



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK MAMOGRAFİ
GÖRÜNTÜLERİ ÜZERİNDEN MEME KANSERİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Şeyma DOĞRU

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2025

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK MAMOGRAFİ
GÖRÜNTÜLERİ ÜZERİNDEN MEME KANSERİ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Şeyma DOĞRU

(21435004006)

ORCID: 0000-0001-7086-6182

**Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı**

Danışman: Doç. Dr. Erdem YAVUZ

ORCID: 0000-0002-3159-2497

OCAK 2025

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 21435004006 numaralı Yüksek Lisans Öğrencisi Şeyma DOĞRU, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK MAMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDEN MEME KANSERİ TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Erdem YAVUZ**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Haydar ÖZKAN**
Bursa Teknik Üniversitesi

Doç. Dr. M. Cem KASAPBAŞI
İstanbul Ticaret Üniversitesi

Teslim Tarihi :
Savunma Tarihi : 20 Ocak 2025



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

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Şeyma DOĞRU

İmzası:

X X X X X



Aileme ve dostlarıma,

ÖNSÖZ

Bu tez çalışmamda; benden bir an olsun desteğini eksik etmeyen danışman hocam Doç. Dr. Erdem YAVUZ hocama teşekkür ederim. Hayatım boyunca bana olan destekleri için sevgili ailem ve dostlarıma sevgi ve teşekkürlerimi sunarım.

Ocak 2025

Şeyma DOĞRU
(Araştırma Görevlisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR.....	x
SEMBOLLER	xi
ÇİZELGE LİSTESİ	xii
ŞEKİL LİSTESİ	xiii
ÖZET.....	xiv
SUMMARY	xv
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Tezin Katkısı	3
2. LİTERATÜR TARAMASI	4
3. YAPAY ZEKA	12
4. DERİN ÖĞRENME.....	15
4.1 Derin Öğrenmeyi Başarılı Kılan Faktörler	16
4.2 Derin Öğrenmenin Matematiksel Temelleri.....	16
4.2.1 Vektörler, matrisler, tensörler	17
4.2.2 Türev ve gerekliliği.....	18
4.2.3 Gradyan iniş ve optimizasyonu.....	18
4.2.4 Zincir kuralı ve geriye yayılım algoritması.....	21
4.3 Derin Sinir Ağları.....	22
4.3.1 Evrişimli sinir ağları (CNN).....	24
4.3.2 Yinelemeli sinir ağları (RNN).....	25
4.3.3 Yapay sinir ağları (ANN).....	25
4.3.4 Katman, model ve kayıp fonksiyonu.....	26
4.3.5 Optimizasyon algoritmaları.....	28
4.4 Yapay Öğrenme Temelleri	29
4.4.1 Denetimli ve denetimsiz öğrenme.....	30
4.4.2 Başarı ölçütleri	31
4.4.2.1 Doğruluk (Accuracy)	32
4.4.2.2 Kesinlik (Precision).....	32
4.4.2.3 Duyarlılık (Recall)	33
4.4.2.4 F1 skoru.....	33
4.4.3 Veri artırma	33
4.4.4 Aşırı öğrenme (overfitting), eksik öğrenme (underfitting)	34
4.4.5 Aktivasyon fonksiyonları.....	35
5. TRANSFER ÖĞRENME	37
5.1 ResNet50 Mimarisi.....	37
5.2 EfficientNetB0 Mimarisi	38
5.3 DenseNet121 Mimarisi.....	39

5.4 VGG16 Mimarisi.....	40
5.5 VGG19 Mimarisi.....	42
6. MATERYAL VE METOT	43
6.1 Veri Setleri	43
6.1.1 CDD-CESM veri seti	43
6.1.2 CESM@UCBM veri seti.....	44
6.2 Kullanılan Donanım	45
7. BULGULAR VE YORUMLAR.....	47
7.1 Veri Setlerinin Farklı Ele Alımları	47
7.2 CDD-CESM Veri Seti İle Elde Edilen Sonuçlar.....	50
7.2.1 Üç sınıflı model eğitimi sonuçları.....	51
7.2.2 İki sınıflı model eğitimi sonuçları.....	52
7.3 CESM@UCM Veri Seti İle Elde Edilen Sonuçlar.....	53
7.3.1 Üç sınıflı model eğitimi sonuçları.....	54
7.3.2 İki sınıflı model eğitimi sonuçları.....	55
7.4 İki Veri Setinin Birleşimi İle Elde Edilen Sonuçlar	57
7.4.1 Üç sınıflı model eğitimi sonuçları.....	57
7.4.2 İki sınıflı model eğitimi sonuçları.....	58
7.4.3 Düşük enerjili (low energy) görüntülerle yapılan eğitimlerin sonuçları ...	59
7.4.3.1 Üç sınıflı model eğitimi sonuçları.....	59
7.4.3.2 İki sınıflı model eğitimi sonuçları.....	60
7.4.4 Bileşik (Recombined) görüntülerle yapılan eğitimlerin sonuçları	60
7.4.4.1 Üç sınıflı model eğitimi sonuçları.....	61
7.4.4.2 İki sınıflı model eğitimi sonuçları.....	61
8. SONUÇLAR VE ÖNERİLER	63
KAYNAKLAR.....	65
ÖZGEÇMİŞ.....	70

KISALTMALAR

AdaGrad	: Uyarlanabilir Gradyan Algoritması
Adam	: Uyarlanabilir Moment Tahminleme
ANN	: Yapay Sinir Ağı
CC	: Kranial-Kudal
CESM	: Kontrastlı Spektral Mamografi
CNN	: Konvolüsyonel Sinir Ağı
DES	: Çift Enerji İle Çıkarma
DM	: Dijital Mamografi
ELU	: Üstel Doğrusal Birim
GAN	: Üretici Çekişmeli Ağlar
L-BFGS	: Sınırlı Bellekli Broyden Feltcher Goldfarb Shanno
LE	: Düşük Enerjili
Leaky ReLU	: Sızıntılı Düzeltilmiş Doğrusal Ünite
MBConv	: Mobil Tersine Darboğaz Konvolüsyonu
MLCM	: Çoklu Etiketli Karışıklık Matrisi
MLO	: Mediolateral Oblik
MSE	: Ortalama Kare Hatası
ReLU	: Düzeltilmiş Doğrusal Ünite
RMSE	: Kök Ortalama Kare Hatası
RMSProp	: Karekök Ortalama Kare Yayılımı
RNN	: Tekrarlayan Sinir Ağı
ROI	: İlgi Alanı
SGD	: Stokastik Gradyan İnişi
Tanh	: Hiperbolik Tanjant

SEMBOLLER

η : Öğrenme oranı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 : Denetimli ve denetimsiz öğrenmenin karşılaştırılması.	31
Çizelge 4.2 : Aktivasyon kodları.	35
Çizelge 6.1 : CDD – CESM veri seti görüntü sayıları.....	44
Çizelge 6.2 : CDD – CESM veri seti düşük enerjili ve bileşik görüntü sayıları.	44
Çizelge 6.3 : CESM@UCBM veri seti görüntü sayıları.....	45
Çizelge 6.4 : CESM@UCBM veri seti düşük enerjili ve bileşik görüntü sayıları	45
Çizelge 7.1 : Veri setlerinin farklı ele alımları.	48
Çizelge 7.2 : CDD-CESM veri seti 3 sınıflı eğitim sonuçları.	52
Çizelge 7.3 : CDD – CESM veri setinde veriler artırılarak 3 sınıflı eğitim sonuçları.	52
Çizelge 7.4 : CDD – CESM veri seti 2 sınıflı eğitim sonuçları.....	53
Çizelge 7.5 : CDD – CESM veri setinde veriler artırılarak 2 sınıflı eğitim sonuçları.	53
Çizelge 7.6 : CESM@UCBM veri seti 3 sınıflı eğitim sonuçları.....	55
Çizelge 7.7 : CESM@UCBM veri setinde verilere artırılarak 3 sınıflı eğitim sonuçları.	55
Çizelge 7.8 : CESM@UCBM veri seti 2 sınıflı eğitim sonuçları.....	55
Çizelge 7.9 : CESM@UCBM veri setinde veriler artırılarak 2 sınıflı eğitim sonuçları.	57
Çizelge 7.10 : İki veri setinin birleşimiyle 3 sınıflı eğitim sonuçları.	57
Çizelge 7.11 : İki veri setinin birleşimiyle artırılarak 3 sınıflı eğitim sonuçları.....	58
Çizelge 7.12 : İki veri setinin birleşimiyle 2 sınıflı eğitim sonuçları.	58
Çizelge 7.13 : İki veri setinin birleşimiyle artırılarak 2 sınıflı eğitim sonuçları.....	58
Çizelge 7.14 : İki veri setindeki toplam düşük enerjili görüntüleri ile 3 sınıflı olarak yapılan eğitimlerin sonuçları.	59
Çizelge 7.15 : İki veri setindeki toplam düşük enerjili görüntüler artırılarak 3 sınıflı olarak yapılan eğitimlerin sonuçları.....	59
Çizelge 7.16 : İki veri setindeki toplam düşük enerjili görüntüler ile 2 sınıflı olarak yapılan eğitimlerin sonuçları.	60
Çizelge 7.17 : İki veri setindeki toplam düşük enerjili görüntüler artırılarak 2 sınıflı olarak yapılan eğitimlerin sonuçları.....	60
Çizelge 7.18 : İki veri setindeki toplam bileşik görüntüler ile 3 sınıflı olarak yapılan eğitimlerin sonuçları.....	61
Çizelge 7.19 : İki veri setindeki toplam bileşik görüntüler artırılarak 3 sınıflı olarak yapılan eğitimlerin sonuçları.....	61
Çizelge 7.20 : İki veri setindeki toplam bileşik görüntüler ile 2 sınıflı olarak yapılan eğitimlerin sonuçları.....	62
Çizelge 7.21 : İki veri setindeki toplam bileşik görüntüler artırılarak 2 sınıflı olarak yapılan eğitimlerin sonuçları.....	62

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1 : Yapay zeka, makine öğrenmesi, derin öğrenme.....	13
Şekil 4.1 : Derin öğrenme katmanları.....	16
Şekil 4.2 : (a) Vektör, (b) matris ve (c) tensör.....	17
Şekil 4.3 : Derin sinir ağları (MRI Questions, 2024).....	23
Şekil 4.4 : Evrişimli sinir ağları (Şebin, 2022).	24
Şekil 4.5 : Yinelemeli sinir ağları (Dive into Deep Learning, 2023).....	25
Şekil 4.6 : Yapay sinir ağları (Altunbas, 2020).	26
Şekil 5.1 : ResNet50 model mimarisi (Mukherjee, 2023).	38
Şekil 5.2 : EfficientNetB0 model mimarisi (Alhichri ve diğ, 2021).	39
Şekil 5.3 : DenseNet121 model mimarisi (DeepKapha Notes, 2021).	40
Şekil 5.4 : VGG16 model mimarisi (Neurohive, 2023).....	41
Şekil 5.5 : VGG19 model mimarisi (Khattar ve Quadri, 2022).....	42
Şekil 7.1 : CDD-CESM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli düşük enerjili görüntüler.	51
Şekil 7.2 : CDD-CESM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli bileşik görüntüler.....	51
Şekil 7.3 : CESM@UCBM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli düşük enerjili görüntüler.	54
Şekil 7.4 : CESM@UCBM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli bileşik görüntüler.....	54
Şekil 7.5 : CESM@UCBM veri setinde 2 sınıflı olarak gerçekleştirilen eğitimlerde en iyi sonucu veren DenseNet121 mimarisinin karışıklık matrisi.....	56
Şekil 7.6 : CESM@UCBM veri setinde kötü huylu olup model tarafından iyi huylu olarak tahmin edilen (a) ve kötü huylu huylu olup model tarafından kötü huylu olarak tahmin edilen (b) görüntüler.	56

DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK MAMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDEN MEME KANSERİ TAHMİNİ

ÖZET

Teknolojik ilerlemeler, birçok sektörde olduğu gibi sağlık alanında da akıllı makinelerin karar verme süreçlerine dahil edilmesine olanak tanımıştır. İnsanlardan daha hızlı analitik düşünebilme ve ilişkileri saptama yetenekleri sayesinde bu makineler, uzmanlara doğru kararların alınmasında önemli ölçüde destek sağlamaktadır. Özellikle kanserin erken teşhisinin hayati öneme sahip olması, bu alanda yapılan yapay zeka çalışmalarını hızlandırmıştır. Kanserın erken tanısı, hastaların sağkalım oranlarının artırılması, organ kaybının önlenmesi ve radyoterapi, kemoterapi gibi tedavilerin en az düzeyde uygulanması bakımından kritik önem taşımaktadır. Memede oluşan küçük lezyonların tespiti genellikle mümkün olmamaktadır. Bu da hastalığın ilerlemesine ve ileri safhalarda fark edilmesine sebep olmaktadır.

Kontrastlı Spektral Mamografi (CESM), bu tespit zorluğunu gidermek için geliştirilmiş yeni bir görüntüleme tekniğidir. Meme hücrelerine enjekte edilen kontrast madde ile lezyonları görünür kılan Kontrastlı Spektral Mamografi, dijital mamografide gözden kaçabilen lezyonları yakalamaya yardımcı olur. Doktorların daha güvenilir tanı koymasına ve hastalığa erken fark edilmesine olanak tanır.

Bu tez çalışmasında, meme kanserinin teşhis sürecine odaklanılarak Kontrastlı Spektral Mamografi (CESM) görüntüleri kullanılmıştır. Çalışmada iki farklı veri seti üzerinde çeşitli derin öğrenme modelleri eğitilerek analizler gerçekleştirilmiştir. Kullanılan bu veri setleri CDD-CESM veri seti ve CESM@UCBM veri setleridir. CDD-CESM veri setinde toplamda 2006 görüntü bulunmaktadır. Bu görüntülerin 1003 tanesi düşük enerjili görüntü, 1003 tanesi ise bileşik görüntüdür. CESM@UCBM veri setinde ise 1138 adet görüntü bulunmaktadır. Bu görüntülerden 569 tanesi düşük enerjili, 569 tanesi ise bileşik görüntüdür. Bu çalışma kapsamında yapılan eğitimlerde veri setlerine 20 farklı açıdan yaklaşılmıştır. Veri seti 3 sınıflı (Normal, İyi Huylu, Kötü Huylu) ve 2 sınıflı (İyi Huylu, Kötü Huylu) olarak, ayrı ayrı ve birlikte olacak şekilde eğitilmiştir. Aynı zamanda bu ele alım şekillerine veri artırma yöntemleri uygulanarak veriler tekrar eğitilmiştir.

Bu kapsamda, ResNet50, DenseNet121, EfficientNetB0, VGG16 ve VGG19 mimarileri uygulanmış ve beşli çapraz doğrulama sonucunda DenseNet121 modeliyle %76,46 kesinlik (precision), %95,35 duyarlılık (recall) ve %84,81 F1-Skor değerleri elde edilmiştir. Bu sonuçlar, önerilen yöntemin meme kanseri tanısında etkin bir destek aracı olabileceğini göstermektedir.

Anahtar kelimeler: Derin öğrenme, Transfer öğrenme, Meme kanseri, Kontrastlı Spektral Mamografi.

BREAST CANCER PREDICTION ON MAMMOGRAPHY IMAGES USING DEEP LEARNING TECHNIQUES

SUMMARY

Technological advancements have enabled the integration of intelligent machines into decision-making processes in various sectors, including healthcare. With their ability to perform analytical thinking and detect relationships faster than humans, these machines provide significant support to experts in making accurate decisions. The critical importance of early cancer diagnosis has accelerated artificial intelligence research in this field. Early cancer diagnosis is crucial for increasing patient survival rates, preventing organ loss, and minimizing the need for treatments such as radiotherapy and chemotherapy.

The detection of small lesions in the breast is often challenging, leading to the disease progressing and being detected at advanced stages. Contrast-Enhanced Spectral Mammography (CESM) is an innovative imaging method designed to address the challenges associated with detection. By making lesions visible with a contrast agent injected into the breast cells, CESM helps to capture lesions that may be missed in digital mammography. It allows doctors to make more reliable diagnoses and detect the disease early.

This thesis centers on diagnosing breast cancer through the analysis of Contrast-Enhanced Spectral Mammography (CESM) images. The study analyzed various deep learning models trained on two different datasets. The datasets used were the CDD-CESM dataset and the CESM@UCBM dataset. The CDD-CESM dataset contains a total of 2006 images, with 1003 low-energy images and 1003 subtracted images. The CESM@UCBM dataset contains 1138 images, with 569 low-energy and 569 subtracted images. In the training conducted within the scope of this study, data sets were approached from 20 different angles. The dataset was trained as 3-class (Normal, Benign, Malignant) and 2-class (Benign, Malignant), separately and together. Data augmentation methods were also applied to these datasets and the data was retrained.

In this context, ResNet50, DenseNet121, EfficientNetB0, VGG16 and VGG19 architectures were applied, and as a result of five-fold cross-validation, an accuracy of 76.46%, sensitivity of 95.35% and F1-score of 84.81% were obtained with the DenseNet121 model. The findings suggest that the proposed approach could serve as a valuable tool in aiding the diagnosis of breast cancer.

Keywords: Deep learning, Transfer learning, Breast cancer, Contrast-enhanced spectral mammography.

1. GİRİŞ

Meme kanseri, hem ülkemizde hem de dünya genelinde kadınlarda kanser türü olarak en sık teşhis edilen hastalıktır. Memede bulunan hücrelerin kontrol dışı bölünmesiyle tümör oluşmasına meme kanseri denir. Daha önceleri meme kanseri sık görülen kanserler arasında akciğeri kanserinden sonra ikinci sıradayken, 2021 yılından sonra akciğer kanserini de geçerek %11,7 ile en çok tanı konulan kanser türü olmuştur (Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü, 2024). Başlangıç safhalarında kendisini belli etmeyen bu kanser türü, ilerleyen zamanlarda türlü şikayetlerle belirti göstermeye başlamaktadır. Memede ağrı, şişlik, meme ucunun içeri çekilmesi, kanlı sıvı gelmesi, meme derisinde bozulmalar olması gibi birçok belirtisi vardır. Gizli şekilde ilerleyebildiğinden, erken teşhisi önemli bir hastalıktır. Birçok çalışmada meme kanserinin erken teşhisi amaçlanmıştır. Bu amaç doğrultusunda, tıp dünyasına hatırı sayılır katkılar sağlayan bilgisayar bilimleri dikkat çekmektedir. Meme kanserinin tespiti için mamografi görüntüleme yöntemi kullanılmaktadır. Mamografi, düşük seviyede gönderilen X ışınları ile çekilen bir röntgen filmidir. Elle muayenede saptanamayacak kadar küçük olan kitlelerin tespiti için önemlidir. Görüntü alımı sırasında ilaç ve iğne gibi işlemler yapılmaz. Bireyin memesi iki plaka arasına koyularak sıkıştırılır ve röntgen çekimi yapılır. Bu işlem sonucunda gri tonlamalı (grayscale) bir görüntü elde edilir. Bu görüntüde düşük yoğunluklu bölgeler siyah, yüksek yoğunluklu bölgeler ise beyaz renkte görülmektedir. Gri tonlamalar ise farklı yoğunluktaki bölgeleri görebilmek için yardımcı olur. Kanserli bölge beyaz ve açık gri tonlarda gözükmemekte ve böylelikle hastalığın tespitini kolaylaştırmaktadır.

Derin öğrenme yöntemleri ile mamografi görüntüleri üzerinden kanser tespiti çalışmaları günümüzde hız kazanmıştır. Dijital mamografi görüntüleri ile algoritmaları eğiterek, bireyin memesinde kitle olup olmadığını; hatta kitle var ise iyi huylu mu kötü huylu mu olduğunu bulmak üzerine birçok çalışma yapılmıştır. Meme kanseri tanılarında artış olduğu bu dönemde, teknolojik olarak tespitinin kolaylaşması önemli rol oynamaktadır. Erken safhada tespit edilen kansere, hastalık ilerlemeden müdahale

edilmektedir. Böylelikle kanserin organ kaybı veya ölümle sonuçlanma ihtimali de azalmaktadır.

İnsan gözüyle tespit edilebilecek seviyeden daha küçük olan kanserli dokular, hekimlerin gözünden kaçabildiği için hastalık fark edilememektedir. Bu da metastaz (hastalığın diğer organlara yayılması) olasılığına da kapı aralamaktadır. Sağlıklı sanılan birey, bir süre sonra daha büyük şikayetler ile hastaneye başvurduğunda, kemoterapi ve radyoterapi yöntemlerine uygunluğuna bakılır. Bu tedaviler gerçekleştikten sonra hastada olumlu bir ilerleme olmazsa kanserli bölge için doktor ameliyat kararı verebilmektedir. Sadece kanserli bölgenin ameliyatla alınması yetebileceği gibi, mastektomi (memenin tamamen alınması) de gerçekleşebilir. Hastalığın ilerleme durumuna göre bireyin ölümüyle de sonuçlanabilmektedir. Bu sebeple eğitilen derin öğrenme modelleri, dikkatten kaçabilecek boyuttaki ve şekildeki kitle görüntülerinin tespiti için hekimlere yardımcı olabilecek kapasitededir. Böylelikle hastalığın tespitinde hekim ihmali olma olasılığı da azalmaktadır.

Bu çalışmada kullanılan veri setleri, diğer mamografi görüntülerinden farklı olarak iki farklı görüntü tipi içermektedir. Düşük enerjili görüntüler ve yüksek enerjili görüntüden düşük enerjili görüntünün bileşik ve kontrastı geliştirilmiş hali olan görüntüler üzerinde çalışmalar yapılmıştır.

Böylelikle sadece dijital mamografi görüntüleri ile yetinilmemiş, farklı tekniklerle elde edilen görüntüler incelenmiş ve bu şekilde transfer öğrenme algoritmaları eğitilmiştir.

1.1 Tezin Amacı

Bu tez çalışması, mamografi görüntüleri üzerinde derin öğrenme teknikleri kullanarak meme kanseri tespiti yapılması konusuna odaklanmaktadır. Bu araştırmada, iki adet veri seti üzerinden birçok farklı bakış açısıyla çalışmalar yapılmıştır. Düşük enerjili (low energy) ve bileşik (recombined) kontrastı geliştirilmiş spektral (CESM) görüntüler üzerinden transfer öğrenme algoritmaları kullanarak görüntü normal mi, tümör varsa hastanın tümörünün iyi huylu mu, kötü huylu mu olduğunu öğrenmek amaçlanmıştır. Çalışmada özellikle kanserli hücrenin türünün tespitine odaklanılmıştır.

1.2 Tezin Katkısı

Bu çalışmada kullanılan CDD-CESM ve CESM@UCBM veri setleri, daha önce kullanıldıkları çalışmalarda sadece test verisi olarak kullanılmış, eğitimler kamuya gizli ve nispeten daha büyük olan veri setleri üzerinden yapılmıştır. Ancak bu çalışmada, söz konusu veri setleri hem eğitim hem de test için kullanılmışlardır. İki veri seti ile elde edilen toplam görüntü sayısı 3144'tür. Bu verilerin bir kısmı modellerin eğitimi için, diğer bir kısmı da eğitilen bu modelleri test etmek için kullanılmıştır. Derin öğrenme modelleri doğru tahmin için daha fazla veriye ihtiyaç duymaktadır. Bu sebeple veri artırma yöntemleriyle veri setindeki görüntüler çeşitli şekillerde çoğaltılmıştır. Böylelikle modellerin daha kolay öğrenmesi sağlanmıştır. Yapılan veri artırma yöntemleri de bir çok kez denenmiş ve en iyi sonucu veren parametreler veri artırma algoritmasına sunulmuştur. Ayrıca iki veri seti hem ayrı ayrı hem de birlikte olacak şekilde 20 farklı bakış açısıyla değerlendirilmiştir. 100 adet test sonucu sunulan bu çalışmada yine aynı şekilde bir çok defa en iyi sonucu verecek olan parametrelerin tespiti için denemeler yapılmıştır. Bu şekilde eğitilen modellerle yapılan çalışma, kanser tespitinde yüksek doğruluk, kesinlik (precision), duyarlılık (recall) ve F1 skoru elde etmeyi amaçlamaktadır. Bu çalışmada, daha az görüntü içerdiği halde yüksek doğruluk, kesinlik (precision), duyarlılık (recall) ve F1 skoru elde edilmesinin yanında, düşük enerjili ve bileşik kontrastı geliştirilmiş spektral görüntüler üzerinden tahmin yapılması açısından, meme kanseri üzerinde yapılan çalışmalardan ayrılmaktadır. Yapılan çalışma, bu özellikleriyle literatüre katkı sağlamaktadır.

2. LİTERATÜR TARAMASI

Günümüzde derin öğrenme algoritmaları kullanılarak görüntü üzerinden birçok tahmin yapılabilmektedir.

Yapılan bir çalışmada (Aslan, 2022) MIAS ve INbreast veri setlerini kullanarak mamografi görüntülerini normal, iyi huylu ve kötü huylu olarak sınıflandırmıştır. Çalışmada yeni bir yaklaşım sunan Aslan, öncelikle sadece evrişimli sinir ağı (CNN) kullanmış, ardından evrişimli sinir ağı ve çift yönlü uzun kısa süreli bellekleri (BiLSTM) hibrit şekilde kullanmıştır. Bu hibrit mimari, çalışmanın literatüre katkılarından biridir. Çalışmayı diğer çalışmalardan farklı kılan en önemli yönlerinden birisi de ROI (Region of Interest) değerinin kullanılmamış olmasıdır. Bu sayede ham mamografi görüntüleri yeterli hale gelmiştir. Diğer çalışmalardan bir farklı yönü de tümörleri “iyi” ve “kötü” diye ayırmasının yanında “normal” diye ayırıyor olmasıdır. Çalışmanın temel motivasyonu, diğer çalışmalarda sunulan yöntemlerin aksine farklı bir derin mimari tasarlayarak aynı veri setlerinde daha üstün başarı elde etmektir. Yapılan deneylerde AlexNet modeli basitliği sebebiyle tercih edilmiştir. Çalışma sonunda bu basit yapıya sahip derin ağı, BiLSTM katmanları eklenerek başarının kolaylıkla arttığı gözlemlenmiştir. Bu sayede, diğer çalışmalarda yapılan özellik çıkarımı, optimizasyon gibi adımlar yapılmadan, uçtan uca basit bir mimari ile meme kanserinin teşhisi sağlanmaktadır. Bu modelde sadece CNN kullanıldığında %91,67 doğruluk elde edilirken, CNN+BiLSTM hibrit modeli kullanıldığında %92,26 doğruluk değerine ulaşılmıştır.

Song ve diğ. (2022) yaptıkları çalışmada, CESM görüntüleri ile meme kanserinin tespiti için çok görünümlü çok modlu bir ağ (MVMM-Net) sunmuşlardır. 21-74 yaş aralığında 95 kişiden alınan 760 adet CESM görüntü, bu modelin eğitimi için kullanılmıştır. Önerilen model, görüntüleri iyi huylu ve kötü huylu olarak sınıflandırmaktadır. Res2Net50 mimarisiyle tasarlanan model %96,59 doğruluk, %96,40 duyarlılık (recall), %96,35 özgüllük (specificity), %96,83 kesinlik (precision) ve 0,966 F1-skoru sonuçlarını vermiştir.

Qian ve diğ. (2024) yaptıkları çalışmada kontrastlı mamografi görüntülerini kullanarak biyobelirteçle ilgili görüntü özelliklerini çıkarmak ve istilacı (invaziv) olmayan biyobelirteç durumunu tahmin etmede ne kadar başarılı olduğunu ölçmek için sinir ağı tabanlı bir yöntem geliştirmişlerdir. Geliştirdikleri bu yöntem, lezyon ve tümörleri saptayarak başarılı bir şekilde otomatik lezyon bölümlemesi yapabilmektedir. Bu model 0,71 AUC skoru elde etmiştir.

Savaridas ve diğ. (2021) yapmış oldukları çalışmanın amacı, kontrastlı spectral mamografi (CESM) görüntülerinden elde edilen verilerin, meme lezyonlarının incelenmesinde nasıl kullanılacağına dair yapılmış olan çalışmaların bir derlemesidir. Bu çalışmada toplamda 23 adet mevcut çalışma incelenmiştir. İncelemeler sonucunda CESM görüntüleme tekniğinin, meme kanserini erken teşhis etmede önemli bir rol oynayabileceği saptanmıştır.

Diğer bir çalışmada (Chouhan ve diğ, 2021) mamografi görüntüsünün normal veya anormal diye sınıflandırılabilirdiği yeni bir sistem (DFeBCD-Çeşitli özelliklere dayalı meme kanseri tespiti) önerilmiştir. Önerilen bu sistem, dört farklı özellik kümesi kullanmaktadır. Derin evrişimli sinir ağı (CNN) kullanarak mamografi görüntülerinden dördüncü özellik kümesini dinamik olarak çıkartmaktadır. Önerilen sistem (DFeBCD) SVM’de %80,5, ELiEC’de %80,3 doğruluk elde etmiştir.

Karthiga ve diğ. (2022) yaptıkları çalışmada iki adet ana yaklaşım sunmuşlardır. İlkinde transfer öğrenme yöntemi kullanılmıştır. İkincisinde yinelemeli sinir ağı mimarisi oluşturulmuş ve hiper parametreleri doğru sınıflandırma elde etmek için ayarlanmıştır. Üç adet veri kümesi tek tek ve birleştirilmiş şekillerde test edilmiştir. MIAS veri setinde %95,95, DDSM veri setinde %99,39, INbreast %96,53 ve son olarak birleştirilmiş veri setinde %92,27 doğruluk değerleri elde etmişlerdir.

Salama ve diğ. (2021) sundukları çalışmada meme kanseri görüntü bölütleme ve sınıflandırma için yeni bir çerçeve önermiştir. InceptionV3, DenseNet121 gibi farklı modeller, farklı veri setleri (MIAS, DDSM, CBIS-DDSM) üzerinde, tümörlerin iyi huylu ve kötü huylu sınıflandırılması için uygulanmıştır. En iyi sonuç DDSM veri setinde, %98,87 doğruluk değeriyle elde edilmiştir. %98,88 AUC, %98,98 kesinlik (precision), %98,79 duyarlılık (recall), %97,99 F1 puanı elde edilmiştir.

Yapılan bir başka çalışmada (Raaj, 2023) hibrit bir evrişimli sinir ağı modeli kullanılmıştır. Mamogram görüntülerinin normal, iyi huylu ve kötü huylu olarak

ayrıldığı bu çalışma, radon dönüşümü, veri artırma modülü ve hibrit CNN mimarisinden oluşmaktadır. Veri seti olarak MIAS ve DDSM veri setleri kullanılmıştır. Geliştirilen CNN mimarisi, DDSM veri seti içerisinde bulunan mamogram görüntüleri üzerinde %97,91 duyarlılık (recall), %97,83 özgüllük (specificity), %98,44 doğruluk sonuçları vermiştir. Aynı mimari, MIAS veri seti üzerinde %98 duyarlılık (recall), %98,66 özgüllük (specificity), %99,17 doğruluk değerleri vermiştir.

Jiang ve diğ. (2022) yaptığı çalışmada meme lezyonlarını (yani kitle ve kireçlenmeyi) otomatik olarak tespit ederek ve mamogramları iyi huylu veya kötü huylu olarak sınıflandırarak tanı performansını artırmak için Olasılıksal Çapa Atama (PAA) adı verilen çapasız bir nesne algılama algoritmasına dayanan üç aşamalı bir derin öğrenme çerçevesi önermişlerdir. CBIS-DDSM veri setinde %87,3, INbreast veri setinde %96,3 AUC değeri elde etmişlerdir.

Song ve diğ. (2022) tarafından yapılan bir çalışmada CESM veri seti kullanılmıştır. Bu çalışmada meme kanseri sınıflandırması için yeni ve esnek birçok modlu temsil öğrenme yöntemi olan çok özellikli derin bilgi darboğazı (MDIB) ilk kez literatüre sunulmuştur. Çalışmanın performans metriklerine bakıldığında %97,18 doğruluk, %94,86 duyarlılık (recall), %95,02 özgüllük (specificity), 0,973 AUC değerleri elde edilmiştir.

Bir başka çalışmada (Gao ve diğ, 2018) CNN kullanılarak yapılmış bir Sığ-Derin Evrişimli Sinir Ağı (SD-CNN) önerilmiştir. Bu modeli test etmek için kontrastlı dijital mamografi görüntüleri (CEDM) kullanılmış ve meme kanseri teşhisi yapılmıştır. Düşük enerjili görüntüler (LE) kullanılarak %85 doğruluk, %84 AUC değerleri elde edilmiştir. Hem LE hem de birleştirilmiş görüntüleme kullanılarak %89 doğruluk, %91 AUC değerleri elde edilmiştir. Daha sonra tekrar aynı vakalar kullanılarak sığ-CNN geliştirilmiştir. Ardından, sanal yeniden birleştirilmiş görüntüler oluşturmak için INbreast veri setinden 89 adet FFDM vakası alınmıştır. FDDM'yi tek başına kullandıklarında %84 doğruluk elde ederken, SD-CNN kullanarak tahmin yapıldığında bu doğruluğun %90'a yükseldiği görülmüştür.

Perek ve diğ. (2018) CESM veri setini kullanarak meme kanseri tespit çalışması yapmıştır. CESM meme kitlesinin iyi huylu veya kötü huylu olarak sınıflandırılması için iki analiz yaklaşımını, önceden eğitilmiş bir ağın ince ayarını ve bir evrişimli sinir

ağının (CNN) eğitimini karşılaştırmışlardır. Radyolojik bir sözlük olan BIRADS'ı, lezyonları kategorize etmek için meme görüntüleriyle beraber kullanmışlardır. 129 meme lezyonu üzerinde 5 kez çapraz doğrulama yapılarak performansı değerlendirilmiştir. Sonuç olarak %100 duyarlılık (recall), %66 özgüllük (specificity) ve 0,89 AUC değerleri elde etmişlerdir.

Danala ve diğ. (2018) 33 adet iyi huylu ve 78 adet kötü huylu vakayı içeren bir CEDM (kontrastlı dijital mamografi) veri seti kullanarak meme kanseri tahmini yapmışlardır. Her bir CEDM, düşük enerjili (LE) ve çift enerji çıkarılmış (DES) görüntüler olmak üzere iki tür görüntü içermektedir. Çapraz doğrulama kullanılarak makine öğrenmesi algoritmaları uygulanmıştır. Orijinal segmentasyonlu DES ve LE görüntülerine bilgisayar destekli tanı uygulandığında, AUC değerleri sırasıyla $0,759 \pm 0,053$ ve $0,753 \pm 0,047$ olmuştur. Çift enerji çıkarılmış görüntülerde optimum şekilde bölümlenen kitle bölgeleri düşük enerjili görüntülere eşlendikten sonra, AUC anlamlı şekilde $0,848 \pm 0,038$ 'e yükselmiştir.

Fanizzi ve diğ. (2019) tarafından yapılan bir çalışmada, CESM veri seti kullanılarak bir sınıflandırma yapılmıştır. Bir Rastgele Orman sınıflandırıcısı, sıralı bir özellik seçimi algoritması ile seçilen önemli özelliklerin bir alt kümesi üzerinde eğitilmiştir ve bir Bilgisayar-Otomatik Tanı Sistemi önerilmiştir. Her bir ROI için, farklı teknikler kullanılarak düşük enerjili ve yeniden birleştirilmiş görüntülerden bir özellik kümesi çıkarılmıştır. Sonuç olarak %87,5 duyarlılık (recall) ve %91,7 özgüllük (specificity) değerleri elde edilmiştir.

Başka bir çalışmada (Patel ve diğ, 2018) uzman bir radyoloğun, lezyonları manuel olarak kendisinin belirttiği bir CESM veri seti kullanılmıştır. Ve bu çalışmada 50 adet lezyon analiz edilmiştir. Daha sonra düşük enerjili ve yeniden birleştirilen görüntülerden bir dizi morfolojik ve dokusal özellik çıkarılmıştır. Daha sonra bu özellikler, destek vektör makineleri algoritmasına verilmiştir. Algoritmanın performansı, iki radyoloğun tanısal tahminleriyle karşılaştırılmıştır. Destek Vektör Makineleri %90 doğruluk oranı sağlarken, %88 duyarlılık (recall), %92 özgüllük (specificity) ve 0,95 AUC değerlerini de elde etmiştir.

Hepsağ (2022) tarafından yapılan tez çalışmasında hibrit bir derin öğrenme sistemi geliştirilmiştir. Önerilen modelde mamogram (görüntü), radyoloji raporu (metin) ve hasta hikayesi (anket) verileri birleştirilerek kullanılmıştır. Daha önce bu üç türün

birleştirilerek üzerinde çalışıldığı bir çalışma olmamıştır. Üç bağımsız parçanın birleştirildiği bu modelde, birinci parçada derin öğrenme modelleri, ikinci parçada anketleri sınıflandırma amacıyla makine öğrenmesi, üçüncü parçada ise radyoloji raporlarını sınıflandırmak için BERTMultilingual gibi modeller kullanılmıştır. Duyarlılık (recall) değerinin %100'e kadar çıkabildiği görülmüştür. Ateş (2023) tarafından yapılan tez çalışmasında meme kanserinin erken teşhisi için yapay zeka tabanlı bir tanı sistemi sunulmuştur. Yapılan çeşitli işlemlerle yeni öznetelikler çıkaran yazar, evrişimli sinir ağı modelleri kullanmıştır. Kullanılan tüm yöntemlerden %100 genel doğruluk elde edilmiştir.

Serin (2020) tarafından yapılan tez çalışmasında BreakHis veri seti kullanılarak derin sinir ağı modeli geliştirilmiştir. Önerilen derin sinir ağı modelinde ResNet50, Xception, Inception V3 ve DenseNet201 olmak üzere dört farklı ağ kullanılarak sonuçlar incelenmiştir. Xception ağı kullanılarak ve 200x yakınlaştırma yapılarak elde edilen model en iyi sonucu vermiştir. %98,01'lik doğruluk değeri, %98,21'lik duyarlılık (recall) değeri, %98,92'lik kesinlik (precision) değerleri elde edilmiştir. Jawzal (2019) tarafından yapılan tez çalışmasında, termal kamera tarafından yakalanan termal görüntüler kullanılarak meme kanseri analizi yapılmıştır. Bu analiz için Bayes optimizasyon algoritması ve evrişimli sinir ağları kullanmıştır. Yapmış olduğu bu analizde, görüntüler normal ve şüpheli olarak ayrılmaktadır. 140 kişi ait termal görüntülerin bulunduğu bu veri seti ile %98,95'lik bir doğruluk değeri elde etmiştir.

Canatalay (2022) tarafından yapılan tez çalışmasında derin öğrenme teknikleriyle 73186 adet X-Ray görüntüleri üzerinde çalışılmıştır. Diğer çalışmalarla benzer şekilde, kişinin tümörünün olup olmadığı, eğer varsa iyi huylu mu kötü huylu mu olduğuna bakılmıştır. Anılan çalışmada yazar iki adet metot önermiştir. Birinci metotta VGG19, ikinci metotta ResNet50 mimarileri kullanılmıştır. ResNet50 mimarisi için %98,81 doğruluk ve VGG için %91,74 doğruluk elde edilmiştir. Kadiroğlu (2019) tarafından yapılan tez çalışmasında, BreakHis veri tabanından alınan histopatolojik görüntüler, evrişimli sinir ağları ile bir sınıflandırma yapılmıştır. Evrişimli sinir ağlarında özellik çıkarımı yapılarak elde edilen model için en yüksek doğruluk değeri %93,78 ile AlexNet-fc7 ve VGG16-fc7 mimarilerinin birleştirilmiş hali olan derin özelliklerden elde edilmiştir.

Amin ve diğ. (2023) yapmış oldukları çalışmada 160 kadın hastadan alınan düşük enerjili görüntüler ve CESM görüntüler ile hibrit bir bilgisayar destekli tanı sistemi (CAD) geliştirmişlerdir. Bu çalışmada sistemin hesaplama verimliliğinin artırılması için WPT (Dalgacık Paket Dönüşümü) kullanmışlardır. Çalışmanın asıl amacı, CESM görüntülerinin sentetik olarak üretilmesi yöntemlerinin ne kadar uygulanabilir olup olmadığı görmektir. Bu sayede intravenöz kontrast maddelerin hastalar üzerindeki kullanımının azaltılması amaçlanmıştır. Yapılan çalışmada sentetik olarak üretilen görüntülerden %92,14, Hibrit düşük enerjili görüntüler ve CESM görüntüleri kullanıldığında ise %96,87 doğruluk değeri elde edildiği görülmüştür.

Huynh ve diğ. (2023), meme kanseri tespiti için derin öğrenme temelli bir model önermektedir. Çalışmada, görüntü üzerinde meme kanseri olduğunun tespit edilebileceği alanların optimize edilmesi konusuna odaklanılmıştır. Bu sebeple YOLOX modelini kullanan araştırmacılar, meme dokusundaki önemli bölgeyi arka plandan ayırıp, lezyon içerebilecek potansiyeli olan noktaları tespit etmişlerdir. Ardından ConvNeXt ve EfficientNet modelleri kullanarak, bu noktaları iyi huylu ve kötü huylu olarak sınıflandırmışlardır. Çalışmada altı adet veri seti kullanılmıştır. Bu sebeple araştırma geniş kapsamlı olmuştur. ROI iyileştirmesi sebebiyle, görüntülerde bulunan gereksiz arka plan bilgileri azaltılmış ve geliştirilen modellerin kanserli bölgeleri tespit etme kapasitesi artırılmıştır. Bu sayede yapılan çalışma literatürdeki diğer çalışmalardan yüksek başarıya ulaşmıştır.

Zheng ve diğ. (2023), derin öğrenme yöntemlerine dayalı, mamografi görüntülerindeki tek kitlenin meme lezyonlarının tipinin belirlenmesi için otomatik bir sistem (FAPS) geliştirmişlerdir. Yapılan çalışma 1912 kadın hastadan alınan görüntüler ile yapılmıştır. Geliştirdikleri otomatik sistem iki alt ağdan oluşmaktadır. Görüntüleri bölümlmek için RefineNet, sınıflandırmak için Xception ve Pyramid Pooling Module kullanılmıştır. Yapılan segmentasyon işleminde dahili test verilerinde %88, dış test verilerinde %82, prospektif test verilerinde ise %89 DSC (Dice Benzerlik Katsayısı) değerine ulaşılmıştır. Sınıflandırmada ise dahili veri setinde %94, harici veri setinde %94, geleceğe yönelik test setinde %89 AUC değerleri elde etmişlerdir. Çalışma, özellikle deneyimsiz radyologların koyduğu teşhislerin doğruluğundan daha yüksek doğruluklar elde etmiştir. Bu açıdan FAPS, klinik uygulamalarda meme kanserinin tespiti için etkili bir araç olarak değerlendirilmektedir.

Zhu ve diğ. (2018), 18 farklı çalışmayı ele alarak, CESM görüntüleri üzerinden meme kanseri tahminin tanısal değeri hakkında bir karşılaştırma yapmışlardır. Son zamanlarda artan CESM görüntü analizi çalışmaları sebebiyle bir meta-analiz yapılması ihtiyacına karşılık böyle bir çalışma ortaya çıkarmışlardır. Bu 18 çalışmada TP (doğru pozitif), TN (doğru negatif), FP (yanlış pozitif) ve FN (yanlış negatif) değerleri karşılaştırılmıştır. Özet olarak çıkarılan sonuçlarda özgüllük (specificity) %84, duyarlılık (recall) %89 olarak elde edilmiştir.

Kobyay ve diğ. (2023), yapmış oldukları çalışmada CDD-CESM veri setini kullanmışlar ve üç model üretmişlerdir. Çalışmada mamografi görüntülerinden elde ettikleri birinci dereceden istatistiksel özellikler kullanarak karar destek sistemi üretmeyi amaçlamışlardır. Karar destek makineleri (SVM), Neural Network (NN) ve RUSBoost sınıflandırma yöntemlerini kullanan ekip, en yüksek doğruluğu %89 ile yüksek enerjili görüntüler üzerinde, %87 doğruluk oranıyla elde etmişlerdir.

Qian ve diğ. (2024), kontrastlı mamografi görüntülerinden elde edilen öznetelikleri kullanarak meme kanserini tahmin edebilmek amacıyla çoklu özellik birleştirme sinir ağı geliştirmişlerdir. Düşük enerjili ve çift enerjili çıkarma görüntüleri gibi farklı özelliklerdeki görüntülerin birleşimiyle meme kanserindeki lezyonların sınıflandırılmasına yönelik bir model sunulmuştur. Oluşturdukları model, dahili veri setinde %90 doğruluk ve %96 AUC sonucu vermiştir. Üretilen model iki adet harici veri setinde de test edilmiş ve bu veri setlerinde de %92 ve %90 oranında AUC değerleri elde etmişlerdir.

Achak ve diğ. (2023) yapmış oldukları çalışma, belirli bir kitle üzerindeki yapılan tahmin çalışmalarından farklı olarak, kitle halinde olmadan artış gösteren lezyonlar üzerinde iyi huylu ve kötü huylu olarak teşhis koyma üzerinde çalışılmıştır. Şüpheli gördükleri alanları Matlab programı ile arka planından ayıran ekip, bu görüntüleri görüntü işleme teknikleriyle iyileştirmiştir. DenseNet201, ResNet18 ve ResNet50 modelleri üzerinde yapılan eğitimlerde en iyi sonucu %100 duyarlılık (recall), %91,25 özgüllük (specificity) ve %96 doğruluk değerleriyle DenseNet201 modelinden elde etmişlerdir. Kitle olarak gözükmediği için anlaşılması güç olan lezyonların fark edilebilmesi için yapılmış önemli bir çalışmadır.

Rofena ve diğ. (2023) yapmış oldukları çalışma, görüntüleme sırasında hasta üzerinde kalıcı hasar bırakabilecek olan kontrast maddenin kullanımını azaltmaya yönelik bir

çalışmadır. Ekip, yüksek ve düşük enerjili görüntüler üzerinde sanal bir kontrast arttırma çalışması yapmış ve bu sanal kontrast artırmanın işe yarayıp yaramadığını test etmişlerdir. Sanal kontrast arttırmak için bir otomatik kodlayıcı ve iki üretici karşıt ağ (GAN) kullanmışlardır. Düşük enerjili görüntüler üzerinde CycleGAN kullanılarak oluşturulan model en iyi sonucu vermiştir. Çalışma, sanal kontrast artırma sayesinde, CESM görüntüleme tekniğinin daha yaygın olarak kullanılabilecek bir görüntüleme tekniği olabileceğini vurgulamıştır.

Cozzi ve diğ. (2021), CESM görüntüleri kullanan çalışmalar hakkında bir meta analiz yapmışlardır. 60 adet çalışma üzerinde yapılan meta analizde düşük enerjili görüntüler ile yeniden birleştirilmiş görüntülerin birlikte kullanılarak eğitildikleri modellerde daha yüksek sonuçlar alındığı görülmüştür. %95 duyarlılık (recall) ve %81 özgüllük (specificity) değerleri elde edildiği raporlanmıştır. Çalışmada, kontrastı artırılmış mamografinin, tolere edilebilirliği, erişilebilirliği ve uygunluğu sebebiyle meme kanseri tanısında kontrastlı mamografiye göre daha iyi olduğu belirtilmiştir.

3. YAPAY ZEKA

Yapay zeka genellikle zeki organizmaların gerçekleştirdiği görevleri yapabilen makinelerin geliştirilmesine odaklanır. Bu kavram, özellikle akıl yürütme, anlam oluşturma, geçmiş deneyimlerden öğrenme veya eldeki verileri genelleştirme gibi insana özgü akıl gerektiren şeyleri taklit ederek yeni sistemler tasarlamayı ifade eder (Sanayi ve Teknoloji Bakanlığı, 2024).

Yapay zeka, belirli kurallar ve parametreler çerçevesinde mevcut durumları analiz eder, bu analizden elde edilen bilgileri işler ve uygun tepkiler üretir (GTech, 2024). Yapay zeka, insanların hayatlarını kolaylaştırmak adına büyük bir devrim niteliğindedir. Çevremize baktığımızda birçok alanda kullanıldığını görmekteyiz. Telefonlarımızdaki sesli asistan uygulamaları, araçlarımızdaki navigasyonlar, dil çeviri robotları, e-ticaret uygulamalarındaki öneri sistemleri, evlerdeki akıllı temizlik robotları gibi birçok alanda bunu görebilmekteyiz. Daha büyük ölçekte baktığımızda, otonom araçlar, savunma sanayiinde kullanılan insansız hava araçları, sağlık ve eğitim alanlarında kullanılan yapay zeka sistemleri günümüzde önemli bir konumdadır.

Yapay zeka terimi ilk defa, Bilgisayar Bilimci John McCarthy tarafından, tarihte yapay zeka alanında düzenlenen ilk konferans olan Dartmouth Konferansı'nda 1956 yılında kullanılmıştır (Sanayi ve Teknoloji Bakanlığı, 2024).

Yapay zeka ve insan zekası birbirine benzer özellikler taşımaktadır. Ancak yapay zeka bazı yönleriyle insan zekasından da üstün konuma gelmektedir. Yapay zeka ve doğal zekayı karşılaştırmak gerekirse; doğal zeka, zamanla bireylerin değişmesi veya bilgilerin unutulması gibi durumlara maruz kalabilir. Buna karşın yapay zeka, sabit bir yapıya sahiptir ve bağlı olduğu sistemler veya programlar değişmediği sürece bilgilerini kaybetmez ya da unutma durumu yaşamaz (Sönmez, 2024). Doğal zekada bilgi aktarımı ve bir kişiyi eğitmek uzun bir zaman alabilir. Ancak yapay zekaya bakıldığında makinenin öğrenmesi daha kısa zaman aldığı gibi, bir makineye öğrettikten sonra o da aynı bilgiler ile diğer makineleri eğitebilmektedir. Bu açıdan insan gücü minimuma inmektedir. İnsan zekasının üstün olduğu yönler de tabii ki bulunmaktadır. İnsan zekasında duygusal zeka da bulunduğundan, kritik anlarda fayda

ve zarar unsurlarını göz önünde bulundurarak, durumun çıkarlarına göre karar verebilmekte ve risk alabilmektedir.

Yapay zekalar veri ile eğitilir. Bu sebeple, verinin bulunmadığı yerde yapay zekadan söz etmek güçtür. Verinin hacmi, çeşitliliği, büyüklüğü ne kadar artarsa, üretilen yapay zeka sistemi de o kadar başarılı olur. Veri ne kadar büyük olursa, çözilemeyen problemlerin çözülme hızı ve etkisi o kadar yüksek olur.

Yapay zeka, birçok alt dalı bünyesinde barındırır. Bu alanlar arasında makine öğrenmesi, derin öğrenme, doğal dil işleme, görüntü analizi, ses tanıma, bilgisayarlı görme, uzman sistemler, desen tanıma, bulanık mantık ve genetik algoritmalar gibi konular yer almaktadır. Her makine öğrenmesi veya derin öğrenme bir yapay zekadır ancak her yapay zeka bir makine öğrenmesi veya derin öğrenme değildir (Şekil 3.1).



Şekil 3.1 : Yapay zeka, makine öğrenmesi, derin öğrenme.

Makine öğrenmesi, insanların öğrenme yöntemlerinden ilham alarak verilerdeki desenleri algoritmalarla işleyen ve bu sayede tahmin yapabilen veri modelleri oluşturan bir yapay zeka dalıdır (Etiya, 2024).

Makine öğrenmesinin birçok faydası bulunmaktadır. Çeşitli alanlarda ve sektörlerde önemli ölçüde avantaj sağlamaktadır. Büyük veri setlerinin analizlerini çok hızlı bir biçimde yapabilir ve gelecekte nasıl bir eğilim göstereceğini tahmin edebilir. Finans ve sağlık alanı gibi alanlarda sonuçları öngörme yeteneği sayesinde sıkça kullanılmaktadır. Yaptığı analizler ile kişiselleştirilmiş öneri sunabilmesi sayesinde birçok dijital platform üzerinde kişiye özel çıkarımlar yapabilmekte, kişinin beğenebileceği ürün, film, müzik gibi önerilerde bulunabilmektedir. Fabrikalarda manuel kullanılan ve otomatize edilebilecek görevleri otomatikleştirerek verimliliği

artırmaya yardımcı olur. Verileri anlık olarak analiz edebilme yeteneđi sayesinde finans piyasasında anlık alım satım kararları verebilir, trafikte otonom aracın çevresel deęişimlere hızlı tepki verebilmesi sayesinde olası kazaları engelleyebilmektedir. İnsan hatalarını minimuma indirgeyebildiğinden, zaman ve maddiyat kaybının da önüne geçebilmektedir.

Makine öğrenmesi, pekiştirmeli öğrenme, denetimli öğrenme ve denetimsiz öğrenme olarak üç temel kategoriye ayrılır. Denetimli öğrenmede makineye hem girdi özellikleri hem de çıktı etiketi verilir. Denetimiz öğrenmede makineye sadece girdi özellikleri verilir. Model, verinin doğal gruplamasını tahmin etmeye çalışır. Pekiştirmeli öğrenme ise, görevli ajanın ödöl ve ceza sistemiyle bir işi optimum şekilde yapmaya çalışmasıdır. Görevleri doğru yaptıkça ödöl, yanlış yaptıkça ceza alır. Böylelikle en iyi stratejiyi belirler.

4. DERİN ÖĞRENME


Derin öğrenme, makinelerin verileri insan beynine benzer şekilde işlemesine olanak tanıyan bir yapay zeka yöntemidir. Derin öğrenme ile oluşturulan modeller doğru tahminler ortaya çıkarmak için ses, fotoğraf, metin gibi verilerdeki karmaşık örüntüleri tanıyabilir. Özellikle yapay sinir ağlarının eğitiminde veri ve model boyutlarının büyümesi, donanımların bu yüksek işlem gücünü sağlayabilmesi sayesinde, araştırmalar üniversite laboratuvarlarından çıkarak projelere dönüşmüş ve gerçek dünyada uygulanabilir hale gelmiştir. Karmaşık problemleri çözmede geleneksel yöntemlerden daha etkili sonuçlar elde ettiği, birçok araştırma ile doğrulanmıştır..

Derin öğrenmenin esas hedefi beyin işleyişini taklit etmek değildir. Ancak, sinir bilimi ve hesaplamalı sinir bilimi alanlarındaki bazı çalışmalar, derin öğrenme araştırmalarına ilham kaynağı olmuştur. Modern derin öğrenme, bilgi kuramı, olasılık ve istatistik, lineer cebir gibi çeşitli disiplinlerden beslenmektedir.

Derin öğrenmenin makine öğrenmesinden ayrılan en önemli özelliği özenitellik çıkarabilme yeteneğidir. Makine öğrenmesinde, makineye verilecek olan verilerin öznitelik çıkarımında bir uzman kişiye ihtiyaç duyulur. Verinin özelliklerine dair bir takım bilgiler çıkarılır ve bu bilgiler modele verilerek eğitim yapılır. Çok fazla veriye ihtiyaç yoktur çünkü özellik çıkarımı yapan kişi bu veriler hakkında uzman birisidir.

Derin öğrenmede, makine öğrenmesinin aksine öznitelik çıkarımı bir uzman tarafından gerçekleştirilmez, bunu modelin kendisi yapar. Bu sebeple girişte çok fazla veriye ihtiyaç duyarız. Öznitelik çıkarımı, derin öğrenmenin sinir ağları boyunca gerçekleşecektir. En önemli farkı budur. Elimizde büyük veri seti varsa makine öğrenmesinden daha başarılı sonuçlar vermesi mümkündür.

Derin öğrenmenin alt alanları vardır. Bunlar kullanıldıkları yerlere göre çeşitlilik göstermektedir.



Şekil 4.1 : Derin öğrenme katmanları.

4.1 Derin Öğrenmeyi Başarılı Kılan Faktörler

Derin öğrenme modellerinin başarılı olmasını sağlayan birkaç unsur bulunmaktadır. Bunların başında büyük veri setleri gelmektedir. Veri setleri, derin öğrenme katmanlarında öznetelik çıkarımının başarılı olabilmesi için çeşitli olmalıdır. Öte yandan güçlü donanım özellikleri de eğitilen modelin başarısını etkilemektedir. Derin öğrenme modelleri, büyük miktarda hesaplama gücü gerektirmektedir. GPU (Graphics Processing Unit) ve TPU (Tensor Processing Unit), ağır hesaplama gerektiren işlemleri hızlandırmaktadır ve böylelikle karmaşık olan ağlar daha kısa sürede eğitilebilmektedir. Derin öğrenme modelleri eğitilirken modelin doğruluğunun artmasında önemli olan faktörlerden birisi de optimizasyon algoritmaları kullanmaktır. RMSprop (Karekök Ortalama Kare Yayılımı), Stokastik Gradyan İniş, Adam (Uyarlanabilir Moment Tahminleme) gibi öğrenme aşamalarını daha verimli hale getiren optimizasyon teknikleri kullanmak, modellerin doğruluğunun artmasında etkilidir. Özellikle 2012 yılından sonra derin öğrenme daha popüler hale gelmiştir. Bunun nedeni, geçen sürede donanım, veri kümeleri ve algoritmaların benzer zamanlarda iyileştirilmesidir.

4.2 Derin Öğrenmenin Matematiksel Temelleri


Derin öğrenmenin matematiksel temelleri, istatistik, optimizasyon, doğrusal cebir ve hesaplamalı matematik gibi disiplinlere dayanır. Katmanlar arasında hesaplanan

ağırlıklar, giriş verileri ve aktivasyonlar, doğrusal cebir ile modellenerek vektör ve matrisler yardımıyla ifade edilir. Bu süreçte çarpma, transpoz ve determinant gibi matematiksel işlemler temel rol oynar.

Veri dağılımlarını modellemek, belirsizlikleri analiz etmek ve öğrenme sürecini düzenlemek için olasılık ve istatistik kullanılır. Optimizasyon perspektifinden, gradyan inişi (gradient descent) gibi algoritmalar, kayıp fonksiyonunu minimize ederek öğrenmeyi optimize eder. Geri yayılım (backpropagation) algoritması ise zincir kuralını kullanarak ağıdaki gradyanları hesaplar ve model parametrelerini günceller. Bu süreçler, derin öğrenme algoritmalarının temel yapı taşlarını oluşturur.

4.2.1 Vektörler, matrisler, tensörler

Derin öğrenmenin temelinde bulunan veri yapıları vektörler, matrisler ve tensörlerdir. Tek başına olan sayılara skaler denir ve skaler, sıfırıncı dereceden bir tensördür. Vektörler ise tek başına olan sayıların (yani skalerlerin) birer dizi haline getirilmesidir. Derin öğrenmede vektörler, özellik vektörlerini temsil eder ve bu vektörün bileşenleri belirli bir özelliğin ne kadar alakalı olduğunu tanımlar. Vektörler birinci edereden bir tensördür. Örneğin bir fotoğrafın piksel değerleri veya bir metnin kelime frekansları birer vektör tarafından temsil edilebilir. Aynı zamanda yapay sinir ağlarındaki her bir nöronun giriş değeri olarak atadığı ağırlıklar da birer vektör olarak ifade edilir.



Şekil 4.2 : (a) Vektör, (b) matris ve (c) tensör.

Matrisler ise ikinci dereceden tensörlerdir. Bir sinir ağındaki katmanlarda bulunan nöronların diğer nöronlara olan bağlantılarını ve bu bağlantılarda bulunan ağırlıkları matrisler temsil eder. Yapay sinir ağına eğitilmesi için birden fazla veri sunulduğunda, her verinin barındırdığı özellikler birer satır olacak şekilde matris oluşturulur.

Tensörler ise çok boyutlu verileri temsil etmektedir. 3 ve daha fazla boyutları olabilmektedir. Örneğin RGB renk kanalına sahip bir görüntü, kırmızı, yeşik ve mavi renk kanallarıyla üç boyutlu bir tensördür. Yapay sinir ağlarında bulunan katmanlarda saklanan ağırlıklar birer tensör olarak tutulur. Aynı zaman aralığında birden fazla veriyi işlemek için tensörler kullanılmaktadır. Örneğin bir mini yığın (mini-batch), örnek sayısı, yükseklik, genişlik ve kanal sayısı olmak üzere 4 boyutu bulunan bir tensördür. Tensorflow ve Pytorch kütüphaneleri, büyük boyuttaki veriler üzerinde hızlı ve verimli hesaplamalar yapabilmek için tensörler konusunda optimize edilmişlerdir.

4.2.2 Türev ve gerekliliği

Türev, derin öğrenmenin matematiksel ve algoritmik altyapısında temel bir role sahiptir. Derin öğrenme modellerinin eğitim süreçleri, hata fonksiyonunun minimize edilerek ağırlıkların optimize edilmesine dayanır. Matematiksel olarak türev, bir fonksiyonun belirli bir noktadaki değişim oranını ifade eder ve bu bağlamda derin öğrenmede, ağ parametrelerinin güncellenme sürecini yönlendiren kritik bir araçtır.

Sinir ağlarında kullanılan parametreler, türev hesaplamaları olmadan optimize edilemez. Türevler, kayıp fonksiyonunun hangi yönde minimize edileceğini belirler ve böylece ağırlıkların doğru şekilde güncellenmesini sağlar. Sigmoid, ReLU ve tanh gibi yaygın aktivasyon fonksiyonlarının türevleri, ağıın ileri ve geri yayılım süreçlerinde hesaplanarak öğrenme sürecine katkıda bulunur.

Türev kavramı olmasaydı, derin öğrenme modellerinin eğitimi yalnızca sezgisel yaklaşımlar veya rastgele denemelerle sınırlı kalırdı. Ancak modern derin öğrenme kütüphaneleri (örneğin TensorFlow ve PyTorch), türev hesaplamalarını otomatikleştirerek karmaşık ve büyük ölçekli ağların hızlı ve etkili bir şekilde eğitilmesini mümkün kılmıştır. Bu nedenle türev, derin öğrenmenin temel yapı taşlarından biri olarak, modellerin başarıyla optimize edilmesinde ve genel performanslarının artırılmasında hayati bir rol oynamaktadır..

4.2.3 Gradyan iniş ve optimizasyonu

Gradyan iniş algoritmaları, matematiksel fonksiyonların minimum değerini bulmaya yönelik temel optimizasyon yöntemlerinden biridir. Derin öğrenme bağlamında ise, genellikle bir kayıp fonksiyonu aracılığıyla modelin tahminleri ile gerçek değerler arasındaki farkı minimize etmek için kullanılır. Bu algoritma, model parametrelerini -

örneğin katmanlar arasındaki ağırlıkları- iteratif olarak güncelleyerek kayıp fonksiyonunu optimize etmeyi hedefler.

Gradyan iniş yöntemleri, uygulama biçimlerine göre üç ana yaklaşıma ayrılmaktadır: Tam gradyan iniş (Batch Gradient Descent), Stokastik Gradyan İniş (Stochastic Gradient Descent - SGD) ve Mini yığın (mini-batch) Gradyan İnişi.

Tam gradyan iniş, bu algoritmaların en temel formunu temsil eder ve her bir iterasyonda tüm veri seti üzerinde hesaplama yapılmasını gerektirir. Model parametrelerinin güncellenmesi, kayıp fonksiyonunun tüm veri seti üzerindeki gradyanının hesaplanması ve bu bilginin parametreleri optimize etmek için kullanılması ile gerçekleştirilir. Bu yöntem, doğruluk açısından avantaj sağlasa da yüksek hesaplama maliyeti nedeniyle büyük veri setleri üzerinde uygulanması zorluklar içermektedir.

$$w = w - \eta \cdot \nabla L(w) \quad (4.1)$$

Denklem 4.1'de w parametresi, modelin eğitimi sürecinde güncellenen model parametreleridir. η öğrenme oranını temsil ederken $\nabla L(w)$, tüm veri seti üzerindeki kayıp fonksiyonunun gradyanını temsil eder.

Tam gradyan iniş algoritması, kararlı yakınsama sağlamasıyla dikkat çeken bir optimizasyon yöntemidir. Tüm veri seti üzerinde hesaplama yapıldığı için her iterasyonda kayıp fonksiyonunun genel davranışı temel alınır ve bu durum, kararlı bir şekilde minimum değere ulaşılmasına olanak tanır. Tüm veri setini içeren gradyan hesaplamaları, yüksek hassasiyet ve doğruluk düzeyleri sunarak model performansını artırır. Ancak, bu yöntem büyük veri setleri üzerinde çalışırken yüksek hesaplama maliyeti ve bellek gereksinimi nedeniyle pratik zorluklar yaratabilir.

Stokastik gradyan iniş (SGD) ise tam gradyan inişin bu sınırlamalarını aşmaya yönelik bir yaklaşımdır. SGD, her iterasyon adımında yalnızca bir veri örneği üzerinden gradyanı hesaplar. Bu özelliği sayesinde büyük veri setlerinde hesaplama maliyetlerini önemli ölçüde azaltır ve daha hızlı güncellemeler yapılmasını mümkün kılar. Ancak, bir örnek üzerinden yapılan hesaplamaların kayıp fonksiyonundaki dalgalanmalara neden olması, SGD'nin daha gürültülü bir yakınsama süreci sergilemesine yol açabilir. Bu durum, belirli optimizasyon teknikleriyle giderilebilmekte ve yöntemin etkili bir şekilde uygulanmasını sağlayabilmektedir.

$$w = w - \eta \cdot \nabla L(w; x_i, y_i) \quad (4.2)$$

Denklem 4.2’de belirtilen (x_i, y_i) , veri setindeki herhangi bir örneği temsil etmektedir.

Büyük veri setlerinde hafıza kullanımını en aza indirmesi nedeniyle stokastik gradyan iniş, verimli bir yöntem olarak öne çıkmaktadır. Ancak bu yöntem, kayıp fonksiyonunda dalgalanmalara neden olabilir. Bu dalgalanmalar, algoritmanın global minimum dışında kalan yerel minimum noktalarını aşmasını kolaylaştırırken, aynı zamanda kararlılığını azaltabilir. Stokastik gradyan iniş, daha hızlı bir şekilde yakınsamaya ulaşabilme potansiyeline sahip olsa da, rastgele doğası nedeniyle yakınsama sürecinin uzamasına yol açabilmektedir.

Stokastik gradyan inişin performansını artırmak için Momentum, RMSProp ve Adam (Adaptive Moment Estimation) gibi ileri optimizasyon teknikleri geliştirilmiştir. Momentum tekniği, yakınsama sırasında oluşan dalgalanmaları azaltmak amacıyla önceki güncellemelerde biriken hız vektörünü dikkate alır ve daha pürüzsüz bir optimizasyon süreci sağlar. RMSProp, öğrenme oranını, her bir parametredeki gradyanların karelerinin hareketli ortalamasına göre uyarlayarak dengede tutar ve yakınsamayı hızlandırır. Adam algoritması ise Momentum ve RMSProp yaklaşımlarını birleştirerek her iki yöntemin avantajlarını bir arada sunar. Bu yöntemde, parametre güncellemeleri gradyanların birinci ve ikinci momentlerinin hareketli ortalamalarına dayanılarak yapılır.

Mini yığın (mini-batch) gradyan inişi, stokastik ve tam gradyan iniş yöntemlerinin olumlu yönlerini birleştiren bir optimizasyon yaklaşımıdır. Veri setinin daha küçük alt gruplara bölünmesi nedeniyle bu isimle anılmaktadır. Her iterasyonda bir mini yığın (mini-batch) üzerindeki gradyan hesaplamaları kullanılarak model parametreleri güncellenir. Bu yöntem, tam gradyan inişin doğruluğu ile stokastik gradyan inişin hızını bir araya getirerek dengeli ve verimli bir optimizasyon süreci sunar. Parametre güncelleme denklemi ise Denklem 4.3'te belirtilmiştir.

$$w = w - \eta \cdot \frac{1}{b} \sum_{i=0} \nabla L(w; x_i, y_i) \quad (4.3)$$

Denklem 4.3’te b ile belirtilen değer mini yığın (mini-batch) boyutudur. (x_i, y_i) , mini yığın (mini-batch) içerisinde bulunan veri örneklerini temsil etmemektedir. $\nabla L(w; x_i, y_i)$ ise, mini yığın (mini-batch)’ler üzerinde oluşan kayıp fonksiyonunun gradyanını belirtir.

Mini yığın (mini-batch) gradyan inişi, tam gradyan inişe kıyasla daha az veri örneği kullandığı için hesaplama maliyetini önemli ölçüde azaltmaktadır. Stokastik gradyan inişteki rastgeleliğin neden olduğu dalgalanmalara ise daha sistematik bir yaklaşım sunarak çözüm sağlamaktadır. Bu yöntem, paralel işlemeye olan uygunluğu sayesinde GPU ve TPU gibi yüksek performanslı donanımlarla etkin bir şekilde çalışabilmektedir. Ayrıca, veri setlerini küçük parçalar halinde ele alması, çok büyük veri setleriyle işlem yapabilme yeteneğini artırmaktadır.

Ancak, mini yığın (mini-batch) boyutlarının doğru şekilde belirlenmesi, yöntemin başarısı açısından kritik öneme sahiptir. Aşırı büyük veya aşırı küçük mini yığın (mini-batch) boyutları, algoritmanın performansını olumsuz etkileyebilir. Bu nedenle, mini yığın (mini-batch) gradyan inişi, doğru yapılandırıldığında hem hız hem de doğruluk açısından derin öğrenme modelleri için etkili bir optimizasyon yöntemi olarak öne çıkmaktadır.

4.2.4 Zincir kuralı ve geriye yayılım algoritması

Derin öğrenme modelleri, büyük veri setlerindeki karmaşık ilişkileri modelleyebilme yeteneği sayesinde, birçok alanda olağanüstü başarılar elde etmiştir. Bu başarının temelinde, model ağırlıklarını optimize eden geriye yayılım algoritması yatmaktadır. Geriye yayılım algoritması, matematiksel olarak zincir kuralı prensibine dayanmaktadır. Zincir kuralı, çok katmanlı yapılar içerisinde kayıp gradyanını etkili bir şekilde giriş katmanına kadar taşıyarak modelin parametrelerinin iyileştirilmesini sağlar. Aynı zamanda, zincir kuralı fonksiyonların türevlerini hesaplayarak türev hesabının temel mekanizmasını oluşturur.

Geriye yayılım algoritması, sinir ağlarının çıktısını istenen hedefe yaklaştırmak için kullanılan temel yöntemdir. Bu algoritma, ağırlıkların optimize edilmesi için dört temel aşamadan oluşur. İlk aşama olan ileri yayılım, modelin girişine verilen verinin, belirlenen ağırlıklar ve yanlılık (bias) değerleriyle işlenmesini içerir. Giriş verisi, katmanlardan geçerken ağırlıklarla çarpılır, yanlılık değeri (bias) eklenir ve ardından aktivasyon fonksiyonları uygulanır. Bu süreç sonunda model, bir çıktı üretir. Ağırlıklar ve yanlılık (bias) değerleri, öğrenme süreci boyunca güncellenen ve modelin performansını doğrudan etkileyen kritik parametrelerdir.

İkinci aşamada, modelin çıktısı ile gerçek değer karşılaştırılarak bir kayıp fonksiyonu hesaplanır. Kayıp, modelin tahminlerinin hedef değerlerden sapma miktarını ölçer.

Daha sonra, bu kaybın en aza indirilmesi amacıyla kayıp fonksiyonunun türevleri hesaplanır. Bu türevler, her bir ağırlığın model performansına katkısını belirler ve ağırlıkların ne yönde ve ne miktarda değiştirilmesi gerektiğini ortaya koyar.

Üçüncü aşama olan geriye yayılım, kayıp fonksiyonunun türevlerinin, zincir kuralı yardımıyla modelin katmanlarında geriye doğru taşınması sürecidir. Hata sinyali, modelin son katmanından giriş katmanına kadar iletilirken, her katmandaki ağırlıkların bu hata üzerindeki etkisi hesaplanır. Böylece, her katmanın eğitim sürecine katkısı değerlendirilir ve parametrelerin nasıl optimize edilmesi gerektiği daha net bir şekilde anlaşılır.

Son aşamada, her bir ağırlık, geriye yayılım sırasında elde edilen türevler kullanılarak güncellenir. Bu işlem genellikle Stokastik Gradyan İnişi (SGD) veya Adam gibi optimizasyon algoritmalarıyla gerçekleştirilir. Ağırlıkların güncellenme hızı, öğrenme oranı adı verilen bir hiperparametre ile kontrol edilir. Bu dört adım (ileri yayılım, kayıp hesaplama, geriye yayılım ve ağırlık güncelleme), modelin performansı istenen düzeye ulaşana kadar tekrar edilir.

Bu yöntem sayesinde, derin öğrenme modelleri büyük ve karmaşık veri setlerindeki ilişkileri etkili bir şekilde öğrenebilir. Geriye yayılım algoritması, sinir ağlarının eğitim sürecinin temel taşı olarak, derin öğrenme alanındaki devrim niteliğindeki gelişmelere olanak tanımaktadır.

4.3 Derin Sinir Ağları


Derin sinir ağları, insan beynindeki nöronlardan esinlenerek geliştirilen ve yapay sinir ağlarının genişletilmiş bir versiyonu olarak öne çıkan çok katmanlı modellerdir. Bu ağlar, doğrusal olmayan ve karmaşık veri yapılarını öğrenme yetenekleri sayesinde geniş veri setlerinde yüksek performans göstermektedir. Günümüzde doğal dil işleme, görüntü işleme ve ses analizi gibi farklı alanlarda yoğun bir şekilde kullanılmaktadır.

Bu ağlar, giriş katmanı, ara katmanlar (gizli katmanlar) ve çıkış katmanı olmak üzere üç ana bileşenden oluşur. Giriş katmanı, veri setindeki her bir özelliği temsil eden nöronlardan oluşur ve ham verilerin modele sunulduğu ilk aşamadır. Gizli katmanlar, modelin derinliğini belirleyen ana bileşenlerdir. Her bir gizli katman, önceki katmandan aldığı çıktıyı işler ve bir sonraki katmana iletir. Nöronlar, ağırlıklar ve aktivasyon fonksiyonları yardımıyla karmaşık hesaplamalar gerçekleştirir. Bu sayede

model, doğrusal olmayan ilişkileri öğrenme kapasitesine sahip olur. Çıkış katmanı ise modelin ürettiği sonuçları içerir ve nöron sayısı, ele alınan probleme özgü bir şekilde belirlenir.

Derin sinir ağlarının temel çalışma mekanizması, ileri yayılım ve geriye yayılım aşamaları ile eğitilir. İleri yayılım sırasında, giriş verisi katmanlardan geçerken her nöronun çıktısı, belirli ağırlıklarla çarpılır ve yanlılık (bias) değeri eklenir. Daha sonra bu değerler, aktivasyon fonksiyonlarından geçirilerek doğrusal olmayan bir forma dönüştürülür. Aktivasyon fonksiyonları arasında sigmoid, ReLU ve tanh gibi seçenekler bulunmaktadır. Modelin tahmin ettiği değer ile gerçek değer arasındaki fark, kayıp fonksiyonu yardımıyla ölçülür. Sıklıkla kullanılan kayıp fonksiyonları arasında ortalama kare hatası (Mean Squared Error - MSE), kök ortalama kare hatası (Root Mean Squared Error - RMSE) ve çapraz entropi kaybı (Cross Entropy Loss) yer almaktadır.

Geriye yayılım aşamasında, zincir kuralı kullanılarak kayıp fonksiyonunun türevleri alınır. Bu türevler, modelin parametrelerinin hata üzerindeki etkisini ortaya koyar ve ağırlıkların hangi yönde ve ne miktarda güncellenmesi gerektiğini belirler. Bu süreçte Adam, RMSProp ve Stokastik Gradyan İnişi (SGD) gibi optimizasyon algoritmaları kullanılarak ağırlıklar güncellenir. Model, bu adımların tekrar edilmesi yoluyla eğitilerek optimum performans düzeyine ulaşır. Derin sinir ağlarının giriş, gizli ve çıkış katmanları Şekil 4.3’de görülmektedir.



Şekil 4.3 : Derin sinir ağları (MRI Questions, 2024).


Derin sinir ağlarının çok sayıda gizli katmana sahip olması, karmaşık ve doğrusal olmayan veri ilişkilerinin keşfedilmesini sağlar. Büyük boyutlu verilerle eğitildiklerinde daha yüksek performans sergileyebilme yeteneği, onları modern yapay zeka uygulamalarında vazgeçilmez kılmaktadır. Ancak, ağların karmaşıklığı nedeniyle

iç işleyişlerinin anlaşılması zor olabilir ve bu durum bazen "kara kutu" etkisi yaratarak güvenilirlik endişelerine neden olabilmektedir.

4.3.1 Evrişimli sinir ağıları (CNN)

Derin öğrenmede önemli bir sinir ağı olan evrişimli sinir ağıları, özellikle görüntü işleme ve diğer ağ yapısı içeren verilerde kullanılmak üzere geliştirilmiştir. Evrişimli sinir ağıları, diğer sinir ağlarından farklı olarak giriş verisindeki karmaşık ilişkileri çözebilmek ve korumak için evrişim işlemini kullanır. Bu sinir ağı, temelde 3 katmandan oluşur. Bunlar evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlardır. Evrişim katmanları, giriş olarak verilen verinin barındırdığı özellikleri öğrenmek için filtreler ya da çekirdekler (kernel) uygular. Uygulanan bu filtreler veri üzerinde kaydırılma yöntemiyle uygulanır ve verideki özelliklerin çıkarılmasını gerçekleştirir. Önemli bilgileri yoğunlaştıran evrişim işlemi, görüntüdeki önemli özellikleri ortaya çıkarmaya olanak tanır.

Doğrusal olmayan ilişkilerin çözümlenmesi ve öğrenilmesi için evrişimli sinir ağlarında aktivasyon fonksiyonları kullanılır. Havuzlama katmanlarında ise, verilerin fiziksel boyutlarını küçülterek modelin maliyetini azaltır. Çıkarılan özelliklerin daha genel bir hale gelmesini sağlar. Havuzlama işleminde en çok kullanılan yöntemlerden ikisi maksimum havuzlama (max pooling) ve ortalama havuzlamadır (average pooling). Görüntüde bulunan önemsiz kaymaların yaptığı etkiyi azaltarak modelin daha iyi bir performans göstermesini sağlar. Tam bağlantılı katmanlar (fully connected layer), evrişimli sinir ağlarının son katmanlarıdır. Elde edilen özellikleri bir araya getirerek yapılacak işlem için sonuç üretir.




Şekil 4.4 : Evrişimli sinir ağıları (Şebin, 2022).

Özellik mühendisliği uygulamaya gerek duymadan, girilen verilerden özellik çıkarabilmektedir. Bir filtre boyutundaki verilerle etkileşimde bulunabildiği ve her

seferinde bu boyuttaki verileri işlediği için hesaplama maliyetini ciddi anlamda düşürmektedir. Küçük bir bölgedeki anlamlı alanları çıkarmada yeteneklidir. CNN'in hiyerarşik bir yapısı vardır ve düşük seviyedeki özelliklerden anlamlı özelliklere kadar bir hiyerarşik yapı kurar. Grid yapı içeren alanlarda başarılı sonuçlar vermektedir.

4.3.2 Yinelemeli sinir ağları (RNN)

Yinelemeli sinir ağları, içerisinde bir düzenin olduğu verileri başarılı bir şekilde işleyebilmektedir. Zaman serileri, ardışık veri gibi verilerdeki sıralı veri noktaları arasındaki ilişkileri öğrenme yeteneği sayesinde, ses analizi, doğal dil işleme gibi alanlarda yaygın olarak kullanılmaktadır. Yinelemeli sinir ağları, önceki katmandan gelen bilgiyi gizli bir durum (hidden state) ile saklayarak bir sonraki katmana aktarma yeteneğiyle diğer sinir ağlarından ayrılmaktadır. Gizli durum (hidden state) sayesinde yinelemeli sinir ağları bir hafıza mekanizmasına sahip olmaktadır. Yinelemeli sinir ağları, her katmanda ağırlıkları tekrar kullanır. Böylelikle aynı ağırlık değerleri tüm adımlarda uygulanır. Bu durum, model eğitilirken gereken parametre sayısını düşürür ve zaman bağımlı veriler üzerinde başarılı bir öğrenme sağlar. Yinelemeli sinir ağlarının mimarisi Şekil 4.5'de görülmektedir.




Şekil 4.5 : Yinelemeli sinir ağları (Dive into Deep Learning, 2023).

4.3.3 Yapay sinir ağları (ANN)

Yapay sinir ağları, beynin sinir sisteminin işleyişini baz alan bir modeldir. Yapay sinir ağlarının en temel özelliği, karmaşık yapılara sahip ilişkileri öğrenmesidir. Nöron veya düğüm şeklinde adlandırılan temel birimlerden oluşur. Bu temel birimler birleşerek bir ağ yapısı oluşturur. Yapay sinir ağları, giriş katmanı, gizli katmanlar ve çıkış katmanı

bileşenlerinden oluşur. Modelin işlemlerini istediğimiz verileri aldığı katman giriş katmanıdır. Burada bulunan her düğüm, verideki bir özelliği temsil eder. Gizli katmanlarda giriş verileri üzerinde doğrusal olmayan dönüşüm işlemlerini gerçekleştirir. Ağın öğrenme yeteneğini artırmaya yarayan aktivasyon fonksiyonları bu katmanlarda kullanılır. Yapay sinir ağları genellikle denetimli öğrenme metodunu kullanarak çalışmaktadır. Denetimli öğrenme süreci şu üç adımı kapsar: İleri yayılma, hata hesaplama ve geri yayılma. Eğitilecek olan ağa girdi verileri verildiğinde bu veriler, eldeki ağırlıklarla çarpılarak çıkış katmanına kadar ilerler. Aktivasyon fonksiyonu kullanılarak bir çıktı üretilir. Daha sonra, çıkış katmanında elde edilen değer ile gerçek çıktı karşılaştırılır ve bir hata fonksiyonu hesaplanır. Bu fonksiyon, modelin ne kadar iyi eğitildiğine dair bilgi verir. Bu değer minimuma indirilmesi için geriye yayılım algoritması kullanılır. Bu süreçte belli optimizasyon yöntemleri kullanılarak ağırlıklar güncellenir ve hata fonksiyonu minimize edilir. Böylelikle ağın sonuçta ürettiği çıktı gerçek değere daha fazla yaklaşır. Şekil 4.6’da yapay sinir ağı modellenmesi görülmektedir. Yapay sinir ağlarında bulunan girdi katmanı, gizli katmanlar ve çıktı katmanı şekilde görülmektedir.



Şekil 4.6 : Yapay sinir ağları (Altunbas, 2020).

4.3.4 Katman, model ve kayıp fonksiyonu

Katmanlar, modeller ve kayıp fonksiyonları, derin öğrenmenin temel yapı taşlarını oluşturur. Sinir ağları, katmanların sıralı bir şekilde düzenlenmesiyle inşa edilir. Giriş katmanında, girdi verileri alınır, işleme tabi tutulur ve çıkışa aktarılır. Giriş katmanı, verinin modele dahil olduğu ilk katmandır. Örneğin, bir görüntünün her pikseli bir giriş nöronu olarak kabul edilebilir. Gizli katmanlar, girdi ve çıktı katmanları

arasındaki katmanlar olup, sinir ağlarında genellikle birden fazla gizli katman bulunur. Gizli katmanlar, ReLU, sigmoid ve tanh gibi aktivasyon fonksiyonlarıyla çalışır. Gizli katmanlar üç ana türe ayrılır: tam bağlantılı katmanlar, konvolüsyonel (Conv2D) katmanlar ve RNN (Recurrent Neural Network – Tekrarlayan Sinir Ağı) veya LSTM (Long Short-Term Memory – Uzun Kısa Süreli Bellek) katmanları. Tam bağlantılı katmanlarda, her nöron bir diğer nöronla bağlantı içerisindedir. Konvolüsyonel katmanlar, özellikle görüntü verileriyle çalışıldığında, görüntülerdeki belirli alanların özelliklerini çıkarma işlevi görür. RNN ve LSTM katmanları ise dizi türünden veriler ve zaman serileri üzerinde işlem yapar.

Çıkış katmanı, oluşturulan modelin son katmanıdır ve modelin tahmin ettiği sonuçları verir. Bu katmanda da aktivasyon fonksiyonları kullanılabilir. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında softmax, sigmoid ve doğrusal fonksiyonlar yer alır. İkili sınıflandırma problemlerinde sigmoid, birden fazla sınıf içeren sınıflandırma problemlerinde softmax ve regresyon problemlerinde doğrusal fonksiyon tercih edilir. Katmanlar bir araya gelerek modelin yapısını oluşturur.

Modeller, başlangıçta belirlenen problemi çözmeye yönelik tasarlanır ve farklı model türleri bulunur. Sıralı (Sequential) modelde katmanlar ardışık olarak eklenir ve bu tür, genellikle basit modellerde tercih edilir. Fonksiyonel model ise daha karmaşık ve dallanan mimarilerin oluşturulmasına olanak tanır. Ayrıca, ResNet, VGG, EfficientNet gibi önceden eğitilmiş modeller de mevcuttur. Bu modeller, büyük veri setleriyle eğitildikten sonra daha küçük veri setleri ile de başarılı sonuçlar verebilme kapasitesine sahiptir ve farklı problemler için yeniden kullanılabilirler.

Kayıp fonksiyonu, modelin çıktı katmanında üretilen tahminlerin gerçek sonuçlarla karşılaştırılmasının ardından, aradaki farkı ölçen bir fonksiyondur. Bu değer, modelde minimum seviyeye indirilmeye çalışılır. Sınıflandırma, regresyon ve özel amaçlı kayıp fonksiyonları mevcuttur. Sınıflandırma problemleri için İkili Çapraz Entropi (Binary Crossentropy), Kategorik Çapraz Entropi (Categorical Crossentropy) ve Seyrek Kategorik Çapraz Entropi (Sparse Categorical Crossentropy) gibi kayıp fonksiyonları kullanılırken, regresyon problemleri için Ortalama Kare Hatası (Mean Squared Error – MSE) ve Ortalama Mutlak Hata (Mean Absolute Error – MAE) gibi fonksiyonlar tercih edilir. Ayrıca, özel amaçlı kayıp fonksiyonları arasında Hinge Kaybı (Hinge Loss) ve Özel Kayıp Fonksiyonu (Custom Loss) yer alır. Hinge kaybı, Destek Vektör Makineleri (Support Vector Machine – SVM) gibi doğrusal sınıflandırma yapan

algoritmalar için kullanılır. Hinge kaybı, sınıf sınır çizgisine olan uzaklığı en üst düzeye çıkarmayı amaçlar ve tahminin yanlış olması durumunda modele büyük cezalar uygular. Özel kayıp fonksiyonu ise probleme özel olarak tasarlanır. Kullanıcılar, bazı hatalara daha fazla ceza vermek ya da belirli durumlarda farklı hesaplamalar yapmak için bu fonksiyonu özelleştirebilir.

4.3.5 Optimizasyon algoritmaları

Derin öğrenmede optimizasyon algoritmaları, modelin doğruluğunu, öğrenme hızını ve verimliliğini maksimum seviyeye çıkarmak için kullanılır. Optimizasyon algoritmasının seçimi, oluşturulan modelin karmaşıklığına, modele sunulan verilerin türüne ve modelin eğitim sürecindeki gereksinimlerine göre belirlenir. Doğru optimizasyon algoritması seçimi, modelin başarısını doğrudan etkilemektedir. Optimizasyon algoritmalarına Stokastik Gradyan İnişi (SGD – Stochastic Gradient Descent), Momentum, AdaGrad (Uyarlanabilir Gradyan Algoritması - Adaptive Gradient Algorithm), RMSprop (Root Mean Square Propagation – Karekök Ortalama Kare Yayılımı), Adam (Uyarlanabilir Moment Tahminleme - Adaptive Moment Estimation), Nadam (Nesterov-accelerated Adaptive Moment Estimation – Nesterov Hızlandırılmış Uyarlanabilir Moment Tahminleme), Adadelta, L-BFGS (Limited-memory Broyden-Fletcher-Goldfarb-Shanno – Sınırlı Bellekli Broyden-Fletcher-Goldfarb-Shanno) algoritmaları örnek olarak verilebilir.

Stokastik Gradyan İnişi Algoritması her aşamada yalnızca bir örneği kullanarak modelde bulunan parametreler üzerinde güncellemeler yapar. Her aşamada gradyan değeri hesaplanır ve öğrenme oranıyla bu değer çarpılır. Daha sonra modeldeki parametreler, bu gradyan değeriyle güncellenir. Her seferinde tüm veri seti üzerinde çalışmak yerine bir örnek üzerinde çalıştığı için büyük veri setlerinde kullanılmaya elverişlidir.

Momentum algoritması, Stokastik Gradyan İniş algoritmasının iyileştirilmiş halidir. Her iterasyonda bir önceki iterasyonda elde edilmiş olan gradyanların modele olan etkisine bakar. Sıklıkla değişen gradyan değerlerinin olduğu modellerde sürecin daha hızlı işlemesine yardımcı olur. Gradyan değerlerinin ortalamasını alır ve daha kararlı bir yakınsama gerçekleştirir. Yerel minimum değerlerine takılan modeller için önemli bir optimizasyon algoritmasıdır.

Uyarlanabilir Gradyan Algoritması (AdaGrad), parametrelerin güncellenme oranına göre adım atar. AdaGrad algoritmasının amacı her paramtereye büyük güncellemeler sağlamaktır. Bu sebeple sık sık güncellenen parametrelerde daha küçük, daha nadir güncellenen parametrelerde daha büyük adımlar atma mantığıyla çalışır. Öğrenme oranı sürekli olarak küçülmektedir.

RMSprop (Karekök Ortalama Kare Yayılımı) algoritması, AdaGrad algoritmasının eksik yanlarını gidermek için geliştirilmiş bir algoritmadır. AdaGrad'da öğrenme oranının sürekli küçülmesi, modelin optimizasyonu açısından kötüdür ve sürecin sonlanmasına sebep olur. Öğrenme oranının sabit kalmasını sağlaması sebebiyle daha uzun zaman alan öğrenme süreçlerinde kullanılır. Bunun için hareketli ortalamayı kullanır.

Adam (Uyarlanabilir Moment Tahminleme), RMSprop ve momentum algoritmalarının birleşimiyle oluşmuştur. Parametre sayısının fazla olduğu büyük veri setlerinde etkili bir optimizasyon algoritmasıdır. Otomatik olarak parametreleri optimize ettiğinden, öğrenme oranının ayarlanması gerekmeyen durumlarda sıklıkla tercih edilir.

4.4 Yapay Öğrenme Temelleri

Yapay öğrenme temelleri, algoritmaların hangi mantık üzerine çalıştığını anlamamızı sağlayacak birkaç temel ilkedен oluşur. Bu temel ilkeler şunlardır;

Veri: Derin öğrenme modeli oluşturmak ve bu modelleri eğitmek için gerekli en temel yapı taşıdır. Büyük, dengeli ve etiketi bulunan veri setleri genellikle iyi sonuçlar vermektedir. Ses, görüntü, metin gibi farklı formatta veriler olabilmektedir.

Özellik: Derin öğrenmede özellik çıkarımını, kurulan model yapmaktadır. Önceden etiketlenmiş verilerin modele verilmesine gerek yoktur. Örneğin görüntüdeki piksellerin çeşitli özelliklerini öğrenir ve buna göre çıkarım yapar.

Katmanlar: Derin öğrenmede oluşturulan modeller katmanlardan oluşur. Giriş katmanı, gizli katmanlar ve çıkış katmanlarını içerir.

Eğitim: Modelin eğitimi, girişte ağı sunulan verilerin katmanlar boyunca ilerlemesi ve elde edilen hataların minimize edilerek ağırlıkların güncellenmesi süreciyle gerçekleşir.

Kayıp fonksiyonu: Modelden elde edilen çıktılar ile gerçek etiketleri karşılaştırarak bunların arasındaki farkı ölçen fonksiyonlardır.

Genelleme: Derin öğrenme modellerinde aşırı öğrenme (overfitting) meydana gelmemesi için model, genelleme yaparak öğrenir.

Transfer öğrenme: Daha önce büyük veri setleri ile eğitilmiş olan modellerin, daha sonrasında benzer bir görevde kullanılmasını sağlar. Özellikle küçük veri setlerinin kullanılması gereken durumlarda, önceden ağırlıkları belirlenmiş olan modellerin kullanılması, daha iyi performans gösterebilmektedir.

4.4.1 Denetimli ve denetimsiz öğrenme

Derin öğrenmede, modellerin eğitimi aşamasında, modele verilen verinin türüne göre denetimli ve denetimsiz öğrenme olarak iki yaklaşım bulunmaktadır.

Denetimli öğrenme, veriler modele verilirken önceden etiketlenerek verilen yaklaşım türüdür. Çıkışta elde edilen sonuçlarla girişte sunulan verinin etiketi karşılaştırılır, böylelikle modelin giriş ve çıkış verileri arasında nasıl bir ilişki kurduğu öğrenilir. Denetimli öğrenme sınıflandırma ve regresyon için kullanılır. Sınıflandırma, verilerin kategorilere ayrılmasını sağlarken, regresyon süreklilik içeren değerlerin tahmini için kullanılır. Denetimli öğrenmede Yapay Sinir Ağları (ANN), Konvolüsyonel Sinir Ağları (CNN) ve Tekrarlayan Sinir Ağları (RNN) en sık kullanılan algoritmalar arasında yer almaktadır.

Denetimsiz öğrenmede verilerin etiketi önceden modele verilmez. Model, etiketsiz verilerle çalışarak bu verileri ortak özelliklerine, birbirlerine yakınlıklarına göre gruplara ayırır. Bunların arasında bulunan örüntüleri ve gizli yapıları keşfetmeye çalışır. Denetimsiz öğrenme, kümeleme ve boyut indirgeme alanlarında sıklıkla kullanılır. Örneğin pazarlama alanında kullanılmak üzere müşteri verileri etiketsiz olarak modele verilir ve bu müşteriler, benzer özelliklerine göre gruplara ayrılabilir. Denetimsiz öğrenmede Otomatik Kodlayıcılar (Autoencoders), Üretici Çekişmeli Ağlar (Generative Adversarial Networks – GAN) ve K-Ortalamlar (K-Means) yöntemleri yer almaktadır.

Denetimli ve denetimsiz öğrenmenin karşılaştırılması Çizelge 4.1’de yapılmaktadır.

Çizelge 4.1 : Denetimli ve denetimsiz öğrenmenin karşılaştırılması.

Özellik	Denetimli Öğrenme	Denetimsiz Öğrenme
Veri Türü	Önceden etiketlenmiş veri	Etiketlenmemiş veri
Amaç	Giriş verileriyle, modelin ürettiği çıktı verileri arasındaki ilişkiyi çözmek	Veriler arasındaki örüntüleri ve gizli yapıları keşfetmek
Çıkış Bilgisi	Çıkış katmanında verilen çıktının doğruluğu bilinir.	Çıkışlar önceden bilinmez.
Kullanım Alanları	Sınıflandırma, regresyon	Kümeleme, boyut indirgeme

4.4.2 Başarı ölçütleri

Araştırmacılar, geliştirdikleri modellerin performanslarını değerlendirmek için bazı ölçümler kullanırlar. Bu ölçümlerin her biri, araştırılan konunun ihtiyacına göre farklı değerlendirmeler sunmaktadır. Doğruluk metriği, en genel kullanılan performans metriğidir. Bunun dışında kesinlik (precision), hassasiyet (sensitivity), özgüllük (specificity), duyarlılık (recall), F1-skor gibi metrikler de kullanılmaktadır.

Karışıklık matrisi, algoritmalarla yapılan eğitimlerin performansını sayısal olarak görmemize yarayan bir araçtır. Doğruluk, kesinlik (precision), duyarlılık ve F-puanı gibi çeşitli performans ölçümlerinin hesaplanmasına izin vererek gerçek ve tahmin edilen sınıflandırmaların görsel bir temsiliyi sağlar. Geleneksel karışıklık matrisi, her örneğin tek bir sınıfa atandığı çok sınıflı sınıflandırma görevlerinde özellikle etkilidir (Heydarian ve diğ, 2023).

Bununla birlikte, örneklerin birden çok sınıfa ait olabileceği çoklu etiketli sınıflandırma senaryolarında, standart matrisin sınırlamalarını ele almak için bir Çoklu Etiketli Karışıklık Matrisi (MLCM) önerilmiştir (Heydarian ve diğ, 2023). Ek olarak, belirsizliği değerlendirme sürecine dahil ederek performans analizini geliştirmek için olasılıksal bir karışıklık matrisi kavramı tanıtılmıştır (Markoulidakis ve Markoulidakis, 2024). Karışıklık matrisinin bu evrimi, özellik ilişkilendirme yöntemleri de dahil olmak üzere çeşitli sınıflandırma bağlamlarında uyarlanabilirliğini ve önemini vurgulamaktadır (Arias-Duart ve diğ, 2023).

Faydasına rağmen, karışıklık matrisi bazen, özellikle belirli sınıfların metriklere hakim olabileceği ve daha az sıklıkta sınıfların performansını potansiyel olarak gizleyebileceği dengesiz veri kümeleri durumlarında yanlış yorumlara yol açabilir.

TP (Doğru Pozitif): Pozitif olarak tahmin edilen verilerin gerçekten pozitif olma durumudur.

FP (Yanlış Pozitif): Pozitif olarak tahmin edilen verilen gerçekte negatif olma durumudur.

TN (Doğru Negatif): Negatif olarak tahmin edilen verilerin gerçekte negatif olma durumudur.

FN (Yanlış Negatif): Negatif olarak tahmin edilen verilerin gerçekte pozitif olma durumudur.

4.4.2.1 Doğruluk (Accuracy)

Yapay zeka projelerinde yapılan eğitimin doğruluğunu ölçmek önemlidir. Bunun için Doğruluk metriği kullanılmaktadır. Bu metriğin hesaplanması için, sınıfı doğru tahmin edilen verilerin, tüm verilere bölünmesi gerekmektedir (Denklem 4.4).

$$\text{Doğruluk} = (TP+TN)/(TP+TN+FP+FN) \quad (4.4)$$

Ancak doğruluk metriği her zaman kesin sonuç vermemektedir. Homojen olmayan veri setlerinde doğruluk yüksek çıkabilir ancak gerçekleri yansıtmama olasılığı bulunmaktadır. Model seçimi yaparken doğruluk metriği ile beraber başka metriklere de bakmak gerekmektedir.

4.4.2.2 Kesinlik (Precision)

Kesinlik (precision) metriği, pozitif olarak tahmin edilenlerinin ne kadarının gerçekten pozitif olduğunu belirten bir metriktir (Denklem 4.5). Örneğin posta kutusuna gelen elektronik postaları gereksiz (spam) olarak işaretlendiği durumlarda, eğer gerekli olan postalar da spam olarak işaretlenmişse bu, kişinin gerekli postaları kaçırmaya sebep olacaktır. Bu sebeple spam olarak işaretlenmiş postaların ne kadarının gerçekten spam olduğu bu noktada önemlidir. Kesinlik (precision) metriğinin bu durumda yüksek olması demek, spam olarak işaretlenenlerin büyük bir çoğunluğu gerçek anlamda spam elektronik postalardır anlamına gelmektedir.

$$\text{Kesinlik} = \text{TP} / (\text{TP} + \text{FP}) \quad (4.5)$$

4.4.2.3 Duyarlılık (Recall)

Duyarlılık (recall) metriği, gerçekte pozitif olan verilerin ne kadarını pozitif olarak tahmin edebiliğimizi gösteren bir metriktir (Denklem 4.6). Örneğin, gerçekte kanser olan hastaların ne kadarına kanser teşhisi koyabildiğimizi görmek için önemli bir metriktir. Bu oran yüksekse, teşhis konulan kişilere doğru teşhis konulduğu da rahatça söylenebilmektedir. Yüksek duyarlılık (recall) değeri, kanser hastalarını gözden kaçırma olasılığını azaltır.

$$\text{Duyarlılık} = \text{TP} / (\text{TP} + \text{FN}) \quad (4.6)$$

4.4.2.4 F1 skoru

F1-Skor değeri, duyarlılık (recall) ve kesinlik (precision) metriklerinin harmonik olarak ortalamasını göstermektedir (Denklem 4.7). Normal bir ortalama yerine harmonik ortalama alınmasının sebebi, uç noktalardaki durumları da gözden kaçırmamayı amaçlamaktır. Doğruluk metriği yerine F1 -skor metriğini kullanmak bu sebeple daha sağlıklıdır. Eşit dağılmamış olan veri kümelerinde doğruluk yüksek çıkabilir ancak F1-skor metriği homojenlik durumunu gözettiği için daha doğru bir model seçimi yapmaya yardımcı olmaktadır.

$$\text{F1 Skoru} = 2 * (\text{kesinlik} * \text{duyarlılık}) / (\text{kesinlik} + \text{duyarlılık}) \quad (4.7)$$

4.4.3 Veri artırma

Veri artırma (data augmentation), makine öğrenmesi ve derin öğrenme modellerinde aşırı öğrenme (overfitting) problemini önlemek ve modelin genelleme yeteneğini artırmak amacıyla kullanılan etkili bir yöntemdir. Bu yöntem, mevcut görüntü verilerine çeşitli dönüşümler uygulanarak yeni veri örnekleri türetilmesi ve böylece veri setinin çeşitlendirilmesi ve boyutunun artırılması esasına dayanır. Döndürme, yansıtma, kırpma, parlaklık seviyelerinin değiştirilmesi, perspektif dönüşümleri gibi işlemler, görüntü verisi üzerinde uygulanan yaygın dönüşüm yöntemleridir. Bu işlemler sonucunda elde edilen yeni veri örnekleri, eğitim veri setine eklenerek modelin daha geniş bir varyasyonla eğitilmesi sağlanır.

Veri artırma teknikleri, modelin performansını ve genelleme yeteneğini artırmada önemli bir rol oynasa da, doğru uygulanmadığında bazı sınırlamalar ve riskler ortaya çıkabilmektedir. Örneğin, görüntüler üzerinde yapılan dönüşümlerin odaklanması gereken önemli alanları etkisiz hale getirmesi veya modelin gereksiz detayları öğrenmesine neden olması durumunda, modelin beklenen performansı sergileyememesi olasıdır. Bununla birlikte, veri artırma işleminin kontrollü ve doğru bir şekilde uygulanması, modellerin performansında anlamlı bir artış sağlamaktadır. Bu bağlamda, veri artırma stratejilerinin dikkatli bir şekilde tasarlanması ve problem bağlamına uygun dönüşüm tekniklerinin seçilmesi kritik öneme sahiptir.

4.4.4 Aşırı öğrenme (overfitting), eksik öğrenme (underfitting)

Aşırı öğrenme ve az öğrenme, derin öğrenmede ve makine öğrenmesinde modeller eğitilirken sıkça karşılaşılan sorunlardandır.

Aşırı öğrenme (overfitting), eğitilen modele verilen girdileri ezberlemesidir. Eğitim veri setinde yüksek doğruluk verirken, ilk defa karşılaştığı test veri setinde düşük performans sergilemektedir. Yeni gelen verilere genelleme yapamamaktadır. Veri setinde sürekli aynı türde verilerin tekrar etmesi, az veri olması, modelin parametrelerinin fazla olması, çok karmaşık bir veri seti olması, çeşitlilik içermeyen veri seti olması gibi durumlarda aşırı öğrenme ile karşı karşıya kalılabilmektedir. Eğitim veri setinden elde edilen sonuçlarda hata oranı düşük, test veri setinden elde edilen sonuçlarda ise hata oranı yüksek olduğunda aşırı öğrenmeden şüphelenilmelidir. Düzenleştirme teknikleri kullanma, veri artırma, model karmaşıklığını azaltma, daha fazla eğitim verisi kullanma gibi yöntemlerle aşırı öğrenmenin önüne geçilebilmektedir.

Az öğrenme (underfitting), modelin veri setindeki temel bağlantıları ve ilişkileri öğrenememesi durumudur. Hem test hem de eğitim veri setinden alınan sonuçlarda hatalar yüksektir. Oluşturulan modelin basit olması, yeterli eğitim süresinin verilmemesi, özellik çıkarımının yanlış veya yetersiz yapılması gibi sebeplerden dolayı az öğrenme durumu ortaya çıkabilir. Eğitim ve test veri setlerinde doğruluk düşük, hata oranı yüksek çıkmaktadır. Daha geniş ve karmaşık bir model kurmak, eldeki verileri anlamlandırarak yeni özellikler elde etmek, daha uzun eğitim süreci kurgulamak, kullanılan hiperparametreleri modele uygun ayarlamak gibi yöntemlerle az öğrenme sorunu çözülebilmektedir.

4.4.5 Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, yapay sinir ağlarının doğrusal olmayan ilişkileri öğrenebilmesini sağlamak amacıyla, her katmanda hesaplanan çıktıyı matematiksel bir dönüşüme tabi tutar. Bu fonksiyonlar, eğitilen modelin veri setindeki karmaşık ilişkileri anlamasına olanak tanıyarak modelin genelleme yeteneğini artırır ve daha yüksek performans elde edilmesini mümkün kılar.

Aktivasyon fonksiyonları, doğrusal, doğrusal olmayan ve çoklu sınıflandırma problemleri için kullanılan türlere ayrılmaktadır. Doğrusal olmayan aktivasyon fonksiyonları arasında Sigmoid, Tanh (Hiperbolik Tanjant), ReLU (Rectified Linear Unit – Düzeltilmiş Doğrusal Ünite), Leaky ReLU (Sızıntılı Düzeltilmiş Doğrusal Ünite), ELU (Exponential Linear Unit – Üstel Doğrusal Birim) ve Swish öne çıkan örneklerdir. Bu fonksiyonlar, modelin doğrusal olmayan ilişkileri öğrenmesini sağlayarak daha karmaşık problemlerin çözümüne katkı sunar.

Softmax aktivasyon fonksiyonu, hem doğrusal olmayan bir yapıya sahip olması hem de çoklu sınıflandırma problemleri için özel olarak tasarlanması nedeniyle, özellikle bu tür problemler için tercih edilmektedir. Doğrusal aktivasyon fonksiyonları, girdiyi herhangi bir dönüşüme uğratmadan doğrudan çıktı olarak veren Doğrusal Aktivasyon Fonksiyonu (Linear Activation) ile temsil edilmektedir. Bu fonksiyonlar genellikle regresyon problemlerinde kullanılmaktadır. Aktivasyon fonksiyonlarının detaylı açıklaması Çizelge 4.2’de görülmektedir.

Çizelge 4.2 : Aktivasyon kodları.

Aktivasyon Fonksiyonu	Tanım	Avantajlar	Dezavantajlar	Tür
Sigmoid	Giriş değerini 0 ile 1 arasına sıkıştırır.	Çıktılar olasılık olarak yorumlanabilir.	Gradyan kaybı problemi yaşanabilir.	Doğrusal olmayan
Tanh	Giriş değerini -1 ile 1 arasına sıkıştırır.	Modelin dengeli öğrenmesini sağlar.	Gradyan kaybı problemi yaşanabilir.	Doğrusal olmayan
ReLU	Pozitif girdileri olduğu gibi alırken negatif girdileri sıfırlar.	Hesaplama maliyeti düşüktür. Gradyan kaybı olmaz.	Ölü nöron problemi yaşanabilir.	Doğrusal olmayan

Çizelge 4.2 (devam) : Aktivasyon fonksiyonları.

Aktivasyon Fonksiyonu	Tanım	Avantajlar	Dezavantajlar	Tür
Leaky ReLU	Negatif giriş değerlerini küçük bir çarpanla geçirir.	ReLU'nun ölü nöron problemini azaltır.	Çarpan değeri her veri setinde optimize edilmelidir.	Doğrusal olmayan
Softmax	Çıkış değerlerini olasılığa çevirir.	Çoklu sınıflandırma problemine yarar.	Hesaplama maliyeti yüksektir.	Doğrusal olmayan
ELU	Negatif girdilere üstel bir dönüşüm uygular.	ReLU'ya göre dengeli gradyan sağlar.	Hesaplama maliyeti yüksektir.	Doğrusal olmayan
Swish	Sigmoid ve doğrusal bileşimden oluşur.	ReLU'dan daha iyi performans gösterebilir.	Hesaplama maliyeti yüksektir.	Doğrusal olmayan
Doğrusal Aktivasyon Fonksiyonu	Girdi verisini olduğu gibi çıkış olarak verir.	Hesaplama maliyeti düşük. Regresyon için uygun.	Doğrusal olmayanlık sağlamadığı için sınırlıdır.	Doğrusal

Sonuç olarak, aktivasyon fonksiyonlarının seçimi, problemin niteliği ve modelin ihtiyaçlarına bağlıdır. Uygun fonksiyonların seçilmesi, modelin veri setindeki karmaşık ilişkileri öğrenme kapasitesini ve genelleme başarısını önemli ölçüde artırmaktadır.

5. TRANSFER ÖĞRENME

Transfer öğrenme, derin öğrenme modellerinin bir problem hakkında elde ettiği bilgiyi başka bir problemi çözmek amacıyla o problemin alanına aktarmasını sağlayan bir yöntemdir. Nispeten daha az verinin bulunduğu veri setlerinin eğitiminde, daha önce daha büyük veri setleri ile eğitilmiş modellerin tekrar kullanılması, performansı artırmak için önemlidir. Daha önce eğitilen modelin ağırlıkları tekrar kullanılır. Böylelikle yeni eğitimin hem süresi daha az olur hem de daha az veriyle daha iyi performans sergiler. Transfer öğrenme, derin öğrenme modellerinin yeniden kullanılabilirliğini ve esnekliğini göstermede önemli bir yoldur. ResNet, EfficientNet, DenseNet, VGG, AlexNet gibi transfer öğrenme modelleri mevcuttur. Herbirinin farklı katman içeren sürümleri bulunmaktadır.

5.1 ResNet50 Mimarisi


ResNet50, derin öğrenme mimarileri arasında öne çıkan ve görüntü tanıma ile sınıflandırma gibi görevlerde sıkça tercih edilen bir modeldir. Microsoft Research tarafından 2015 yılında ImageNet yarışmasındaki etkileyici başarısından sonra geliştirilmiş olan bu model, derin öğrenmede yeni bir standart belirlemiştir. ResNet'in yapısı, "artık öğrenme" yöntemi olarak bilinen bir teknikle daha basit ve daha yüksek doğruluğa sahip modellerin elde edilmesine olanak tanıyarak, artan derinlikteki modellerde doğruluk oranlarının yükselmesini sağlamıştır.

ResNet50, 50 katmana ulaşan bir konvolüsyonel sinir ağı mimarisidir ve adındaki "50" ifadesi, modelin katman sayısını belirtir. ResNet'in temelinde, "artık" (residual) yapı olarak bilinen bir özellik yer alır. Bu yapı, her katmandan gelen çıktının aynı katmanın girdisine eklenmesi yoluyla çalışır. Artık bloklar, katmanlar arasında kimlik eşlemesi (identity mapping) sağlayarak doğrudan bağlantılar oluşturur; böylece model, girdiyi yalnızca bir sonraki katmana iletmekle kalmaz, aynı zamanda "atlama" yaparak daha sonraki katmanlara doğrudan ulaşmasını sağlar.

ResNet50, dört ana bloktan oluşur ve bu blokların her biri farklı sayıda katman içerir. Bu bloklar; konvolüsyonel (evrişimli) katmanlar, kaydırmalı ortalama havuzlama

(strided average pooling), ve tam bağı (fully connected) bir katman gibi bileşenlerden meydana gelir. ResNet50'nin temel bileşenleri “İlk Konvolüsyonel Katman”, “Artık Bloklar”, “Tam Bağlantılı Katman” ve “Softmax”tir. İlk Konvolüsyonel Katman, 7x7 boyutunda bir filtre içerir ve ardından max pooling uygulanır. Artık Bloklar, toplamda 16 artık bloktan oluşur ve bu bloklarda 1x1, 3x3 ve 1x1 boyutlarında konvolüsyon filtreleri bulunur. Tam Bağlantılı Katman ve Softmax katmanı, modelin son aşamasında yer alır ve sınıflandırma için olasılık çıktıları üretir.

ResNet50, görüntü sınıflandırması, yüz tanıma ve bitki hastalıklarının teşhisi gibi çeşitli alanlarda eğitim verimliliğini ve doğruluğu artıran bir derin evrişimli sinir ağı (CNN) mimarisidir. Yapısı, 49 evrişimli katman ve bir tam bağı katmandan oluşur ve bu özellik, kaybolan gradyan problemine karşı etkin bir çözüm sunarak çok derin ağların eğitilmesine olanak tanır (Liu, 2024). ResNet50, torba sınıflandırması gibi görevlerde %98 doğruluk oranına ulaşmış (Singla ve diğ., 2024) ve görüntü sahteciliğini yüksek bir doğruluk oranıyla tespit etmiştir (Naidu ve diğ., 2024). Ayrıca, saçılma ortamındaki optik parametrelerin çıkarımı gibi spesifik alanlarda çok yönlülüğünü kanıtlamış (Deng ve diğ., 2024) ve transfer öğrenimiyle yakınsamayı hızlandırarak hastalık teşhisi gibi alanlarda doğruluğu artırmıştır (Desanamukula ve diğ., 2024). Genel olarak, ResNet50'nin sağlam mimarisi ve yenilikçi tasarımı, onu derin öğrenme alanında güçlü bir araç haline getirmektedir.




Şekil 5.1 : ResNet50 model mimarisi (Mukherjee, 2023).

5.2 EfficientNetB0 Mimarisi

EfficientNetB0 2019 yılında Google tarafından tanınmış olup EfficientNet serisinin en temel modelidir. Evrişimli sinir ağı (CNN) yapısında yenilikçi bir bakış açısı sunar. Bu mimarinin temel özelliği, doğruluğu artırırken aynı zamanda hesaplama yükünü dengelemeye yönelik geliştirilmiş ölçekleme tekniğidir. Bu teknik, eş zamanlı olarak modelin derinlik, çözünürlük ve genişliğini uyumlu şekilde büyütür. Böylelikle daha az parametre ile yüksek performanslar elde etmeyi hedefler. EfficientNetB0, düşük

güç gerektiren mobil platformlarda çalışmak üzere optimize edilmiştir ve Mobil Tersine Dar Boğaz Konvolüsyonu (Mobile Inverted Bottleneck Convolution – MBConv) katmanları üzerine inşa edilmiştir. Mimaride bulunan katmanlar parametreleri ve giriş verisini daha verimli bir şekilde kullanmak için sıkıştırır. Böylelikle veri kaybını minimize etmiş olur. Sonuç olarak EfficientNetB0, büyük veri setleri ile eğitimde yüksek enerji verimliliği ve daha az hesaplama gereksinimi sunmaktadır.

EfficientNetB0, özellikle tıbbi görüntülemelerde görüntü sınıflandırma görevleri için tasarlanmış son teknoloji evrişimli sinir ağı mimarisidir. Derinliği, genişliği ve çözünürlüğü en iyi şekilde dengeleyen bir bileşik ölçekleme yöntemi kullanır ve geleneksel modellere kıyasla daha az parametreyle daha iyi performans sağlar. EfficientNetB0, %99,5 eğitim doğruluğu ve %92,2 validasyon doğruluğu ile pnömoni tespiti gibi çeşitli uygulamalarda dikkate değer doğruluk göstermiştir (Singh ve diğ., 2024). Ek olarak, sigara içen gözetim sistemlerinde %92,78 (Sharma ve diğ., 2024) doğruluk elde edilerek ve akut lenfoblastik lösemiye %98,48 (Fajrina ve diğ., 2024) test doğruluğu ile sınıflandırmada etkili bir şekilde kullanılmıştır. Çok yönlülüğü diyabetik retinopati tanısına kadar uzanır ve %91 (Anand ve diğ., 2024) doğrulukla diğer modellerden daha iyi performans gösterir. Mimarinin verimliliği ve uyarlanabilirliği, onu tıbbi teşhis ve görüntü analizinde değerli bir araç haline getirerek çeşitli sağlık uygulamalarında potansiyelini sergilemektedir. EfficientNetB0'nın mimarisi Şekil 5.2'de görüldüğü gibidir.




Şekil 5.2 : EfficientNetB0 model mimarisi (Alhichri ve diğ., 2021).

5.3 DenseNet121 Mimarisi

DenseNet121, katmanlar arasında verimli özelliklerin yeniden kullanılmasına izin veren yoğun bağlantı modeli ile karakterize edilen evrişimli bir sinir ağı mimarisidir.

Bilgi kaybını önlemek amacıyla yoğun bağlantılar mantığını kullanır. Her bir katman, kendinden önce gelen katmanların çıktısını tekrar kullandığından dolayı, eğitilecek olan model daha az parametre ile daha yüksek başarı sergileyebilir. DenseNet121, 121 katmandan oluşur. Görüntü sınıflandırma, nesne tespiti gibi alanlarda başarılı olduğundan dolayı, tarım, atık sınıflandırması, işaret dili tanıma ve tıbbi teşhis dahil olmak üzere çeşitli alanlarda başarıyla uygulanmıştır. Tarımda DenseNet121, geleneksel CNN'lerden daha iyi performans göstererek mahsul yaprağı hastalıklarının tanımlanması için %98,27'lik bir eğitim doğruluğu elde etti. Atık yönetiminde atık türlerini genel doğruluk %93 (Zulhusni ve diğ,2024) ile sınıflandırmıştır. İşaret dili tanıma için %97'lik dikkate değer bir doğruluk gösterdi (Dabwan ve diğ, 2024). Ek olarak, retinal hastalık tespitinde, ince ayarlanmış bir DenseNet121 modeli %93,68'lik bir eğitim doğruluğuna ulaştı (Kaur ve diğ, 2024).

Bu uygulamalar, modelin karmaşık görüntü sınıflandırma görevlerini yerine getirmedeki çok yönlülüğünü ve etkinliğini vurgulayarak çeşitli alanlarda potansiyelini sergiliyor. Bununla birlikte, DenseNet121 güçlü performans gösterirken, InceptionResNetV2 gibi diğer mimarilerin, derin sahte algılama gibi belirli görevlerde daha da yüksek doğruluk sağladığı bildirilmiştir, bu da model seçiminin belirli uygulama gereksinimlerine bağlı olabileceğini gösterir (Manoranjitham & Swaroop, 2024). DenseNet121'in model mimarisi Şekil 5.3'de görüldüğü gibidir.




Şekil 5.3 : DenseNet121 model mimarisi (DeepKapha Notes, 2021).

5.4 VGG16 Mimarisi

VGG16 veya Görsel Geometri Grubu 16, görüntü sınıflandırma görevlerinde derin öğrenme yetenekleri ile ünlü bir evrişimli sinir ağı (CNN) mimarisidir. VGG16 toplamda 16 adet aktman içerir. Bu katmanlardan 3'ü tam bağlantılı katman, 13'ü ise

konvolüsyon katmanıdır. Bu derinliği sayesinde, eğitilen modelin daha soyut ve karmaşık özellikleri kolayca öğrenebilmesi sağlanır. Konvolüsyon katmanları 3x3 boyutunda sabit filtre boyutlarına sahiptir. Böylelikle, modelin parameter sayısı optimize edilirken aynı zamanda derin bir mimari kurulması amaçlanır. Havuzlama işlemlerinde 2x2'lik filtreler kullanılır. Bu yapılan filtreleme, boyut azaltılmasını sağlamaktadır. Konvolüsyon katmanları, giriş verisinin fiziksel boyutlarını korurken özellik haritaları oluşturmaktadır. Maksimum havuzlama ile, bu özellik haritalarının boyutları aşamalı olarak küçültür. Böylelikle maliyet azaltılır. Sadece en belirgin özellikler ortaya çıkarılır. VGG16'nın mimarisi oldukça basit ve düzenlidir. Yaklaşık olarak 138 milyon parametresi bulunmaktadır. Bu sebeple yüksek bellek gereksinimi duymaktadır. Başlangıçta genel görüntü tanıma için geliştirilen VGG16, tarımsal hastalık tespiti, bitki türlerinin tanımlanması, tıbbi görüntü sınıflandırması ve uydu görüntüsü analizi dahil olmak üzere çeşitli uygulamalar için uyarlanmıştır. Mimarisi, görüntülerden özellikleri etkili bir şekilde çıkaran ve sınıflandırma doğruluğunu artıran birden fazla evrişimli katmandan oluşur. Mimarisi, çok yönlülüğünü gösteren pamuk yaprağı hastalığı sınıflandırması (Walia ve diğ, 2024) , bitki türleri tespiti (Praveen ve diğ, 2024) ve tıbbi görüntü sınıflandırması (Ismail ve diğ, 2024) gibi belirli görevler için optimize edilmiştir. Anahtar uygulamalar şunları içerir: Tarımsal uygulamalar, tıbbi görüntüleme, uzaktan algılama.

Güçlü yönlerine rağmen, VGG16'nın karmaşıklığı, kaynak kısıtlı ortamlarda kullanımını sınırlayabilecek yüksek hesaplama taleplerine yol açabilir. Bununla birlikte, devam eden araştırmalar, çeşitli alanlarda daha geniş uygulanabilirlik için mimarisini düzene sokmayı amaçlamaktadır. VGG16'nın katman yapısı Şekil 5.4'de görüldüğü gibidir.




Şekil 5.4 : VGG16 model mimarisi (Neurohive, 2023).

5.5 VGG19 Mimarisi

VGG19, özellikle görüntü sınıflandırması ve stil aktarımında çeşitli uygulamalarda öne çıkan bir evrişimli sinir ağı (CNN) mimarisidir. Görüntülerden etkili bir şekilde özellikleri çıkarmasını sağlayan 19 katmandan oluşan derin yapısı ile karakterizedir. Birden fazla evrişimli katmana, havuzlama katmanına ve tam bağlantılı katmana sahiptir. VGG19, yara sınıflandırması gibi görevlerde yüksek doğruluk göstermiştir ve dokuz sınıf bir yara sınıflandırma sisteminde % 82,4 doğruluk elde etmiştir (Lee ve diğ., 2024). Ek olarak, üzüm yaprağı hastalığı tespiti için tarımsal ortamlarda başarıyla uygulanmıştır ve burada %98 (Bj ve diğ., 2024) etkileyici bir doğruluk elde edilmiştir. Ayrıca, VGG19, farklı görüntülerden içerik ve stili birleştirmede, canlı ve ayrıntılı çıktılar üretmede mükemmel olduğu Neural Style Transfer'de kullanılır (Xu, 2024). Genel olarak, VGG19'un çok yönlülüğü, onu hem tıbbi hem de yaratıcı alanlarda değerli bir araç haline getirerek görüntüyle ilgili çeşitli görevlerdeki etkinliğini gösterir.

Güçlü yönlerine rağmen, VGG19'un derin mimarisi artan hesaplama taleplerine yol açabilir ve bu da kaynak kısıtlı ortamlarda uygulanabilirliğini sınırlandırabilir. Alternatif modeller, model seçiminde dengeli bir yaklaşıma duyulan ihtiyacı vurgulayarak belirli görevler için daha verimli çözümler sunabilir. VGG19'un model mimarisi Şekil 5.5'de görüldüğü gibidir.



Şekil 5.5 : VGG19 model mimarisi (Khattar ve Quadri, 2022).

6. MATERYAL VE METOT

Bu bölümde, yapılan çalışmada kullanılan veri setleri ve kullanılan donanım hakkında bilgi verilmiştir.

6.1 Veri Setleri

Bu çalışmada iki adet CESM görüntü içeren veri seti kullanılmıştır. Bunlar CDD-CESM veri seti ve CESM@UCBM veri setidir.

6.1.1 CDD-CESM veri seti

CESM, hastalardaki yoğun meme dokularında kanser olup olmadığını tespit etmede dijital mamografinin (DM) yetersiz kaldığı noktalarda kullanılan daha yeni ve başarılı bir görüntüleme tekniğidir. Hastaya damardan iyotlu kontrast madde verilerek görüntüleme ile takip edilmesine dayanmaktadır. CESM görüntülemeye yüksek ve düşük enerjili görüntüler birlikte kullanılarak meme dokusunun belirginleştirilmesiyle elde edilen bileşik görüntüler yer alır. Düşük enerjili görüntüler, mamografi görüntülemesi sırasında X-ışınlarının düşük seviyede gönderilmesiyle elde edilir. 20-35 keV aralığında gönderilen bu ışınlar ile, memedeki yumuşak doku ve kalsifikasyon olan bölgeler daha net görülebilmektedir. Düşük seviyeli X-ışını, memedeki kontrastı artırdığı için küçük anormallikler daha iyi görülmektedir. Bileşik görüntüler ise yüksek ve düşük enerjili görüntüler matematiksel bir algortimayla birleştirilerek elde edilmektedir. Bu işlem, ikili enerji ayrıştırma ile gerçekleştirilir. Düşük enerjili görüntüden elde edilen bilgiler, arka plan bilgileridir. Yüksek enerjili görüntüler ise kontrastlı maddenin biriktiği bölge hakkında bilgi verir. Bu iki görüntü arasındaki fark hesaplanarak arka plan çıkartılır ve kontrastlı maddenin belli olduğu bölge kalır.

CDD-CESM veri setinde (Khaled ve diğ., 2022) toplamda 2006 adet görüntü bulunmaktadır. 326 kadından çeşitli özelliklerde çekilmiş dijital mamografi ve CESM görüntülerini içermektedir. Görüntüler her kadın için her meme tarafında bileşik ve düşük enerjili CESM görüntüleri olacak şekilde MLO (Mediolateral Oblique - Mediolateral Oblik) ve CC (Craniocaudal – Kranial-kudal) açılardan görüntülemeler

yapılmıştır. Bu görüntüler, çeşitli lezyonları taşımaktadır. 751 tanesi normal görüntü olan bu veri setinde, 159 adet ameliyat sonrası görüntü, 184 adet kitle dışı geliştirme görüntüsü, 310 adet kitle görüntüsü, 222 adet asimetri görüntüsü, 48 adet yapısal bozulma görüntüsü, 8 adet kemoterapi sonrası görüntüsü, 238 adet kalsifikasyon görüntüsü ve 334 adet kitle geliştirme görüntüsü içermektedir.

Veri setinde aynı zamanda, Amerikan Radyoloji Koleji Meme Görüntüleme, Raporlama ve Veri Sistemi (ACR BIRADS) 2013 sözlüğüne göre yapılan raporlar ve anotasyonlar bulunmaktadır. Bu anotasyonlar, kitlenin yoğunluğu, şekli, kenarı, yapısal bozukluğu, asimetri, kalsifikasyon dağılımı ve türü, geliştirme paterni gibi tanımları da içermektedir. Anotasyonlarda her hasta için el ile yapılan muayeneler ve tıbbi raporlar da bulunmaktadır. CDD-CESM veri seti, CESM görüntüleri içeren halka açık bir veri setidir. Derin öğrenme tabanlı modellerin geliştirilmesi için halka açık olarak sunulan sınırlı verilerdendir.

Çizelge 6.1 : CDD – CESM veri seti görüntü sayıları.

	Normal	İyi Huylu	Kötü Huylu
Görüntü Sayısı	757	587	662

Çizelge 6.2 : CDD – CESM veri seti düşük enerjili ve bileşik görüntü sayıları.

	Düşük Enerjili	Bileşik
Görüntü Sayısı	1003	1003

6.1.2 CESM@UCBM veri seti

CESM@UCBM veri seti (Rofena ve diğ, 2023) İtalya’da bulunan Fondazione Policlinico Campus Bio-Medico’da 2021-22 yıllarında elde edilen 1138 CESM görüntüsünden oluşmaktadır. 105 hastadan alınan 569 DES (Dual Energy Subtracted – Çift Enerji İle Çıkarma) görüntü ve 569 LE (Düşük Enerjili) görüntü içerir. CESM görüntüler, hastanın her iki memesi içinde MLO (Mediolateral Oblique) ve CC (Craniocaudal) açılardan görüntüleme yapılarak elde edilmiştir. Bu görüntülerin 984 tanesi 2850 x 2396, 154 tanesi 2294 x 1916 piksel boyutlarındadır.

Yaş ortalaması 57,4 olan kadın hastaların yaşları 31-90 arasında değişmektedir. Amerikan Radyoloji Koleji (ACR) sınıflamasına göre hastaların meme dokusunun yoğunlukları değerlendirilmiştir ve 4 adet kategoride sınıflandırılmıştır. 130 adet görüntü “neredeyse tamamen yağlı dokular”, 360 görüntü “dağınık fibroglandüler

yoğunluk”, 414 görüntü “heterojen yoğunluk”, 190 görüntü “aşırı yoğun dokular” olarak sınıflandırılmıştır. Geriye kalan 44 görüntünün ise kategorisi ACR olarak belirtilmemiştir.

Veri setinde bulunan 258 görüntüde kötü huylu (malignant) lezyonu, 104 görüntüde iyi huylu (benign) lezyonu ve 16 görüntüde sınırda (borderline) lezyon saptanmıştır. Bu lezyonlar tıbbi raporlar ve biyopsi sonuçları ile doğrulanmıştır.

Veri setindeki düşük enerjili görüntüler, dijital mamografi görüntülerine benzemektedir. DES görüntülerde memedeki kontrastlı alanlar vurgulanır ve bu da memedeki sorun içeren lezyonların görüntülenmesini daha iyi hale getirmektedir.

Bu veri setinin üretilmesinin asıl amacı, hastaya kontrastlı madde vermeden, düşük enerjili görüntülerden yapay olarak DES görüntüler üretmektir. Bu sayede hastaya verilen kontrast maddenin oluşturduğu riskler ve hastanın aldığı yüksek radyasyon dozu gibi olumsuz koşullar azaltılabilir.

Çizelge 6.3 : CESM@UCBM veri seti görüntü sayıları.

	Normal	İyi Huylu	Kötü Huylu
Görüntü Sayısı	760	104	274

Çizelge 6.4 : CESM@UCBM veri seti düşük enerjili ve bileşik görüntü sayıları

	Düşük Enerjili	Bileşik
Görüntü Sayısı	569	569

6.2 Kullanılan Donanım

Model eğitimi sırasında hem Google Colab platformu hem de yerel bir bilgisayar kullanılmıştır. Google Colab, Google tarafından sunulan, bulut tabanlı bir derin öğrenme geliştirme ortamıdır. Eğitim sürecinde, Colab’ın "Pro" sürümü tercih edilerek 25 GB’a kadar yükseltilebilen RAM kapasitesinden yararlanılmıştır. Bu sayede, büyük veri kümeleri ve yüksek boyutlu modellerin eğitimi daha verimli bir şekilde gerçekleştirilmiştir. Ayrıca, Colab’ın sunduğu NVIDIA Tesla T4 veya P100 GPU donanımları, modelin paralel işlemlerle hızla eğitilmesine olanak sağlamıştır.

Yerel olarak model eğitimi ve denemeleri için kullanılan bilgisayarın özellikleri ise şu şekildedir:

-İşlemci: 11. Nesil Intel(R) Core(TM) i7-11800H @ 2.30GHz, 8 çekirdek ve 16 iş parçacığı

-Ekran Kartı: NVIDIA GeForce RTX 3050 Ti Laptop GPU ve Intel(R) UHD Graphics

- Çekirdek Frekansı: 210 MHz

- Bellek Frekansı: 405 MHz

- Bellek (RAM): 15,8 GB

- Depolama Aygıtı: Samsung MZVL21T0HCLR-00B00, NVMe SSD, 1TB

Google Colab'ın yüksek RAM ve GPU desteği, özellikle büyük veri kümeleriyle yapılan model eğitiminde önemli bir avantaj sağlamıştır. Bunun yanı sıra, yerel bilgisayarın güçlü işlemci ve GPU kombinasyonu, küçük ölçekli işlemler ve kodlama görevleri için etkin bir destek sunmuştur.



7. BULGULAR VE YORUMLAR

Bu bölümde, veri setlerinin nasıl ele alındığına, nasıl eğitildiğine ve eğitimlerin sonuçlarına odaklanılmıştır. Bu çalışmada, CESM görüntüleme tekniğiyle elde edilmiş meme görüntüleri üzerinden, derin öğrenme yöntemleri kullanılarak kanser tespiti yapmak amaçlanmıştır. Bu işlemler için iki adet veri seti ve beş adet transfer öğrenme mimarisi kullanılmıştır. Ardından sonuçlar karşılaştırılmıştır. Veri setlerindeki görüntüler düşük enerjili ve bileşik görüntü olmak üzere ikiye ayrılmaktadır. Veri setinde bulunan görüntülerin 2 farklı türde olması ile, veri setlerinin 2 sınıflı (iyi huylu ve kötü huylu) ve 3 sınıflı (normal, iyi huylu ve kötü huylu) olarak ele alınması, modellerin 20 farklı şekilde eğitilmesine olanak tanımıştır.

Veri setleri ayrı ayrı olarak 3 sınıflı ve 2 sınıflı olarak eğitilmiştir. Ardından bu veri setleri artırılarak algoritmalara tekrar verilmiştir. Daha sonra veri setleri birleştirilip tekrar 3 sınıflı ve 2 sınıflı olarak önce artırmadan, sonra da artırılarak eğitilmiştir. Son olarak veri setleri düşük enerjili ve bileşik görüntü olarak ayrı ayrı 3 sınıflı ve 2 sınıflı şekilde önce artırılmadan, daha sonra da artırılarak test edilmişlerdir. Bu şekilde veri setleri 20 farklı yolla ele alınmış ve detaylı olarak incelenmiştir.

Veri setleri üçer sınıftan oluşmaktadır; iyi huylu, kötü huylu ve normal. Veri setleri, verilen raporlara göre öncelikle sınıflara ayrılmıştır. Ardından ilk olarak CDD-CESM veri seti ele alınmış ve herhangi bir veri artırımı yapılmadan üç sınıflı olarak her bir mimaride eğitilmiştir. Doğru sonuç verebilmesi için veri seti k-çapraz doğrulama yöntemiyle beşe ayrılmış ve bu şekilde eğitimler gerçekleştirilmiştir. Verilerin %80'i eğitim, %20'si test verisi olarak kullanılmıştır.

7.1 Veri Setlerinin Farklı Ele Alımları

Bu çalışmada kullanılan iki veri seti, elde edilen sonuçların yüksek doğruluk vermesi amacıyla, toplamda 20 farklı şekilde ele alınmıştır. Ele alım şekilleri, veri setinin barındırdığı verilerin sınıf sayısına, sentetik veri üretilip üretilmediğine, veri setlerinin birleştirilip birleştirilmediğine göre ayrıştırılmış ve bunlara göre 5 adet transfer

öğrenme modeline (EfficientNetB0, ResNet50, DenseNet121, VGG16 ve VGG19) eğitilmek üzere verilmiştir. Veri setlerinin ele alım şekilleri ve türetilen veri setinin etiketi Çizelge 7.1’de belirtilmiştir.

Çizelge 7.1 : Veri setlerinin farklı ele alımları.

Veri Kümesi	Sınıf Sayısı	Veri Türü	Sentetik Veri	Türetilen Veri Setinin Etiketi	Modeller
CDD-CESM	3 Sınıflı	Ham Veri	Yok	TD1	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM	2 Sınıflı	Ham Veri	Yok	TD2	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM	3 Sınıflı	Ham Veri	Herbir sınıftan 3000 adet	TD3	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM	2 Sınıflı	Ham Veri	Herbir sınıftan 3000 adet	TD4	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CESM@UCBM	3 Sınıflı	Ham Veri	Yok	TD5	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CESM@UCBM	2 Sınıflı	Ham Veri	Yok	TD6	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CESM@UCBM	3 Sınıflı	Ham Veri	Herbir sınıftan 3000 adet	TD7	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19

Çizelge 7.1 (devam): Veri setlerinin farklı ele alımları.


Veri Kümesi	Sınıf Sayısı	Veri Türü	Sentetik Veri	Türetilen Veri Setinin Etiketi	Modeller
CESM@UCBM	2 Sınıflı	Ham Veri	Herbir sınıftan 3000 adet	TD8	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	3 Sınıflı	Birleştirilmiş Veri	Yok	TD9	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	2 Sınıflı	Birleştirilmiş Veri	Yok	TD10	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	3 Sınıflı	Birleştirilmiş Veri	Herbir sınıftan 3000 adet	TD11	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	2 Sınıflı	Birleştirilmiş Veri	Herbir sınıftan 3000 adet	TD12	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	3 Sınıflı	Düşük Enerjili Görüntüler	Yok	TD13	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	3 Sınıflı	Bileşik Görüntüler	Yok	TD14	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	3 Sınıflı	Düşük Enerjili Görüntüler	Herbir sınıftan 3000 adet	TD15	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19

Çizelge 7.1 (devam): Veri setlerinin farklı ele alımları.


Veri Kümesi	Sınıf Sayısı	Veri Türü	Sentetik Veri	Türetilen Veri Setinin Etiketi	Modeller
CDD-CESM+ CESM@UCBM	3 Sınıflı	Bileşik Görüntüler	Herbir sınıftan 3000 adet	TD16	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	2 Sınıflı	Düşük Enerjili Görüntüler	Yok	TD17	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	2 Sınıflı	Bileşik Görüntüler	Yok	TD18	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	2 Sınıflı	Düşük Enerjili Görüntüler	Herbir Sınıftan 3000 Adet	TD19	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19
CDD-CESM+ CESM@UCBM	2 Sınıflı	Bileşik Görüntüler	Herbir Sınıftan 3000 Adet	TD20	EfficientNetB0, ResNet50, DenseNet121, VGG16, VGG19

7.2 CDD-CESM Veri Seti İle Elde Edilen Sonuçlar

CDD-CESM veri seti ile üç sınıflı ve iki sınıflı olacak şekilde eğitimler gerçekleştirilmiştir. Üç sınıflı olarak etiketlenen veri setinde “Normal”, “İyi Huylu” ve “Kötü Huylu” olarak çıktılar sınıflandırılmıştır. İki sınıflı olan veri setinde ise “Normal” etiketi kaldırılarak sadece “İyi Huylu” ve “Kötü Huylu” etiketli verilerle eğitimler gerçekleştirilmiştir. Veri setlerinin her bir ele alım şekillerinde aynı zamanda veri artırma yöntemleri uygulanmış ve bu artırılmış veri setleri tekrar aynı mimariler üzerinde eğitilmiştir. CDD-CESM veri setinde bulunan görüntülerin tipi Şekil 7.1 ve Şekil 7.2’de görülmektedir.



Şekil 7.1 : CDD-CESM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli düşük enerjili görüntüler.



Şekil 7.2 : CDD-CESM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli bileşik görüntüler.

7.2.1 Üç sınıflı model eğitimi sonuçları

CDD-CESM veri setinde yapılan üç sınıflı eğitimlerde performanslar iyi sonuç getirmediği için veri seti sentetik yöntemlerle artırılmıştır. Bunun için ImageDataGenerator kullanılarak piksel değerleri 0-1 aralığına getirilmiş, görüntüler ± 40 derece döndürülmüş, yatay ve dikeyde %20 oranında kaydırılmış, $\pm$ %20 kayma (shearing) uygulanmış, $\pm$ %20 oranında yakılaştırma ve uzaklaştırma yapılmış, görüntüler yatay olarak çevrilmiş ve yeni alanları doldurmak için ‘nearest’ metodu kullanılmıştır.

Çizelge 7.2 : CDD-CESM veri seti 3 sınıflı eğitim sonuçları.

	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,7110	0,5074	0,3533	0,3500	0,3500
ResNet50	0,8319	0,4828	0,3900	0,3900	0,3900
DenseNet121	0,6484	0,4729	0,3433	0,3367	0,3333
VGG16	0,7144	0,4828	0,3300	0,3300	0,3267
VGG19	0,7121	0,5172	0,2967	0,2967	0,2933

Bu şekilde 10803 görüntü elde edilmiştir. Ardından tekrar bu veriler modellere verilerek eğitim gerçekleştirilmiştir. Artırılmadan ve artırılmış eğitim sonuçları Çizelge 7.2 ve Çizelge 7.3’de görülmektedir.

Çizelge 7.3 : CDD – CESM veri setinde veriler artırılarak 3 sınıflı eğitim sonuçları.

	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,7188	0,4926	0,3334	0,3367	0,3300
ResNet50	0,7154	0,5271	0,3167	0,3233	0,3167
DenseNet121	0,5556	0,4483	0,3067	0,3067	0,2933
VGG16	0,5905	0,4975	0,3433	0,3400	0,3433
VGG19	0,5848	0,4778	0,3367	0,3333	0,3100

CDD-CESM veri setinin üç sınıflı olarak eğitildiği durumlarda metriklerin değerlerinin çok düşük çıktığı görülmektedir. Görüntülerin büyük bir çoğunluğu “normal” olarak tahmin edilmektedir.

7.2.2 İki sınıflı model eğitimi sonuçları

Üç sınıflı olarak yapılan eğitimlerde verilerin “Normal” olarak tahmin edilmesi sebebiyle veri setinden “Normal” etiketli veriler çıkartılıp kalan veriler tekrar eğitilmiştir. Daha sonra görüntüler ± 40 derece döndürülmüş, yatay ve dikeyde %20 oranında kaydırılmış, $\pm$ %20 kayma (shearing) uygulanmış, $\pm$ %20 oranında yakılaştırma ve uzaklaştırma yapılmış, görüntüler yatay olarak çevrilmiş ve yeni alanları doldurmak için ‘nearest’ metodu kullanılmıştır. Her bir sınıf 3000 adet artırılmıştır. Artırılmadan ve artırılmış eğitim sonuçları Çizelge 7.4 ve Çizelge 7.5’de görülmektedir.

Çizelge 7.4 : CDD – CESM veri seti 2 sınıflı eğitim sonuçları.


	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,7818	0,6825	0,5000	0,4394	0,4677
ResNet50	0,8629	0,6111	0,4918	0,4545	0,4724
DenseNet121	0,7622	0,5952	0,5510	0,4091	0,4695
VGG16	0,7988	0,5556	0,5834	0,5303	0,5556
VGG19	0,7649	0,6349	0,6764	0,3484	0,4601

Çizelge 7.5 : CDD – CESM veri setinde veriler artırılarak 2 sınıflı eğitim sonuçları.

	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,7681	0,6508	0,5344	0,4696	0,5000
ResNet50	0,8244	0,6746	0,5438	0,4696	0,5041
DenseNet121	0,7088	0,6429	0,5714	0,3030	0,3960
VGG16	0,7320	0,6508	0,5417	0,3939	0,4561
VGG19	0,7247	0,6667	0,5147	0,5303	0,5224

7.3 CESM@UCM Veri Seti İle Elde Edilen Sonuçlar

CESM@UCBM veri seti ile üç sınıflı ve iki sınıflı olacak şekilde eğitimler gerçekleştirilmiştir. Üç sınıflı olarak etiketlenen veri setinde “Normal”, “İyi Huylu” ve “Kötü Huylu” olarak çıktılar sınıflandırılmıştır. İki sınıflı olan veri setinde ise “Normal” etiketi kaldırılarak sadece “İyi Huylu” ve “Kötü Huylu” etiketli verilerle eğitimler gerçekleştirilmiştir. Veri setlerinin her bir ele alım şekillerinde aynı zamanda veri artırma yöntemleri uygulanmış ve bu artırılmış veri setleri tekrar aynı mimariler üzerinde eğitilmiştir. CESM@UCBM veri setindeki görüntülerin tipi Şekil 7.3 ve Şekil 7.4’de görülmektedir.




(a)

(b)

(c)

Şekil 7.3 : CESM@UCBM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli düşük enerjili görüntüler.



(a)

(b)

(c)

Şekil 7.4 : CESM@UCBM veri setinde iyi huylu (a), kötü huylu (b) ve normal (c) etiketli bileşik görüntüler.

7.3.1 Üç sınıflı model eğitimi sonuçları

İkinci veri seti olan CESM@UCBM veri setine de CDD-CESM veri setine uygulanan yöntemler uygulanmış ve aynı şekilde derin öğrenme algoritmalarına verip eğitimleri yapılmıştır. 3 sınıflı olarak gerçekleştirilen eğitimlerde aynı zamanda artırma uygulanarak da sonuçlar karşılaştırılmıştır. Her bir sınıf 3000'er artırılmış ve toplamda 9910 adet görüntü elde edilmiştir. Sonuçları Çizelge 7.6 ve 7.7'de belirtilmiştir.

Çizelge 7.6 : CESM@UCBM veri seti 3 sınıflı eğitim sonuçları.

	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,9538	0,6754	0,3200	0,3200	0,3200
ResNet50	0,9538	0,6754	0,3200	0,3200	0,3200
DenseNet121	0,8264	0,6447	0,4800	0,3600	0,3500
VGG16	0,8747	0,6140	0,3100	0,3300	0,3100
VGG19	0,9538	0,6754	0,3200	0,3200	0,3200

Çizelge 7.7 : CESM@UCBM veri setinde verilere artılarak 3 sınıflı eğitim sonuçları.

	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,8077	0,6579	0,2800	0,2900	0,2800
ResNet50	0,9582	0,6930	0,3100	0,3300	0,3200
DenseNet121	0,8209	0,7105	0,3500	0,3800	0,3700
VGG16	0,8209	0,7105	0,3500	0,3800	0,3700
VGG19	0,8538	0,6535	0,3100	0,3300	0,3200

7.3.2 İki sınıflı model eğitimi sonuçları

Üç sınıflı olarak yapılan eğitimlerde verilerin “Normal” olarak tahmin edilmesi sebebiyle veri setinden “Normal” etiketli veriler çıkartılıp kalan veriler tekrar eğitilmiştir. Daha sonra görüntüler ± 40 derece döndürülmüş, yatay ve dikeyde %20 oranında kaydırılmış, $\pm$ %20 kayma (shearing) uygulanmış, $\pm$ %20 oranında yakılaştırma ve uzaklaştırma yapılmış, görüntüler yatay olarak çevrilmiş ve yeni alanları doldurmak için ‘nearest’ metodu kullanılmıştır.

Çizelge 7.8 : CESM@UCBM veri seti 2 sınıflı eğitim sonuçları.

	Eğitim	Test	Kesinlik	Duyarlılık	F1-Skor
	Doğruluğu	Doğruluğu	(Precision)	(Recall)	
EfficientNetB0	0,8133	0,6741	0,7616	0,9143	0,8292
ResNet50	0,9105	0,7071	0,7772	0,8998	0,8329
DenseNet121	0,7909	0,7198	0,7646	0,9535	0,8481
VGG16	0,8440	0,6597	0,7514	0,8789	0,8093
VGG19	0,8359	0,6772	0,7514	0,8784	0,8093


Her bir sınıf 3000 adet artırılmıştır. Artırılmadan ve artırılmış eğitim sonuçları Çizelge 7.8 ve Çizelge 7.9’da görülmektedir. Sonuçlar incelendiğinde 0,9535 duyarlılık

(recall) skoruyla şimdiye kadarki en iyi sonucu DenseNet121 mimarisiyle 2 sınıflı olarak eğitilen CESM@UCBM veri setinde aldığımız görülmektedir. En iyi sonucu DenseNet121 mimarisi verdiği için Şekil 7.5’de karışıklık matrisini de sunmaktayız.

Doğru Pozitif 35	Yanlış Pozitif 11
Yanlış Negatif 2	Doğru Negatif 25

Şekil 7.5 : CESM@UCBM veri setinde 2 sınıflı olarak gerçekleştirilen eğitimlerde en iyi sonucu veren DenseNet121 mimarisinin karışıklık matrisi.

Eğitmiş olduğumuz modelin, sınıfını doğru tahmin ettiği ve edemediği iki görüntü şekil 7.6’da örnek olarak gösterilmiştir. Doğru tahmin edilebilen görüntüde (Şekil 7.6 (b)) lezyon açıkça görülebilirken, doğru tahmin edilemeyen görüntüde (Şekil 7.6 (a)) görüntüleme açısının dar olması sebebiyle modelimizin yanlış tahmin etmiş olabileceğini öngörmekteyiz.



(a)

(b)

Şekil 7.6 : CESM@UCBM veri setinde kötü huylu olup model tarafından iyi huylu olarak tahmin edilen (a) ve kötü huylu olup model tarafından kötü huylu olarak tahmin edilen (b) görüntüler.

Yanlış tahmin edilen görüntüler, genellikle sınıf sınırına yakın örnekler, düşük kaliteli görseller veya verideki etiket hatalarından kaynaklanmaktadır. Yanlış tahmin analizi, modelin performansını iyileştirmek için önemlidir.

Çizelge 7.9 : CESM@UCBM veri setinde veriler artırılarak 2 sınıflı eğitim sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,8872	0,6849	0,7321	0,7454	0,7387
ResNet50	0,9426	0,7397	0,7222	0,7091	0,7156
DenseNet121	0,7777	0,5736	0,7654	0,6603	0,6951
VGG16	0,8486	0,6120	0,7560	0,7567	0,6951
VGG19	0,8349	0,6986	0,7636	0,7636	0,7636

7.4 İki Veri Setinin Birleşimi İle Elde Edilen Sonuçlar

Bu aşamadan sonra veri setleri birleştirilmiş ve eğitimlere bu şekilde devam edilmiştir. Öncelikle veri artırma işlemi yapmadan, 3 sınıflı ve 2 sınıflı olarak eğitim gerçekleştirilmiştir. 3 sınıflı olarak gerçekleştirilen eğitimlerde toplam görüntü sayısı 2844, 2 sınıflı olarak gerçekleştirilen eğitimlerde toplam görüntü sayısı 1415'tir.

7.4.1 Üç sınıflı model eğitimi sonuçları

İki veri setini birleştirdiğimiz de yüksek doğruluk değerleri elde edilmediği görülmektedir. Görüntülerin DataImageGenerator ile artırımının etkisinin olup olmayacağını görmek için daha önce kullanılan parametrelerle görüntü artırma yapılmıştır. Artırarak elde edilen yeni veri setinde 3 sınıflı olarak yapılan eğitimlerde toplam görüntü sayısı 11844'dır. Artırılarak elde edilen 2 sınıflı yeni veri setinde ise görüntü sayısı 7415'dir. Bu görüntüler tekrardan aynı mimarilere verilmiş ve eğitim gerçekleştirilmiştir. Üç sınıflı olarak eğitilen verilerin sonuçları Çizelge 7.10 ve Çizelge 7.11'de görülmektedir.

Çizelge 7.10 : İki veri setinin birleşimiyle 3 sınıflı eğitim sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7215	0,4600	0,3100	0,3200	0,2900
ResNet50	0,7215	0,4600	0,3100	0,3200	0,2900
DenseNet121	0,6821	0,4267	0,2900	0,3000	0,2600
VGG16	0,7338	0,4333	0,3000	0,3100	0,3000
VGG19	0,7131	0,4267	0,3400	0,3333	0,3100

Çizelge 7.11 : İki veri setinin birleşimiyle artırılarak 3 sınıflı eğitim sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7370	0,4633	0,3800	0,3500	0,3200
ResNet50	0,8235	0,4500	0,3600	0,3500	0,3400
DenseNet121	0,6821	0,4267	0,2900	0,3000	0,2600
VGG16	0,7338	0,4333	0,3000	0,3100	0,3000
VGG19	0,7226	0,4533	0,3100	0,3100	0,3000

7.4.2 İki sınıflı model eğitimi sonuçları

Veri setinden “Normal” etiketi çıkarılarak 2 sınıflı olarak yapılan eğitimlerden elde edilen sonuçlar Çizelge 7.12 ve Çizelge 7.13’de görülmektedir. Sonuçların tatmin edici olmadığı görülmektedir. İki veri setini birleştirdiğimizde aşırı öğrenme (overfitting) olduğu hem 3 sınıflı hem de 2 sınıflı olarak yapılan eğitimlerde görülmektedir.

Çizelge 7.12 : İki veri setinin birleşimiyle 2 sınıflı eğitim sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7943	0,6800	0,4909	0,5400	0,5142
ResNet50	0,8770	0,6500	0,5250	0,6300	0,5727
DenseNet121	0,8225	0,6500	0,4767	0,4100	0,4409
VGG16	0,8071	0,5850	0,4579	0,4900	0,4734
VGG19	0,7823	0,6600	0,4694	0,4600	0,4646

Çizelge 7.13 : İki veri setinin birleşimiyle artırılarak 2 sınıflı eğitim sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7694	0,6450	0,5052	0,4900	0,4977
ResNet50	0,8225	0,6500	0,4767	0,4100	0,4409
DenseNet121	0,8225	0,6500	0,4767	0,4100	0,4409
VGG16	0,8071	0,5850	0,4549	0,4900	0,4734
VGG19	0,8225	0,6500	0,4767	0,4100	0,4409

7.4.3 Düşük enerjili (low energy) görüntülerle yapılan eğitimlerin sonuçları

Yapılan eğitimlerin ardından görüntüler “düşük enerjili” ve “bileşik görüntü” olarak ikiye ayrılmış ve bu şekilde de eğitimler hem 2 sınıflı hem de 3 sınıflı olarak eğitilmişlerdir. 3 sınıflı düşük enerjili görüntülerin sayısı 1400’dür. 2 sınıflı düşük enerjili görüntülerin sayısı 745’tir. Önceki eğitimlerde olduğu gibi bu eğitimlerde de veri setleri veri artırma yöntemleri uygulanarak artırılmıştır. Görüntülerin piksel değerleri 0-1 aralığına getirilmiş, görüntüler ± 40 derece döndürülmüş, yatay ve dikeyde %20 oranında kaydırılmış, $\pm$ %20 kayma (shearing) uygulanmış, $\pm$ %20 oranında yakılaştırma ve uzaklaştırma yapılmış, görüntüler yatay olarak çevrilmiş ve yeni alanları doldurmak için ‘nearest’ metodu kullanılmıştır.

7.4.3.1 Üç sınıflı model eğitimi sonuçları

Düşük enerjili görüntüler üzerinde eğitim gerçekleştirdiğimizde yine overfitting olduğu ve çıktıların “Normal” olarak tahmin edildiği tespit edilmiştir. Yapılan bu eğitimlerin sonuçları Çizelge 7.14 ve Çizelge 7.15’de görülmektedir.

Çizelge 7.14 : İki veri setindeki toplam düşük enerjili görüntüleri ile 3 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7286	0,5407	0,3200	0,3200	0,3000
ResNet50	0,8779	0,4128	0,3200	0,3600	0,3200
DenseNet121	0,7157	0,5407	0,3500	0,3500	0,3300
VGG16	0,7850	0,5174	0,3300	0,3400	0,3100
VGG19	0,7464	0,4651	0,3100	0,3200	0,2900

Çizelge 7.15 : İki veri setindeki toplam düşük enerjili görüntüler artırılarak 3 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7357	0,5465	0,4800	0,4400	0,4300
ResNet50	0,8407	0,5465	0,3800	0,3800	0,3600
DenseNet121	0,7100	0,5000	0,3500	0,3400	0,3400
VGG16	0,7686	0,5349	0,4900	0,4500	0,4400
VGG19	0,7686	0,5349	0,4900	0,4500	0,4400

7.4.3.2 İki sınıflı model eğitimi sonuçları

Düşük enerjili görüntülerle iki sınıflı olarak veri artırma uygulanmadan ve uygulayarak eğitilen verilerin sonuçları Çizelge 7.16 ve Çizelge 7.17’de verilmiştir. “Normal” sınıfını çıkartıp tekrar eğitim yapıldığında, artırmadan yapılan eğitimlerde EfficientNetB0 mimarisinin diğerlerine göre nispeten daha iyi sonuç verdiği görülmektedir.

Çizelge 7.16 : İki veri setindeki toplam düşük enerjili görüntüler ile 2 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7919	0,6600	0,5571	0,7800	0,6500
ResNet50	0,8846	0,6700	0,5238	0,6600	0,5841
DenseNet121	0,7758	0,6600	0,5429	0,7600	0,6333
VGG16	0,8282	0,5800	0,5395	0,8200	0,6508
VGG19	0,8201	0,6300	0,5068	0,7400	0,6016

Çizelge 7.17 : İki veri setindeki toplam düşük enerjili görüntüler artırılarak 2 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7827	0,6600	0,4722	0,6800	0,5573
ResNet50	0,8468	0,6500	0,4921	0,6200	0,5487
DenseNet121	0,7248	0,6800	0,5806	0,7200	0,6429
VGG16	0,7500	0,5500	0,4900	0,7000	0,5785
VGG19	0,7428	0,6500	0,5424	0,6400	0,5871

7.4.4 Bileşik (Recombined) görüntülerle yapılan eğitimlerin sonuçları

Bu aşamada düşük enerjili ve bileşik olarak ikiye ayrılan verilerden bileşik görüntüler üç sınıflı ve iki sınıflı olarak eğitilmiştir. Aynı zamanda hem üç sınıflı hem de iki sınıflı veriler artırılarak da performansları gözlemlenmiştir. Önceki eğitimlerde olduğu gibi bu eğitimlerde de veri setleri veri artırma yöntemleri uygulanarak artırılmıştır. Görüntülerin piksel değerleri 0-1 aralığına getirilmiş, görüntüler ± 40 derece döndürülmüş, yatay ve dikeyde %20 oranında kaydırılmış, $\pm$ %20 kayma (shearing) uygulanmış, $\pm$ %20 oranında yakılaştırma ve uzaklaştırma yapılmış, görüntüler yatay olarak çevrilmiş ve yeni alanları doldurmak için ‘nearest’ metodu kullanılmıştır.

7.4.4.1 Üç sınıflı model eğitimi sonuçları

Bileşik (Recombined) görüntüler ile, 3 sınıflı veriler artırılmadan ve artırılarak gerçekleştirilen eğitimlerinden elde edilen sonuçlar Çizelge 7.18 ve Çizelge 7.19’da gösterilmiştir. Sadece bileşik görüntülerin kullanıldığı eğitimlerde sonuçların iyi bir performans sergilemediği görülmektedir.

Çizelge 7.18 : İki veri setindeki toplam bileşik görüntüler ile 3 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7686	0,6188	0,3660	0,3630	0,3510
ResNet50	0,8832	0,5347	0,3600	0,3500	0,3500
DenseNet121	0,7131	0,5297	0,3231	0,3226	0,3228
VGG16	0,7964	0,5792	0,3600	0,3600	0,3500
VGG19	0,7927	0,5594	0,3372	0,3438	0,3246

Çizelge 7.19 : İki veri setindeki toplam bileşik görüntüler artırılarak 3 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7759	0,6188	0,3700	0,3600	0,3400
ResNet50	0,9044	0,5545	0,4100	0,3900	0,3900
DenseNet121	0,7146	0,5693	0,3800	0,3500	0,3400
VGG16	0,8095	0,6386	0,2800	0,2900	0,2700
VGG19	0,7854	0,5396	0,3700	0,3600	0,3600

7.4.4.2 İki sınıflı model eğitimi sonuçları

Bileşik (Recombined) görüntüler ile, 2 sınıflı veriler artırılmadan ve artırılarak gerçekleştirilen eğitimlerinden elde edilen sonuçlar Çizelge 7.20 ve Çizelge 7.21’de gösterilmiştir. Sadece bileşik görüntülerin kullanıldığı eğitimlerde sonuçların iyi bir performans sergilemediği görülmektedir. Artırmadan 2 sınıflı olarak eğitilen VGG19 modelinin duyarlılık (recall) değeri tatmin edici bir skor sağlamıştır.

Çizelge 7.20 : İki veri setindeki toplam bileşik görüntüler ile 2 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,8209	0,6500	0,4789	0,6800	0,5619
ResNet50	0,9343	0,6500	0,4935	0,7600	0,5984
DenseNet121	0,7866	0,6600	0,4861	0,7000	0,5738
VGG16	0,8284	0,7200	0,5535	0,6200	0,5849
VGG19	0,8164	0,6300	0,5634	0,8000	0,6612

Çizelge 7.21 : İki veri setindeki toplam bileşik görüntüler artırılarak 2 sınıflı olarak yapılan eğitimlerin sonuçları.

	Eğitim Doğruluğu	Test Doğruluğu	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skor
EfficientNetB0	0,7742	0,7442	0,4800	0,6700	0,5600
ResNet50	0,8345	0,6300	0,4900	0,6300	0,5400
DenseNet121	0,7000	0,6800	0,5900	0,7200	0,6500
VGG16	0,7200	0,5600	0,5200	0,6900	0,5900
VGG19	0,7316	0,6500	0,5424	0,6400	0,5900

8. SONUÇLAR VE ÖNERİLER

Makine öğrenmesi ve derin öğrenmenin kullanımının yaygınlaşmasıyla birlikte, kanserle ilgili çalışmalar da günümüzde hız kazanmıştır. Özellikle kadınlarda en sık görülen kanser türü olan meme kanserinin erken teşhisiyle birlikte hayatta kalımın arttığı çokça vakada gözlemlenmiştir. Erken teşhis için memedeki lezyonların henüz küçük boyutlardayken teşhis edilmesi gerekmektedir. Dijital mamografi (DM) ile çekilen görüntülerde küçük lezyonlar çok göze çarpmamakla birlikte, doktorların gözünden de kaçabilmektedir. Dijital mamografide kanserli bölge beyaz olarak gözükmemektedir. Görüntüleme esnasında beyaz olarak görünen süt kanalları gibi başka alanlarda olabilmektedir. Bu sebeple kanserli alan gözükmebilmektedir. Kontrast artırılmış spektral mamografi (CESM), aynı anda iki farklı şekilde görünüm oluşturabileceği ileri bir teknolojiye sahiptir. Hastaya damardan kontrastlı madde verilir ve memede bulunan damarlardaki ışımaları izlenir. Kanserli dokuyla karşılaşan kontrastlı madde, parlama yapar. Bu sayede o bölgede bir lezyon olduğu saptanır. Kontrast artırılmış spektral mamografide normal dokuların görünümü azaltılır ve süt bezleri örtülür. Sadece tümörlü bölgenin parladığı mamografi görüntüleri, kanserli bölgenin saptanmasını ciddi anlamda kolay hale getirir. Aynı anda elde edilen görüntülerden birisi düşük enerjili görüntüdür. Bu görüntü, dijital mamografi ile elde edilen görüntünün aynısıdır. Bir de yüksek enerjili görüntü elde edilir. Yüksek ve düşük enerjili görüntüler kullanılarak bileşik görüntü elde edilir ve sadece kontrast maddeninin parladığı alanlar ortaya çıkar. Hızlı, ucuz ve kolay ulaşılabilir bir teknolojidir. Nispeten yeni bir teknoloji olması sebebiyle bu konuda yapılan çalışmalar, dijital mamografi hakkında yapılan çalışmalardan daha azdır.

Bu araştırma, CESM görüntüleri ve derin öğrenme algoritmaları kullanılarak meme kanseri teşhisi için bir model üretmeyi amaçlamıştır ve bu konuda literatüre katkı sağlayacak niteliktedir. İki farklı veri seti kullanımı, düşük enerjili görüntü, bileşik görüntü ve çoklu şekilde görüntü kullanımı, farklı sınıf sayısında ele alım gibi yöntemler açısından kapsamlı bir tartışma sağlamaktadır. Farklı yollarla ele alınan veri setleri 20 şekilde bakış açısı sunmuştur. 5 adet transfer öğrenme mimarisi ile eğitimi

yapıldığında 100 farklı sonuç elde edilmiştir. Bu kadar çeşitli yönlerden veri setine bakılması, farklı bakış açılarının değerlendirilmesi için önemli bir araştırmadır.

CESM@UCBM veri setinde düşük enerjili ve bileşik görüntülerin beraber kullanılarak, ‘iyi huylu’ ve ‘kötü huylu’ olmak üzere iki sınıflı ve 5 çapraz doğrulamalı olarak yapılan eğitimde DenseNet121 mimarisi en iyi sonucu vermektedir. %79,09 eğitim doğruluğu veren DenseNet121 mimarisi, %84,81 F1-Skor değeri, %76,46 kesinlik (precision) değeri ve %95,35 duyarlılık (recall) değeri vermiştir. Bu metriklerden bizim çalışmamız için en önemli olanı duyarlılık (recall) değeridir. Çünkü duyarlılık (recall) metriği, kanser olan kişilerin kaçının modelimiz tarafından doğru tahmin edildiği kapasitesini bildirmektedir. Bu da neredeyse yüzde yüz değerine yaklaşmaktadır. Bu haliyle bir uzmanın çalışmalarına yardım edebilecek nitelikte bir duyarlılık (recall) ve F1-skor sonuçları vermiştir. Halka açık CESM görüntülerinin az bulunması, bu çalışmanın daha da ilerlemesini bir miktar engellemektedir. Gelecek çalışmalarda elde edilebilecek yeni CESM görüntülerinin eklenmesiyle beraber bütün metriklerin değerlerinin iyileşebileceği aşikardır. Aynı zamanda görüntülerin sentetik olarak artırılmasının iyileştirilmesi de hastalardan daha fazla görüntü almak yerine, kendi ürettiğimiz görüntülerin kullanılması açısından daha sağlıklı olacaktır. İlerideki çalışmalarda bu konular üzerine gidilebilecek kapasiteye sahip bir çalışmadır. Sonuç olarak yapılan bu çalışma, yeni bir görüntüleme yöntemi olan CESM görüntüleme tekniğini kullanarak meme kanseri teşhisi yapmak isteyen uzmanlara yardımcı olacak niteliktedir.

KAYNAKLAR

- Achak, A., & Hedyehzadeh, M. (2023).** *Determining the differentiation of benign and malignant NME lesions in contrast-enhanced spectral mammography images based on convolutional neural networks.* Journal of Medical and Biological Engineering, 43(5), 585–595. <https://doi.org/10.1007/s40846-023-00814-y>.
- Altunbas, C. (2020).** *Yapay sinir ağı (YSA).* Medium. <https://medium.com/t%C3%BCrkiye/yapay-sinir-a%C4%9Flar%C4%B1-ysa-caec1cc0bf9f> (Erişim tarihi: 11 Aralık 2024).
- Amin, M. N., Kamal, R., Farouk, A., Gomaa, M., Rushdi, M. A., & Mahmoud, A. M. (2023).** *An efficient hybrid computer-aided breast cancer diagnosis system with wavelet packet transform and synthetically-generated contrast-enhanced spectral mammography images.* Biomedical Signal Processing and Control, 85, 104808.
- Aslan, M.F. (2022).** *A hybrid end-to-end learning approach for breast cancer diagnosis: convolutional recurrent network.* Computer and Electrical Engineering, 105, 108562.
- Ateş, F.F. (2023),** *Meme kanserinin iyi huylu veya kötü huylu durum tespitinde derin öğrenme modellerinin kullanılması* (Yüksek lisans tezi). Batman Üniversitesi, Lisansüstü Eğitim Enstitüsü, Batman.
- Deng, B., Zhang, Y., Parkes, A., Bentley, A., Wright, A., Pound, M. P., & Somekh, M. G. (2024).** *Application of RESNET50 convolution neural network for the extraction of optical parameters in scattering media.* arXiv preprint arXiv:2404.16647.
- Sebin, B. (2023, May 20).** *Evrişimli Sinir Ağı (Convolutional Neural Network).* Medium. <https://medium.com/@sebinbusra/evrişimli-sinir-ağı-convolutional-neural-network-f49f7b65c72>. (Erişim tarihi: 25 Kasım 2024).
- Canatalay, P.J. (2022),** *Derin öğrenme yöntemleri kullanılarak meme kanseri teşhisi* (Doktora tezi). Altınbaş Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Chouhan, N., Khan, A., Shah, J. Z., Hussnain, M., Khan, M.W. (2021).** *Deep convolutional neural network and emotional learning based breast cancer detection using digital mammography,* Computers in Biology and Medicine, 132, 104318.
- Cozzi, A., Magni, V., Zanardo, M., Schiaffino, S., & Sardanelli, F. (2022).** *Contrast-enhanced mammography: A systematic review and meta-analysis of diagnostic performance.* Radiology, 302(3), 568–581.

- Danala, G., Patel, B., Aghaei, F., Heidari, M., Li, J., Wu, T., Zheng, B. (2018).** *Classification of Breast Masses Using a Computer-Aided Diagnosis Scheme of Contrast Enhanced Digital Mammograms*, Annals of Biomedical Engineering, 46(9), pp. 1419-1431.
- Dang, N. C., Moreno-Garcia, M. N., La Prieta, F. D. (2020).** *Sentiment analysis based on deep learning: A comparative study*, Electronics, 9(3), 483.
- DeepKapha Notes. (2021).** *Implementing DenseNet-121 in PyTorch: A step-by-step guide*. Medium. <https://medium.com/deepkapha-notes/implementing-densenet-121-in-pytorch-a-step-by-step-guide-c0c2625c2a60>. (Eriřim Tarihi: 26 Kasım 2024).
- Dive into Deep Learning. (2023).** 8.7. *Zamanda geri yayma*. Eriřim adresi: https://tr.d2l.ai/chapter_recurrent-neural-networks/rnn.html. (Eriřim tarihi: 26 Kasım 2024).
- Etiya. (2024).** *Makine öğrenmesi (machine learning) ve derin öğrenme nedir?* https://www.etiya.com/tr/blog/makine-ogrenmesimachine-learning-ve-derin-ogrenme-nedir?gad_source=1&gclid=Cj0KCQjw_sq2BhCUARIsAIVqmQsMIb0b0k7ty4LEcTgFA3qSsKgEH91NcV7mLSS2l150vQiVAuy9LcgaArVfEALw_wcB (Eriřim tarihi: 30 Ağustos 2024).
- Fanizzi, A., Losurdo, L., Basile, T. M. A., Bellotti, R., Bottigli, U., Delogu, P., Diacono, D., Didonna, V., Fausto, A., Lombardi, A., Lorusso, V., Massafra, R., Tangaro, S., La Forgia, D. (2019).** *Fully Automated Support System for Diagnosis of Breast Cancer in Contrast-Enhanced Spectral Mammography Images*, Journal of Clinical Medicine, 8(6), p.891.
- Gao, F., Wu, T., Li, J., Zheng, B., Ruan, L., Shang, D., Patel, B. (2018).** *SD-CNN: A shallow- deep CNN for improved breast cancer diagnosis*, Computerized Medical Imaging and Graphics, pages 53-62.
- GeekforGeeks (2022).** *Introduction to Recurrent Neural Network*. Eriřim: 17.03.2023, <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>.
- GTech. (2024).** *Yapay zeka nedir? Yapay zeka hakkında bilmeniz gerekenler*. <https://www.gtech.com.tr/yapay-zeka-nedir-yapay-zeka-hakkinda-bilmeniz-gerekenler/> (Eriřim tarihi: 30 Ağustos 2024).
- Hepsağ, P. U. (2022).** *Biopsy cost reduction for early diagnosis of breast cancer using hybrid deep learning Techniques/Hibrit derin öğrenme teknikleri kullanılarak meme kanserinde erken teşhis için biyopsi maliyetinin düşürülmesi* (Doktora tezi). Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Huynh, H. N., Tran, A. T., & Tran, T. N. (2023).** *Region-of-interest optimization for deep-learning-based breast cancer detection in mammograms*. Applied Sciences, 13(13), 6894. <https://doi.org/10.3390/app13126894>.
- Jawzal, H. (2019).** *Analyzing breast cancer using thermography and convolutional neural networks / Termografi ve evriřimli sinir ağıları ile meme kanseri*

analizi (Yüksek lisans tezi). Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.

- Jiang, J., Peng, J., Hu, C., Jian, W., Wang, X., Liu, W. (2022).** *Breast cancer detection and classification in mammogram using a three stage deep learning framework based on PAA algorithm*, Artificial Intelligence In Medicine, 134, 102419.
- Jingyu, Liu. (2024).** 2. *Face recognition technology based on ResNet-50*. Applied and Computational Engineering.
- Kadiroğlu, Z. (2019),** *Histopatolojik meme kanseri görüntülerinin evrişimli sinir ağları kullanılarak sınıflandırılması* (Yüksek lisans tezi), Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Karthiga, R., Narasimhan, K., Amirtharajan, R. (2022).** *Diagnosis of breast cancer for modern mammography using artificial intelligence*, Mathematics and Computers In Simulation, 202, 316-330.
- Khaled, R., Helal, M., Alfarghaly, O., Mokhtar, O., Elkorany, A., El Kassas, H., Fahmy, A. (2022).** *Categorized contrast enhanced mammography dataset for diagnostic and artificial intelligence research*, Scientific Data, 9:122.
- Khattar, A., & Quadri, S. M. K. (2022).** *Generalization of convolutional network to domain adaptation network for classification of disaster images on Twitter*. Multimedia Tools and Applications, 81(4).
- Kobya, M. E., Türe, H., Doğan, R. Ö., Kayıkçıoğlu, T., Teymur, A., & Kul, S. (2023).** *Kontrastlı mamografi görüntülerinde kitlelerin şekil ve birinci dereceden istatistiksel özniteliklere dayalı sınıflandırması*. Proceedings of the 31st Signal Processing and Communications Applications Conference (SIU), 1-6.
- Koelpin, D. (2021).** *Recurrent Neural Networks*. Erişim: 20.03.2023, <https://morioh.com/p/1bc305d7dbdf>.
- Manoranjitham, R., & Swaroop, S. S. (2024ORCID).** A Comparative Study of DenseNet121 and InceptionResNetV2 model for DeepFake Image Detection. In *2024 3rd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)* (pp. 432-438). IEEE.
- MRI Questions. (2024).** *Shallow vs Deep Machine Learning Techniques*. <https://mriquestions.com/shallow-v-deep-ml.html>. (Erişim tarihi: 25 Kasım 2024).
- Muskan, Singla., Kanwarpartap, Singh, Gill., Rahul, Chauhan., Hemant, Pokhariya. (2024).** *ResNet50 Utilization for Bag Classification: A CNN Model Visualization Approach in Deep Learning*, IEEE Transactions on Knowledge and Data Engineering, 28(10), 88-96.
- Nalluri, Brahma, Naidu., Thokala, Kavyasree., Tadikonda, Ravi, Teja., Pulimela, Sushma, Sarayu., Siva, Sai. (2024).** *Image Forgery Detection using ResNet50*. International Journal For Science Technology And Engineering.

- Neurohive.** (2023). *VGG16: Overview and application*. Neurohive. <https://neurohive.io/en/popular-networks/vgg16/>. (Eriřim Tarihi: 25 Kasım 2024).
- Öztürk, M.** (2021). *Python ile sınıflandırma analizleri – Yapay sinir ağıları*, <https://miracozturk.com/python-ile-siniflandirma-analizleri-yapay-sinir-aglari-ysa/>, (Eriřim: 20.03.2023)
- Patel, B. K., Ranjbar, S., Wu, T., Pockaj, B. A., Li, J., Zhang, N., Lobbes, M., Zhang, B., Mitchell, J.R.** (2018). *Computer-aided diagnosis of contrast-enhanced spectral mammography: A feasibility study*, European Journal of Radiology, 98, pp. 207-213.
- Perek, S., Kiryati, N., Zimmerman-Moreno, G., Sklair-Levi, M., Konen, E., Mayer, A.** (2019). *Classification of contrast-enhanced spectral mammography (CESM) images*, International Journal of Computer Assisted Radiology and Surgery, 14:249–257.
- Qian, N., Jiang, W., Guo, Y., Zhu, J., Qiu, J., Yu, H., & Huang, X.** (2024). *Breast cancer diagnosis from contrast-enhanced mammography using multi-feature fusion neural network*. European Radiology, 34(2), 917–927.
- Qian, N., Jiang, W., Wu, X., Zhang, N., Yu, H., & Guo, Y.** (2024). *Lesion attention guided neural network for contrast-enhanced mammography-based biomarker status prediction in breast cancer*. Computer Methods and Programs in Biomedicine, 250, 108194.
- Raaj, R. S.** (2023). *Breast cancer detection and diagnosis using hybrid deep learning architecture*, Biomedical Signal Processing and Control, 82, 104558.
- Rofena, A., Guarrias, V., Sarlib, M., Piccolob, C. L., Sammarab, M., Beomonte Zobel, B., & Soda, P.** (2023). *A deep learning approach for virtual contrast enhancement in contrast enhanced spectral mammography*. arXiv.
- Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü.** (2024, Ekim). *Ekim, meme kanseri farkındalık ayı*. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü. <https://hsgm.saglik.gov.tr/tr/haberler-kanser/ekim-meme-kanseri-farkindalik-ayi.html>. (Eriřim tarihi: 30 Ağustos 2024).
- Saha, S.** (2018). *A comprehensive guide to convulutional neural networks-the ELI5 way*, Eriřim: 17.03.2023, <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>.
- Salama, W. M., Aly, M. H.** (2021). *Deep learning in mammography images segmentation and classification: Automated CNN approach*, Alexandria Engineering Journal, 60, 4701- 4709.
- Sanayi ve Teknoloji Bakanlığı.** (2024). *Yapay zeka: Sıkça sorulan sorular*. Cumhurbaşkanlığı Dijital Dönüşüm Ofisi. <https://cbddo.gov.tr/sss/yapay-zeka/> (Eriřim tarihi: 30 Ağustos 2024).
- Savaridas, S. L., & Tennant, S. L.** (2022). *Quantifying lesion enhancement on contrast-enhanced mammography: a review of published data*. Clinical Radiology, 77, e313-e320.

- Serin, Z. (2020),** *Meme kanserinin histopatolojik görüntüler üzerinde derin sinir ağları kullanılarak bilgisayar destekli otomatik tespiti* (Yüksek lisans tezi). Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik.
- Song, J., Zheng, Y., Wang, J., Ullah, M. Z., Li, X., Zou, Z., & Ding, G. (2022).** *Multi-feature deep information bottleneck network for breast cancer classification in contrast enhanced spectral mammography*. Pattern Recognition, 131, 108858.
- Song, J., Zheng, Y., Ullah, M. Z., Wang, J., Jiang, Y., Xu, C., Zou, Z., & Ding, G. (2021).** *Multiview multimodal network for breast cancer diagnosis in contrast-enhanced spectral mammography images*. International Journal of Computer Assisted Radiology and Surgery, 16, 979-988.
- Sönmez, B. (2024).** *Yapay zeka içerik 1.6*. İstanbul Teknik Üniversitesi. https://web.itu.edu.tr/~sonmez/lisans/ai/yapay_zeka_icerik1_1.6.pdf (Erişim tarihi: 30 Ağustos 2024).
- Venkata, Subbaiah, Desanamukula., Thatikonda, Dharma, Teja., Potluri, Rajitha. (2024).** *An In-Depth Exploration of ResNet-50 and Transfer Learning in Plant Disease Diagnosis*.
- Zheng, T., Lin, F., Li, X., Chu, T., Gao, J., Zhang, S., Li, Z., Gu, Y., Wang, S., Zhao, F., Ma, H., Xie, H., Xu, C., Zhang, H., & Mao, N. (2023).** *Deep learning-enabled fully automated pipeline system for segmentation and classification of single-mass breast lesions using contrast-enhanced mammography: A prospective, multicentre study*. eClinicalMedicine, 58, 101913.
- Zhu, X., Huang, J., Zhang, K., Xia, L., Feng, L., Yang, P., Zhang, M., Xiao, W., Lin, H., & Yu, Y. (2018).** *Diagnostic value of contrast-enhanced spectral mammography for screening breast cancer: Systematic review and meta-analysis*. Clinical Breast Cancer, 18(5), e985-e995.

ÖZGEÇMİŞ

TARANMIŞ
VESİKALIK
FOTOĞRAF

Ad-Soyad : Şeyma DOĞRU

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** :
- **Yüksek Lisans** :

MESLEKİ DENEYİM VE ÖDÜLLER:

•

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

•

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

•

