Üye :

.....

Üye :

.....

Üye :

.....

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

TEŞEKKÜR

Bu tezin hazırlanmasında bilgi ve deneyimlerini sunan herkese teşekkür ederim.

Öncelikle tez çalışmanın her aşamada değerli bilgi ve deneyimlerini paylaşan, akademik ve bilimsel rehberliğiyle yol gösteren saygıdeğer danışman hocam Dr. Öğr. Üyesi Kadir SARIKAYA'ya en derin teşekkürlerimi iletmek isterim. Tezimdeki yönlendirmeleri ve eleştirileri, bu tezin şekillenmesinde büyük bir rol oynamıştır.

Beni bu zorlu süreçte motive eden, manevi destekleriyle her zaman orada olan sevgili aileme teşekkür etmek isterim. Bu süreçte manevi desteğini hiç eksik etmeyen sevgili eşim Nurcan KAYA, oğlum Taha KAYA, oğlum Fatih KAYA' ya teşekkürü bir borç bilirim.

Son olarak, akademik kariyerim boyunca bilgi ve deneyimlerinden yararlandığım Öğr.Gör.Dr. Ersin ERSOY hocama, Doç.Dr.Emre ASLAN hocama ,Doç.Dr. Emre BAYRAM ,Doç.Dr.Hüda Melike BAYRAM hocama ,tüm hocalarıma ve araştırma sürecinde dolaylı veya doğrudan emeği geçen herkese şükranlarımı sunarım.

İlyas KAYA

ÖZET

DERİN ÖĞRENME YÖNTEMİ İLE MLO VE CC GÖRÜNTÜLERİ KULLANILARAK MEME KANSERİNİN SINIFLANDIRILMASI

Kaya, İlyas

Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Kadir SARIKAYA

Temmuz 2025, x + 61 sayfa

Bu çalışmada, meme kanseri teşhisi için popüler derin öğrenme modellerinden olan ResNet50 ve InceptionV3 mimarileri karşılaştırılmıştır. Kadınlar arasında en yaygın şekilde görülen malign neoplazilerden biri olan meme kanseri, zamanında tanı konulmadığında mortalite oranlarında ciddi artışlara neden olabilmektedir. Bu nedenle, erken teşhis için kullanılan mamografik görüntülerin doğru bir şekilde değerlendirilmesi büyük önem taşımaktadır. Ancak mamografi görüntülerinin manuel olarak yorumlanması, çeşitli hata risklerini barındırmakta ve sonuçların doğruluğunu etkileyebilmektedir. Bu bağlamda, yapay zeka ve derin öğrenme tabanlı otomatik tanı sistemleri, tıbbi görüntülemelerde meme kanseri tespiti için önemli bir alternatif olarak öne çıkmaktadır. DDSM (Digital Database for Screening Mammography) veri seti kullanılarak yapılan çalışmada, her iki modelin mamografik görüntüler üzerinden meme kanseri sınıflandırma performansları incelenmiştir. Bu süreçte, hem Cranio-Caudal (CC) hem de Medio-Lateral Oblique (MLO) açılardan alınan mamografi görüntüleri kullanılarak, modellerin kategorik doğruluk metrikleri üzerinden karşılaştırmaları yapılmıştır. Elde edilen sonuçlar, ResNet50 ve InceptionV3 modellerinin meme kanseri sınıflandırmasında farklı performanslar sergilediğini göstermektedir. ResNet50 modeli özellikle CC görüntülerinde daha yüksek doğruluk oranları sunarken, InceptionV3 modeli hem CC hem de MLO görüntülerinde tutarlı ve rekabetçi bir performans sergilemiştir. Sonuçlar, her iki modelin de otomatik meme kanseri teşhisinde etkin bir şekilde kullanılabileceğini gösterirken, farklı veri türlerinde ve görüntü açılarında performans farklılıklarının olduğu görülmüştür. Bu çalışma, yapay zeka tabanlı otomatik tanı sistemlerinin meme kanseri teşhisinde kullanılabilirliğine dair önemli bulgular sunmakta ve bu sistemlerin klinik uygulamalarda yaygınlaştırılmasına yönelik potansiyel katkılar sağlamaktadır.

Anahtar Kelimeler: Derin Öğrenme, Meme Kanseri, ResNet50, InceptionV3

ABSTRACT

CLASSIFICATION OF BREAST CANCER USING MLO AND CC IMAGES WITH DEEP LEARNING METHOD

Kaya, İlyas

Master's Degree, Department of Computer Engineering

Thesis Advisor: Asst. Prof. Dr. Kadir SARIKAYA

July 2025, x + 61 pages

This study was conducted to compare ResNet50 and InceptionV3 architectures, which are popular deep learning models for breast cancer detection. Breast cancer, one of the most common malignant neoplasms among women, can cause significant increases in mortality rates if not diagnosed in time. Therefore, accurate evaluation of mammographic images used for early detection is of great importance. However, manual interpretation of mammography images carries various error risks and can affect the accuracy of the results. In this context, artificial intelligence and deep learning-based automated diagnosis systems are emerging as an important alternative for breast cancer detection in medical imaging. In this study, using the Digital Database for Screening Mammography (DDSM) dataset, the breast cancer classification performances of both models on mammographic images were examined. In this process, mammographic images from both Cranio-Caudal (CC) and Medio-Lateral Oblique (MLO) angles were used to compare the models on categorical accuracy metrics. The results show that ResNet50 and InceptionV3 models perform differently in breast cancer classification. While the ResNet50 model provides higher accuracy rates, especially on CC images, the InceptionV3 model performs consistently and competitively on both CC and MLO images. While the results show that both models can be effectively used in automatic breast cancer diagnosis, there are performance differences in different data types and image angles. This study provides important findings on the usability of AI-based automated diagnostic systems in breast cancer diagnosis and provides potential contributions to the dissemination of these systems in clinical applications.

Keywords: Deep Learning, Breast Cancer, ResNet50, InceptionV3

İÇİNDEKİLER

ETİK SÖZLEŞME	i
JÜRİ KABUL VE ONAY SAYFASI	ii
TEŞEKKÜR.....	iii
ÖZET.....	iv
DERİN ÖĞRENME YÖNTEMİ İLE MLO VE CC GÖRÜNTÜLERİ KULLANILARAK MEME KANSERİNİN SINIFLANDIRILMASI.....	iv
ABSTRACT	v
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ	ix
KISALTMALAR LİSTESİ.....	xi
1. GİRİŞ	1
1.1. Tezin Özgün Değeri.....	1
1.2. Meme Kanseri ve Mamogram.....	3
1.3. Mamografi Çekim Teknikleri	5
1.3.1. Cranio-Caudal (CC) görüntüleme yöntemi.....	5
1.3.2. Medio-Lateral Oblique (MLO) görüntüleme yöntemi.....	6
1.4. Literatürde Mamografi Sınıflandırma.....	8
1.5. Yapay Zekâ ve Makine Öğrenmesi	12
1.5.1. Makine öğrenmesi çeşitleri.....	12
1.6. Yapay Sinir Ağı	15
1.6.1. Sigmoid fonksiyonu	17
1.6.2. Tanh (Hiperbolik Tanjant) fonksiyonu.....	17
1.6.3. ReLu fonksiyonu	18
1.6.4. Leaky ReLu fonksiyonu	18
1.6.5. Exponential Linear Unit (ELU)	19
1.6.6. Maxout fonksiyonu	19
1.7. Derin Öğrenme	20
1.8. Evrişimli Sinir Ağı Mimarisi	20
1.8.1. Evrişim katmanı.....	23
1.8.2. Havuzlama.....	24
1.8.3. Dropout katmanı.....	25
1.8.4. Tam bağlantı katmanı	26
1.9. Hiper Parametre Optimizasyonu ve Optimizasyon Algoritmaları	26
1.10. Transfer Öğrenme	27
1.11. Derin Öğrenme Yöntemleri ile Görüntü Sınıflandırma.....	28
1.12. Görüntü İşleme ve Görüntü Filtreleri	29
1.12.1. Kontrast sınırlı uyarlamalı histogram eşitleme	32
2. MATERYAL VE YÖNTEM.....	34
2.1. Veri Seti	34
2.2. Veri Ön İşleme ve Hazırlık	35
2.3. Kullanılan Algoritmalar	35
2.3.1. ResNet algoritması	35
2.3.2. Inception algoritması	37
2.3.3. Resnet50 ve Inception karşılaştırılması.....	39
2.4. Hata Matrisi.....	40
2.5. Sistem Parametreleri.....	46
2.5.1. ImageDataGenerator parametreleri (Veri ön işleme).....	46
2.5.2. Model parametreleri.....	47

2.5.3.	Model katmanları parametreleri	47
2.5.4.	Model derleme parametreleri (Compilation parameters).....	47
2.5.5.	Model eğitim parametreleri (Training parameters).....	48
3.	BULGULAR VE TARTIŞMA.....	48
3.1.	Resnet50 Algoritması ile CC Sınıflandırması.....	48
3.2.	InceptionV3 Algoritması ile CC Sınıflandırması	48
3.3.	Resnet50 ile MLO Sınıflandırması	49
3.4.	Inception V3 ile MLO Sınıflandırması	49
3.5.	ResNet50 ve InceptionV3 Modellerinin Karşılaştırılması	50
3.6.	CC ve MLO Görüntülerinin Performans Karşılaştırması	51
4.	SONUÇ VE ÖNERİLER.....	53
5.	KAYNAKLAR	55



TABLÖLAR LİSTESİ

Tablo 1.1	Çalışmaların özet tablosu.....	11
Tablo 3.1	CC görüntülerinin Resnet50 algoritması kullanılarak elde edilen hata matrisi tablosu.....	48
Tablo 3.2	CC görüntülerinin InceptionV3 algoritması kullanılarak elde edilen hata matrisi tablosu.....	49
Tablo 3.3	MLO görüntülerinin Resnet50 algoritması kullanılarak elde edilen hata matrisi tablosu.....	49
Tablo 3.4	MLO görüntülerinin InceptionV3 algoritması kullanılarak elde edilen hata matrisi tablosu	49



ŞEKİLLER LİSTESİ

Şekil 1.1 CC ve MLO görüntüleme yöntemi (İşeri, 2020)	5
Şekil 1.2 Retromammary boşluk ve pektoralis kasının görüldüğü ideal bir sağ-sol CC görünümü (Popli ve ark., 2014)	6
Şekil 1.3 (A) CC görünümü ve (B) MLO görünümü üzerinde pektoralis-meme ucu Çizgisi (PNL) (Popli ve ark., 2014)	7
Şekil 1.4 İkili MLO: Ayna görüntüleri olarak bakıldığında pektoralis kasının “V” şekli (Popli ve ark., 2014)	7
Şekil 1.5 Makine öğrenmesi çeşitleri (Nassif, A. B. ve ark., 2019)	12
Şekil 1.6 Denetimli öğrenme (Gökalp, Ö. M., 2022)	13
Şekil 1.7 Denetimsiz öğrenme (Gökalp, Ö. M., 2022)	14
Şekil 1.8 Yarı denetimli öğrenme (Turhost, 2021)	15
Şekil 1.9 Pekiştirmeli öğrenme (Sarıcan & Engin, 2024)	15
Şekil 1.10 Bir sinir hücresinin matematiksel modellenmesi (Kızrak & Bolat, 2018)	16
Şekil 1.11 Sigmoid fonksiyon grafiği	17
Şekil 1.12 Tanh aktivasyon fonksiyonu grafiği	17
Şekil 1.13 ReLu aktivasyon fonksiyonu grafiği	18
Şekil 1.14 Leaky ReLu aktivasyon fonksiyonu grafiği	19
Şekil 1.15 Exponential linear unit (ELU) aktivasyon fonksiyonu grafiği	19
Şekil 1.16 Tipik bir evrişimli sinir ağının mimarisi (Özbay, E. ve Özbay, A., 2021)	21
Şekil 1.17 Tek ve çok gizli katmanlı yapay sinir ağı modelleri	22
Şekil 1.18 Yapay sinir ağı akış diyagramı (Ersoy, 2022)	23
Şekil 1.19 Evrişim işlemi gösterimi (Ersoy, 2022)	24
Şekil 1.20 Havuzlama işlemi (Ersoy, 2022)	25
Şekil 1.21 Dropout işlemi ile temsili sadeleştirme (Ersoy, 2022)	26
Şekil 1.22 Derin öğrenme ile medikal görüntülerin sınıflandırılması (Eker ve Duru, 2021)	28
Şekil 1.23 Görüntü işleme filtreleri (Desai ve ark., 2020)	29
Şekil 1.24 Kutu bulanıklığına örnek (Desai ve ark., 2020)	29
Şekil 1.25 Medyan filtresine örnek (Chandel ve Gupta, 2013)	31
Şekil 1.26 CLAHE uygulanan görsel (Musa ve ark., 2018)	33
Şekil 2.1 Residual blok (artık blok) örneği (Atik, I., 2024)	36
Şekil 2.2 Resnet50 mimarisi (Sahin, N. ve ark., 2023)	36
Şekil 2.3 Basit Inception modeli (Szegedy, C. ve ark., 2015)	37
Şekil 2.4 Inception V1 modeli (Szegedy, C. ve ark., 2015)	38
Şekil 2.5 3x3 evrişim yerine önerilen 3x1 evrişim adımları (Chaudhari, D. J. ve Malathi, K., 2023)	38
Şekil 2.6 Modellere göre başarılar (Canziani ve ark., 2017)	39
Şekil 2.7 Başarılar göre modellerin işlem yükü (Canziani ve ark., 2017)	39
Şekil 2.8 Hata matrisi (Aldashash, 2024)	41
Şekil 2.9 ResNet50 modeli için MLO görünümünde doğrulama kaybı grafiği	42
Şekil 2.10 ResNet50 modeli için MLO görünümünde eğitim doğruluğu grafiği	42
Şekil 2.11 ResNet50 modeli için CC görünümünde doğrulama kaybı grafiği	43
Şekil 2.12 ResNet50 modeli için CC görünümünde eğitim doğruluğu grafiği	43
Şekil 2.13 InceptionV3 modeli için MLO görünümünde doğrulama kaybı grafiği....	43
Şekil 2.14 InceptionV3 modeli için MLO görünümünde eğitim doğruluğu grafiği ...	44

Şekil 2.15 InceptionV3 modeli için CC görünümünde doğrulama kaybı grafiği	44
Şekil 2.16 InceptionV3 modeli için CC görünümünde eğitim doğruluğu grafiği	44



KISALTMALAR LİSTESİ

ADAGRAD	Adaptive Gradient Algorithm
ADAM	Adaptive Moment Estimation
AutoML	Automated Machine Learning
BDT	Bilgisayar Destekli Tanı
BO	Bayes Optimizasyonu
CC	Cranio-Caudal
CLAHE	Kontrast Sınırlı Uyarlamalı Histogram Eşitleme
CNN	Convolutional Neural Networks
DDSM	Digital Database for Screening Mammography
DL	Derin Öğrenme
ELU	Exponential Linear Unit
ESA	Evrişimli Sinir Ağı
LR	Lojistik Regresyon
MGSOA	Modified Garter Snake Optimization Algorithm
MIAS	Mamografik Görüntü Analizi Derneği Dijital Mamogram Veri Tabanı
MLO	Medio-Lateral Oblique
PNL	Pektoralis-Meme Ucu Çizgisi
PSO	Parçacık Sürü Optimizasyonu
ResNet	Residual Networks
RMSPROP	Root Mean Square Propagation
ROI	Region of Interest
SA	Sinir Ağı
SVM	Support Vector Machine
Tanh	Hiperbolik Tanjant
YSA	Yapay Sinir Ağı
YZ	Yapay Zekâ

1. GİRİŞ

1.1. Tezin Özgün Değeri

Meme kanseri, kadınlar arasında dünya genelinde en sık görülen kanser türlerinden biri olup, kanserden kaynaklanan ölümlerin başlıca nedenleri arasında yer almaktadır. 2020 yılında dünya genelinde 2,3 milyon yeni meme kanseri vakası teşhis edilmiş ve bu hastalık 685.000'den fazla ölümle sonuçlanmıştır (IARC, 2020). Bu veriler, meme kanserinin küresel sağlık açısından ne kadar kritik bir sorun olduğunu göstermektedir. Meme kanseri vakalarının erken evrede tespit edilmesi, hastalığın yayılmadan tedavi edilme şansını önemli ölçüde artırmaktadır. Erken teşhisin, hasta sağkalım oranlarını iyileştirme üzerindeki bu önemli etkisi, meme kanserinin taranması ve teşhisinde doğru ve güvenilir yöntemlerin geliştirilmesini zorunlu kılmaktadır (Al-Hadidi ve ark., 2016; Özgür & Bozkurt Keser, 2021).

Meme kanseri taramasında en yaygın kullanılan yöntemlerden biri mamografi'dir. Mamografi, düşük dozda X-ışınları kullanarak meme dokusunun detaylı bir görüntüsünü sunar ve meme kanserinin erken tespiti için etkili bir araçtır (Karellas & Vedantham, 2008). Ayrıca mamografi taraması, şu anda asemptomatik kadınların toplu taraması için uygun kabul edilen tek yöntemdir (Heywang-Köbrunner ve ark., 2011). Ancak mamografi sonuçlarının yorumlanması, özellikle meme dokusu yoğunluğu gibi çeşitli faktörler nedeniyle oldukça zaman alıp yorumlanması için bilgi gerektirmektedir. Özellikle mamografik görüntülerdeki küçük kitleler, mikrokalsifikasyonlar ve asimetrik yoğunluklar kanserli dokuların işaretleri olabilir, ancak bunların doğru bir şekilde tespit edilmesi yüksek uzmanlık ve dikkat gerektiren bir süreçtir (İşeri, 2014). Özellikle tarama radyologlarının giderek azalması göz önüne alındığında, verimlilik ve hasta sağlığı için tehdit oluşturan yüksek bir iş yükü yaratmaktadır (Rimmer, 2017).

Dolayısıyla bu zorluklar, meme kanseri tarama ve teşhis süreçlerinde otomatik tanı sistemlerine olan ihtiyacı artırmaktadır. Özellikle son yıllarda görüntüleme teknolojilerindeki gelişmeler ve tıp alanında yapay zekâ ve derin öğrenme tekniklerinin kullanımı; patolojideki geniş varyasyonlar, insan hatasına yatkın ve uzmandan uzmana farklılık gösterebilen durumların üstesinden gelmek için büyük bir potansiyel sunmaktadır (Eker & Duru, 2021). Derin öğrenme, görüntü işleme ve sınıflandırma görevlerinde son derece başarılı sonuçlar vermiştir ve bu başarılar, tıbbi

görüntüleme alanında da yaygın bir şekilde kullanılmaya başlanmıştır. Bu kapsamda, Convolutional Neural Networks (CNN) gibi derin öğrenme mimarileri, özellikle görüntü sınıflandırma problemlerinde üstün performans sergileyen yöntemler arasında yer almaktadır (Y. Wu & Feng, 2018; Eker & Duru, 2021).

Bu çalışmamız, derin öğrenme tabanlı görüntü analizi yöntemlerinin meme kanseri teşhisi alanındaki etkinliğini araştırmaktadır. Bu bağlamda, ResNet50 ve InceptionV3, meme kanseri teşhisi gibi karmaşık görevlerde gösterdikleri kanıtlanmış başarı ve mimari yenilikleri nedeniyle odak modeller olarak seçilmiştir (Araújo, T ve ark.,2017). Tezimizde, model derinliğinin ve mimari optimizasyonların performans üzerindeki etkilerini karşılaştırmak hedeflenmiştir. ResNet50, derinliğin etkilerini artırmak için artık bağlantıların gücünü gösterirken, InceptionV3 farklı evrişim yollarının birleşimiyle verimliliği ve çok ölçekli özellik çıkarımını temsil etmektedir. Bu iki modelin karşılaştırılması, meme kanseri teşhisi problemine dair önemli içgörüler sunmuştur.

Derin öğrenme modelleri arasında, ResNet (Residual Networks) ve InceptionV3 gibi gelişmiş mimariler, büyük veri setleri üzerinde eğitildiğinde son derece yüksek doğruluk oranları sunabilmektedir (He ve ark., 2016; Szegedy ve ark., 2016). ResNet, özellikle derin katmanlı yapılarda gradyan kaybı problemlerini çözmesi ve modelin daha derin katmanlara sahip olabilmesini sağlamasıyla öne çıkmaktadır (He ve ark., 2016). InceptionV3 ise, farklı boyutlardaki filtrelerin aynı anda kullanılmasıyla daha fazla özellik haritalarının çıkarılmasına olanak tanıyan bir mimariye sahiptir (Szegedy ve ark., 2016). Bu çalışmada her iki modelin, mamografik görüntüler üzerinden meme kanseri sınıflandırmasındaki performansları değerlendirilmiştir. Bu iki modelin seçilmesindeki temel neden, literatürde meme görüntüleri üzerinde başarılarının kanıtlanmış olması ve birbirinden farklı mimari yapıları ile model performanslarını karşılaştırmaya olanak sağlamasıdır.

Çalışmada, yaygın kullanımı ve etiketli mamografi görüntüleri sağlaması nedeniyle DDSM (Digital Database for Screening Mammography) veri seti tercih edilmiştir. DDSM, dünya genelinde en yaygın kullanılan mamografik veri tabanlarından biri olup, meme kanseri araştırmalarında sıklıkla tercih edilmektedir. Veri setinde yer alan mamografi görüntüleri, meme dokusunun iki temel açıdan çekilen görüntülerinden oluşmaktadır: Cranio-Caudal (CC) ve Medio-Lateral Oblique (MLO) açıları. CC

görüntüleri, meme dokusunun yukarıdan aşağıya doğru alınan bir kesitini sunarken, MLO görüntüleri meme dokusunun çapraz bir açıdan incelenmesini sağlar (Popli ve ark., 2014). Bu iki farklı açıdan elde edilen görüntüler, meme kanserinin tespit edilmesinde tamamlayıcı bilgiler sunabilir. Ancak bu görüntülerin sınıflandırılması, her iki açıya özgü zorluklar barındırmakta olup, farklı derin öğrenme modellerinin bu iki veri tipine nasıl uyum sağlayacağını değerlendirmek önemlidir. Dolayısıyla bu çalışma, meme kanserinin erken teşhisi amacıyla DDSM veri seti kullanılarak, ResNet50 ve InceptionV3 modelleri üzerinde gerçekleştirilen sınıflandırma işlemlerini kapsamaktadır. Araştırmanın temel amacı, bu iki derin öğrenme mimarisinin meme kanseri tanısında hangi açıdan daha etkili olduğunu ortaya koymak ve Cranio-Caudal (CC) ve Medio-Lateral Oblique (MLO) görüntülerin sınıflandırılması üzerindeki etkilerini değerlendirmektir.

Elde edilen bulgular, mamografi görüntülerin derin öğrenme modelleri kullanılarak sınıflandırılmasında hangi mimarinin daha etkin olduğunu göstermeye yönelik önemli ipuçları sunacaktır. Ayrıca çalışma sonuçları, yapay zekâ ve derin öğrenme tekniklerinin meme kanseri taramasında nasıl bir dönüşüm yaratabileceğine dair gelecekteki araştırmalar için bir yol haritası sunabilir. Derin öğrenme tabanlı otomatik tanı sistemlerinin klinik ortamlarda etkin bir şekilde kullanılabilir hale getirilmesi, meme kanseri teşhisinde daha hızlı, daha güvenilir ve daha erişilebilir çözümler sunarak, kanserin erken evrelerinde yakalanmasını ve buna bağlı olarak hasta sağkalım oranlarının artırılmasını sağlayacaktır.

1.2. Meme Kanseri ve Mamogram

Meme kanseri, ölümle sonuçlanan en yaygın bir kanser türlerinden biridir (Özgür & Bozkurt Keser, 2021). Ayrıca meme kanseri dünya çapında en sık teşhis edilen kadın kanseridir (World Health Organization, 2014). 2020 yılında, dünya çapında 2,3 milyon yeni meme kanseri vakasıyla en sık teşhis olunan tür olmuş ve meme kanserinden dolayı 684.996 ölüm gerçekleşmiştir (Sung ve ark., 2021). Kanser hastalığının erken ölüm nedeni olarak konumunu ulusal, sosyal ve ekonomik kalkınma düzeylerini önemli ölçüde yansıttığı aşikardır (Sung ve ark., 2021). Erken teşhis ve etkili tarama programları aracılığıyla meme kanserinin daha erken saptanması sayesinde vaka ve ölüm oranlarında önemli oranlarda düşüş gözlemlenmektedir (Al-Hadidi ve ark., 2016;

Özgür & Bozkurt Keser, 2021). Meme kanserinin erken teşhisi için çok sayıda görüntüleme yöntemi sürekli olarak geliştirilmektedir. Bu yöntemlerin bir kısmı teşhis amacıyla, bir kısmı tarama amacıyla ve bir kısmı da uzmanlara ilk kararlarında daha fazla güvence sağlamak için yardımcı değerlendirme olarak kullanılmaktadır (Karellas & Vedantham, 2008). Meme kanseri tespiti için en yaygın kullanılan tıbbi görüntüleme yöntemleri genel olarak mamografi, ultrason, manyetik rezonans görüntüleme, termografi, sintimamografi, histopatoloji ve bilgisayar destekli tanı (Computer Aided Diagnosis) sistemleri kullanılmaktadır (İşeri, 2014; Karellas & Vedantham, 2008)


Mamografi esasen meme kanseri taraması için kullanılan tek görüntüleme yöntemidir (Karellas & Vedantham, 2008). Mamografiyi takiben meme kanserine özgü ölüm riskindeki azalma yaşa göre değişmekle birlikte genellikle %15-20 olarak belirtilmektedir (Pace & Keating, 2014). Mamografinin temel amacı, düşük doz genlikli X ışınları kullanarak meme içerisinde oluşan kalsiyum birikintileri ve anormal kitleleri daha parlak alanlar olarak göstererek erken teşhisi sağlanmasıdır (Sardanelli ve ark., 2017).

Tarama mamografisi, kendi kendine palpasyon veya klinik muayeneden önce küçük kanserleri bulmak için periyodik olarak gerçekleştirilir (Sardanelli ve ark., 2017). Amerikan Kanser Derneği (American Cancer Society), meme kanserine yakalanma riski ortalama olan kadınların 45 yaşından itibaren düzenli tarama mamografisi yaptırmalarını, 45 ila 54 yaş arasındaki kadınların her yıl taranmalarını, 55 yaş ve üzeri kadınlarında iki yılda bir tarama yaptırarak doktor kontrolünden geçmelerini önerir. (Oeffinger ve ark., 2015). Türkiye Halk Sağlığı Kurumu Kanser Daire Başkanlığı 20 yaşından sonra iki yılda bir, 40 yaşından sonra yılda bir kez mamografi yöntemi ile doktor kontrolünden geçilmesini tavsiye etmektedir (İşeri, 2014). Tanısal mamografisi ise, şüpheli klinik semptomlar gösteren hastalarda meme kanserini teşhis etmek veya dışlamak için yapılır (Sardanelli ve ark., 2017). Meme kanserinin teşhisinde, radyologlar tarafından incelen mamogram görüntüleri ile hastalığın gidişatı hakkında bilgi edinmek mümkündür (Özgür & Bozkurt Keser, 2021). Özellikle anormallik bölgesinin yayılma ve genişleme ihtimaline yönelik tam sınırlarının ve yerinin tespit edilmesi için yapılan ve daha fazla zaman alan bir yöntemdir (İşeri, 2014). Radyologlar mamografi görüntülerinden potansiyel kanserli lezyonların karakteristik belirtilerini deneyimleri neticesinde gözle algılayarak ve yorumlayarak teşhisini sağlayabilirler

(İşeri, 2014). Ancak, taranan çok sayıda kişinin olması, bazı ülkelerde muayenelerde çift okumanın kullanılması ve tarama radyologlarının giderek azalması göz önüne alındığında, verimlilik için tehdit oluşturan yüksek bir iş yükü yaratmaktadır (Rimmer, 2017). Bundan dolayı sonuçların incelenmesi uzun zaman almakta hatta zaman zaman bu incelemelerde hatalı sonuçlar elde edilebilmektedir. Bu durum, radyologların tanı koyma konusunda performanslarını iyileştirebilecek bir araca duyulan ihtiyacın önemini vurgulamaktadır. Özetle patolojideki geniş varyasyonlar, insan hatasına yatkın ve uzmandan uzmana farklılık gösterebilen durumlar göz önüne alındığında, bilgisayar destekli tanı (BDT) yöntemleri gibi müdahalelerden yararlanmanın oldukça gerekli olduğu söylenebilir (Eker & Duru, 2021).

1.3. Mamografi Çekim Teknikleri


Mamografinin amacı, maksimum meme dokusu görüntülemesiyle birlikte optimum bir görüntü elde etmektir (Popli ve ark., 2014). Mamografi çekimi, kranio-kaudal (CC) projeksiyon ve medio-lateral oblik (MLO) projeksiyon olarak adlandırılan (Şekil 1.1) ve her meme için ikişer tane olmak üzere dört görünümünden oluşan standart bir işlemdir (Sardanelli ve ark., 2017).



Şekil 1.1 CC ve MLO görüntüleme yöntemi (İşeri, 2020)

1.3.1. Cranio-Caudal (CC) görüntüleme yöntemi

CC görüntüleme memenin üstünden aşağıya görüntünün elde edilmesidir ve bu görüntü tüm memeyi göstermektedir (Aldashash, 2024). İdeal bir CC görünümünde retromammary boşluk ve bazı pektoral kaslarla birlikte maksimum dokuyu ideal olarak görülmelidir (Şekli 1.2) (Popli ve ark., 2014).



Şekil 1.2 Retromammary boşluk ve pektoralis kasının görüldüğü ideal bir sağ-sol CC görünümü (Popli ve ark., 2014)

1.3.2. Medio-Lateral Oblique (MLO) görüntüleme yöntemi

MLO görüntülemesinde ise meme 45 ile 60 derecelik bir açı ile sıkıştırılır ve görüntü göğsün ortasından dışa doğru elde edilmektedir. MLO görünümü, istatistiksel olarak patolojik değişiklikler için en olası yer olan memenin lateral tarafının en iyi görünümünü sunar (Aldashash, 2024). İdeal bir MLO görünümünde pektoralis kası kenarı iyi görüntülenmelidir; pektoralis kasının alt kenarı pektoralis-meme ucu çizgisi (PNL) seviyesinde veya altında olmalıdır (Şekil 1.3) ve her iki memenin MLO görüntüsü ayna görüntüsü olarak incelendiğinde, pektoralis kası orta hatta birleşmeli ve bir "V" oluşturmalıdır (Şekil 1.4) (Popli ve ark., 2014).



Şekil 1.3 (A) CC görünümü ve (B) MLO görünümü üzerinde pektoralis-meme ucu çizgisi (PNL)
(Popli ve ark., 2014)



Şekil 1.4 İkili MLO: Ayna görüntüleri olarak bakıldığında pektoralis kasının “V” şekli
(Popli ve ark., 2014)

1.4. Literatürde Mamografi Sınıflandırma

Sağlıkta bilgi teknolojisinin kullanılması tanı doğruluğunu artırmak ve süreci hızlandırmak için alan uzmanına ikinci bir görüş sağlaması konusunda bir zorunluluk olmuştur (Yassin ve ark., 2018). Bu bölümde, mamografi görüntüleri kullanarak meme kanserinin sınıflandırılmasına yardımcı olmak için 2019'den itibaren yapılan yüksek doğruluk içeren çalışmalar ve uygulamalar açıklanmaktadır.

Li ve arkadaşları iyi ve kötü huylu mamografi görüntülerini sınıflandırmak için DenseNet-II sinir ağı modelini kullanmıştır. 2042 görüntülü mamogram veri seti üzerinde model eğitildikten sonra 10 kat çapraz doğrulama kullanılarak değerlendirilmiştir. DenseNet-II modeli AlexNet, VGGNet, GoogLeNet modellerinden daha başarılı olup ortalama %94.55 doğruluk, %95.60 duyarlılık ve %95.36 özgüllük ile sonuçlanmıştır (Li ve ark., 2019).

Wu ve arkadaşları BI-RADS meme görüntüleme ve raporlama skalasına göre sınıflandırma yapmak için 22 katmanlı Residual Sinir Ağını (Residual Network) kullanmıştır. Veri setindeki hastaların 229426 dijital tarama mamogramı, patoloji raporlarına göre etiketlenmiştir. Tarama grubunun AUC değerleri malign kitleler için 0.886 benign kitleler için ise 0.765'tir. Ayrıca, biyopsi yapılmış iyi huylu kitleler için 0.696 ve kötü huylu kitleler için 0.843 AUC elde edilmiştir (N. Wu ve ark., 2020).

Abdel ve arkadaşları önceden segmente edilmiş DDSM veri setindeki 2500 mamografi görüntüsünden tümörleri sınıflandırmak için eğitilmiş iki çeşit Evrişimli Sinir Ağı (ESA) modelinden Inception V3 ve ResNet50'i kullanıldı. ResNet50 modeli %85,7 hassasiyet oranı, %85,71 doğruluk oranı ve %84 özgüllük oranına sahipti. Önerilen ResNet50 modeli doğruluk oranında %6,6 ve hassasiyet oranında %10,3 artışla InceptionV3'ten biraz daha iyi performans gösterdi (Abdel Rahman ve ark., 2020).

BCWD veri kümesinden 569 görüntünün kullanıldığı Lamboy ve arkadaşlarının yaptığı çalışma iyi ve kötü huylu meme kanserini sınıflandırmak için Destek Vektör Makine- Support Vector Machine (SVM), Lojistik Regresyon (LR) ve Sinir Ağı (SA) modeli ile üç makine öğrenimi yönteminin uygulanması sunmuştur. 10 katlı çapraz doğrulamayla üç model arasında %99,4'lük bir derecelendirme ile SA en yüksek performansı sağlamıştır bu oran SVM %98,8'den ve LR %97,7'den önemli ölçüde yüksektir. SA için önerilen modelde, %99,55 AUC, %98,25 doğruluk, %97,85 kesinlik, ve %96,2 özgüllük elde edilmiştir (Lomboy & Hernandez, 2021).

2022 yılında Mahmood ve arkadaşları yeni bir ESA kullanarak (bir ConvNet ve beş DESA mimarisi) kanser teşhisinde mamogram görüntülerini iyi ve kötü huylu olarak sınıflandırmışlardır. 322 Mamografik Görüntü Analizi Derneği Dijital Mamogram Veri Tabanından (MIAS) ve 580’de özel bir veri setinden alınan mamograma ön işleme, veri artırımı ve transfer öğrenme teknikleri uygulanarak iyileştirilmiştir. Daha sonra Region of Interest (ROI) tespiti, özellik öğrenimi ve kitle sınıflandırması gerçekleştirilmiştir. Önerilen model 0.99 AUC, %99 duyarlılık, %98 eğitim doğruluğu ve %97 test doğruluğu, ve elde etmiştir (Mahmood ve ark., 2022).

2023 yılında Sun ve arkadaşları, sınıflandırma modelinin özellik çıkarma yeteneğini geliştirmek için TA-ESA adında yeni bir meme kütlesi sınıflandırma yöntemi önerdiler. TA-ESA, iki mamografi görüntüsü kullanarak (CC ve MLO) iki tamamlayıcı bilgi türünü aynı anda çıkarmak için alır ve sınıflandırma sonucunu çıktı olarak verir. Çalışmada tüm sınıflandırma modelleri önce 2600 veri içeren DDSM veri seti üzerinde önceden eğitilmiş ardından bu modeller INbreast ve MIAS üzerinde ince ayarlanmıştır. Önerilen model, 0.8347 AUC, %78.39 doğruluk, % 82.69 kesinlik, ve % 74.07 özgüllük ile kullanılan veri setlerindeki tüm görüntü sınıflandırma yöntemleri arasında en yüksek sınıflandırma performansını ve önemli sağlamlığı elde etmektedir (Sun ve ark., 2023).

2024 yılında Prinzi ve arkadaşları mamogramlarda YOLOv3, YOLOv5 ve YOLOv5-Transformer mimarilerini karşılaştırılmıştır. Çalışmada ilk olarak, 1514 verilik CBIS-DDSM ve 107 verilik INbreast veri setlerini kullanarak modeller eğitilmiştir. Daha sonra eğitilmiş bu veri setlerinden yararlanılarak 278 veri içeren özel veri seti ile modele ince ayar yapılmıştır ve ROI görsel işleme modeli kullanılmıştır. Transfer öğrenimiyle ve transfer öğrenimi olmadan eğitim göz önünde bulundurulduğunda YOLOv5s modeli 0.621 ± 0.035 mAP ile en iyi performansı göstermiştir (Prinzi ve ark., 2024).

Umamaheswari ve Babu 2024 yılında yaptıkları çalışmada 3 Boyutlu (3D) mamografi görüntü verileri kullanılmış ve bir meme kanseri teşhis modeli uygulanmıştır. Verilere bir medyan filtresi ve görüntü ölçekleme yöntemi kullanılarak bir ön işleme yapılmış daha sonra, segmentasyon işlemi Bölge Büyüyen Füzyon Modeli (AT-RGFM) ile parametrelerin optimizasyonu ise Modified Garter Snake Optimization Algorithm (MGSOA) olarak adlandırılan algoritma kullanılarak yapılmıştır. Önerilen tümör

tespit modeli Vision Transformer tabanlı Çok Ölçekli Uyarlanabilir Verimli NetB7 (ViT-MAENB7) modelidir. MGSOA-ViT-MAENB7 modelinin meme kanseri teşhis performansı, geleneksel kanser teşhis modellerine göre daha yüksek olup %96,6 doğruluk %96,6 duyarlılık ve %93,4 özgüllük gösterir. (Umamaheswari & Babu, 2024).

Jabeen ve arkadaşları 2024 yılında yaptıkları çalışmada mamogram görüntülerinden meme kanseri sınıflandırması ve tanısı için kuantum optimizasyon algoritması ile yeni bir derin darboğaz evrişimli sinir ağı kullanmışlardır. Üç bloklu darboğaz kalıntı modeli ve dört bloklu darboğaz kalıntı modeli adlı iki yeni ESA mimarisi önerilmiştir. Hiper parametre değerlerini başlatmak ve mimarileri seçilen veri seti üzerinde eğitmek için Bayes Optimizasyonu (BO) kullanıldı. 410 adet görüntü INbreast veri kümesi üzerinden alındı. Önerilen yöntem için %96,5'lik maksimum doğruluk, %96,45 duyarlılık, %96,5 kesinlik oranı, F1 skor değeri 96,64, MCC değeri %92,97 ve Kappa değeri sırasıyla %92,97'dir (Jabeen ve ark., 2024).

2024 yılında yapılan başka bir çalışma ESA'ye dayalı yeni bir derin öğrenme yöntemi önermektedir. Önerilen yöntem, uygun hiper parametreleri ve ESA modeli için mimariyi aramak amacıyla Parçacık Sürü Optimizasyonu (PSO) algoritmasına dayanmaktadır. PSO kullanan ESA modeli, DDSM ve MIAS veri kümelerinde sırasıyla %98,23 ve %97,98 başarı oranlarına ulaşmıştır. Deneysel sonuçlar, önerilen PCOESA modelinin; DDSM veri seti için alandaki YOLO tabanlı CAD, DBN tabanlı CAD ve NN tabanlı sınıflandırıcıdan CAD sistemi gibi diğer çalışmalarla karşılaştırıldığında ve MIAS için alandaki DBN, MA-ESA, WFRFT + PCA + SVM ve NN tabanlı sınıflandırıcı gibi diğer çalışmalarla karşılaştırıldığında en iyi doğruluk değerlerini verdiğini kanıtlamıştır (Aguerchi ve ark., 2024).

Tablo 1.1'de, bu bahsedilen çalışmaların yazarı, yılı, kullanılan veri seti, görüntü sayısı, algoritma modeli ve çalışma sonuçlarını listeleterek özetlenmiştir.

Tablo1.1 Çalışmaların özet tablosu

Yazar Adı ve Yıl	Kullanılan Veri Seti	Görüntü Sayısı	Model	Sonuçlar
(Li ve ark., 2019)	Özel veri seti	2042	DenseNet-II	Doğruluk = %94,55 Duyarlılık = %95,60 Özgüllük = %95,36
(N. Wu ve ark., 2020)	Özel veri seti	229426	ResNet	AUC = 0,895
(Abdel Rahman ve ark., 2020)	DDSM	2500	Inception V3 ve ResNet50	ResNet50 daha başarılı Doğruluk = %85,7 Duyarlılık = %87,3 Özgüllük = %84
(Lomboy & Hernandez, 2021)	BCWD veri seti	569	SVM, LR ve SA	NN daha başarılı Doğruluk = %98,25 Duyarlılık = %97,85 Özgüllük = %96,2
(Mahmood ve ark., 2022)	MIAS, Özel veri seti	322, 580	ESA	Doğruluk = %97 Duyarlılık = %99 AUC = 0.99
(Sun ve ark., 2023)	DDSM, INbreast ve MIAS	2600	TA-ESA	Doğruluk = %78,39 Duyarlılık = %82,69 Özgüllük = %74.07
(Prinzi ve ark., 2024)	CBIS-DDSM, INbreast, Özel veri seti	1514, 107 ve 278	YOLOv5s	mAP = 0.621 ± 0.035
(Umamaheswari & Babu, 2024)	The Complete Mini- DDSM	https://www.kaggle.com/datasets/cheddad/miniddsm2 : Access Date 2023-08-01	ViT-MAENB7	Doğruluk = %96,6 Duyarlılık = %96,6 Özgüllük = %93,4
(Jabeen ve ark., 2024)	INbreast	410	Üç ve dört bloklu darboğaz modeli	Doğruluk = %96,5 Duyarlılık = %96,45 Keskinlik = %96,5
(Aguerchi ve ark., 2024)	DDSM ve MIAS	53 ve 2188	PSOESA	DDSM= %98,23 doğruluk MIAS= %97,98 doğruluk


1.5. Yapay Zekâ ve Makine Öğrenmesi

Yapay zekânın net bir tanımı olmasa da, genel olarak öğrenme ve akıl yürütmeye yönelik çok çeşitli sembolik ve istatistiksel yaklaşımları kapsayan, verilerden anlamlı sonuçlar çıkararak kendi kendine öğrenen sistemlerin oluşturulmasını amaçlayan bir bilgisayar bilim dalı olarak tanımlanabilir (Miller & Brown, 2018). Kısaca yapay zekâ (YZ) terimi, akıllı davranışlar sergileyebilen ve eğitilebilen herhangi bir makine veya sistemi tanımlamak için kullanılmaktadır (Aldashash, 2024).

Yapay zekanın bir alt alanı olan makine öğrenimi, deneysel verilerden karmaşık ilişkileri veya kalıpları öğrenebilen ve doğru kararlar alabilen bilgisayar algoritmalarının incelenmesidir (Jones ve ark., 2018). Makine öğrenimi, makinelere verileri daha verimli bir şekilde nasıl kullanacaklarını öğretmek için kullanılır (Mahesh, 2019). Yani bir görevi yerine getirmek için belirli talimat kümelerini kodlamak yerine, makineye görevi nasıl gerçekleştireceğini öğrenme yeteneğini kazandırmak için büyük miktarda veri ve algoritmalar kullanılarak makine 'eğitilir'. Normal algoritmaların aksine, makineye 'iyi cevabın' ne olduğunu 'söyleyen' veridir ve öğrenme açık programlama olmadan gerçekleşir. Makine öğrenmesi algoritmaları gibi yapay zekâ yöntemleri, disiplinler arası bir yaklaşıma sahiptir ve özellikle tanısı görüntüleme veya sinyal analizine dayananlar olmak üzere çeşitli hastalıkların tahmini ve teşhisinde yaygın olarak kullanılmakla birlikte sağlık profesyonellerinde destek olmaktadır (Ghaffar ve ark., 2023; Secinaro ve ark., 2021).


1.5.1. Makine öğrenmesi çeşitleri

Makine öğrenimi, bilgisayarların açık talimatlar yerine kalıplar ve çıkarımlar kullanarak belirli görevleri yerine getirmesini sağlayan istatistiksel modeller ve algoritmalar oluşturma yöntemidir (Mahesh, 2019). Büyük miktardaki verilerin eski işlenmiş verilerden öğrenip tahmin analizinde bulunabilmesi için makine öğrenmesi yöntemleri oluşmuştur (Avaner, 2018). Makine Öğrenmesi algoritmaları Şekil 1.5'teki gibi esas olarak dört kategoriye ayrılır: denetimli öğrenme (sınıflandırma ve regresyon), denetimsiz öğrenme (ilişkilendirme ve kümeleme), yarı denetimli öğrenme ve güçlendirilmiş öğrenme (Sarker, 2021).



Şekil 1.5 Makine öğrenmesi çeşitleri
(Nassif, A. B. ve ark., 2019)

Denetimli öğrenme (Supervised Learning) modeli makine öğreniminin, bir girdiyi belirli bir çıktıyla eşleştirmeyi öğrenme sürecidir. Bu yöntemde, modelin doğru tahmin yapabilmesi için önceden etiketlenmiş bir veri kümesi kullanılır (Şekil 1.6) ve model veri kümesi sayesinde eğitilir. Her girdi verisine karşılık gelen doğru çıktı model tarafından bilinir ve model, bu örneklerden öğrenerek yeni veriler için doğru tahminler yapmaya çalışır (Mahesh, 2019; Sarker, 2021). En yaygın denetimli görevler, verileri önceki bilgilerden kategorilere ayıran "sınıflandırma" ve olasılıkları tahmin etmek için verilere aşırı uyum sağlayan "regresyon" algoritmalarıdır (Sarker, 2021; Singh ve ark., 2016).




Şekil 1.6 Denetimli öğrenme
(Gökarp, Ö. M., 2022)

Denetimsiz öğrenme (Unsupervised Learning) yönteminde, insan müdahalesine ihtiyaç duymadan etiketlenmemiş veri kümelerini analiz eder, yani model verilerle

ilişkili belirli çıktılarına sahip değildir. Bu model verilerdeki gizli kalıpları, ilişkileri ve anlamlı eğilimleri çıkarmak veya sonuçlardaki gruplamaları yapmak için yaygın olarak kullanılır (Sarker, 2021). Yani algoritmalar, verilerdeki ilginç yapıyı keşfetmek ve sunmak için kendi düzeneklerine bırakılır (Şekil 1.7). Denetimsiz öğrenme algoritmaları verilerden birkaç özellik öğrenir. Yeni veriler tanıtıldığında, verilerin sınıfını tanımak için önceden öğrenilmiş özellikleri kullanır (Mahesh, 2019). Örneğin denetlenen bir makine öğrenme algoritmasında, makineye 'yüz' veya 'yüz olmayanın' birkaç örneği gösterilir ve algoritma, görülmeyen bir görüntünün yüz olup olmadığını tahmin etmeyi öğrenir. Denetlenmeyen öğrenmede, makineye gösterilen görüntüler 'yüz' veya 'yüz olmayan' olarak etiketlenmez (Jones ve ark., 2018).


Genel olarak veri setindeki benzerlik ve farklılıkları kümelere ayıran kümeleme (clustering) ve belirli olayların veya oluşumların sıklıkla birlikte gerçekleştiğini gösteren eğilimleri araştıran ilişkilendirme (association) gibi teknikler bu kategoriye örnektir (Aldashash, 2024; Sarker, 2021).



Şekil 1.7 Denetimsiz öğrenme
(Gökalp, Ö. M., 2022)


Yarı denetimli öğrenmede (Semi-Supervised Learning) daha iyi bir tahmin sonucu için denetlenen ve denetlenmeyen makine öğrenimi yöntemlerinin bir kombinasyonudur. Şekil 1.8'de gösterilmiştir. Kombinasyon olmasının sebebi hem etiketli hem de etiketlenmemiş verilerin kullanılmasıdır. Model, etiketli verilerden öğrenerek etiketlenmemiş verilerden de faydalanmaya çalışır. Bu yöntem, etiketlemesi zor veya maliyetli olan veri kümeleri üzerinde kullanışlıdır (Mahesh, 2019; Sarker, 2021). Yarı-

denetimli öğrenmenin kullanıldığı bazı uygulama alanları arasında veri etiketleme, kümeleme ve metin sınıflandırması vb. bulunur (Sarker, 2021).



Şekil 1.8 Yarı denetimli öğrenme
(Turhost, 2021)

Pekiştirmeli öğrenmede (Reinforcement Learning) ise, model belirli bir ortamda kararlar alır ve aldığı kararların sonuçlarına göre ödüllendirilir yani pekiştirilir veya cezalandırılır (Şekil 1.9). Bu ödül-ceza mekanizması aracılığıyla, uzun vadede en yüksek ödül elde etmek veya riski en aza indirmek için nasıl hareket etmesi gerektiğini öğrenir (Mahesh, 2019). Oyun teorisi ve robotik gibi alanlarda kullanılır. Ayrıca operasyonel verimliliğini optimize etmeye yardımcı olabilen YZ modellerini eğitmek için güçlü bir araçtır, ancak temel veya basit sorunları çözmek için kullanılması tercih edilmez (Mahesh, 2019). Şekil 8’de pekiştirmeli öğrenme modeli gösterilmiştir.




Şekil 1.9 Pekiştirmeli öğrenme
(Sarıcan & Engin, 2024)

1.6. Yapay Sinir Ağı

Yapay Sinir Ağları (YSA), insan beyninin sinir ağını bilgi işleme açısından benzetir, basit bir model kurar ve farklı bağlantılara göre farklı ağlar oluşturur. Sinir ağı, birbirine bağlı çok sayıda düğüm (nörona benzetilir) ile bir hesaplama modelidir ve

her düğüm, aktivasyon fonksiyonu adı verilen belirli bir çıktı fonksiyonunu temsil eder (Grossi & Buscema, 2007; Y. Wu & Feng, 2018). Şekil 1.10'da gösterilmiştir.



Şekil 1.10 Bir sinir hücresinin matematiksel modellenmesi (Kızrak & Bolat, 2018)

Biyolojik bir nöronun işlevsel modelini oluştururken, dikkate alınması gereken üç temel unsur vardır. Bunlardan ilki, nöronun sinapslarının ağırlıklar olarak temsil edilmesidir. Bir girdinin nöronla olan bağlantısının gücü, bu ağırlık değeriyle tanımlanır. Pozitif ağırlıklar bağlantının uyarıcı olduğunu, negatif ağırlıklar ise engelleyici bir etkiye sahip olduğunu gösterir. Diğer iki unsur ise nöronun içindeki temel aktiviteleri modellemek için kullanılır. İlk olarak, toplayıcı adı verilen bir mekanizma, girdilerin tümünü ilgili ağırlıklarıyla çarparak toplar. Bu işlem, doğrusal bir kombinasyon olarak adlandırılır. Son olarak, aktivasyon fonksiyonu devreye girerek nöronun çıktısının genliğini düzenler. Bu çıktı genellikle 0 ile 1 veya -1 ile 1 arasında bir aralıkta sınırlıdır (Dongare ve ark., 2012).

Yapay sinir ağı dediğimiz yapılara karmaşık verileri öğretmek için aktivasyon fonksiyonları gerekmektedir bu fonksiyonlar sayesinde nöron denilen düğümler tetiklenmektedir. Fonksiyonlarının amacı ağırlık (weight) ve bias değerlerini ayarlamaktır. Eşitlik 1.1. de formülü verilmiştir (Kumawat, 2024; Sharma ve ark., 2020).

$$L = X.W + b$$


W: ağırlık, X: giriş, b: bias

(1. 1)

Aktivasyon fonksiyonu için kullanılan çeşitli algoritmalar vardır.

1.6.1. Sigmoid fonksiyonu


Bu fonksiyon aldığı değerleri 0 ve 1 arasındadır. Şekil 1.11’ de görüldüğü gibi yüksek bir değer geldiğinde 1’e yakın olurken düşük bir değer geldiğinde 0’a yakın olur. Dolayısıyla 1’i ve 0’ı geçen herhangi bir değer gözlemlenmez. Sigmoid fonksiyonunun bazı dezavantajları vardır. Gradient ölümünün fazla olması, sıfır odaklı bir fonksiyon olmaması ve exp. hesaplamalarının oldukça yavaş olması bunlara örnek olarak gösterilebilir (Kumawat, 2024; Sharma ve ark., 2020).



Şekil 1.11 Sigmoid fonksiyon grafiği

1.6.2. Tanh (Hiperbolik Tanjant) fonksiyonu


Hiperbolik tanjant kısaca *tanh* ise sigmoid’e benzemektedir. İkisinde de sıkıştırma vardır ancak tanh gelen değerleri $[-1,1]$ arasına hapseder (Şekil 1.12). Sigmoid fonksiyona göre daha iyi sonuçlar alınabilir çünkü sıfır odaklıdır. Ancak gradient ölümleri hala devam etmektedir (Kumawat, 2024; Sharma ve ark., 2020).



Şekil 1.12 Tanh aktivasyon fonksiyonu grafiği

1.6.3. ReLu fonksiyonu


2012 yılında ilk defa kullanılmaya başlanan ve günümüze kadar yaygın bir şekilde kullanılmaya devam eden aktivasyon fonksiyonudur. ReLu fonksiyonunun çalışma mantığı, gelen değerlerin pozitif mi negatif mi olduğuna karar vererek değer negatif ise işlem sonucunu 0, gelen değer pozitifse herhangi bir sıkıştırma ya da değiştirme işlemi uygulanmadan olduğu gibi geçmesine izin vermektir. Bilgisayarlar Tanh ve sigmoid'de karmaşık hesaplamalar yaparken ReLu'da yalnızca pozitiflik negatiflik durumuna bakar (Şekil 1.13). Bu nedenle bilgisayar bu denklemi 6 kat daha hızlı hesaplayabilmektedir. Yine de bu fonksiyonda sıfır odaklı olmadığından bazı nöronlar (%40'a kadar) ölebilmektedir (Kumawat, 2024; Sharma ve ark., 2020).



Şekil 1.13 ReLu aktivasyon fonksiyonu grafiği

1.6.4. Leaky ReLu fonksiyonu

Leaky ReLu aktivasyon fonksiyonu ReLu' nun ölü nöron sonunu ortadan kaldırmak için geliştirilmiş bir modifikasyonudur. Şekil 1.14'teki gibi negatif bir değer geldiğinde sıfır yerine çok küçük (genellikle 0.01 gibi) bir değerle nöronların ölmesinin önüne geçer. Hesaplama sayısının artmasına rağmen diğer fonksiyonlara göre oldukça hızlı çalışır (Kumawat, 2024; Sharma ve ark., 2020).




$$F(x) = \max(0.01x, x)$$

Şekil 1.14 Leaky ReLu aktivasyon fonksiyonu grafiği

1.6.5. Exponential Linear Unit (ELU)

Bu fonksiyon girdiler pozitif olduğunda ReLU gibi çalışır ancak negatif girdiler için üstel bir eğim kullanır (Şekil 1.15). Orta nokta ELU'nun çıktısı sifıra yakınsayarak, aktivasyonların sıfır ortalamaya (zero mean) daha yakın olmasını sağlar dolayısıyla ölü nöron sorunun önüne geçebilir. Eşitlik 1.2’de gösterilen bu fonksiyon Exponential yani e^x cinsinden hesaplama yaptığı için oldukça yavaştır. (Kumawat, 2024; Sharma ve ark., 2020).



Şekil 1.15 Exponential linear unit (ELU) aktivasyon fonksiyonu grafiği

$$f(x) = \begin{cases} x & \text{eğer } x > 0 \\ \alpha(e^x - 1) & \text{eğer } x \leq 0 \end{cases} \quad (1. 2)$$

Exponential linear unit (ELU) aktivasyon fonksiyonu formülü

1.6.6. Maxout fonksiyonu

Maxout fonksiyonu, ReLu ve Leaky ReLu’nun daha kapsamlı bir fonksiyondur ve Eşitlik 1.3’te gösterilmiştir ancak parametre sayısı 2 katına çıktığı için ReLu’ ya göre oldukça yavaş çalışır. Bu fonksiyonda nöron ölümü gerçekleşmez ve fonksiyonun herhangi bir grafiksel gösterimi yoktur. (Kumawat, 2024; Sharma ve ark., 2020).

$$\max(w_1^T x + b_1, w_2^T x + b_2) \quad (1. 3)$$

Maxout aktivasyon fonksiyonu formülü


Derin öğrenme algoritmalarının son katmanı YSA olduğu için derin öğrenme hiper parametrelerinde bu aktivasyon fonksiyonları belirtilir (Kumawat, 2024; Sharma ve ark., 2020).

1.7. Derin Öğrenme

Makine öğrenmesi her ne kadar verilerden öğrenip karar verebilse de çok karmaşık görevleri yerine getirememektedir (Aldashash, 2024). Bu durum, makine öğrenmesi alanını derin öğrenme (DL) olarak özetlenen gelişmiş öğrenme yeteneklerine sahip daha derin sinir ağı mimarilerine doğru evrimleştirmiştir (Mahesh, 2019). Kısacası, DL, büyük verileri analiz etmek için makine öğrenmesinin geliştirilmiş halidir (Ghaffar ve ark., 2023). DL, özellik çıkarma aşamasının önemli bir bölümünün otomasyonuna yardımcı olur, gerekli görülen manuel insan müdahalesinin miktarını azaltır ve böylece daha kapsamlı veri kümelerinin kullanılmasına izin verir (Danladi M.S.,2022).

1.8. Evrişimli Sinir Ağı Mimarisi


Derin öğrenme modellerinden biri olan Evrişimli Sinir Ağı (ESA) mimarileri ileri beslemeli, çok katmanlı ve eğitilebilir özel bir sinir ağı türüdür (Khan ve ark., 2020; LeCun vd. 2010). ESA'lar, görüntü tanıma, segmentasyon, nesne algılama ve benzeri alanlarda üstün performans göstermiş olup, görüntü analizleri için en etkili performanslardan biri olarak kabul edilmektedir (Cong & Zhou, 2023; Wang ve ark., 2019). Tipik bir ESA'nin mimarisi genellikle evrişim ve havuzlama katmanları arasında dönüşümlü geçişi içerir ve genel olarak ESA mimarileri dört bölümden oluşur: giriş katmanı, evrişim katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıktı katmanı (Şekil 1. 16). ESA mimarileri, ağ katmanları arasındaki ilişkiyi artırabileceği veya ağdaki gereksiz hesaplamaları azaltabileceği için sinir ağı mimarilerinin tasarımında önemli bir rol oynar; bu da genellikle daha üstün bir performans sağlayabileceği anlamına gelir (Cong & Zhou, 2023).



Şekil 1.16. Tipik bir evrişimli sinir ağının mimarisi (Özbay, E. ve Özbay, A.,2021).

ESA'in çekici özelliği, verilerdeki mekânsal veya zamansal korelasyonu kullanma yeteneğidir. ESA'in topolojisi, evrişimsel katmanlar, doğrusal olmayan işlem birimleri ve alt örnekleme katmanlarının bir kombinasyonundan oluşan birden fazla öğrenme aşamasına ayrılmıştır (Jarrett ve ark., 2009). Evrişimli Sinir Ağlarının katmanları, çözülmek istenen probleme göre özelleştirilmektedir ve her zaman tüm katman türlerini içermesi gerekmez (Karpathy, 2016).


Sinir ağı doğrusal ve doğrusal olmayan işlemlerin çoklu katmanlarını içeren en yaygın DL modellerinden biridir (Wang ve ark., 2020). Yapay sinir ağında, bir nöron işleme birimi, özellikler, harfler, kavramlar veya bazı anlamlı soyutlama desenleri gibi farklı nesneleri temsil edebilir. Ağdaki işleme birimi genellikle bir giriş katmanı, bir veya birden fazla gizli katman ve en son olarak bir çıkış katmanından meydana gelir. Giriş katmanı dış dünyadan sinyalleri ve verileri alır; çıkış katmanı, sistem işleme sonucunun çıktısını gerçekleştirir. Gizli katman ise, giriş ve çıkış katmanları arasında bulunan ve sistemin dışından gözlemlenemeyen bir birimdir (Y. Wu & Feng, 2018). Çok katmanlı sinir ağlarında her bir hücre, bulunduğu katmana ve tüm ağın işleyişine katkıda bulunur ve kendisine gelen veriyi işler, dönüştürür ardından sonucu bir sonraki katmana iletir (Kızrak & Bolat, 2018; Sarker, 2021). Gizli katmanların sayısı arttıkça model daha karmaşık ilişkileri öğrenebilmektedir. Genelde modelin katman yapısı, çözülmek istenen probleme göre tasarlanır (Sarker, 2021). Şekil 1.17'de tek ve çok gizli katmanlı yapay sinir ağı modelleri görülmektedir.



Şekil 1.17 Tek ve çok gizli katmanlı yapay sinir ağı modelleri
(Kızrak & Bolat, 2018)

Katmanlardaki hücre sayısı, sinir ağının performansını etkileyen temel faktörlerden biridir. Bu hücreler, aktivasyon değerleri üzerinden birbirlerine etki eder. Ayrıca, ağırlıkların başlangıçta belirlenme yöntemi de ağın performansını şekillendiren önemli bir unsurdur. Rastgele değerlerle başlatma veya önceden eğitilmiş bir ağdan ağırlık transferi gibi farklı yaklaşımlar kullanılabilir (Kızrak & Bolat, 2018). Ağın çalışma süreci boyunca, elde edilen performansa göre ağırlıklar yeniden ayarlanır.

Sinir ağının başarısını değerlendiren yitim (loss) fonksiyonu ise optimizasyon yöntemleriyle mümkün olduğunca sifıra yaklaştırılmaya çalışılır. Kullanım amaçlarına uygun olacak şekilde YSA tek katmanlı veya çok katmanlı olabilir (Ersoy, 2022). Şekil 1.18 temel olarak yapay sinir ağı akış diyagramını göstermektedir.




Şekil 1.18 Yapay sinir ağı akış diyagramı (Ersoy, 2022)

Çok katmanlı ağlarda kullanılan ara katmanlar, ağın öğrenme kapasitesini ve problem çözme yeteneğini artırsa da işlem süresini uzatabilir. Her bir sinir hücresi, önceki hücrelerden aldığı bilgiyi toplar ve bu bilgiyi işlemden geçirir daha sonra eşik değerini aşan sinyaller bir sonraki hücreye iletilerek çalışmasını sürdürür (Ersoy, 2022).

1.8.1. Evrişim katmanı

Şekil 1.19’ da gösterildiği gibi evrişim katmanı, çalışma diyagramı bir dizi evrişim çekirdeğinden oluşur (Cong & Zhou, 2023). Bu katman, öğrenilebilir bir yapıya sahip olup filtrelerden oluşmakta olup her bir filtre, ileri yayılım (geçiş) sırasında evrişim işleminde kullanılır (Karpathy, 2016). Bu işlem, öğrenilen bir evrişimin (ağırlık matrisi) kullanılarak her küçük veri parçası (özellik dökemesi) üzerinde kayıtlı bir filtreyle birleştirilerek özetlenmesi ve belirli özelliklerin çıkarılmasını içerir (Cong &

Zhou, 2023). İşlem sonucunda öznitelik haritaları elde edilir. Bu öznitelik haritaları, her filtreye özgü olarak üretilir ve ilgili gelişim bölümünde saklanır. (Ersoy, 2022).




Şekil 1.19 Evrişim işlemi gösterimi
(Ersoy, 2022)

1.8.2. Havuzlama

Aşağı örnekleme katmanı olarak da bilinen havuzlama katmanı evrişim işlemi sonrasında elde edilen öznitelik haritalarını daha küçük boyutlara indirgemek ve bilgi artırmak için kullanılan bir katmandır. Bu katman, öznitelik haritasını alt bölümlere ayırır ve her alt bölgedeki değerlerden bir özet bilgi çıkarır (Ersoy E., 2022). Havuzlama işlemi, genellikle maksimum havuzlama (maximum pooling), ortalama havuzlama (average pooling) ve stokastik havuzlama yaklaşımlarını içerir. (Cong & Zhou, 2023).


Maksimum havuzlama yönteminde ise ilgili çerçevedeki özellik noktalarının maksimum değerini alır (Cong & Zhou, 2023). Şekil 1.20’ de havuzlama işlemi örneği gösterilmiştir. Görüldüğü gibi havuzlama işlemi için 2x2’lik bir çerçeve belirlenmiş yani kayma (stride) değeri iki olarak belirlenmiştir (Ersoy, 2022). Ortalama havuzlama işleminde, kaydedilen boyutlardaki bir çerçeve verisi üzerindeki özellik noktaları tek tek taranır ve çerçeve içindeki piksellerin aritmetik ortalaması alınırken, stokastik havuzlamada çerçevedeki rastgele özellik noktalarının değerini alır (Cong & Zhou, 2023).



Şekil 1.20 Havuzlama işlemi
(Ersoy, 2022)

1.8.3. Dropout katmanı

Evrişimli sinir ağlarında ağ içindeki aşırı öğrenmeyi (overfitting) engellemek için dropout katmanı kullanılır. Bu yöntemde, belirli bir olasılık değeri kullanılarak gizli katman bölümlerinden seçilmiş rastgele düğümler devre dışı bırakılarak sadeleştirilir.(Krizhevsky ve ark., 2017). Şekil 1.21’ de ilk hali ve dropout uygulanmış ikinci halinin muhtemel şeklini göstermektedir.



Şekil 1.21 Dropout işlemi ile temsili sadeleştirme
(Ersoy, 2022)

1.8.4. Tam bağlantı katmanı

Tam bağlantılı ve softmax katmanları, sınıflandırma için ağıın son kısmında yer alır (Khan ve ark., 2020). Kendinden önce gelen katmana bağlıdır ve önceki katman tarafından üretilen iki boyutlu özellik bilgisi çıktısını tek boyutlu sınıflandırma bilgisine dönüştürmek için kullanılır (Cong & Zhou, 2023). Bu katman, dağılımlardan önce her sınıf etiketine karşılık gelen değerleri temsil eder dolayısıyla üretilen değerlerin hangi sınıfa ait olduğunu ve sınıf etiketini gösterir (Ersoy E., 2022). Tam bağlantı katmanı havuzlama ve evrişimin aksine, küresel bir işlemdir. Özellik çıkarma aşamalarından girdi alır ve önceki tüm katmanların çıktısını küresel olarak analiz eder. Sonuç olarak, verilerin sınıflandırılması için kullanılan özelliklerin doğrusal olmayan bir kılavuzu elde edilir (Khan ve ark., 2020).

1.9. Hiper Parametre Optimizasyonu ve Optimizasyon Algoritmaları

Makine öğrenimindeki hiper parametreler, eğitim süreci başlamadan önce ayarlanan ve öğrenme algoritmasının davranışının çeşitli yönlerini düzenleyen değişkenlerdir. (Aguerchi ve ark., 2024). Her evrişimli sinir ağı sisteminin hiper parametreleri vardır (Feurer & Hutter, 2019). Bu parametreler, eğitim sürecinin başlamasından önce kararlaştırılan ve öğrenme sürecinin kendisinin nasıl yürütüleceğini düzenleyen ayarlardır. Veri öğrenimi tarafından değil, kullanıcı seçimi veya bir arama prosedürü (hiper parametre ayarı) yoluyla belirlenirler (Aguerchi ve ark., 2024). Makine öğrenimi modelleri için en iyi hiper parametre yapılandırmasını seçmek, modelin

performansı üzerinde doğrudan bir etkiye sahiptir (Yang & Shami, 2020). Ek olarak çapraz doğrulama uygulaması (cross-validation), makine öğreniminde hiper parametre ayarlamaları alanında değerlendirme sürecinin güvenilirliğini ve nesnelliği sağlayan önemli bir yaklaşımdır. Veri setini birden fazla alt kümeye veya katmana bölen çapraz doğrulama, en iyi hiper parametrelerin aranması devam ederken bir modelin performansının tarafsız bir şekilde değerlendirilmesini sağlar (Aguerchi ve ark., 2024). Hiper parametre optimizasyon yöntemleri arasında; Gradyan tabanlı optimizasyon (Gradient Descent), Stokastik gradyan inişi (Stochastic Gradient Descent), ızgara araması, rastgele arama, Bayes optimizasyonu, genetik algoritma, Automated Machine Learning (AutoML), ADAM (Adaptive Moment Estimation), ADAGRAD (Adaptive Gradient Algorithm), RMSPROP (Root Mean Square Propagation) gibi teknikler vardır (Aguerchi ve ark., 2024; Monica & Agrawal, 2024; Yang & Shami, 2020).

1.10. Transfer Öğrenme


Transfer öğrenmesi, bir veri seti ile eğitilmiş olan modelden öğrenilen bilgileri başka bir görevde kullanmasını ifade eden derin öğrenme yöntemidir. Bu yaklaşımda, modeli sıfırdan eğitmek yerine, mevcut bir modelin ağırlıkları alınır ve yeni bir görev için uyarlanır. Böylece hem eğitim süresi kısalır hem de daha az veriyle etkili sonuçlar elde edilir. İnce ayar (fine-tuning) adı verilen süreçte, modelin belirli katmanları yeni veri setine uygun şekilde optimize edilir ve hedef probleme özgü bir performans artışı sağlanır (Abdulghani ve ark., 2020). Kısacası transfer öğrenimi, görevler için çok büyük bir veri kümesi üzerinde eğitilmiş önceden var olan bir modelin kullanılmasını sağlar ve yeni derin öğrenme modellerinin eğitim maliyetini düşürür (Pan & Yang, 2010). Transfer öğrenme yöntemleri aşağıdaki gibidir:

İlk olarak önceden eğitilmiş yöntemde, veri kütüphaneleri aracılığıyla veri paylaşımı yapılarak eğitilmiş modeller paylaşılır, Daha sonra özellik çıkarımı yöntemi gelir; bu teknikte, SoftMax (son) katmanı hariç tüm katmanlar dondurulur. Ayrıca, son katmandaki sınıflandırma sayıları ihtiyaçlara göre değiştirilebilir. Örneğin, meme kanseri türlerini sınıflandırmak için iyi huylu veya kötü huylu olmak üzere iki sınıf olabilir. Ancak, meme kanserinin alt türlerini sınıflandırırken birden fazla sınıflandırma yapılabilir. Son olarak ince ayar yönteminde de özellik çıkarmayla aynı şekilde önceden eğitilmiş modeller uygulanır. Ancak, yalnızca son katmanın

değiştirildiği özellik çıkarma işleminin aksine, bu ince ayar tekniği araştırmacıların yeni verilere dayanarak birkaç katmanı yeniden eğitmelerine olanak tanır (Muralikrishnan & Anitha, 2020).

1.11. Derin Öğrenme Yöntemleri ile Görüntü Sınıflandırma

DL kullanılarak yapılan tıbbi görüntü analizi, geleneksel makine öğrenimi yaklaşımına kıyasla bilimsel araştırmacılar için daha iyi olduğu kanıtlanmıştır (Debelee ve ark., 2020). Sınıflandırma görevleri, bir hastalığın varlığı ya da yokluğu gibi sağlık alanındaki tanı süreçlerinde ya da farklı hastalık türlerini ayırt etmede önemli bir rol oynar. Örneğin, bir kanser türünün iyi huylu veya kötü huylu olup olmadığını belirlemek gibi tıbbi sınıflandırma problemlerinde derin öğrenme sıkça kullanılır (Eker & Duru, 2021). Derin öğrenme, tıbbi görüntü analizinde başarılı olsa da bazı zorluklar sürmektedir. İlk olarak, geniş tıbbi veri setleri oluşturup araştırmacılara erişim sağlamak önemlidir; ikinci olarak sınırlı veriyle derin öğrenme modellerini eğitmek için yeni algoritmalar geliştirilerek, belirli tıbbi alanlarda daha az veriyle güçlü modeller oluşturulabilir (Debelee ve ark., 2020).




Şekil 1.22 Derin öğrenme ile medikal görüntülerin sınıflandırılması (Eker & Duru, 2021)

Şekil 1.22’de bazı sınıflandırma çalışmaları gösterilmektedir: A) Beyin tümörlerini meningioma, glioma ve pituitary türlerine ayıran bir sınıflandırma çalışması (Díaz-Pernas ve ark., 2021); B) Meme tümörünün varlığını ve iyi/kötü huylu olup olmadığını

belirleyen bir model (Zheng ve ark., 2020); C) Fotoğraflardan cilt kanseri türlerini sınıflandıran bir çalışma (Esteva ve ark., 2017); D) Covid-19'un akciğer röntgenleri üzerinden otomatik tespitini gösteren çalışma (Hemdan ve ark., 2020). Bu tarz örnekler, sağlık alanındaki derin öğrenme uygulamalarının çeşitliliğini göstermektedir. Ayrıca son 10 yılda yapay sinir ağları üzerine yapılan araştırmalarda büyük ilerlemeler kaydedilmiştir örneğin desen tanıma, akıllı robot, otomatik kontrol, tahmin ve kestirim, biyoloji, tıp, ekonomi vb. (Y. Wu & Feng, 2018).

1.12. Görüntü İşleme ve Görüntü Filtreleri


Makine öğrenmesinde, yaygın olarak kullanılan görüntü işleme, görüntü oluşturma, görüntü sıkıştırma ve kodlama, görüntü bulanıklığını giderme, süper çözünürlük, görüntü segmentasyonu, sınıflandırma ve nesne tanıma, değişiklik algılama, görüntü açıklaması ve görüntü alma vb. içerir. Görüntü filtreleme, görüntünün kalitesini iyileştirmek için yapılır ve bu filtreler, özellikle görüntü analizi ve derin öğrenme uygulamalarında ön işleme adımları olarak sıklıkla kullanılır ve görüntülerin model tarafından daha verimli bir şekilde işlenmesine yardımcı olur (Jiao & Zhao, 2019). Şekil 1.23'te görüldüğü gibi genel olarak iki tür görüntü işleme algoritması vardır: doğrusal ve doğrusal olmayan.



Şekil 1.23 Görüntü işleme filtreleri
(Desai ve ark., 2020)

Doğrusal filtreler, giriş sinyali bir çekirdek veya maske ile birleştirerek işler, genellikle evrişim veya Fourier dönüşümleri kullanarak uygulanır. Bu tür filtreler, görüntüdeki tüm piksellere aynı şekilde etki eder (Desai ve ark., 2020). Örneğin Kutu bulanıklığı, Hann Penceresi, Gauss Bulanıklığı (Chandel & Gupta, 2013).

Kutu bulanıklığı, "hareketli ortalama" olarak da bilinen en hızlı bulanıklık algoritmasıdır, bir görüntünün her pikseli için çevresindeki piksellerin ortalaması hesaplanır ve bu değer o pikselin yerine yerleştirilir (Chandel & Gupta, 2013). Şekil 24'teki örneğe göre, 9x9 piksel boyutundaki bir görüntüde; her piksel, çevresindeki 3x3 komşu piksellerle ortalama alınarak yeni değeriyle değiştirilir. Bir pikselin çevresindeki 3x3 piksellerin toplam değeri 360 ise, bu değer 9'a bölümüyle ortalama alınır ($360 / 9 = 40$), ve merkez piksele 40 değeri atanır. Bu işlemi her piksel için uygulayarak yeni bir çıktı görüntüsü oluşturulur. Böylece, daha yüksek değerlerin (örneğin, 90'lar) düşük değerlerle (örneğin, 0'lar) çevrelendiği bölgelerde, çevre etkisiyle piksellerin yoğunluğu yumuşatılır. Bu işlem aynı zamanda ani parlaklık değişimlerini azaltarak daha pürüzsüz bir görünüm elde edilmesine olanak tanır. Kutu filtresi hızlı ve etkili bir yöntem olmasına rağmen, kenarları belirginleştirme gibi özelliklere sahip değildir; bu yüzden temel bulanıklaştırma amaçları için kullanılır (Desai ve ark., 2020).



Şekil 1.24 Kutu bulanıklığına örnek
(Desai ve ark., 2020)

Gauss Bulanıklığı, "mükemmel" bir bulanıklık olarak kabul edilir. Gauss filtresi, merkez pikselin etrafındaki komşu piksellere mesafeye göre ağırlık vererek görüntüyü yumuşatır. Yakın piksellere daha yüksek ağırlık verilmesi, görüntüde pürüzsüz bir geçiş sağlar ancak kenarları bulanıklaştırabilir. Gauss fonksiyonu, merkez piksel ile

komşuları arasındaki mesafeye göre bu ağırlıkları hesaplar. Benzer yoğunlukta olan piksellerin ağırlık katsayısı 1'e yakın olurken, çok farklı olanların katsayısı 0'a yaklaşır, böylece filtreleme etkisi azalır. Ancak bu filtre, her piksele aynı tür ağırlıklandırma uyguladığı için kenar detaylarını tam olarak koruyamaz (Desai ve ark., 2020; Chandel & Gupta, 2013).

Doğrusal olmayan filtreler ise farklı bir yapıdadır ve genellikle evrişim veya Fourier çarpımıyla uygulanamaz. Bu filtreler, belirli bir pikselin değerini çevresindeki piksellere göre farklı kurallarla düzenler ve sonuç olarak görüntüde gürültü giderme gibi görevlerde daha etkili olabilirler (Desai ve ark., 2020). Örneğin Medyan filtreleme ve ikili morfolojik işlemler gibi (Chandel & Gupta, 2013). Medyan filtresi, genellikle bir görüntü veya sinyal üzerinde "tuz ve karabiber" tarzı gürültüyü gidermek için kullanılan doğrusal olmayan bir dijital filtreleme tekniğidir. Bu tür bir gürültü azaltma, daha sonraki işlemenin sonuçlarını iyileştirmek için tipik bir ön işleme adımıdır (Chandel & Gupta, 2013).

```
y[1] = Median[2 2 80] = 2
y[2] = Median[2 80 6] = Median[2 6 80] = 6
y[3] = Median[80 6 3] = Median[3 6 80] = 6
y[4] = Median[6 3 3] = Median[3 3 6] = 3
i.e. y = [2 6 6 3].
```

Şekil 1.25 Medyan filtresine örnek
(Chandel & Gupta, 2013)

Şekil 1.25' deki gibi bu doğrusal olmayan filtre, bir pikselin çevresindeki belirli bir pencere içerisindeki değerlerin sıralanmasıyla çalışır ve bu dizinin ortanca (medyan) değerini merkez piksel olarak yeniden atar. Medyan filtreleme, aykırı değerlere dayanıklı olduğu için, yüksek veya düşük değerli piksellerin etkisini minimize eder ve bu sayede kenar detaylarını korur. Özellikle darbe gürültüsünün (rastgele siyah veya beyaz pikseller) yaygın olduğu görüntülerde, medyan filtre kenarları bulanıklaştırmadan veya ayrıntıları kaybetmeden gürültüyü etkili bir şekilde azaltabilir (Desai ve ark., 2020; Chandel & Gupta, 2013). Bilateral filtreleme ise, gürültüyü azaltırken kenarları koruyan doğrusal olmayan bir filtredir. Piksellerin hem konumlarını hem de renk veya gri tonlarındaki benzerliklerini dikkate alır. Bu sayede yalnızca yakın ve benzer yoğunlukta pikseller ortalaması alınır, böylece kenarlarda detay kaybı olmadan yumuşatma sağlanır. Bilateral filtre, Gauss filtresi gibi çalışsa da

yoğunluk değişimlerini dikkate aldığı için kenarları daha etkili şekilde korur (Desai ve ark., 2020).

1.12.1. Kontrast sınırlı uyarlamalı histogram eşitleme

Kontrast Sınırlı Uyarlamalı Histogram Eşitleme (CLAHE), bir görüntünün kontrastını artırmak için kullanılan bir görüntü işleme tekniğidir (Musa ve ark., 2018). Araştırmacılar tarafından özellikle ön işleme aşamasında görüntülerin kontrast iyileştirilmesi için yaygın olarak kullanılır (Kuran, U. & Kuran, E. C. 2021). CLAHE özellikle düşük kontrastın sorun olduğu X-ışını görüntüleri olmak üzere tıbbi görüntülerin kullanımını daha uygun hale getirir (Kuran, U. & Kuran, E. C. 2021). Qiao vd. (2017) 'de CLAHE algoritmasının hem daha iyi bir kontrast sağladığı hem de detayları koruduğu belirtilmektedir. Mat Radzi ve ark. (2020) çalışmasında araştırmacılar, 2 boyutlu mamogram radyografileri için klasik histogram eşitleme ile CLAHE'yi karşılaştırdıklarında, CLAHE algoritmasının daha iyi sonuçlar sağladığını bulmuşlardır. Genel olarak CLAHE desen tanıma ve bilgisayarlı görme uygulamalarının performansını iyileştirmek için yaygın olarak tercih edilmektedir (Kuran, U. & Kuran, E. C. 2021).

CLAHE, tüm bir görüntü yerine, bir görüntüdeki küçük bir alanda, yani bir bütün görüntünün döşemelere (tiles) bölünmesi (alan boyutu 8x8) ve her döşeme için ayrı bir eşitleme işlemi yapılması şeklinde çalışır. Her döşeme kontrastını ayarlamak ve gürültüyü önlemek için bir sınır değeri uygulanır (contrast limiting). Eğer histogramdaki yoğun pikseller belirtilen bir kontrast sınırını aşarsa, bu pikseller kırılır ve diğer bölmelere eşit olarak dağıtılır. Döşemeler arasındaki sınır geçişlerini yumuşatmak için ikili doğrusal enterpolasyon yapılır yani bu bölgeler arasında keskin geçişler olmaması için komşu döşemeler birleştirilir. Kontrast, esas olarak homojen alanlarda hem görüntüdeki detayları artırır hem de görüntüde bulunabilecek bir gürültüyü yükseltmekten kaçınmak için sınırlandırılacaktır (Musa ve ark., 2018). Şekil 1.26'te görüntü bir giriş görüntüsünü (a)'da ve (b) uyarlanabilir histogram eşitlemesinden sonraki aşırı gürültülü görüntüsü (c)'de ise CLAHE' nin uygulandığı hem kontrastın hem gürültünün düzenlendiği görüntüsü görülmektedir.



(a) Giriş görüntüsünü



(b) Uyarlanabilir histogram eşitlemesinden sonraki görüntü



(c) CLAHE' nin uygulandığı görüntü

Şekil 1.26 CLAHE uygulanan görsel
(Musa ve ark., 2018)

2. MATERYAL VE YÖNTEM

Bu bölümde, tez çalışmasında kullanılan veri seti, programlama dili, DL eğitiminde kullanılan platform ve görüntülerin işaretleme için kullanılan araçlar hakkında bilgi verilmiş olup tezde uygulanan yöntem detaylı bir şekilde açıklamaktadır. Bu çalışmada, meme kanseri teşhisi için popüler derin öğrenme modellerinden olan ResNet50 ve InceptionV3 mimarileri karşılaştırılmıştır. Bu süreçte, hem Cranio-Caudal (CC) hem de Medio-Lateral Oblique (MLO) açılardan alınan mamografi görüntüleri kullanılarak, modellerin kategorik doğruluk metrikleri üzerinden karşılaştırmaları yapılmıştır.

2.1. Veri Seti

Bu çalışmada, meme kanseri teşhisinde yaygın olarak kullanılan DDSM (Digital Database for Screening Mammography) veri seti kullanılmıştır. Veri setinde toplam 7808 mamografi görüntüsü yer almakta olup, bu görüntüler kanserli (anormal) ve normal olarak sınıflandırılmıştır. 2684 görüntü Benign, 2716 görüntü kanserli, 2408 görüntü ise normal örneklerden oluşmaktadır. Kanserli örneklerde, lezyonların iyi huylu (benign) veya kötü huylu (malign) olup olmadığına dair detaylı anotasyonlar yer almaktadır. Normal örnekler ise herhangi bir patolojik bulgu içermemektedir.

DDSM veri seti, standart bir eğitim/test ayırımına sahip değildir. Ancak bu çalışmada yaygın bir uygulama olan %80 eğitim ve %20 test oranı temel alınarak örnekleme yapılmıştır. Bu dağılıma göre, çalışmamızda MLO görüntülerinin eğitim setinde 3904 görüntü (1342 benign, 1358 kanserli, 1204 normal), ve CC görüntülerinin eğitim setinde 3904 görüntü (1342 benign, 1358 kanserli, 1204 normal) bulunmaktadır. Çalışmamızda görüntü birleştirme işlemiyle birlikte MLO görüntülerinin eğitim setinde 1952 görüntü (671 benign, 679 kanserli, 602 normal), ve CC görüntülerinin eğitim setinde 1952 görüntü (671 benign, 679 kanserli, 602 normal) görüntü elde edilmiştir. Çalışmamızda CC ve MLO görüntüleri ayrı ayrı çalıştırıldığında 1563 eğitim görüntüsü 389 test görüntüsü ile işlemler yapılmıştır.

Veri setindeki tüm görüntüler ön işleme aşamasından geçirilmiştir. Bu süreçte, lezyonların bulunduğu ROI (Region of Interest) bölgeleri çıkarılmış ve görüntüler,

derin öğrenme modelleriyle uyumlu olacak şekilde 299x299 piksel boyutuna dönüştürülmüştür. Bu çalışmada kullanılan "CBIS-DDSM" veri seti, meme kanseri mamografi görüntülerinden oluşmakta olup orijinal olarak The Cancer Imaging Archive (TCIA) tarafından yayımlanmıştır (Lee et al., 2017). Çalışmada veri setinin Kaggle platformuna yüklenmiş versiyonu (Awsaf49, 2018) kullanılmıştır.

2.2. Veri Ön İşleme ve Hazırlık

Görüntü işlemede görüntü kontrastını arttırarak daha belirgin hale getirmek için bir histogram filtresi olan CLAHE (Kontrast Sınırlı Uyarlamalı Histogram Eşitleme) filtresi kullanılmıştır. Formül kaynakçada açıklanmaktadır (Zuiderveld, 1994).

2.3. Kullanılan Algoritmalar


Görüntü işleme parçalarında, özellikle derin öğrenme modellerinde kullanılan çeşitli etkiler, modelin önemli ölçüde özelliklerinin özellikleridir. Bu etkinin, verinin arttırılması, ön işlenmesi, modelin yapılandırılması, derlenmesi ve eğitilmesi gibi farklı aşamalarda modelin şekillendirilmesi önemli bir rol oynamaktadır. Aşağıda, çalışmada kullanılan derin öğrenme algoritmaları detaylı bir şekilde açıklanmıştır.

2.3.1. ResNet algoritması

ResNet (Residual Network) temel fikri, "residual" bağlantıları Türkçe karşılığı “Artık Ağlar” olarak adlandırılan bağlantılar kullanarak derin ağların daha verimli çalışmasını sağlamaktır. ResNet, 2015 yılında Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından geliştirilmeye başlanan bir derin öğrenme algoritmasıdır. Katman sayısı fazla olan ağların eğitimini kolaylaştırmayı amaçlayarak geliştirilmiştir. İlk olarak “Deep Residual Learning for Image Recognition” makalesinde literatüre girmiştir (He ve ark., 2016). Resnet Algoritması kendinden daha karmaşık katman yapısına sahip VGG algoritması ile image net veri seti üzerindeki eğitim sonuçları değerlendirildiğinde %3,57 hata oranı ile ILSVRC 2015 ve COCO 2015 sınıflandırma yarışmasında birinci olmuştur (He ve ark., 2016). Donanım birimlerini gelişmesi ve işlem gücünün artması ile derin öğrenme algoritmalarında katman sayıları artırılarak daha başarılı hale getirilmeye çalışmıştır. Çok derin katmanlı ağlarının


eđitilmesi olduka zor ve maliyetlidir. Bunun en nemli sebeplerinden birisi daha derin modellerin optimize edilmesinin kolay olmamasıdır (He ve ark., 2016).

Őekil 2.1’de gsterilen x yolu artık yol (kısa yol bađlantısı) ile bir veya daha fazla katmanı atlanması, ađrılıkların sonraki katmana aktarılması ile yapılır.



Őekil 2.1 Residual blok (artık blok) rneđi
(Atik, I., 2024)

Kısayol bađlantısıyla beraber ıktımız; $H(x) = f(x) + x$ olarak elde edilmiŐ olundur. Temel olarak katmanlar arası ađrılık aktarımı ve bazı katmanları azaltılması hedeflenerek ađ hatasını artırmadan katman sayısını azaltmaktır. Dolayısıyla girdiyi dođrudan daha derin katmanlara ulaŐmasını sađlayan kısayol bađlantıları, yani atlama bađlantıları sunmaktadır. Kısayol bađlantıları bu bloklar arasına eklenir ve ađın daha karmaŐık zellikleri đrenmesine ve dođruluđunu artırmasına olanak tanır (He ve ark., 2016).




Őekil 2.2 Resnet50 mimarisi
(Sahin, N. ve ark., 2023).

ResNet50, Residual Network50 anlamına gelir. Evrişimsel sinir ağları arasında yaygın olarak kullanılan bir modelidir. ResNet50, resnet ailesine dahil bir algoritmadır ve toplamda 50 katman içerir. ResNet50 genellikle nesne tespiti, görüntü sınıflandırma ve görüntü tanıma gibi sorunlarda başarılı olduğunu literatürde ispatlamıştır (Koonce, 2021). Sonuç olarak, ResNet50, geniş bir kullanım alanına sahip olup derin öğrenme alanında önemli bir algoritmadır. Şekil 2.2’de resnet50 mimarisi gösterilmiştir (Ali ve ark., 2021).

2.3.2. Inception algoritması

Google, “Going Deeper with Convolutions” makalesindeki fikrini GoogLeNet mimarisi adıyla, başlangıç noktası olarak, 2015 yılında yayınlamıştır. (Szegedy ve ark., 2015). Burada hem ‘daha derin’ hem de ‘daha geniş’ bir model tasarlanmıştır. Model içindeki genişlik ögesini ‘inception’ adını verdikleri modüllerle elde etmektedirler. Evrişimli sinir ağı modelleri içinde genişlik kavramını kullanan ilk yayındır. Inception modelinde katman kanal sayısının azaltılmış olması modelin hızlı çalışmasını sağlamıştır. Genel olarak bu Inception ağının dokuz adet Inception modülü ve yüzden fazla katmanı bulunmaktadır. Şekil 2.3’te Temel Inception Modeli gösterilmiştir (Szegedy ve ark., 2015).



Şekil 2.3 Basit Inception modeli
(Szegedy, C. ve ark., 2015)

Inception V1 modeli, Inception Modüllerinin versiyon1’ini oluşturmaktadır. Inception modüllerindeki genişleme etkisi evrişim katmanlarındaki 1×1 , 3×3 , 5×5 gibi farklı filtreleri ve 3×3 maksimum havuzlama işleminin paralel olarak gerçekleştirilmesiyle

oluşturulmaktadır. Ancak işlem karmaşıklığı ve parametre sayısının paralel işlemler yüzünden çok büyümesinden dolayı 1×1 evrişim katmanları işlem öncesine eklenerek, parametre sayısı ve işlemler azaltılmıştır. Şekil 2.4’de Inception V1 Modeli gösterilmiştir (Szegedy ve ark., 2015).

Şekil 2.4 Inception V1 modeli
(Szegedy, C. ve ark., 2015)


Inception V2, Inception V1'in geliştirilmiş bir versiyonudur. Inception v2 modelinin amacı kümeleme normalizasyonu ve seyreltme katmanları ile performansın arttırmaktır. Örneğin daha büyük boyutlu konvolüsyon filtreleri (örneğin, 5x5) yerine iki ardışık 3x3 konvolüsyon uygulanmaktadır ya da 3x3 evrişim katmanından 3x1 evrişimlik alt katmanlar oluşturma işlemi yapılmaktadır. Şekil 2.5'te 3x3 evrişim yerine önerilen 3x1 evrişim adımları gösterilmiştir (Szegedy ve ark., 2015).

Şekil 2.5 3x3 evrişim yerine önerilen 3x1 evrişim adımları (Chaudhari, D. J. ve Malathi, K., 2023).

model arasındaki karşılaştırmada Inception V3, He ve diğerlerinin (He ve ark., 2015) modelinden en iyi 5 hatayı %25 , en iyi 1 hatayı ise %14 oranında azaltarak daha iyi performans göstermektedir (Szegedy ve ark., 2016).


2.3.3. Resnet50 ve Inception karşılaştırılması

Res-Net derine gitmekle ilgilidir ve Inception ailesi genişlemeye gitmekle ilgilidir. Genel bir karşılaştırma yapmak gerekirse Canziani ve arkadaşlarının 2017 yılında yayınladıkları “An Analysis of Deep Neural Network Models for Practical Applications” makalesinden yola çıkarak (Canziani ve ark., 2017); ağlar ve ağların başarıları (%) olarak karşılaştırılması Şekil 2.6’ da gösterilmektedir.



Şekil 2.6 Modellere göre başarılar
(Canziani ve ark., 2017)

Şekil 2.7’ de ise y ekseninde hesaplanan parametre ve x ekseninde başarı yüzdesi cinsinden ağ modellerinin parametre hesap yükü-başarı karşılaştırılması verilmektedir (Canziani ve ark., 2017).



Şekil 2.7 Başarılar göre modellerin işlem yükü
(Canziani ve ark., 2017)

2.4. Hata Matrisi

Performans değerlendirme metrikleri, makine öğrenmesi ve derin öğrenme modellerinin seçiminde ve en iyi modele karar vermede kullanılır (Aldashash. 2024). Bu tez çalışmasında yaygın olarak kullanılan metrikler aşağıda ele alınmıştır.

Doğruluk veya hata oranı (Accuracy veya Error Rate), sınıflandırıcıların genelleme kapasitesini değerlendirmede en sık kullanılanlardan yöntemlerden biridir çünkü eğitilmiş bir sınıflandırıcı modelinin, eğitim sırasında görmediği verilerle karşılaştırıldığında doğru tahmin ettiği örneklerin toplamını ifade eden bir metriktir. Eşitlik 2.1’de gösterilen metrik, model sonuçlarının genel performans değerlendirmeleri için önemli bir ölçüm sağlar (Mehmood ve ark., 2023).

$$\text{Doğruluk} = \frac{TP + TN}{TP + FN + FP + TN} \quad (2. 1)$$

Eşitlikteki kısaltmalar doğru pozitif (TP), doğru şekilde meme kanseri teşhisi konulan vakaları; doğru negatif (TN), sağlıklı olarak doğru teşhis edilen vakaları, yanlış pozitif (FP), sağlıklı bireylerin yanlışlıkla hasta olarak teşhis edilmesi; yanlış negatif (FN), hastaların yanlışlıkla sağlıklı olarak teşhis edilmesi durumudur.

Kesinlik, pozitif tahminlerin ne kadarının doğru olduğunu gösterir ve yüksek kesinlik, daha az yanlış pozitif (FP) demektir. Hesaplama için Eşitlik 2.2 kullanılır (Mehmood ve ark., 2023).

$$Kesinlik = \frac{TP}{TP + FP} \quad (2. 2)$$

Duyarlılık, doğru teşhis edilen meme kanseri vakalarının (TP), toplam meme kanseri vakalarına (TP+FN) oranıdır ve Eşitlik 2.3 ile hesaplanır (Mehmood ve ark., 2023).

$$Duyarlılık = \frac{TP}{TP + FN} \quad (2. 3)$$


Özgüllük (Specificity), modelin her veri sınıfını tahmin etme yeteneği olarak tanımlanabilir. Özgüllüğü hesaplamak için Eşitlik 2.4 kullanılmaktadır (Mehmood ve ark., 2023).

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (2. 4)$$

F1 skoru, modelin duyarlılık (hassasiyet) ve kesinlik değerlerinin harmonik ortalaması olarak tanımlanmaktadır. F1 skoru yükselmesi modelin performans değerinin iyileştiğini göstermektedir. F1 skoru Eşitlik 2.5 ile elde edilmektedir (Mehmood ve ark., 2023).


$$F1 \text{ skoru} = \frac{2 * Keskinlik * Duyarlilik}{Keskinlik + Duyarlilik} \quad (2. 5)$$

Makine öğrenmesinde performans değerlendirme yöntemleri arasında yaygın olarak kullanılan karışıklık matrisi, bir sınıflandırma sisteminin belirlediği tahmin edilen ve gerçek sınıflar hakkında bilgiler içerir (Taner ve ark., 2021). Şekil 2.8’de gösterildiği gibi her sütun tahmin edilen bir sınıfı temsil ederken, her satır gerçek bir sınıf örneğini göstermektedir.




Şekil 2.8 Hata matrisi
(Aldashash, 2024)


Bu çalışmada kullanılan ResNet50 ve InceptionV3 derin öğrenme mimarileri, CC ve MLO olmak üzere iki farklı mamografi görünümüne göre ayrı ayrı eğitilmiştir. Aşağıda yer alan grafikler, her model ve görüntüleme açısı için elde edilen eğitim doğruluğu (training accuracy) ve doğrulama kaybı (validation loss) değerlerinin, eğitim süresi boyunca (epoch bazında) nasıl değiştiğini göstermektedir. ResNet50 modeline ait grafiklerde hem MLO hem de CC görüntüleri için doğrulama kaybı ve eğitim doğruluğu izlenmiştir (Şekil 2.9–2.12). Benzer şekilde, InceptionV3 modeline ait grafiklerde de her iki görünüm için doğrulama ve eğitim süreci ayrı ayrı sunulmuştur (Şekil 2.13–2.16). Bu grafikler, modellerin öğrenme performansını, aşırı öğrenme (overfitting) eğilimlerini ve eğitim sürecindeki istikrar düzeylerini değerlendirmek amacıyla kullanılmıştır.




Şekil 2.9 ResNet50 modeli için MLO görünümünde doğrulama kaybı grafiği




Şekil 2.10 ResNet50 modeli için MLO görünümünde eğitim doğruluğu grafiği




Şekil 2.11 ResNet50 modeli için CC görünümünde doğrulama kaybı grafiği




Şekil 2.12 ResNet50 modeli için CC görünümünde eğitim doğruluğu grafiği




Şekil 2.13 InceptionV3 modeli için MLO görünümünde doğrulama kaybı grafiği



Şekil 2.14 InceptionV3 modeli için MLO görünümünde eğitim doğruluğu grafiği



Şekil 2.15 InceptionV3 modeli için CC görünümünde doğrulama kaybı grafiği



Şekil 2.16 InceptionV3 modeli için CC görünümünde eğitim doğruluğu grafiği

2.5. Sistem Parametreleri

Bu çalışmada 5 çeşit hiper parametre kullanılmıştır. Bunlar;

2.5.1. ImageDataGenerator parametreleri (Veri ön işleme)

- rescale=1./255: Görüntülerin piksel değerlerini [0,1] aralığına ölçekler.
- rotation_range=20: Görüntüler rastgele ± 20 derece döndürülecek.

- width_shift_range=0.2: Görüntüler yatay olarak %20 oranında kaydırılacak.
- height_shift_range=0.2: Görüntüler dikey olarak %20 oranında kaydırılacak.
- horizontal_flip=True: Görüntüler rastgele yatay ekseninde çevrilecek.
- validation_split=0.2: Eğitim verisinin %20'si doğrulama için ayrılacak.
- target_size=(224, 224): Görüntüler 224x224 piksel boyutlarına yeniden boyutlandırılacak.
- color_mode='rgb': Görüntüler RGB (renkli) olarak işlenecek.
- batch_size=32: Her bir eğitim adımında 32 görüntü kullanılacak.
- class_mode='categorical': Çok sınıflı bir sınıflandırma yapıldığı belirtiliyor.
- shuffle=True/False: Eğitim verisi rastgele karıştırılacak, doğrulama seti ise karıştırılmayacak.

2.5.2. Model parametreleri

- input_shape=(224, 224, 3): Modelin giriş boyutları 224x224 piksel ve 3 kanallı (RGB).
- include_top=False: InceptionV3'nin son sınıflandırma katmanı dahil edilmemiş.
- weights='imagenet': Model, ImageNet veri setiyle önceden eğitilmiş ağırlıkları kullanıyor.
- trainable=True: Tüm katmanlar eğitilebilir halde bırakılmış.

2.5.3. Model katmanları parametreleri

- Dense(1024, activation='relu'): Tam bağlantılı katman, 1024 nöron ve ReLU aktivasyon fonksiyonu ile.
- Dropout(0.2): %20 oranında dropout uygulanarak aşırı öğrenmenin önüne geçiliyor.
- Dense(3, activation='sigmoid'): Çıkış katmanı, 3 sınıf ve sigmoid aktivasyon fonksiyonu ile.

2.5.4. Model derleme parametreleri (Compilation parameters)

- optimizer=Adam(lr=0.0001): ADAM optimizasyon algoritması, öğrenme oranı 0.0001.

- `loss='categorical_crossentropy'`: Kategorik çapraz entropi kaybı fonksiyonu.
- `metrics=['categorical_accuracy', f1_m, precision_m, recall_m, ...]`: Modelin doğruluğunu ve performansını ölçmek için kullanılan metrikler:

`categorical_accuracy`: Doğruluk.

- `f1_m`: F1 skoru.
- `precision_m`: Kesinlik (Precision).
- `recall_m`: Duyarlılık (Recall).
- Diğer ek metrikler: TruePositives, TrueNegatives, FalsePositives, FalseNegatives.

2.5.5. Model eğitim parametreleri (Training parameters)

- `steps_per_epoch=ceil(num_samples / 32)`: Eğitimde her epoch için adım sayısı, numune sayısının 32'ye bölünmesi ile belirlenir.
- `epochs=10`: Eğitim, 10 epoch boyunca yapılacaktır.

3. BULGULAR VE TARTIŞMA

Bu bölümde çalışma bulgularına yer verilmiştir.

3.1. Resnet50 Algoritması ile CC Sınıflandırması

Resnet50 Algoritması ile CC Sınıflandırması 10 tur 10 defa çalıştırılmıştır.

Tablo 3.1 CC görüntülerinin Resnet50 algoritması kullanılarak elde edilen hata matrisi tablosu

Sınıf	Pozitif (Gerçek)	Negatif (Gerçek)
Pozitif (Tahmin)	356,60 (TP)	215,93 (FP)
Negatif (Tahmin)	294,07 (FN)	1085,41 (TN)

Accuracy (Doğruluk): $(TP+TN)/(TP+TN+FP+FN) = (356,60+1085,41) / (356,60$

$+1085,41 + 215,93 + 294,07) = 1442,01 / 1952 \approx 0.738$

Precision (Kesinlik): $TP/(TP+FP) = 356,60/(356,60+215,93) = 356,60/572,53 \approx 0.62$

Recall (Duyarlılık): $TP/(TP+FN) = 356,60 / (356,60 + 294,07) = 356,60 / 650,67 \approx 0.54$

F1-Score: $2 * (Precision * Recall) / (Precision + Recall) = 2 * (0.62 * 0.54) / (0.62 + 0.54) = 2 * 0.3348 / 1,16 \approx 0.58$

3.2. InceptionV3 Algoritması ile CC Sınıflandırması

Resnet50 Algoritması ile CC Sınıflandırması 10 tur 10 defa çalıştırılmıştır.

Tablo 3. 2. CC görüntülerinin InceptionV3 algoritması kullanılarak elde edilen hata matrisi tablosu

Sınıf	Pozitif (Gerçek)	Negatif (Gerçek)
Pozitif (Tahmin)	443.71 (TP)	406.28 (FP)
Negatif (Tahmin)	206.95 (FN)	895.05 (TN)

Accuracy (Doğruluk): $(TP+TN)/(TP+TN+FP+FN) = (443.71+895.05)/(443.71 + 895.05 + 406.28 + 206.95) = 1338.76 / 1952 \approx 0.686$

Precision (Kesinlik): $TP/(TP+FP) = 443.71/(443.71+406.28) = 443.71 / 849.99 \approx 0.522$

Recall (Duyarlılık): $TP/(TP+FN) = 443.71/(443.71 + 206.95) = 443.71 / 650.66 \approx 0.682$

F1-Score: $2 * (Precision * Recall) / (Precision + Recall) = 2 * (0.522 * 0.682) / (0.522 + 0.682) = 2 * 0.356 / 1.204 \approx 0.592$

3.3. Resnet50 ile MLO Sınıflandırması

İnception V3 ile MLO Sınıflandırması 10 tur 10 defa çalıştırılmıştır.

Tablo 3. 3. MLO görüntülerinin Resnet50 algoritması kullanılarak elde edilen hata matrisi tablosu

Sınıf	Pozitif (Gerçek)	Negatif (Gerçek)
Pozitif (Tahmin)	453,93 (TP)	196,74 (FP)
Negatif (Tahmin)	124,93(FN)	1176,40(TN)

Accuracy (Doğruluk): $(TP+TN)/(TP+TN+FP+FN) = (453,93 + 1176,40) / (453,93 + 1176,40 + 196,74 + 124,93) \approx 0.8351 \rightarrow \%83,51$

Precision (Kesinlik): $TP/(TP+FP) = 453,93 / (453,93 + 196,74) \approx 0.6977 \rightarrow \%69,77$

Recall (Duyarlılık): $TP/(TP+FN) = 453,93 / (453,93 + 124,93) \approx 0.7842 \rightarrow \%78,42$

F1-Score: $2 * (Precision * Recall) / (Precision + Recall) = 2 * (0.6977 * 0.7842) / (0.6977 + 0.7842) \approx 0.7379 \rightarrow \%73,79$

3.4. Inception V3 ile MLO Sınıflandırması

İnception V3 ile MLO Sınıflandırması 10 tur 10 defa çalıştırılmıştır.

Tablo 3. 4. MLO görüntülerinin InceptionV3 algoritması kullanılarak elde edilen hata matrisi tablosu

Sınıf	Pozitif (Gerçek)	Negatif (Gerçek)
Pozitif (Tahmin)	443,71 (TP)	406,28 (FP)
Negatif (Tahmin)	206,95(FN)	895,05(TN)

Accuracy (Doğruluk): $(TP+TN)/(TP+TN+FP+FN) = (443,71 + 895,05) / (443,71 + 895,05 + 406,28 + 206,95) = 1338,76 / 1952 \approx 0,6857 \rightarrow \% 68,57$

Precision (Kesinlik): $TP/(TP+FP)=443,71/(443,71+406,28)=443,71/849,99 \approx \% 52,2$

Recall (Duyarlılık): $TP/(TP+FN)=443,71/(443,71+206,95)=443,71/650,66 \approx 68,18$

F1-Score: $2 * (Precision * Recall) / (Precision + Recall) = 2 \times (0,522 \times 0,6818) / (0,522 + 0,6818) \approx 0,5913 \rightarrow \% 59,13$

Bu çalışmada, DDSM (Digital Database for Screening Mammography) veri setinden elde edilen mamogram görüntüleri kullanılarak meme kanseri sınıflandırmasında ResNet50 ve InceptionV3 modellerinin performansları karşılaştırılmıştır. Sınıflandırma işlemleri, meme görüntüleme yöntemleri olan Cranio-Caudal (CC) ve Medio-Lateral Oblique (MLO) görüntüleri kullanılarak yapılmış olup modellerin kategorik doğruluk metrikleri üzerinden değerlendirme yapılmıştır. Elde edilen sonuçlar, model performanslarının hem kullanılan veri türüne hem de model mimarisine bağlı olarak önemli ölçüde değiştiğini ortaya koymuştur. Araştırma sonucunda elde edilen tüm bulgular ve değerler literatürde bulunan benzer çalışmalarla karşılaştırılarak tartışılmıştır.

3.5. ResNet50 ve InceptionV3 Modellerinin Karşılaştırılması

Sonuçlarımızdaki ResNet50 modelinin performansını inceleyecek olursak, ResNet mimarisi, derin katman yapısına sahip olmasına rağmen skip connections ile gradyan kaybı problemini azaltarak daha derin katmanların verimli bir şekilde eğitilmesine olanak tanımaktadır. Bu özellik, modelin özellikle karmaşık verilerde başarılı olmasını sağlamaktadır. Cranio-Caudal görüntülerinde, ResNet50 modeli 0.7453 ile 0.855 arasında değişen doğruluk değerlerine ulaşmıştır. En yüksek başarı cc_resnet50_5 modelinde 0.855 doğruluk ile elde edilmiştir. Bu sonuçlar, ResNet50 mimarisinin CC görüntülerinde etkili bir performans sunduğunu göstermektedir. Medio-Lateral Oblique görüntülerinde ise ResNet50 modeli, 0.5893 ile 0.6895 arasında doğruluk değerleri elde etmiştir. En yüksek doğruluk mlo_resnet50_8 modelinde 0.6895 olarak gözlemlenmiştir. MLO görüntülerinde performansın daha düşük olması, bu görüntülerin sınıflandırma açısından daha karmaşık yapıda olabileceğini

göstermektedir. Ancak genel olarak, ResNet50 mimarisi her iki görüntü tipi için tatmin edici sonuçlar vermiştir.

InceptionV3 modelinin performansını incelediğimizde ise model, farklı boyutlardaki filtrelerin aynı anda uygulanabilmesi sayesinde daha çeşitli özelliklerin yakalanmasını sağlayan bir yapıya sahiptir. Ancak bu mimari, özellikle karmaşık veri setlerinde daha fazla ayar gerektiren bir yapıdır. Cranio-Caudal görüntülerinde, InceptionV3 modeli 0.6827 ile 0.8217 arasında doğruluk oranları elde etmiştir. En yüksek doğruluk cc_InceptionV3_10 modelinde 0.8217 olarak kaydedilmiştir. InceptionV3'ün CC görüntülerinde elde ettiği bu performans, karmaşık yapısına rağmen sınıflandırma açısından etkili olabileceğini göstermektedir. Medio-Lateral Oblique görüntülerinde ise InceptionV3 modeli performans olarak 0.5043 ile 0.6448 arasında kalmıştır. En yüksek doğruluk mlo_InceptionV3_4 modelinde 0.6448 ile gözlemlenmiştir. Bu sonuçlar, InceptionV3'ün MLO görüntülerinde sınırlı bir performans sergilediğini, özellikle bu görüntülerin sınıflandırılmasında daha fazla zorluk yaşandığını göstermektedir.

3.6. CC ve MLO Görüntülerinin Performans Karşılaştırması

Cranio-Caudal (CC) görüntüleri, meme dokusunun yukarıdan aşağıya doğru elde edilmesi nedeniyle daha homojen ve sınıflandırma için daha uygun özellikler içermektedir. Her iki model de CC görüntülerinde daha yüksek performans sergilemiş ve doğru sınıflandırmalar yapmıştır. ResNet50 modelinde cc_resnet50_5 ile elde edilen 0.855 doğruluk oranı, çalışmadaki en yüksek doğruluk değeridir. Benzer şekilde, InceptionV3 modeli cc_InceptionV3_10 ile 0.8217 doğruluğa ulaşarak bu veri tipi üzerinde etkili bir performans göstermiştir.

Medio-Lateral Oblique (MLO) görüntüleri, meme dokusunun çapraz bir açıdan görüntülenmesi nedeniyle daha fazla örtüşen dokulara ve daha karmaşık yapılara sahiptir. Bu durum, sınıflandırmayı zorlaştıran unsurlar sunmaktadır. Her iki model de MLO görüntülerinde CC görüntülerine kıyasla daha düşük performans sergilemiştir. ResNet50 modeli MLO görüntülerinde mlo_resnet50_8 ile 0.6895 doğruluğa ulaşarak en iyi performansı göstermiştir. InceptionV3 modeli ise mlo_InceptionV3_4 ile 0.6448 doğruluk elde etmiştir. Bu sonuçlar, MLO görüntülerinin sınıflandırma için daha

zorlayıcı olduğunu ve mevcut modellerin performansını sınırlandığını göstermektedir.



4. SONUÇ VE ÖNERİLER

Araştırma sonucunda elde edilen cevaplara göre, ResNet50 modeli, genel olarak daha yüksek performans sergilemiş ve özellikle Cranio-Caudal (CC) görüntülerde en yüksek doğruluğa ulaşmıştır. InceptionV3 modeli ise daha karmaşık bir yapıya sahip olmasına rağmen belirli veri türlerinde etkili sonuçlar vermiştir. Ancak Medio-Lateral Oblique (MLO) görüntülerinde her iki modelin performansında bir düşüş gözlemlenmiştir. MLO görüntüleri üzerindeki düşük performans, bu görüntülerin sınıflandırılması için daha gelişmiş modellerin veya veri işleme tekniklerinin gerekliliğine işaret etmektedir.

Gelecek çalışmalarda:

- Veri ön işleme ve veri artırma (data augmentation) tekniklerinin kullanılması, MLO görüntüleri üzerinde performansı artırabilir.
- Modellerin hiperparametre optimizasyonu ve daha derin katman yapıları kullanılarak geliştirilmesi, sınıflandırma doğruluğunu iyileştirebilir.
- Ayrıca, transfer öğrenme teknikleri ile daha geniş ve çeşitli veri setleri üzerinde önceden eğitilmiş modellerin kullanılması, sınıflandırma başarısını artırmada etkili olabilir.

Sonuç olarak, bu çalışma, meme kanseri sınıflandırmasında ResNet50 ve InceptionV3 modellerinin performanslarının, kullanılan veri tipine göre farklılık gösterdiğini ortaya koymuştur. ResNet50 modeli, genelde daha yüksek doğruluk sağlamış ve meme görüntülerinin sınıflandırılmasında daha tutarlı bir performans sunmuştur. InceptionV3 modeli ise daha karmaşık yapısı nedeniyle belirli veri tiplerinde etkili olmasına rağmen, özellikle MLO görüntülerde sınırlı kalmıştır.

Gelecek çalışmalar, özellikle MLO görüntülerinde gözlemlenen düşük sınıflandırma başarısını artırmaya yönelik daha gelişmiş veri işleme ve modelleme tekniklerine odaklanabilir. Bu kapsamda, gürültü azaltma, kontrast iyileştirme ve kenar belirginleştirme gibi ileri düzey ön işleme yöntemleriyle görüntü kalitesi artırılarak, modelin öğrenme kabiliyeti geliştirilebilir. Ayrıca, veri artırma stratejileri sayesinde eğitim setinin çeşitliliği ve genelleme yeteneği güçlendirilerek, modellerin farklı meme yapılarıyla daha iyi başa çıkması sağlanabilir. Derin öğrenme mimarileri açısından ise, yalnızca ResNet50 ve InceptionV3 gibi klasik modellerle sınırlı

kalınmayıp, EfficientNet, DenseNet gibi daha yeni ve güçlü yapılar denenerek performans karşılaştırmaları yapılabilir. Bununla birlikte, hiperparametre optimizasyonu ve katman ince ayarı (fine-tuning) gibi tekniklerle modellerin daha verimli öğrenmeleri sağlanabilir. Son olarak, klinik geçerliliğin artırılması adına açıklanabilir yapay zeka yöntemlerinin (örneğin Grad-CAM) entegre edilmesi, model çıktılarının uzmanlar tarafından yorumlanabilirliğini kolaylaştırarak, bu tür sistemlerin gerçek dünyada kullanılabilirliğini artıracaktır.



5. KAYNAKLAR

- Abdel Rahman, A. S., Belhaouari, S. B., Bouzerdoum, A., Baali, H., Alam, T., & Eldaraa, A. M. (2020). Breast Mass Tumor Classification using Deep Learning. 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT), 271-276. <https://doi.org/10.1109/ICIoT48696.2020.9089535>
- Abdulghani, S., Fadhil, A., & Gültekin, S. S. (2020). Transfer Learning using Alexnet with Support Vector Machine for Breast Cancer Detection. Avrupa Bilim ve Teknoloji Dergisi, 423-430. <https://doi.org/10.31590/ejosat.806679>
- Aguerchi, K., Jabrane, Y., Habba, M., & El Hassani, A. H. (2024). A CNN Hyperparameters Optimization Based on Particle Swarm Optimization for Mammography Breast Cancer Classification. Journal of Imaging, 10(2), Article 2. <https://doi.org/10.3390/jimaging10020030>
- Aldashash A., 2024. Derin Öğrenme Modellerine Dayalı Mamografi Görüntülerinin Sınıflandırılması (Yüksek Lisans Tezi), Karabük Üniversitesi. Biyomedikal Mühendisliği Bölümü, Karabük.
- Al-Hadidi, M. R., Alarabeyyat, A., & Alhanahnah, M. (2016). Breast Cancer Detection Using K-Nearest Neighbor Machine Learning Algorithm. 2016 9th International Conference on Developments in eSystems Engineering (DeSE), 35-39. <https://doi.org/10.1109/DeSE.2016.8>
- Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., & Serhani, M. A. (2021). Performance evaluation of deep ESA-based crack detection and localization techniques for concrete structures. Sensors, 21(5), 1688.
- Araújo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., ... & Campilho, A. (2017). Classification of breast cancer histology images using convolutional neural networks. PloS one, 12(6), e0177544.
- Atik, I. (2024). Pneumonia detection on chest x-ray images using residual convolutional neural network. Journal of the Faculty of Engineering and Architecture of Gazi University, 39(3), 1719-1731.
- Avaner, E. B. (2018). Turing Testi Işığında Düşüncenin Multidisipliner İncelemesi Multidisciplinary Approach to Thought Through the Turing Test. 5(1).
- Canziani, A., Paszke, A., & Culurciello, E. (2017). An Analysis of Deep Neural Network Models for Practical Applications (arXiv:1605.07678). arXiv. <https://doi.org/10.48550/arXiv.1605.07678>
- Chaudhari, D. J., & Malathi, K. (2023). Detection and prediction of rice leaf disease using a hybrid CNN-SVM model. Optical Memory and Neural Networks, 32(1), 39-57.
- Chandel, R., & Gupta, G. (2013). Image filtering algorithms and techniques: A review. International Journal of Advanced Research in Computer Science and Software Engineering, 3(10).
- Cong, S., & Zhou, Y. (2023). A review of convolutional neural network architectures and their optimizations. Artificial Intelligence Review, 56(3), 1905-1969. <https://doi.org/10.1007/s10462-022-10213-5>

- Danladi M.S. 2022. Comparison of deep learning methods in medical image classification / Tıbbi görüntü sınıflandırmasında derin öğrenme yöntemlerinin karşılaştırılması (Yüksek Lisans Tezi), Fırat Üniversitesi. Yazılım Mühendisliği Ana Bilim Dalı, Elâzığ.
- Debelee, T. G., Schwenker, F., Ibenthal, A., & Yohannes, D. (2020). Survey of deep learning in breast cancer image analysis. *Evolving Systems*, 11(1), 143-163. <https://doi.org/10.1007/s12530-019-09297-2>
- Desai, B., Kushwaha, U., & Jha, S. (2020). Image Filtering -Techniques, Algorithm and Applications. *Applied GIS*, 7, 101.
- Díaz-Pernas, F. J., Martínez-Zarzuela, M., Antón-Rodríguez, M., & González-Ortega, D. (2021). A Deep Learning Approach for Brain Tumor Classification and Segmentation Using a Multiscale Convolutional Neural Network. *Healthcare*, 9(2), Article 2. <https://doi.org/10.3390/healthcare9020153>
- Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to Artificial Neural Network. 2(1).
- Eker, A. G., & Duru, N. (2021). Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları. *Acta Infologica*, 5(2), Article 2. <https://doi.org/10.26650/acin.927561>
- Ersoy E., 2022. Makine Öğrenmesi Yaklaşımları Kullanılarak EKG İşaretlerinden Aritmi Teşhisi (Doktora Tezi), Ankara Üniversitesi. Bilgisayar Mühendisliği Bölümü, Ankara.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 3-33.
- Ghaffar Nia, N., Kaplanoglu, E., & Nasab, A. (2023). Evaluation of artificial intelligence techniques in disease diagnosis and prediction. *Discover Artificial Intelligence*, 3(1), 5.
- Gökalp, Ö. M. (2022). Makine öğrenmesi. Gazi Üniversitesi, Gazi BilişimEnstitüsü, Adli Bilişim Bölümü, 1-14.
- Grossi, E., & Buscema, M. (2007). Introduction to artificial neural networks. *European Journal of Gastroenterology & Hepatology*, 19(12), 1046. <https://doi.org/10.1097/MEG.0b013e3282f198a0>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034). <https://doi.org/10.48550/arXiv.1502.01852>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). <https://doi.org/10.48550/arXiv.1512.03385>
- Hemdan, E. E.-D., Shouman, M. A., & Karar, M. E. (2020). COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images (arXiv:2003.11055). *arXiv*. <https://doi.org/10.48550/arXiv.2003.11055>
- Heywang-Köbrunner, S. H., Hacker, A., & Sedlacek, S. (2011). Advantages and Disadvantages of Mammography Screening. *Breast Care*, 6(3), 199-207. <https://doi.org/10.1159/000329005>

- International Agency for Research on Cancer (IARC). (2020). GLOBOCAN 2020 database. World Health Organization. <https://gco.iarc.fr/> (30.11.2024)
- İşeri İ., 2014. Mamogram Görüntülerinden Makine Öğrenmesi Yöntemleri ile Meme Kanseri Teşhisi (Doktora Tezi), Sakarya Üniversitesi. Bilgisayar ve Bilişim Mühendisliği Bölümü, Sakarya.
- Jabeen, K., Khan, M. A., Hameed, M. A., Alqahtani, O., Alouane, M. T.-H., & Masood, A. (2024). A novel fusion framework of deep bottleneck residual convolutional neural network for breast cancer classification from mammogram images. *Frontiers in Oncology*, 14. <https://doi.org/10.3389/fonc.2024.1347856>
- Jarrett, K., Kavukcuoglu, K., Ranzato, M., & LeCun, Y. (2009). What is the best multi-stage architecture for object recognition? 2009 IEEE 12th International Conference on Computer Vision, 2146-2153. <https://doi.org/10.1109/ICCV.2009.5459469>
- Jiao, L., & Zhao, J. (2019). A Survey on the New Generation of Deep Learning in Image Processing. *IEEE Access*, 7, 172231-172263. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2019.2956508>
- Jones, L. D., Golan, D., Hanna, S. A., & Ramachandran, M. (2018). Artificial intelligence, machine learning and the evolution of healthcare: A bright future or cause for concern? *Bone & Joint Research*, 7(3), 223-225. <https://doi.org/10.1302/2046-3758.73.BJR-2017-0147.R1>
- Karellas, A., & Vedantham, S. (2008). Breast cancer imaging: A perspective for the next decade. *Medical Physics*, 35(11), 4878-4897. <https://doi.org/10.1118/1.2986144>
- Karpathy, A. (2016). Connecting images and natural language (Doctoral dissertation, Stanford University).
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455-5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Kızrak, M. A., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), Article 3. <https://doi.org/10.17671/gazibtd.419205>
- Koonce, B. (2021). ResNet50. İçinde B. Koonce (Ed.), *Convolutional Neural Networks with Swift for Tensorflow: Image Recognition and Dataset Categorization* (ss. 63-72). Apress. https://doi.org/10.1007/978-1-4842-6168-2_6
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Commun. ACM*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- Kumawat, D. 2024. 7 Types of Activation Functions in Neural Network. <https://www.analyticssteps.com/blogs/7-types-activation-functions-neural-network>; (20.11.2024).
- Kuran, U., & Kuran, E. C. (2021). Parameter selection for CLAHE using multi-objective cuckoo search algorithm for image contrast enhancement. *Intelligent Systems with Applications*, 12, 200051.

- Lee, R. S., Gimenez, F., Hoogi, A., Miyake, K. K., & Rubin, D. L. (2017). Curated Breast Imaging Subset of DDSM (CBIS-DDSM) [Veri seti]. The Cancer Imaging Archive. <https://www.cancerimagingarchive.net/collection/cbis-ddsm/>
- LeCun, Y., Kavukcuoglu, K., & Farabet, C. (2010). Convolutional networks and applications in vision. In *Proceedings of 2010 IEEE international symposium on circuits and systems* (pp. 253-256). IEEE.
- Li, H., Zhuang, S., Li, D., Zhao, J., & Ma, Y. (2019). Benign and malignant classification of mammogram images based on deep learning. *Biomedical Signal Processing and Control*, 51, 347-354. <https://doi.org/10.1016/j.bspc.2019.02.017>
- Lomboy, K. E. M., & Hernandez, R. (2021). A comparative performance of breast cancer classification using hyper-parameterized machine learning models. *International Journal of Advanced Technology and Engineering Exploration*, 8, 1080-1101. <https://doi.org/10.19101/IJATEE.2021.874380>
- Mahesh, B. (2019). Machine Learning Algorithms -A Review. *İçinde International Journal of Science and Research (IJSR)* (C. 9). <https://doi.org/10.21275/ART20203995>
- Mahmood, T., Li, J., Pei, Y., Akhtar, F., Rehman, M. U., & Wasti, S. H. (2022). Breast lesions classifications of mammographic images using a deep convolutional neural network-based approach. *PLoS ONE*, 17(1), e0263126. <https://doi.org/10.1371/journal.pone.0263126>
- Mehmood, F., Ahmad, S., & Whangbo, T. K. (2023). An Efficient Optimization Technique for Training Deep Neural Networks. *Mathematics*, 11(6), 1-22.
- Miller, D. D., & Brown, E. W. (2018). Artificial Intelligence in Medical Practice: The Question to the Answer? *The American Journal of Medicine*, 131(2), 129-133. <https://doi.org/10.1016/j.amjmed.2017.10.035>
- Monica, & Agrawal, P. (2024). A Survey on Hyperparameter Optimization of Machine Learning Models. *2024 2nd International Conference on Disruptive Technologies (ICDT)*, 11-15. <https://doi.org/10.1109/ICDT61202.2024.10489732>
- Muralikrishnan, M., & Anitha, R. (2020). Comparison of Breast Cancer Multi-class Classification Accuracy Based on Inception and InceptionResNet Architecture. *İçinde D. J. Hemanth, V. D. A. Kumar, S. Malathi, O. Castillo, & B. Patrut (Ed.), Emerging Trends in Computing and Expert Technology* (ss. 1155-1162). Springer International Publishing. https://doi.org/10.1007/978-3-030-32150-5_118
- Musa, P., Al Rafi, F., & Lamsani, M. (2018, October). A Review: Contrast-Limited Adaptive Histogram Equalization (CLAHE) methods to help the application of face recognition. In *2018 third international conference on informatics and computing (ICIC)* (pp. 1-6). IEEE.
- Nassif, A. B., Shahin, I., Attili, I., Azzeh, M., & Shaalan, K. (2019). Speech recognition using deep neural networks: A systematic review. *IEEE access*, 7, 19143-19165.

- Oeffinger, K. C., Fontham, E. T. H., Etzioni, R., Herzig, A., Michaelson, J. S., Shih, Y.-C. T., Walter, L. C., Church, T. R., Flowers, C. R., LaMonte, S. J., Wolf, A. M. D., DeSantis, C., Lortet-Tieulent, J., Andrews, K., Manassaram-Baptiste, D., Saslow, D., Smith, R. A., Brawley, O. W., & Wender, R. (2015). Breast Cancer Screening for Women at Average Risk: 2015 Guideline Update From the American Cancer Society. *JAMA*, 314(15), 1599-1614. <https://doi.org/10.1001/jama.2015.12783>
- Özbay, E., & Özbay, F. A. (2021). Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(2), 211-219.
- Özgür, S. N., & Keser, S. B. (2021). Meme kanseri tümörlerinin derin öğrenme algoritmaları ile sınıflandırılması. *Türk Doğa ve Fen Dergisi*, 10(2), 212-222.
- Pace, L. E., & Keating, N. L. (2014). A systematic assessment of benefits and risks to guide breast cancer screening decisions. *JAMA*, 311(13), 1327-1335. <https://doi.org/10.1001/jama.2014.1398>
- Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359. *IEEE Transactions on Knowledge and Data Engineering*. <https://doi.org/10.1109/TKDE.2009.191>
- Popli, M. B., Teotia, R., Narang, M., & Krishna, H. (2014). Breast Positioning during Mammography: Mistakes to be Avoided. *Breast Cancer: Basic and Clinical Research*, 8, BCBCR.S17617. <https://doi.org/10.4137/BCBCR.S17617>
- Prinzi, F., Insalaco, M., Orlando, A., Gaglio, S., & Vitabile, S. (2024). A Yolo-Based Model for Breast Cancer Detection in Mammograms. *Cognitive Computation*, 16(1), 107-120. <https://doi.org/10.1007/s12559-023-10189-6>
- Qiao, X., Bao, J., Zhang, H., Zeng, L., & Li, D. (2017). Underwater image quality enhancement of sea cucumbers based on improved histogram equalization and wavelet transform. *Information processing in agriculture*, 4(3), 206-213.
- Radzi, S. F. M., Karim, M. K. A., Saripan, M. I., Abd Rahman, M. A., Osman, N. H., Dalah, E. Z., & Noor, N. M. (2020). Impact of image contrast enhancement on stability of radiomics feature quantification on a 2D mammogram radiograph. *IEEE Access*, 8, 127720-127731.
- Rimmer, A. (2017). Radiologist shortage leaves patient care at risk, warns royal college. *BMJ*, j4683. <https://doi.org/10.1136/bmj.j4683>
- Sahin, N., Alpaslan, N., Ilcin, M., & Hanbay, D. (2023). Evrisimsel Sinir Ağı Mimarileri ve Öğrenim Aktarma ile Bitki Zararlısı Çekirge Türlerinin Sınıflandırması. *Fırat Univ. Mühendis. Bilim. Derg.*, 35, 321-331.
- Sardanelli, F., Fallenberg, E. M., Clauser, P., Trimboli, R. M., Camps-Herrero, J., Helbich, T. H., Forrai, G., & for the European Society of Breast Imaging (EUSOBI), with language review by E. D. E. B. C. C. (2017). Mammography: An update of the EUSOBI recommendations on information for women. *Insights into Imaging*, 8(1), 11-18. <https://doi.org/10.1007/s13244-016-0531-4>

- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>
- Sarıcan, B., & Engin, O. (2024). Makine Çizelgeleme Problemlerinin Çözümünde Pekiştirmeli Öğrenme Etkisinin Analizi. *ALKÜ Fen Bilimleri Dergisi*, 6(2), 116-140. <https://doi.org/10.46740/alku.1390397>
- Scuccimarra E. A, 2018. DDSM dataset, <https://www.kaggle.com/datasets/skooch/ddsm-mammography> (27.12.2024).
- Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: a structured literature review. *BMC medical informatics and decision making*, 21, 1-23.
- Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation functions in neural networks. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 310-316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>
- Singh, A., Thakur, N., & Sharma, A. (2016). A review of supervised machine learning algorithms. 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), 1310-1315. <https://ieeexplore.ieee.org/document/7724478/>
- Sun, L., Wen, J., Wang, J., Zhao, Y., Zhang, B., Wu, J., & Xu, Y. (2023). Two-view attention-guided convolutional neural network for mammographic image classification. *CAAI Transactions on Intelligence Technology*, 8(2), 453-467. <https://doi.org/10.1049/cit2.12096>
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209-249. <https://doi.org/10.3322/caac.21660>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Taner, A., Öztekin, Y. B., & Duran, H. (2021). Performance Analysis of Deep Learning CNN Models for Variety Classification in Hazelnut. *Sustainability*, 13(12), Article 12. <https://doi.org/10.3390/su13126527>
- Turhost. (2021, 26 Kasım). Makine öğrenmesi (machine learning) nedir? <https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>
- Umamaheswari, T., & Babu, Y. M. M. (2024). ViT-MAENB7: An innovative breast cancer diagnosis model from 3D mammograms using advanced segmentation and classification process. *Computer Methods and*

- Programs in Biomedicine, 257, 108373.
<https://doi.org/10.1016/j.cmpb.2024.108373>
- Wang, Z., Lin, S., Xie, J., & Lin, Y. (2019). Pruning Blocks for CNN Compression and Acceleration via Online Ensemble Distillation. *IEEE Access*, 7, 175703-175716. *IEEE Access*.
<https://doi.org/10.1109/ACCESS.2019.2957203>
- World Health Organization. (2014). WHO position paper on mammography screening. *World Health Organization*.
<https://iris.who.int/handle/10665/137339>
- Wu, N., Phang, J., Park, J., Shen, Y., Huang, Z., Zorin, M., Jastrzębski, S., Févry, T., Katsnelson, J., Kim, E., Wolfson, S., Parikh, U., Gaddam, S., Lin, L. Y., Ho, K., Weinstein, J. D., Reig, B., Gao, Y., Toth, H., ... Geras, K. J. (2020). Deep Neural Networks Improve Radiologists' Performance in Breast Cancer Screening. *IEEE Transactions on Medical Imaging*, 39(4), 1184-1194. *IEEE Transactions on Medical Imaging*.
<https://doi.org/10.1109/TMI.2019.2945514>
- Wu, Y., & Feng, J. (2018). Development and Application of Artificial Neural Network. *Wireless Personal Communications*, 102(2), 1645-1656.
<https://doi.org/10.1007/s11277-017-5224-x>
- Yang, L., & Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316. <https://doi.org/10.1016/j.neucom.2020.07.061>
- Yassin, N. I., Omran, S., El Houby, E. M., & Allam, H. (2018). Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A systematic review. *Computer methods and programs in biomedicine*, 156, 25-45.
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). Dive into Deep Learning. *ArXiv Preprint ArXiv:2106.11342*.
- Zheng, J., Lin, D., Gao, Z., Wang, S., He, M., & Fan, J. (2020). Deep Learning Assisted Efficient AdaBoost Algorithm for Breast Cancer Detection and Early Diagnosis. *IEEE Access*, 8, 96946-96954. *IEEE Access*.
<https://doi.org/10.1109/ACCESS.2020.2993536>
- Zuiderveld, K. (1994). Contrast limited adaptive histogram equalization. In *Graphics gems IV* (pp. 474-485).