

**KARAMANOĞLU MEHMETBEY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAMOGRAFİ GÖRÜNTÜLERİ KULLANILARAK RESNET MODELLERİ
İLE MEME KANSERİ TEŞHİSİ**

YÜKSEK LİSANS TEZİ

Hasan Serdar MACİT

**Fen Bilimleri Enstitüsü
Elektrik - Elektronik Mühendisliği Ana Bilim Dalı**

TEMMUZ 2024

**KARAMANOĞLU MEHMETBEY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAMOGRAFİ GÖRÜNTÜLERİ KULLANILARAK RESNET MODELLERİ
İLE MEME KANSERİ TEŞHİSİ**

YÜKSEK LİSANS TEZİ

**Hasan Serdar MACİT
(210801105)**

Elektrik – Elektronik Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Kadir SABANCI

TEMMUZ 2024

TEZ ONAYI

Hasan Serdar MACİT tarafından hazırlanan “Mamografi Görüntüleri Kullanılarak ResNet Modelleri ile Meme Kanseri Teşhisi” adlı tez çalışması aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Karamanoğlu Mehmetbey Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman: Doç. Dr. Kadir SABANCI

Jüri Üyeleri

İmza:

Doç. Dr. Kadir SABANCI

Doç. Dr. Selami BALCI

Doç. Dr. Muhammed Fahri ÜNLERŞEN

Tez Savunma Tarihi: 29/07/2024

Yukarıdaki sonucu onaylarım

Prof. Dr. Murat MAYDA
Enstitü Müdürü



BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Hasan Serdar MACİT







Eşime ve biricik aileme,



ÖNSÖZ

Yüksek lisans tez çalışmalarım süresinde, ikinci lisans eğitimimde ve makale çalışmalarımda yönlendirmelerini, değerlendirmelerini, yardımlarını, desteklerini esirgemeyen, bilgilerini, tecrübelerini, deneyimlerini sürekli olarak paylaşan ve çalışmalarımı çok yakından takip eden danışmanım Sayın Doç. Dr. Kadir SABANCI'ya minnettarlığımı sunarım. Karamanoğlu Mehmetbey Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nün birbirinden değerli bütün öğretim üyelerine özverilerinden dolayı teşekkür ederim.

Tezim, yayınlarım ve ikinci lisansım aşamalarında sonsuz bir sabırla her türlü desteğini esirgemeyen eşime ve çocuklarıma, desteklerini ve dualarını üzerimden eksik etmeyen bütün aile bireylerime teşekkür ederim.

Temmuz 2024

Hasan Serdar MACİT
Bilişim Teknolojileri Öğretmeni
Elektrik – Elektronik Mühendisi



İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
ABSTRACT	xxiii
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Literatür Araştırması	2
2. MAKİNE ÖĞRENMESİNİN TEMELLERİ	9
2.1 Görev	9
2.1.1 Sınıflandırma.....	9
2.2 Deneyim	9
2.2.1 Denetimsiz öğrenme	10
2.2.2 Denetimli öğrenme.....	11
2.2.3 Veri kümesi (data set)	12
2.2.4 Test kümesi	12
2.2.5 Doğrulama kümesi (validation)	13
2.3 Fonksiyonlar.....	14
2.3.1 Softplus fonksiyonu	14
2.3.2 ReLu (Rectified Linear Unit) fonksiyonu	15
2.3.3 Fonksiyonların önemi	15
3. EVRİŞİMLİ (KONVOLÜSYONEL) SİNİR AĞLARI	17
3.1 Evrişim Katmanı	18
3.2 Aktivasyon Katmanı.....	21
3.3 Havuzlama (Pooling).....	22
3.4 Tek Düzlemlili Vektör (Flattening) ve Tam Bağlantı (Fully Connected) Katmanları	22
3.5 Toplu Normalleştirme (Batch Normalization)	24
3.6 Öğrenme Aktarımı (ResNet Transfer Learning)	25
4. MODEL DEĞERLENDİRME	29
4.1 Karışıklık Matrisi (Confusion Matrix)	29
4.2 ROC Eğrisi (Receiver Operator Characteristic).....	31
5. VERİ KÜMESİNDE DÜZENLİLEŞTİRME	37
5.1 Veri Kümesi Çeşitleme, Sentetik Veri Artırma (Augmentation).....	37
5.2 Erken Durdurma (Early Stopping)	38
6. KERAS KÜTÜPHANESİ	39
7. MİAS VERİ KÜMESİ ANALİZİ İÇİN GELİŞTİRİLEN SENARYO	41

7.1 MIAS Veri Kümesi.....	41
7.2 Veri Kümesi Ön İşleme	43
7.2.1 Görüntü formatı dönüştürme	43
7.2.2 Görüntü maskeleyme.....	43
7.2.3 Görüntü eşikleme	44
7.2.4 Veri artırma	45
7.3 Eğitim ve Test Verilerinin Hazırlanması	47
7.4 ResNet Modelleri ile Sınıflandırma.....	49
7.5 Derin Özellik Çıkarma ve SVM ile Sınıflandırma	56
8. SONUÇLAR VE ÖNERİLER.....	59
8.1 Sonuçlar.....	59
8.1.1 ResNet modelleri ile sınıflandırma	59
8.1.2 ResNet18+SVM yöntemi	61
8.2 Öneriler.....	64
KAYNAKLAR.....	66



KISALTMALAR

ML	: Makine Öğrenmesi (Machine Learning)
DL	: Derin Öğrenme (Deep Learning)
TL	: Öğrenme Aktarımı (Transfer Learning)
SVM	: Destek Vektör Makinası (Support Vector Machine)
ROI	: Region of Interest Processing
MIAS	: Mammography Image Analysis Society
ALIE	: Automated Lesion Intensity Enhancer
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
ROC	: Receiver Operating Characteristic Curve
CM	: Karışıklık Matrisi (Confusion Matrix)
Colab	: Google Colaboratory
HOG	: Histogram of Oriented Gradients
PCA	: Temel Bileşen Analizi
RGB	: Red-Green-Blue Işık Modeli
BreakHis	: Breast Cancer Histopathological Database
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified Linear Unit)
CBIS-DDSM	: Breast Cancer Image Digital Dataset
ResNet	: Artık Ağ (Residual Network)
GLCM	: Gri Seviye Eşzamanlı Oluşum Matrisi
HYSA	: Hücresel Yapay Sinir Ağı
kNN	: k En Yakın Komşuluk Algoritması (k-Nearest Neighbours Algorithm)
PNG	: Taşınabilir Ağ Grafiği (Portable Network Graphics)
PGM	: Gri Tonlamalı Görüntü (Portable Gray Map)
TP	: Doğru Pozitif (True Positive)
FP	: Yanlış Pozitif (False Positive)
TN	: Doğru Negatif (True Negative)
FN	: Yanlış Negatif (False Negative)
SGD	: Rastgele Değişken Azalım (Stochastic Gradient Descent)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
F1	: Harmonik Ortalama

FC	: Tam Baęlantılı Katman (Fully Connected Layer)
Conv	: Evriřim (Convolution)
Avg pool	: Global Average Pooling
Re-sample	: Yeniden Örnekleme
Pre-trained	: Önceden Eęitilmiş
MLP	: Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
ANN	: Yapay Sinir Aęı (Artificial Neural Network)
CWT	: Sürekli Dalgacık Dönüřümü (Continuous Wavelet Transform)
YSA	: Yapay Sinir Aęı
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
RF	: Rastgele Orman (Random Forest)
NN	: Sinir Aęı (Neural Network)
GAN	: Üretken Çekiřmeli Aę (Generative Adversarial Network)
SOTA	: Son Teknoloji Ürünü (State-of-the-art)

SEMBOLLER

x_{train}	: Eğitim Kümesi
y_{label}	: Etiket
n	: Piksel Kümesi
x	: Vektör
y	: Vektör
ω	: Ağırlık
$f(x)$: ReLu Fonksiyon
α	: Asal gerilme doğrultusundan sapma açısı
ρ	: Yoğunluk
b	: Bias
\emptyset	: Rastgele Değişken
i, j, m, n	: Matris Boyutları
$\zeta(x)$: Softmax Fonksiyonu
m	: Ortalama, mean
$x_{normalize}$: Normalizasyon
\tilde{y}	: Öngörü



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Iris veri kümesinden örnek.	10
Çizelge 4.1 : Karışıklık matrisi çizelgesi.	30
Çizelge 7.1 : MIAS veri kümesi görüntü isimleri ve tipleri.	41
Çizelge 7.2 : MIAS veri kümesi etiket dosyası bilgileri.	42
Çizelge 7.3 : İterasyon sayıları ve erken durdurma değerleri sonuçları.	52
Çizelge 7.4 : ResNet18 evrişim katmanları ayarları.	54
Çizelge 8.1 : ResNet18 modelleri için elde edilen doğruluk değerleri.	59
Çizelge 8.2 : ResNet modelleri ile elde edilen performans ölçütleri.	59
Çizelge 8.3 : ResNet18 pool5 katmanından çıkartılan numerik özellikler.	61
Çizelge 8.4 : SVM modelleri ile elde edilen performans ölçütleri.	63
Çizelge 8.5 : İlgili çalışmalarla, yöntemlerin ve doğruluklarının karşılaştırılması.	64



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Denetimsiz öğrenme modelleri ve biyomedikal araştırmalarda kullanılan algoritmalar.	11
Şekil 2.2 : Denetimli öğrenme modelleri ve biyomedikal araştırmalarda kullanılan algoritmalar.	12
Şekil 2.3 : Veri kümesinin eğitim, doğrulama ve test kümesi olarak bölünmesi.	14
Şekil 2.4 : Softplus ve ReLu Fonksiyonu.	15
Şekil 2.5 : Yapay sinir ağları yapısı.	16
Şekil 3.1 : Kernel matrisi uygulanmış evrişimli görüntü örneği.	19
Şekil 3.2 : Birinci lokasyonun oluşumu.	20
Şekil 3.3 : Konvolüsyon işleminde yatay ve dikey kenar algıma işlemi.	21
Şekil 3.4 : ReLu aktivasyonundan geçen bir girdi ve çıktı.	22
Şekil 3.5 : Havuzlama örneği.	22
Şekil 3.6 : Beyin tümörü sınıflandırması Softmax kullanımı.	24
Şekil 3.7 : CNN mimarisi örneği.	24
Şekil 3.8 : Dengesiz bloklar.	25
Şekil 3.9 : Residual blok diyagram.	27
Şekil 3.10 : ResNet mimarisi.	28
Şekil 4.1 : Sigmoid aktivasyon çıkışları.	32
Şekil 4.2 : Örnek bir ROC eğrisi.	32
Şekil 4.3 : ROC eğrisi sonuçları.	33
Şekil 4.4 : ROC eğrisi olasılık dağılım grafikleri.	35
Şekil 7.1 : MIAS veri kümesi örnek medikal görüntüleri.	42
Şekil 7.2 : MIAS görüntüleri örnek anomali tanımlama etiketleri.	43
Şekil 7.3 : Maskeleme görüntüleri.	44
Şekil 7.4 : Mamografi görüntüsü eşikleme.	45
Şekil 7.5 : Habis huylu bir görüntü verisi ve artırılmış veri örnekleri.	46
Şekil 7.6 : Eğitim ve test klasör yapısı.	48
Şekil 7.7 : Yeniden örneklem stratejisi.	49
Şekil 7.8 : ResNet mimarisi sınıflandırma akış şeması.	50
Şekil 7.9 : Yığın boyutu rastgele 32 görüntüden oluşmaktadır.	51
Şekil 7.10 : ResNet18 evrişimli sinir ağı katmanları.	53
Şekil 7.11 : ResNet 64x7x7 Filtre (Kernel) yapısı.	54
Şekil 7.12 : MIAS veri kümesi mdb124.png için ResNet18 evrişim görüntüleri.	55
Şekil 7.13 : MIAS veri kümesi mdb148.png için ResNet50 ilk katman.	56
Şekil 7.14 : ResNet18+SVM yönteminin uygulama akış diyagramı.	57
Şekil 8.1 : ResNet18 CM değerleri.	60
Şekil 8.2 : ResNet18 modeli ile elde edilen ROC eğrisi.	60
Şekil 8.3 : SVM karışıklık matrisleri.	62
Şekil 8.4 : ResNet18+SVM ROC eğrisi.	63



ÖZET

Yüksek Lisans Tezi

MAMOGRAFİ GÖRÜNTÜLERİ KULLANILARAK RESNET MODELLERİ İLE MEME KANSERİ TEŞHİSİ

Hasan Serdar MACİT

Karamanoğlu Mehmetbey Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik – Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Kadir SABANCI

Temmuz, 2024, 69 sayfa

Meme kanseri, dünya genelinde ölüm oranı yüksek kanser türlerinden biridir. Bu ölüm oranını azaltmak için erken teşhis büyük önem taşımaktadır. Bilgisayar destekli erken tanı sistemleri doktorların daha kesin ve hızlı karar vermelerini sağlamaktadır. Bu çalışmada Mammographic Image Analysis Society (MIAS) veri kümesi kullanılmıştır. Mamografi görüntülerinde maskeleyen yapılarak meme bölgesi seçilmiştir. Veri artırma teknikleri kullanılarak görüntü sayısı artırılmıştır. Mamografi görüntüleri, dört farklı ResNet modeli kullanılarak normal, iyi huylu ve habis olarak sınıflandırılmıştır. En yüksek sınıflandırma doğruluğu %93,83 ile ResNet18 modeli kullanılarak elde edilmiştir. ResNet50, ResNet101 ve ResNet152 ile elde edilen doğruluk değerleri sırasıyla %87,24, %87,44 ve %91,25'tir. Daha sonra en yüksek sınıflandırma doğruluğunun elde edildiği ResNet18 modelinin son katmanından 512 adet derin özellik çıkartılmıştır. Bu özellikler farklı çekirdek fonksiyonları ile Destek Vektör Makinaları kullanılarak yeniden sınıflandırılmıştır. ResNet18+SVM yöntemi ile %99,6 sınıflandırma doğruluğu elde edilmiştir.

Anahtar Kelimeler: Meme kanseri, CNN, ResNet modelleri, SVM



ABSTRACT

MsThesis Thesis

BREAST CANCER DIAGNOSIS WITH RESNET MODELS USING MAMMOGRAPHY IMAGES

Hasan Serdar MACİT

**Karamanoğlu Mehmetbey University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Supervisor: Associate Professor Doctor Kadir SABANCI

July, 2024, 69 pages

Breast cancer is one of the cancer types with a high mortality rate worldwide. Early detection is crucial to reduce this mortality rate. Computer-aided early detection systems enable doctors to make more precise and faster decisions. In this study, Mammographic Image Analysis Society (MIAS) dataset was used. Mammography images were masked and breast region was selected. The number of images was increased by using data augmentation techniques. Mammography images were classified as normal, benign and malignant using four different ResNet models. The highest classification accuracy was obtained using ResNet18 model with 93.83%. The accuracies obtained with ResNet50, ResNet101 and ResNet152 were 87.24%, 87.44% and 91.25%, respectively. Then, 512 deep features were extracted from the last layer of the ResNet18 model where the highest classification accuracy was obtained. These features were reclassified using Support Vector Machines with different kernel functions. A classification accuracy of 99.6% was obtained with the ResNet18+SVM method.

Keywords: Breast cancer, CNN, ResNet models, SVM



1. GİRİŞ

Dünya çapında yaklaşık altı ölümden biri kanserden kaynaklanmaktadır. 2018 yılında kanser; ikinci en yaygın ölüm nedeni olarak belirlenmiştir. Bu da Dünya çapında tahmini 9,6 milyon ölüme karşılık gelmektedir. 2040'a kadar, bu sayının 16,4 milyona çıkması beklenmektedir (Chauvet, 2020).

Uluslararası Kanser Araştırma Ajansı'nın (IARC) en son küresel kanser yükü tahminlerine göre, meme kanseri artık dünya çapında en sık teşhis edilen kanserler listesinin başında yer almakla birlikte ilk kez akciğer kanserini geride bırakmıştır. Kadınlar arasında meme kanseri, 2020'de tahmin edilen 19,3 milyon yeni kanser vakasının %11,7'sini ve kadınlar arasında tüm kanser vakalarının yaklaşık %25'ini oluşturmaktadır (Weiderpass, 2021).

Kanser meme dokusunun herhangi bir yerinden kaynaklanabilir. En sık görülen tipi; meme kanallarından kaynaklanan "duktal" kanser denenen kanserlerdir. Süt üreten bezlerden köken alan "lobüler" kanserler de sık görülür. Ayrıca diğer dokulardan kaynaklanan daha nadir medüller, tübüler, müsinöz gibi tipleri de vardır. 40-69 yaş arası bayanların; iki yılda bir mamografi çekilmesi gerekmektedir (T.C. Sağlık Bakanlığı, 2020).

Mamografi, meme kanserinin erken teşhisi ve tedavisi için etkili bir tarama aracıdır. Bununla birlikte, radyologların meme kanserini doğru bir şekilde tespit etmelerine veya sınıflandırmalarına yardımcı olmak için çeşitli bilgisayar destekli görü sistemleri ve derin öğrenme yöntemleri geliştirilmektedir (Loizidou ve diğerleri, 2023).

Bu tez çalışmasında hem geleneksel özellik tabanlı makine öğrenimi hem de derin öğrenme algoritmaları kullanılarak mamografi görüntülerinde meme kanserinin otomatik tespiti ve sınıflandırılmasına ilişkin son literatürler incelenmektedir. Bu çalışmada; meme kanseri hastalarında kanser parametrelerini, kanserli hücre görüntülerini, iyi huylu ve normal hücre görüntülerini sunan veri kümesindeki görüntülere derin öğrenme modelleri uygulanacaktır. Derin öğrenme yöntemleri ile veri kümesi görüntülerinin doğruluk oranlarının araştırılması amaçlanmıştır. Bu amaç

doğrultusunda mamografi görüntülerinden derin öğrenme modelleri ile meme kanseri teşhisi yapılmaya çalışılacaktır.

1.1 Tezin Amacı

Kanserde erken tanının önemi ve pek çok kanser çeşidinin tedavi edilebildiği herkes tarafından bilinmektedir. Gelişen teknoloji sayesinde uygulanan tetkiklerle erken kanser teşhisi konan kişilerin hastalıktan kurtulması mümkün olabilmektedir. Bu çalışmada Kaggle sitesinden elde edilen MIAS mamografi görüntü veri kümesi (Mader, 2017) ile derin öğrenme yöntemi kullanılarak iyi huylu ve habis tümörlerin öznelikleri çıkartılarak analiz edilecek, elde edilen görüntülere erken tanı teşhisi konmaya çalışılacaktır. Derin Öğrenme (DL), tahminlerin görevini otomatikleştirir, yani veri kümelerini geçebileceğimiz bir model tasarlamaya yardımcı olur, derin öğrenme, analiz ve tahminler için önemli olan tüm özellikleri/kalıpları otomatik olarak hesaplar. Derin öğrenme, çok çeşitli yapay sinir ağları ile gerçekleştirilmektedir. Bir verinin bu model ile işlenmesi sırasında işlem katmanlarının tümünde öğrenme gerçekleştirilmektedir. Her yeni katman, bir önceki katmandan edindiği bilgileri çıktı olarak kabul etmektedir. Derin makine öğrenmesi, elimizdeki verilerin analizini sistemsal olarak gerçekleştirerek hangi parametrelere daha fazla ağırlık vermesi gerektiğini kendi kendine belirlemektedir. Bu da öğrenme sürecinin daha hızlı bir biçimde tamamlanmasına ve ortaya konulacak ürün, teknoloji ya da hizmetin çok daha başarılı bir şekilde çalışmasına hizmet etmektedir.

Bu çalışmada veri kümesindeki görüntüler derin öğrenme yöntemiyle ele alınarak meme kanseri tespiti konularında bir veriye ulaşılması, bu verilerin hızlı ve doğru analiz edilmiş olması istendiğinden bu tez çalışması özgün bir nitelik taşımaktadır. Bu tez çalışması teknik açıdan yapılabilirliği araştırılmış ve ön fizibilite çalışmaları yapılmıştır.

1.2 Literatür Araştırması

Civcık (2013), yaptığı doktora tezinde, MIAS veri kümesi analizini ve hastane veri kümesi analizini karşılaştırmıştır. MIAS veri kümesindeki mammogram görüntülerindeki pektoral kasları kaldırmış ve threshold uygulayarak görüntü güçlendirme işlemi yaptığını belirtmiştir. Mammogram görüntüleri için yeni

geliştirilen histogram temelli ve otomatik olarak kitle yoğunluğunun güçlendirilmesi üzerine geliştirilmiş ALIE algoritması kullandığın vurgulamıştır. Bölütlenme adımında hücrel yapay sinir ağları (HYSA) kullanarak mikrokalsifikasyon ve tümörleri belirlemiştir. Ardından sınıflandırma aşmasına geçmiş, iyi huylu ve kötü huylu anomali sınıflandırmasını gerçekleştirmiştir. Hastane veri kümesinde güçlendirilmiş görüntüleri sınıflandırmada %93,1 doğruluk ve MIAS veri kümesi güçlendirilmiş görüntüleri sınıflandırmada %82 doğruluk elde ettiğini öne sürmüştür.

Görgel ve diğerleri (2015), çalışmalarında bölütlenmiş ilgi bölgesi yöntemi (Region of interest, ROI) yöntemini kullanmış ve daha sonra continuous wavelet (CWT) dönüşümünü kullanarak öznelikleri çıkarmışlardır. Daha sonra sınıflandırıcı olarak Destek Vektör Makinesi (SVM) kullanmışlardır. Bu yöntemleri kullanarak sınıflandırma için %91,4 doğruluk elde etmişlerdir.

Zhang, Wang, ve diğerleri (2016), anormal vakaları tespit etmek için yeni bir bilgisayarlı tanı sistemi kullanmışlardır. SVM ve kNN yakın komşu yöntemlerini kullanarak %92,16 doğruluk oranına ulaşmışlardır.

Zhang, Wu, ve diğerleri (2016), MIAS veri kümesindeki gürültüleri azaltmak, görüntüleri iyileştirmek ve arka plan ile pektoral kasları kaldırmak için önışleme işlemi gerçekleştirmişlerdir. Çalışmalarında özellik çıkararak analiz işlemi yapmışlar ve on katlı çapraz doğrulama modeli uygulamışlardır. Analiz sonuçlarında %92,52 başarı elde etmişlerdir.

Han ve diğerleri (2017), histopatolojik görüntülerden meme kanseri sınıflandırma çalışmalarında BreakHis veri kümesini kullanmışlar, derin öğrenme metodu ile analiz etmişler ve %93,2 başarı elde ettiklerini vurgulamışlardır. BreakHis veri kümesi görüntülerinin her biri RGB ve 8 bit, 700x460 pikselden oluşmaktadır. BreakHis veri kümesi; adenozis, fibroadenom, fillodes ve tübüler adenom olmak üzere dört farklı iyi huylu meme tümörünü, duktal karsinom, lobüler karsinom, müsinöz karsinom ve papiller karsinom olmak üzere 4 farklı habis tümörü içermektedir. BreakHis veri kümesi büyütme metodu ile büyütülmüş ve sınıflardaki düzensizlikleri düzeltmişlerdir. Evrişimsel sinir ağı (CNN) modelini uygulamışlardır. Kanser hücrelerini sarı kutu ile işaretlemişlerdir.

Çelik ve diğerleri (2019), yapmış oldukları çalışmada, teknolojideki son gelişmelerin ışığında hızlı işlemcili bilgisayarlar kullanarak hastalık teşhisinin yapay sinir ağları ve

görüntü işleme yöntemlerinin geliştirilmesine olanak sağladığını vurgulamışlardır. Kanserin erken teşhisi, hastalığın ilerlemesi üzerinde olumlu bir etkiye sahip olduğunu belirtmişlerdir. Önerdikleri yöntemde görüntü işleme ve yapay sinir ağlarını entegre ederek hızlı ve doğru teşhisi amaçlamışlardır. Bilgisayar destekli otomatik sınıflandırma kullanarak, çeşitli test parametrelerini değerlendirmişlerdir. Çalışmalarında, meme kanseri sınıflandırması için MIAS veri kümesini kullanmışlardır. Her bir görüntüye özellik çıkartma için eşik seçimi (threshold), morfolojik işlemler uygulamışlar, aynalama işlemi ile görüntü artırmışlar, maskeleme ve konvolüsyon tekniklerini çalışmalarında kullanmışlardır. Gri seviye eş zamanlı oluşum matrisini (GLCM) temel aldıkları çalışmalarında doku özelliklerine dayalı olarak yoğunluk ve iyi-kötü huyluluk sınıflandırması için yapay sinir ağı sınıflandırıcı kullanmışlardır. MIAS veri kümesindeki görüntülerden 280 adetini eğitim için, 42'sini ise test için meme anomali yoğunluğu sınıflandırması aşamasında kullanmışlardır. Sonuç olarak meme anomali yoğunluğu doğruluk değeri ortalaması olarak %83,33 başarı elde etmişlerdir. İyi-kötü huylu sınıflandırmada ise, MIAS veri kümesindeki görüntülerden 100 görüntüyü eğitim için, 15 görüntüyü ise test için kullanmışlardır. İyi-kötü huylu anomali doğruluk sınıflandırma başarı ortalamasını %57,33 olarak hesaplamışlardır.

Sha ve diğerleri (2020), MIAS veri kümesi kullanarak yaptıkları çalışmada görüntülerin gürültülerini azaltma önilemi yapmışlar, grasshopper optimizasyon algoritması kullanmışlar ardından özellik çıkarmışlardır. Önerdikleri sistemin verimliliğini analiz etmek için elde ettikleri simülasyon sonuçlarını on farklı son teknoloji yöntemlerle karşılaştırmışlardır. Önerdikleri yöntemin %92 doğruluğa sahip olduğunu belirtmişlerdir.

Taşdemir ve diğerleri (2020), yaptıkları çalışmada MIAS veri kümesini kullanmışlar, meme kanseri ile dokusal öznelik çıkarımı ile sınıflandırma çalışması yapmışlardır. Histogram eşitleme yöntemiyle görüntüleri iyileştirmişler, Histogram of Oriented Gradients (HOG) ve Haralick özneliklerini çıkarmışlardır, öznelik çıkarımı için 2B-DWT (The Discrete Wavelet Transform) modelini kullanmışlardır, özneliklerin sayısını azaltmak için temel bileşenler analizi (PCA) algoritması kullanmışlardır. Yapay sinir ağı mimarisi içerisindeki ADAM algoritmasını kullanarak %81 doğruluk oranı elde etmişlerdir.

Krishna ve Rajabhushanam (2021), yaptıkları çalışmada MIAS veri kümesini kullanmışlardır. Yaptıkları çalışmada veri kümesini analiz için derin öğrenme yöntemlerinden evrişimsel sinir ağını (CNN), VGG16, AlexNet öğrenme aktarımı algoritmalarını kullanmışlar ve bu ağların doğruluk oranlarını karşılaştırmışlardır. CNN, VGG16 ve AlexNet öğrenme algoritmalarında sırasıyla 0,967, 0,952 ve 0,92 doğruluk oranı elde ettiklerini belirtmişlerdir.

Vedalankar ve diğerleri (2021), çalışmalarında görüntü artırma tekniğini önermişlerdir. AlexNet kullanarak MIAS veri kümesinden özellik çıkarmışlar ve Destek Vektör Makinası (SVM) kullanarak analiz etmişlerdir. Maksimum %92 doğruluk elde ettiklerini makalelerinde belirtmişlerdir.

Sönmez ve diğerleri (2021), mikroalgler sınıflandırmaları üzerine çalışmalar yapmışlardır. Mikroalglerin, biyoteknoloji, farmakoloji ve gıda sektörlerinde yaygın olarak kullanılan tek hücreli organizma olduklarından bahsetmişler ve pek çok mevcut mikroalga grubunun tanımlanması ve sınıflandırılmasının, klasik yöntemlerle uzun süre ve yüksek nitelikli iş gücü gerektirdiğini çalışmalarında vurgulamışlardır. Çalışmalarında Cyanobacteria ve Chlorophyta mikroalga gruplarının görüntülerini ters mikroskop kullanarak yakalamışlardır. Konvolüsyonel sinir ağları (CNN) modellerinde sınıflandırma başarısını artırmak için veri artırma tekniklerini kullanmışlardır. Topladıkları görüntüleri iki farklı yöntemle sınıflandırmışlardır. İlk senaryolarında, yedi farklı CNN modeli ile sınıflandırma yapmışlardır. İkinci senaryolarında ise en düşük doğruluğa sahip AlexNet modelinin sınıflandırma başarısını artırmak için SVM kullanmışlardır. Bu amaçla AlexNet modelinden çıkardıkları özellikleri SVM ile sınıflandırmışlardır. Farklı CNN modelleri arasında en yüksek doğruluk oranını %99,66 olarak bulmuşlardır.

Talo (2022), Meme kanseri histopatolojik görüntülerinin evrişimsel sinir ağları ile sınıflandırılması çalışmasında iyi huylu ve habis tümörleri ayırmak için CNN tabanlı ResNet-50 mimarisini önermiştir. BreakHis veri kümesini kullanmıştır. Görüntülerin boyutlarını 32x32 piksel veya 64x64 piksel boyutunda boyutlandırmıştır. Görüntüleri filtrelemiştir. Boyut küçültme amacıyla ortalama havuz katmanını kullanmıştır. Modelin eğitim verilerini ezberlemişini engellemek için bazı nöronların rastgele etkisiz hale getirmek amacıyla model seyreltme katmanını eklemiştir.

Karakurt ve İřeri (2022), derin öğrenme mimarilerinden evriřimsel sinir ađı (CNN) kullanarak, meme patoloji görüntülerinin sınıflandırması işlemini gerçekleřtirmiřtir. Kanserli ve kanserli olmayan patoloji görüntülerinin sınıflandırılmasında dođruluk deđeri 0,8775, F1 skoru 0,8238, hassasiyet deđeri 0,8381, MSE deđeri 0,1195, MAE deđeri 0,2497 elde etmişlerdir. Çalışmalarında Kaggle web sitesinde Paul Mooney tarafından 2017 yılında sunulan meme patoloji görüntülerinden oluşan bir veri kümesi kullanmışlardır. Görüntüler 50x50 olarak yeniden boyutlandırmışlardır. Toplam 60000 görüntünün 40000 tanesini eğitim kalanını test amacıyla kullanmışlardır. CNN mimarisi çalışmalarında 3 tane evriřim katmanı, 3 tane ReLu katmanı ve 3 tane havuzlama katmanı kullanmış, görüntü boyutlarını küçültmüş ve bu görüntülerden anlamlı bilgiler çıkarmışlardır. Aktivasyon fonksiyonları olarak, gizli katmanlarda Rectified Linear Unit (Dođrultulmuş Dođrusal Birim) (ReLu) ve tam bađlı katmanda sigmoidal eđri veya lojistik işlev (sigmoid) fonksiyonları kullanılmıştır. Geri yayımlı yapay sinir ađlarını kullanarak hata deđerlerini çıkarmışlardır. Dođruluk deđerini %87,75 olarak bulmuşlardır.

Tiryaki (2022), meme kanseri alanında dünyadaki büyük ve yeni veri kümelerinden biri olan CBIS-DDSM kullanarak meme kanseri anormalliklerinin öğrenme transferi yöntemiyle sınıflandırılmasını çalışmıştır. ImageNet veri kümesi ile eğitilmiş ResNet50, Xception, ve NASNetLarge ađları; sınıflandırıcı geliştirilmesinde kullanarak öğrenme transferi işlemini gerçekleřtirmiřtir. Görüntüleri %10 kaydırma yaparak ve 0-90 derece arasında çevirerek veri büyültme işlemi uygulamıştır. Xception modeli ile %93,64 dođruluk oranı bulmuřtur.

Sunnetci ve Alkan (2022), akciđer kanseri üzerine bir çalışma yapmışlar, yaptıkları çalışmada 1000 görüntü bulunan veri kümesi kullanmışlardır. Veri kümesinin %80'ini eğitim, %20'sini test verisi olarak kullanmışlardır. Görüntü özniteliklerini çıkarmak için Bag of Words Features metodunu kullanarak 2000 adet öznitelik çıkarmışlardır. Sınıflandırma için Lineer Diskriminant, SVM, kNN modellerini tercih etmişlerdir. En iyi modeli kNN algoritmasını kullanarak %99,28 dođruluk elde etmişlerdir.

Alruwaili ve Gouda (2022), MIAS veri kümesi üzerine yaptıkları çalışmada kötü huylu ve iyi huylu meme kanserini ayırt etmek için öğrenme aktarımı algoritmasını kullanmışlar, istikrarlı öğrenmeyi sağlamak için görüntü sayısını artırmışlardır. Bunun için çeřitli dönme kombinasyonları uygulamışlar, ölçekleme ve kaydırma işlemleri yapmışlardır. Çalışmalarında ResNet50 kullanarak %89,5 dođruluk elde etmişlerdir.

Önceden eğitilmiş sınıflandırma ağlarının, özellikle küçük eğitim kümeleri ve tıbbi görüntüler için daha kabul edilebilir, etkili ve verimli olduğunu belirtmişlerdir.

Mubeen ve diğerleri (2023), yaptıkları çalışmada MIAS veri kümesini kullanmışlardır. Çalışmalarında bilgisayar destekli tanı ve derin öğrenme yöntemlerinin her yönden sayısal olarak daha iyi performans gösterdiğini belirtmişlerdir. DenseNet121 mimarisi üzerine inşa ettikleri modelde %88 oranında doğruluk elde ettiklerini belirtmişlerdir.

Jafari ve Karami (2023), yaptıkları çalışmada mamografi görüntülerinde meme kanserinin doğru teşhisini ele almak için yeni yöntemler geliştirdiklerini belirtmişlerdir. Çalışmalarında önceden eğitilmiş AlexNet, ResNet50, EfficientNet, MobileNet, ConvNeXt derin öğrenme mimarilerini kullanarak MIAS veri kümesinden habis ve iyi huylu görüntülerin sayısal özelliklerini çıkarttıklarını açıklamışlardır. Çalışmalarında sınıflandırma yapmak için kNN, SVM, RF ve NN makine öğrenimi algoritmalarını kullanmışlardır. En yüksek doğruluk oranını NN sınıflandırma yöntemini kullanarak %94,5 oranında elde ettiklerini vurgulamışlardır.

Joseph ve diğerleri (2024), yaptıkları çalışmada meme kanserini incelemek için MIAS veri kümesini kullandıklarını belirtmişlerdir. Bu veri kümesinde normal görüntüleri kıyasla az sayıda habis ve iyi huylu vakaya karşılık gelen görüntü bulunduğunu açıklamışlardır. Derin öğrenmenin, tıbbi görüntüleme çözümlerinde ve klinik uygulamalarda hayati önem taşıdığını belirterek, bununla birlikte tıbbi görüntü veri kümesindeki veri kıtlığının ve dengesizliğinin çeşitli derin öğrenme modellerinde performans sorunlarına neden olacağını vurgulamıştır. Gerçek görüntüleri yakın sentetik tıbbi verilerin üretilmesinin acil bir ihtiyaç olduğunu belirtmişlerdir. Normal, iyi huylu ve habis huylu gibi farklı vakaların sentetik mamografi görüntülerini artırmak için Üretken Çekişmeli Ağ (GAN) mimarisine dayalı bir veri artırma modeli kullanmışlardır. Bu artırılmış görüntülerin mamografi veri kümesi sınıf dengesizliği sorunlarını ortadan kaldırmak için faydalı bir çözüm olduğunu vurgulamışlardır.

Thwin ve diğerleri (2024), yaptıkları çalışmada MIAS veri kümesini kullanmışlardır. Sınırlı veri kümesi görüntülerinin model performansını etkileyebileceğini belirtmişlerdir. Bu nedenle görüntüleri döndürme, çevirme, ölçekleme gibi veri artırma teknikleri uygulamışlardır. Veri artırma stratejisinin, eğitim ve test kümelerinin çeşitliliğini ve miktarını artırmada önemli bir rol oynadığını, doğruluk, hassasiyet ve özgüllük açısından gelişmiş bir model performansına yol açacağını

vurgulamışlardır. Çalışmalarının diğer aşmasında özellik çıkarma için ResNet50 ve InceptionV3 algoritma modellerini kullanmışlardır. Ardından baskın özelliklerin seçimini gerçekleştirmişlerdir. Sınıflandırma aşamasında önerdikleri state-of-the-art (SOTA) teknolojisi teknikleri arasında kapsamlı deneyler yaptıklarını belirtmişler, %95,33 doğruluk elde etmişlerdir.

Bu çalışmada MIAS veri kümesindeki görüntüler kullanılarak ResNet derin öğrenme modelleri ve Destek Vektör Makinası ile meme kanseri tespiti yapılmıştır. Derin öğrenme modelleri için Python kütüphanesi kullanılmıştır.

Google Colab (Google Colaboratory), derin öğrenme çalışmaları üzerinde etkileşimli, tamamen bulut tabanlı, ortak çalışmaya dayalı bir program platformu kullanılarak yüksek hızlı GPU ihtiyacının karşılanması için düşünülmüştür.

2. MAKİNE ÖĞRENMESİNİN TEMELLERİ

Makine öğrenmesi, insanlar tarafından tasarlanmış ve yazılmış olan, sabit programlar tarafından çözülemeyecek kadar zor olan görevleri ele alan algoritmalarıdır. Makine öğrenmesi görevleri, genellikle, makine öğrenmesi sistemlerinin bir örneğin nasıl işlenmesi gerektiğine göre tanımlanır. Burada örnek, makine öğrenmesi sisteminin işlenmesini istediğimiz bir obje ya da olay üzerinden nicel olarak ölçülmüş öznelikler bütünüdür. Genellikle örnekler $x \in R^n$ şeklinde bir vektör olarak tanımlanır. Her x_i elemanı ise bir öznelik belirtir. Örneğin bir resmin öznelikleri resmin piksel değerleridir.

2.1 Görev

Makine öğrenmesi birçok görev ile çözülebilir. Bu tez çalışmasında görev tipi sınıflandırmadır.

2.1.1 Sınıflandırma

Bu görev tipinde, bilgisayar programından herhangi bir girdinin k ayrı kategoriden hangisine dahil olduğunu belirlemesi istenir. Bu görevi çözebilmek için öğrenme algoritmasını bir $f: R^n \rightarrow \{1, \dots, k\}$ fonksiyonu belirlemesi gerekir. Öyle ki algoritma x ile gösterilen bir girdiyi $y = f(x)$ olacak şekilde y olarak belirlenen kategoriye atayacaktır. Modern nesne tanıma görevleri en başarılı şekilde derin öğrenme yöntemleriyle çözülebilir (Krizhevsky vd.,2012; Ioffe ve Szegedy, 2015). Nesne tanıma ile bilgisayarların yüz tanımasını sağlayan teknoloji aynı teknolojidir (Taiman vd.,2014).

2.2 Deneyim

Makine öğrenmesi algoritmaları, öğrenme esnasında kullanılmalarına izin verilen deneyimlerin türüne göre denetimli öğrenme (supervised), denetimsiz öğrenme (unsupervised) ve pekiştirmeli öğrenme (reinforcement) olarak bölümlere ayrılır. Öğrenme algoritmalarının çoğunluğu bütün bir veri kümesi (data set) deneyimlemesine izin vermektedir. Veri kümesi, verinin özneliklerini oluşturduğu koleksiyona verilen isimdir. İstatistikçiler ve makine öğrenmesi araştırmacılarının kullandığı en eski veri kümelerinden birisi İris veri kümesidir (Fisher, 1936). Bu veri kümesi 150 değişik iris bitkisinin farklı parçalarının ölçümlerinden elde edilmiş bir

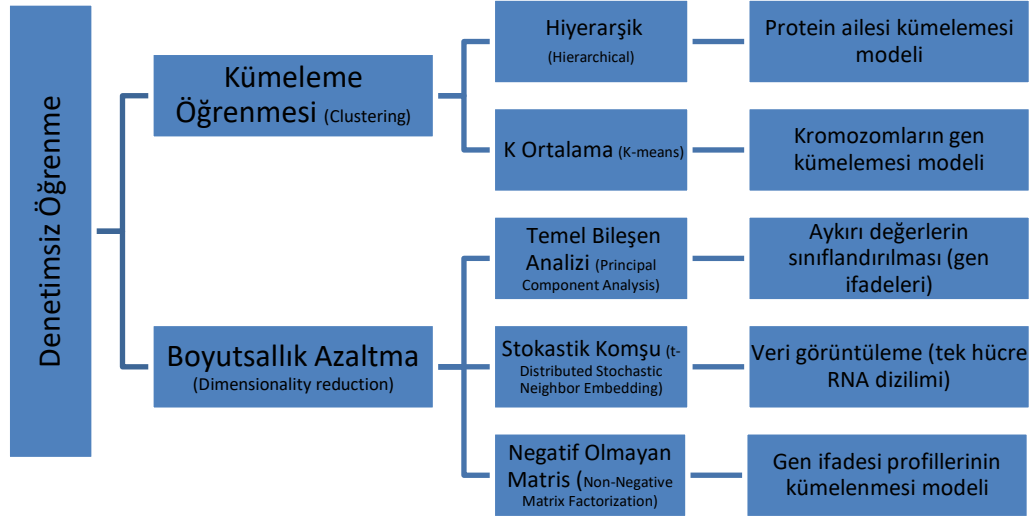
koleksiyondur. Her bir bitki parçası bir örnek oluşturmaktadır. Öznitelikler ise örneği oluşturan çanak yaprağı boyu ve genişliği ile taç yaprağı boyu ve genişliği ölçümleridir. Veri kümesi toplam 3 farklı türe ait setosa, versicolor ve virginia etiketlerini içermektedir. Örnekler (instances) ve gözlemler (observations) ile öznitelik çıkarma (feature extraction) işlemi gerçekleştirilmektedir. Çizelge 2.1’de iris veri kümesi örneği görülmektedir.

Çizelge 2.1 : Iris veri kümesinden örnek.

Çanak Yaprak Uzunluk	Çanak Yaprak Genişlik	Taç Yaprak Uzunluk	Taç Yaprak Genişlik	Etiket
5.1	3.5	1.4	0.2	Setosa
6.4	3.5	4.5	1.2	Versicolor
5.9	3.0	5.0	1.8	Virginia

2.2.1 Denetimsiz öğrenme

Denetimsiz öğrenme algoritmaları birçok özneliğe sahip bir veri kümesi deneyimler ve yapısında elverişli olabilecek özellikleri öğrenir. Derin öğrenmede, çoklukla, veri kümesini oluşturan olasılık dağılımı öğrenilmek istenmektedir. Bu, yoğunluk kestirimi görevinde olduğu gibi açık bir şekilde veya sentezleme ve gürültüsüzleştirme örneklerinde olduğu gibi dolaylı olarak da yapılabilmektedir. Benzer örnekleri bir araya getirecek şekilde veri kümesini gruplayan kümeleme, başka bir denetimsiz öğrenme algoritmasıdır. Şekil 2.1’de denetimsiz öğrenme modelleri ve biyomedikal araştırmalarda sıklıkla kullanıldığı algoritmalar gösterilmiştir.



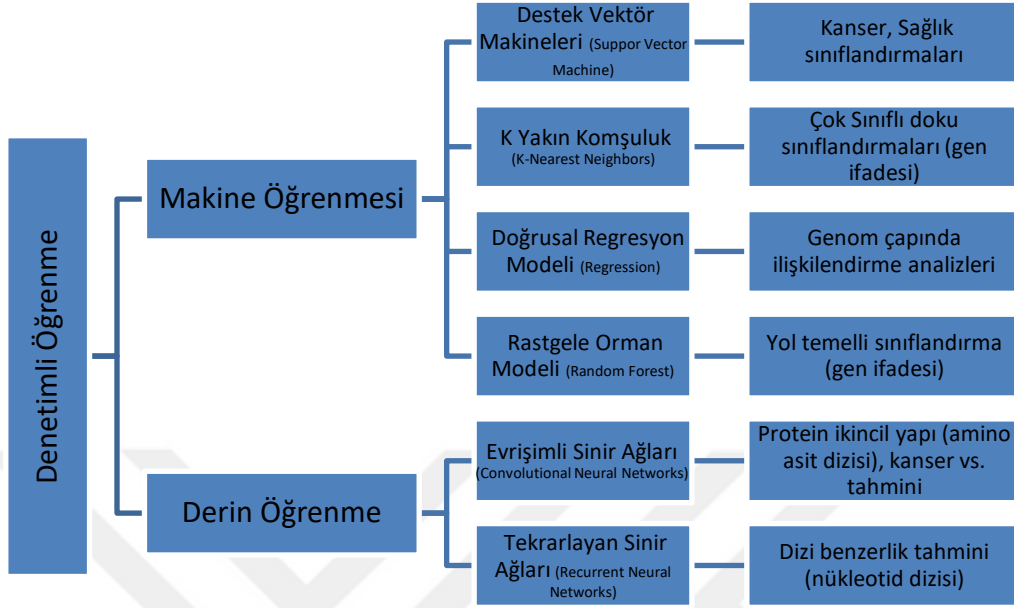
Şekil 2.1 : Denetimsiz öğrenme modelleri ve biyomedikal araştırmalarda kullanılan algoritmalar.

2.2.2 Denetimli öğrenme

Denetimli öğrenme algoritmaları da benzer şekilde öznitelikleri ile tanımlanmış veri kümelerini öğrenirler. Ancak burada her örnek, bir etiket (label) veya hedef (target) ile ilişkilendirilmiştir. Örnek olarak, İris veri kümesi her bitkinin türünü belirtecek şekilde etiketlenmiştir. Denetimli öğrenme algoritması bu veri kümesini deneyimleyip, ölçümlerine göre üç türe ait bu bitkileri sınıflandırmayı öğrenebilmektedir. Şekil 2.2’de denetimli öğrenme modelleri ve biyomedikal araştırmalarda sıklıkla kullanıldığı algoritmalar gösterilmiştir.

Denetimsiz öğrenme rastgele bir x vektörünü alır ve bu vektördeki farklı örneklerini deneyimler. Daha sonra, doğrudan veya dolaylı olarak veri kümesinin olasılık dağılımını gösteren $p(x)$ değerini veya bu dağılımın farklı özelliklerini öğrenmeye çalışır. Denetimli öğrenme, rastgele bir x vektörünü ve bu vektördeki örneklerle ilişkilendirilmiş değer veya vektör olan y ’yi ele alır. Buradan x verilerini kullanarak y değerlerini öngörmeye çalışır. Öngörü genellikle $p(y | x)$ olasılığını hesaplayarak yapılır. Bir eğitmen ya da öğretmenin makine öğrenmesi algoritmasına y etiket değerlerini vererek modelin ne yapması gerektiği düşünüldüğünde denetimli öğrenme modeli bu benzeştirmeden yola çıkılarak türemiştir. Denetimsiz öğrenmede ise bir eğitici yoktur. Algoritma herhangi bir yönlendirme olmaksızın kendi kendine veriyi anlamlandırmaya çalışır. Denetimli öğrenme aşağıdaki gibi çözülür.

$$p(y | x) = \frac{p(x, y)}{\sum_{y'} p(x, y')} \quad (2.1)$$



Şekil 2.2 : Denetimli öğrenme modelleri ve biyomedikal araştırmalarda kullanılan algoritmalar.

2.2.3 Veri kümesi (data set)

Veri kümesi açıklayıcı değişkenler matrisi olarak tanımlanmaktadır. Açıklayıcı değişkenler matrisi her bir satırında farklı örnekler içermektedir. Her sütun ise farklı bir özneliğe karşılık gelmektedir. Bir veri kümesinin dört özneliğe sahip olan 150 örnek içerdiğini düşünelim. Yani veri kümesinin boyutları $X \in R^{150 \times 4}$ olan açıklayıcı değişkenler matrisi ile belirtilir. İris veri kümesini düşünecek olursak $X_{i,1}$, i bitkisinin çanak yaprağı boyunu; $X_{i,2}$, i bitkisinin çanak yaprağı genişliğini vb. göstermektedir.

Denetimli öğrenmede bir örnek hem bir etiket hem de öznelikler değerlerini içermektedir. Derin öğrenme algoritmasından bazı fotoğraflardan nesne tanıma görevini yürütmesi tanımlandığında, hangi nesnenin hangi fotoğrafa olduğu belirtilmelidir. Bunu sayısal kodlar kullanarak yapabiliriz. 0 bir kediyi belirtebilir, 1 arabayı, 2 köpeği vb. Bu tip veri kümesiyle çalışırken, genellikle bir de etiket vektörü y buldururuz. Bu vektörde y_i değeri, i örneğinin etiketini belirtir.

2.2.4 Test kümesi

İsminden de anlaşılacağı üzere doğrusal bağlanım bir bağlanım problemini çözer. Başka bir deyişle amaç, $x \in R^n$ vektörünü girdi olarak alıp, $y \in R$ skaler çıktısının

değerin öngören bir sistem oluşturmaktır. \tilde{y} değişkeni ile modelin öngördüğü y değerini ifade edersek. Çıktı aşağıdaki gibi tanımlanır;


$$\tilde{y} = \omega^T x \quad (2.2)$$

Burada $\omega \in R^n$, parametreler vektörüdür.

Parametreler sistemin davranışlarını kontrol eden değerlerdir. Bu durumda ω_i , bütün öznitelikler katkı sağlamak için toplanmadan önce, x_i özneliği ile çarptığımız katsayıdır. ω 'yı bir ağırlıklar kümesi olarak düşünebiliriz. Bu ağırlıklar, özniteliklerin öngörüyü nasıl etkileyeceğini belirler. Eğer bir özneliğin aldığı ağırlık sıfır ise o özneliğin öngörü üzerine bir etkisi yoktur. Görev T için tanımımız : $\tilde{y} = \omega^T x$, bu tanım için bir de performans ölçütü P olarak tanımlanır. Toplamda m örnek girdiden oluşan bir açıklayıcı değişkenler matrisi düşünelim, ancak bu açıklayıcı değişkenler matrisin eğitime amacıyla değil, sadece modelin performansını ölçmek için kullanıldığını varsayalım. Ayrıca elimizde bir de her örneğin gerçek değeri y 'yi veren bağlanım hedefler vektörü olduğunu düşünelim. Bu veri kümesi sadece değerlendirme amacıyla kullanılacağından, buna test kümesi adını veriyoruz. Girdilerin açıklayıcı değişkenler matrisi x_{test} bağlanım hedefler vektörü ise y_{test} ifadesiyle tanımlanmaktadır.

2.2.5 Doğrulama kümesi (validation)

Test örneklerinin herhangi bir şekilde model ya da hiperparametreler hakkında karar verilirken kullanılmadığı bilgisi çok önemlidir. Bu nedenle, Şekil 2.3'te görüldüğü üzere, test kümesinden hiçbir örnek doğrulama kümesinde kullanılmaz. Dolayısıyla doğrulama kümesini her zaman eğitim verilerinden oluştururuz. Spesifik olarak eğitim kümesini iki ayrı altkümeğe ayırırız. Bu altkümeğelerden birini, parametreleri öğrenmek (eğitim, train) için ayırırız. Diğer altkümeği ise doğrulama kümesi olarak kullanırız. Genellikle eğitim verilerinin yüzde 80'i eğitim için kalan ise doğrulama için kullanılır. Doğrulama kümesi eğitim kümesi içerisinde seçilir fakat optimizasyon sırasında kullanılmaz. Geri besleme (backpropagation) ile parametrelerin güncellenmesinde kullanılır. Bu nedenle öğrenme eğitimi sürecine doğrudan etki etmektedir. Her iterasyon sonunda (epoch) doğrulama kümesi ile test kümesi ile modelin başarımı ölçülür. Test kümesinin sonucu öğrenme işleminin hiçbir basamağında kullanılmaz.



Şekil 2.3 : Veri kümesinin eğitim, doğrulama ve test kümesi olarak bölünmesi.


2.3 Fonksiyonlar

2.3.1 Softplus fonksiyonu

Derin öğrenmede sıkça kullanılan bir diğer dağılım fonksiyonu ise Softplus fonksiyonudur (Dugas, 2001).

$$\zeta(x) = \log(1 + \exp(x)) \quad (2.3)$$

Softplus fonksiyonu, normal dağılımın β ya da σ parametresini oluştururken yararlı olabilmektedir. Bunun sebebi görüntü kümesinin $(0, \infty)$ aralığında olmasıdır. Aynı zamanda sigmoid içeren ifadeleri kullanırken sıkça ortaya çıkmaktadır. Şekil 2.4'te Softplus ve ReLu fonksiyonu görülmektedir.



Şekil 2.4 : Softplus ve ReLu Fonksiyonu.

2.3.2 ReLu (Rectified Linear Unit) fonksiyonu

ReLu fonksiyonu derin öğrenme metotlarında iyi bir tahmin edici olarak kullanılmaktadır. ReLu'nun kombinasyonları ile herhangi bir başka fonksiyona da yakınsamak mümkündür. Şekil 2.4'te ReLu fonksiyonu grafiği görülmektedir. ReLu, $[0, +\infty]$ aralığında değer almaktadır. Negatif ekseninde 0 değerlerini alması ağı'nın daha hızlı çalışacağı anlamına gelmektedir. Hesaplama yükü sigmoid fonksiyonuna göre az olması çok katmanlı ağlarda daha çok tercih edilmesine sebep olmuştur.

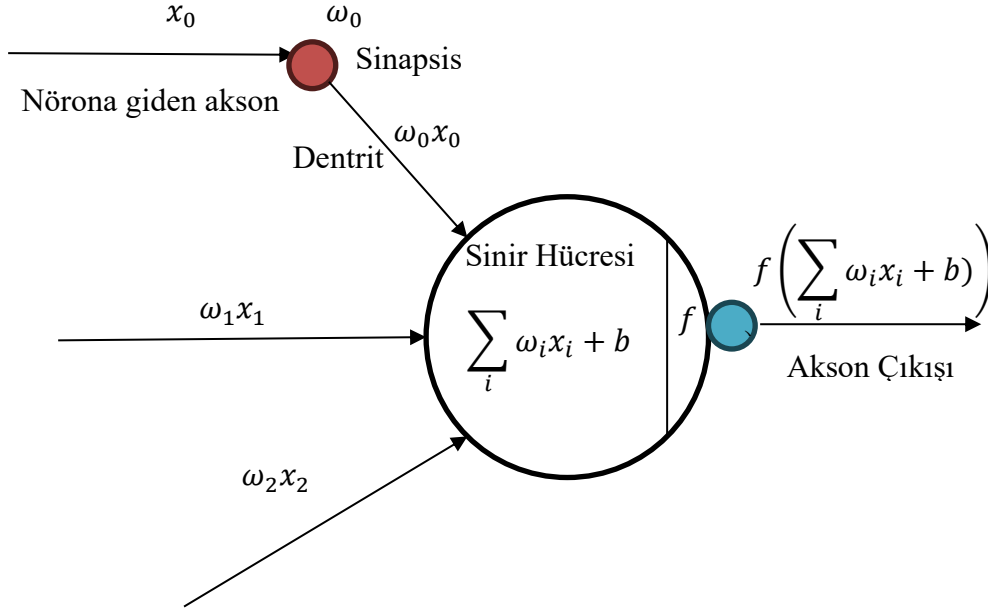
$$f(x) = \begin{cases} 0 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases} \quad (2.4)$$

2.3.3 Fonksiyonların önemi

Yapay sinir ağları, canlıların öğrenme yapısının sinir sistemi aracılığıyla modellenerek taklit edilmesi prensibine dayalı yapay bir öğrenme tekniğidir. Canlı'nın sinir yapısı hiyerarşik bir elektrik akımı sonucunda gerçekleştirilir. Doğduğumuz andan itibaren alıcılardan aldığımız elektriksel uyarı ile gördüğümüz, duyduğumuz, hissettiğimiz ve düşündüğümüz her şeyi öğrenmemizi, hatırlamamızı ve ezberlememizi sağlar.

Doğrusal olmayan gerçek dünya özelliklerini yapay sinir ağlarına tanıtmak için aktivasyon fonksiyonlarına ihtiyaç duyulmaktadır. Temel olarak basit bir yapay sinir

ağında x girdi ve ω ise ağırlık olarak tanımlanmaktadır ve aktivasyon işlemi için ağın çıkışına aktarırken $f(x)$ değerine uygulanmaktadır. Bu, ağın son çıkışı veya başka bir katmanın girişi olacaktır. Şekil 2.5'te Sinir ağları yapısı gösterilmektedir.



Şekil 2.5 : Yapay sinir ağları yapısı.

Aktivasyon fonksiyonu uygulanmazsa çıkış sinyali basit bir lineer (doğrusal) fonksiyon haline gelecektir. Lineer fonksiyonlar sadece tek derecelik polinomlardır. Aktivasyon fonksiyonu kullanılmayan bir yapay sinir ağı, sınırlı öğrenme güncüce sahip lineer bir regresyon yapı gibi davranacak, öğrenme gücü düşük olacaktır. Ancak sinir ağımızın doğrusal olmayan yapıları da öğrenmesini istemekteyiz. Fonksiyon sayesinde yapay sinir ağı, çok katmanlı derin sinir ağları verilerinden daha anlamlı özellikler öğrenebilmektedir.

3. EVRİŞİMLİ (KONVOLÜSYONEL) SİNİR AĞLARI

Yapay zekanın ilk günleri olan 1950'lerden bu yana, araştırmacılar görsel verileri anlayabilen bir sistem yapmak için mücadele ettiler. İlerleyen yıllarda bu alan Derin Öğrenme olarak anılmaya başlandı. 2012 yılında Toronto Üniversitesi'nden bir grup araştırmacı, en iyi görüntü tanıma algoritmalarını büyük bir farkla geride bırakan bir yapay zekâ modeli geliştirdiğinde derin öğrenme bir kuantum sıçraması yaşadı. Alexnet (adını ana yaratıcısı Alex Krizhevsky'den almıştır) olarak bilinen yapay zeka sistemi ImageNet bilgisayarla görme yarışmasını yüze 85 gibi inanılmaz bir doğruluk oranıyla kazandı. AlexNet merkezinde, insan görüşünü kabaca taklit eden özel bir sinir ağı olan evrişimli sinir ağı vardı (Mandal, 2024).

Evrışimli sinir ağı sayesinde görüntü ve videolar üzerinden en iyi şekilde işlemler yapılabilir ve nesne tespiti yapılabiliriz. İlk olarak 1995 yılında LeCun tarafından CNN, bir makale şeklinde yayınlandı. Ardından ilk uygulama 1998 yılında Yann LeCun ve ekibi tarafından gerçekleştirildi. Aynı zamanda bu model CNN modeli olarak ilk başarılı sonucu vermiştir (Şakar, 2021).

Görüntü verileri, bir veya birden fazla sayısal değeri temsil eden iki boyutlu bir piksel ızgarasıdır. Daha önce görüntüler, pikseller arasındaki uzamsal ilişkiye bakılmaksızın düzleştirilerek sayı vektörleri olarak ele alınıyordu. Bu tatmin edici olmayan yaklaşım, ortaya çıkan tek boyutlu vektörleri tam bağlantılı bir Çok Katmanlı Programlama (MLP) aracılığıyla beslemek için gerekiyordu. Konvolüsyonel sinir ağları (CNN) (LeCun vd.,1995) bu amaç için tasarlanmış güçlü bir sinir ağı ailesidir ve artık bilgisayarla görmede her yerde bulunmaktadır. Örneğin, imagenet koleksiyonunda (Deng vd.,2009) yalnızca evrişimli sinir ağlarının, kısaca Convnet'lerin kullanılması önemli performans iyileştirmeleri sağlamıştır (Krizhevsky vd.,2012). Modern CNN'ler biyoloji, grup teorisi ve deneysel müdahalelerden esinlenmiştir. Hesaplama açısından verimlidirler, tam bağlantılı mimarilerden daha az parametre gerektirir ve GPU çekirdekleri arasında paralelleştirilmeleri kolaydır. Uygulayıcılar mümkün olan her durumda CNN'leri kullanmaktadır; ses, metin ve zaman serisi analizi gibi tek boyutlu dizi yapısına sahip görevlerde bile güvenilir rakipler olarak ortaya çıkmışlardır. CNN'lerin bazı akıllıca uyarlamaları, onları grafik yapıları verilerde de kullanılabilir hale getirmiştir. Temel anlamda bir CNN mimarisinde evrişim, aktivasyon, havuzlama (pooling), tek düzlemlili vektör (flattening), tam bağlantı (fully connected) katmanları yer almaktadır. Bunlara ek olarak dolgu (padding), adımlama

(stride), toplu normalleştirme (batch normalization) ve seyreltme (dropout) teknikleri de opsiyonel olarak kullanılabilir.


3.1 Evrişim Katmanı

Evrişim iki matris (giriş ve filtre matrisleri) arasında yapılan matematiksel bir işlemdir ve çıktısı da bir matristir. Evrişimsel ağ terminolojisinde, evrişimin ilk değişkeni x , girdi olarak, ikinci değişkeni ω fonksiyonu Kernel olarak adlandırılır. Çıktı öznitelik haritası (feature map) olarak tanımlanır. Daha az gürültülü bir kestirim elde etmek için değişik ölçümlerin ortalamasını almak isteriz. Daha yeni ölçümler daha uygun olduğu için bunun son ölçümlere daha fazla ağırlık veren ağırlıklı ortalama olmasına gerek duyarız. Bunu, a bir ölçüm olmak üzere $\omega(a)$ ağırlık fonksiyonu ile yapabiliriz. Bu şekilde bir ağırlık ortalama işlemini her an uygularsak pürüzsüzleştirilmiş bir kestirimi sağlayan bir s fonksiyonu elde ederiz:

$$s(t) = \int x(a)\omega(t - a)da \quad (3.1)$$

$$s(t) = (x * \omega)(t) \quad (3.2)$$

Bu işleme (Eş. 3.1) evrişim adı verilir, evrişim işlemi tipik olarak yıldız işareti (Eş. 3.2) ile gösterilir. Şekil 3.1'de MIAS veri kümesindeki bir verinin evrişimli görüntü örneği görülmektedir.



MIAS veri kümesi
mdb019.png

Kernel

Evrişimli görsel

Şekil 3.1 : Kernel matrisi uygulanmış evrişimli görüntü örneği.

Makine öğrenmesi uygulamalarında, girdi genellikle çok boyutlu bir veri dizisidir ve kernel genellikle öğrenme algoritması tarafından uyarlanan çok boyutlu parametreler dizisidir. Bu çok boyutlu diziler tensör olarak tanımlanır. İki boyutlu bir I görüntüsünü girdimiz olarak kullanırsak, iki boyutlu bir K kerneli kullanırız:

$$s(i, j) = (K * I)(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (3.3)$$

Eş. 3.3'teki denklemin bir makine öğrenmesi kütüphanesinde uygulanması daha kolaydır.

Kernelin girdi tensörünün sol üst bölgesine uygulanarak, çıktı tensörünün sol üst elemanının nasıl oluştuğu Şekil 3.2'de gösterilmiştir.

20	24	11	12	16	19
19	17	20	23	15	9
21	40	25	13	14	8
9	18	8	6	11	22
31	3	7	9	17	13
20	12	3	11	19	30

6x6 giriş

*

1	0	-1
2	0	-2
1	0	-1

Sobel Kernel 3x3

=

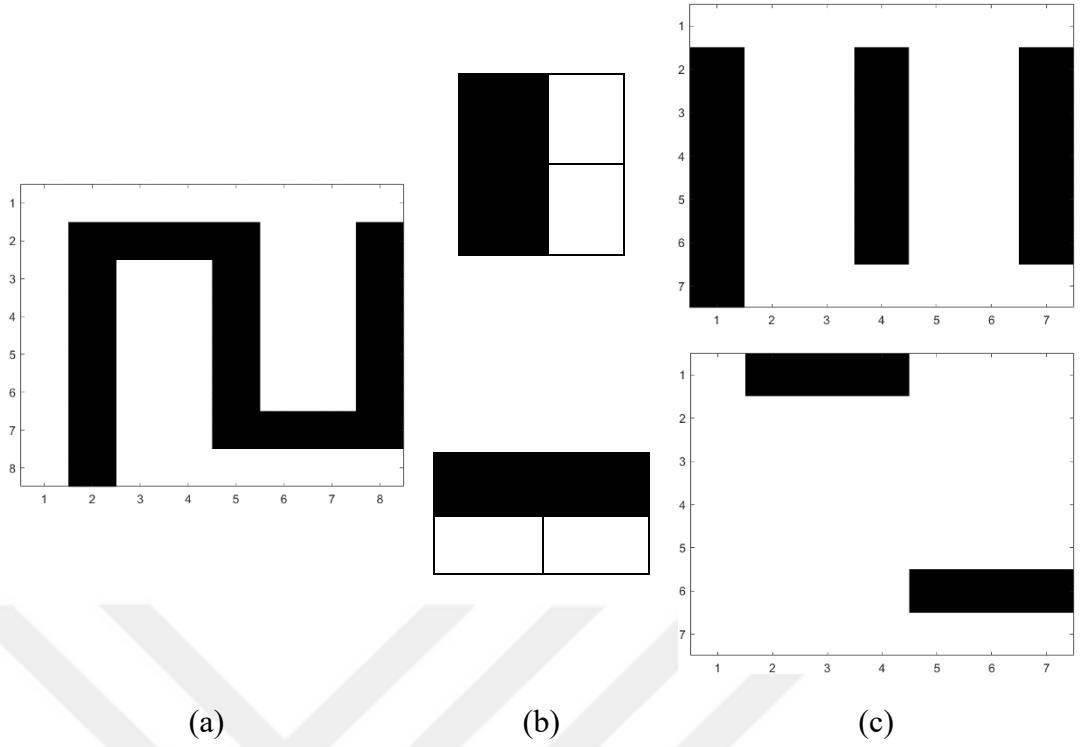
3			

4x4 çıkış

$$(20 \times 1) + (24 \times 0) + (11 \times -1) + (19 \times 2) + (17 \times 0) + (20 \times -2) + (21 \times 1) + (40 \times 0) + (25 \times -1) = 3$$

Şekil 3.2 : Birinci lokasyonun oluşumu.

Çıkış matrisin boyutu = Giriş matrisinin boyutu – Filtre boyutu+1 olarak hesaplanır, Şekil 3.2'ye bakacak olursak çıkış matrisi boyutu = (6-3+1)x(6-3+1) = 4x4 olacaktır. Şekil 3.2'de bir sobel çekirdeği sol sütunda pozitif, orta sütunda sıfır ve sağ sütunda negatif değerlere sahip olduğundan, çekirdek görüntü boyunca soldan sağa doğru hareket ettirildiğinde konvolüsyon işlemi yatay yöndeki türevin sayısal bir yaklaşımıdır ve bu nedenle üretilen çıktı dikey kenarları tespit eder. Bu örnek, belirli çekirdeklerin görüntülerdeki kenarlar gibi çeşitli yapıları nasıl tespit edebileceğinin bir örneğidir. Şekil 3.3'te orijinal görüntünün yatay dikey kenar tespit etme işlemi gösterilmiştir. Diğer çekirdekler yatay çizgileri/kenarları veya çapraz çizgileri/kenarları tespit etmek için kullanılır. Padding ve stride kullanılmış ise n:input, p: padding, k: kernel, s: stride olmak üzere çıkış matrisi= $\lceil \frac{(n+2p-k)}{s} \rceil + 1$ şeklinde hesaplanır.



Şekil 3.3 : Konvolüsyon işleminde yatay ve dikey kenar algıma işlemi

(a) Orijinal görüntü, (b) yatay ve dikey kenar algılama filtreleri, (c) çıktı.

3.2 Aktivasyon Katmanı

İlk bölümde bahsettiğimiz üzere aktivasyon fonksiyonu içermeyen bir yapay sinir ağı, basit bir doğrusal regresyon modelinden farksızdır. Aktivasyon işlemi giriş sinyali üzerinden yapılan doğrusal olmayan bir dönüşüm olarak tanımlanır. Bu dönüştürülmüş sinyal daha sonra girdi olarak bir diğer takip edilen katmana gönderilir. Genel olarak ReLu, sigmoid, tanh gibi aktivasyon fonksiyonları kullanılmaktadır. Hız konusunda en iyi sonucu ReLu verdiği için çoğunlukla makine öğrenme algoritmalarında sıklıkla tercih edilmektedir. ReLu fonksiyonu her evrişim işleminden sonra, Şekil 3.4'te görüldüğü üzere piksel piksel işlem yaparak tüm negatif değerleri sıfıra çeker, tüm pozitif değerleri aynı tutar (Mit., 2022).

1	-3	2	-2
-2	0	4	3
-1	-2	-2	-3
-2	4	4	2

Girdi

1	0	2	0
0	0	4	3
0	0	0	0
0	4	4	2

Çıktı

Şekil 3.4 : ReLu aktivasyonundan geçen bir girdi ve çıktı.

3.3 Havuzlama (Pooling)

Havuzlama katmanında, boyut indirgeme (down sampling) işlemi yapılmaktadır. Bu katmanda herhangi bir öğrenme işlemi gerçekleşmez, öğrenilebilir parametreleri yoktur çünkü tek yaptığı belirli bir sayıyı hesaplamaktır, geriye dönük öğrenme sözkonusu değildir. Amacı input matrisinin kanal sayısını sabit tutarak en ve boy bazında boyut indirgenmesi yapmaktır. Avantaj olarak hesaplama karmaşıklığını azalttığı söylenebilir. Bu nedenle evrişim katmanından sonra kullanılmaktadır. Yaygın olarak ortalama (average) ve maksimum (maximum) havuzlama yöntemleri kullanılmaktadır. Ortalama, görüntünün çekirdek tarafından kapsanan kısmındaki tüm değerlerin ortalamasını verir, maksimum havuzlama ise çekirdek tarafından kapsanan kısmındaki maksimum değerleri döndürür (Vasudev, 2019). Şekil 3.5’te maksimum ve ortalama havuzlama örneği görülmektedir.

12	20	30	0	20	30	Maksimum havuzlama
8	12	2	0	112	37	
34	70	37	4	13	8	Ortalama havuzlama
112	100	25	12	79	20	

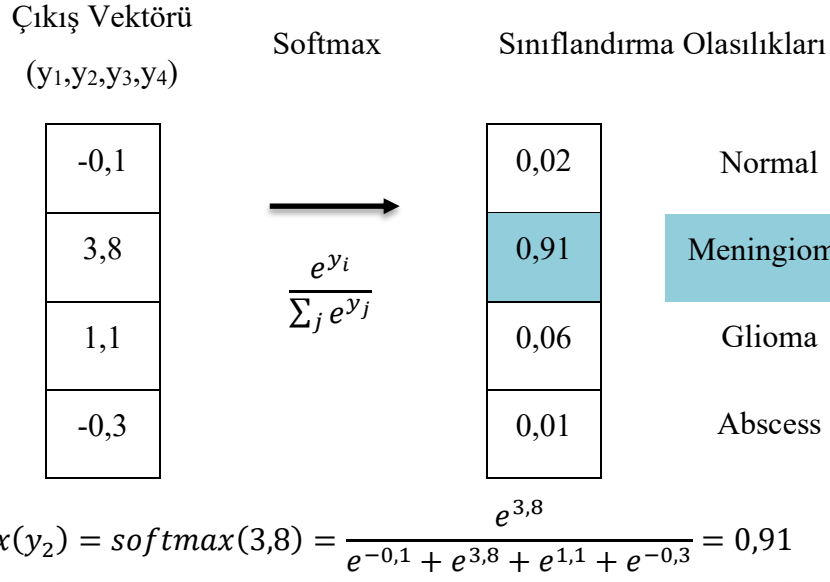
Şekil 3.5 : Havuzlama örneği.

3.4 Tek Düzlemli Vektör (Flattening) ve Tam Bağlantı (Fully Connected) Katmanları

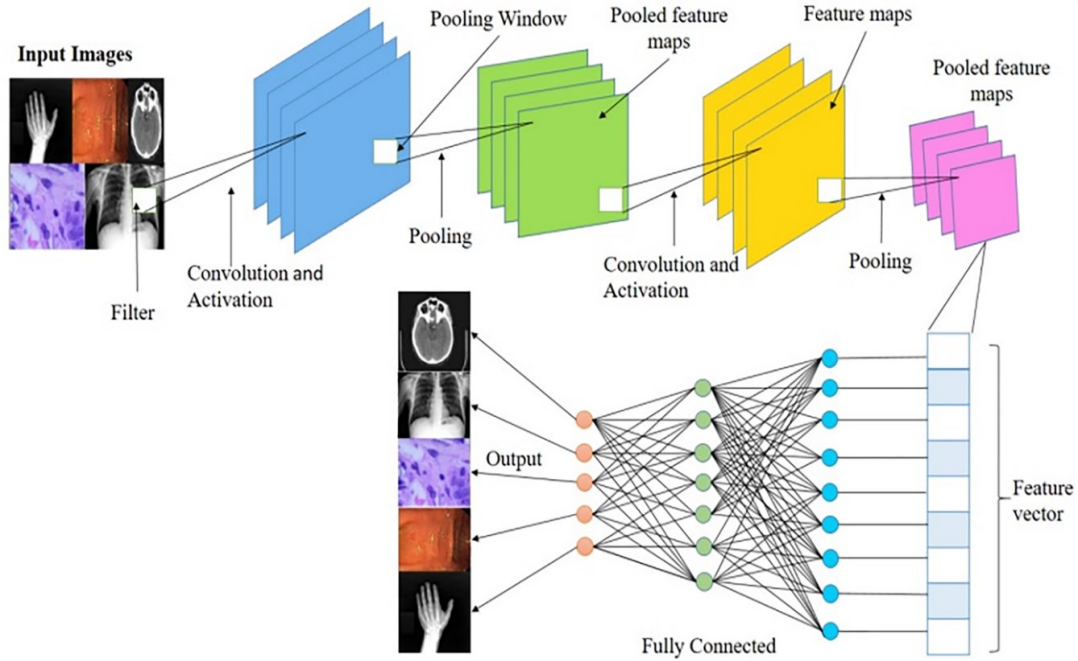
Yapay sinir ağlarına matrisi aktarıp işlenebilir hale getirebilmek için tek düzlemli vektör oluşturmak gerekmektedir. Tek düzlemli vektör katmanında, tek düzlemli hale dönüştürülen vektörler alınıp yapay sinir ağlarına tam bağlantı katmanının beslemesi olarak verilir. Son evrişimsel katmandan sonra tam bağlantı katmanı vardır. Evrişim

ve havuzlama katmanlarının hedefi girdiden çıkarılan yüksek seviyeli özniteliklerin çıktısını almaktır. Tam bağlantı katmanı, bu öznitelikleri, giriş görselini sınıflandırmak için kullanır. Bu sınıflandırma işlemini softmax işlevi adı verilen aktivasyon fonksiyonunu kullanarak yapar (Aslan ve diğerleri, 2021). Softmax işlevi, olasılık dağılımını temsil eden basit bir normalleştirme işlevidir. Olasılık dağılımlarının çeşitli özellikleri vardır, tüm değerlerinin toplamının bir olması gerekir ve her zaman sıfır ile bir arasında olması gerekir. Dolayısıyla bu iki özelliği korumak için yumuşak bir Max işleminin yapılması gerekmektedir (Eş. 3.4). Şekil 3.6'te CNN beyin tümörü sınıflandırmasının son aşamasında softmax kullanımı gösterilmiştir. Şekil 3.7'de bir CNN mimarisi örneği görülmektedir.

$$\text{softmax}(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad (3.4)$$



Şekil 3.6 : Beyin tümörü sınıflandırması Softmax kullanımı.



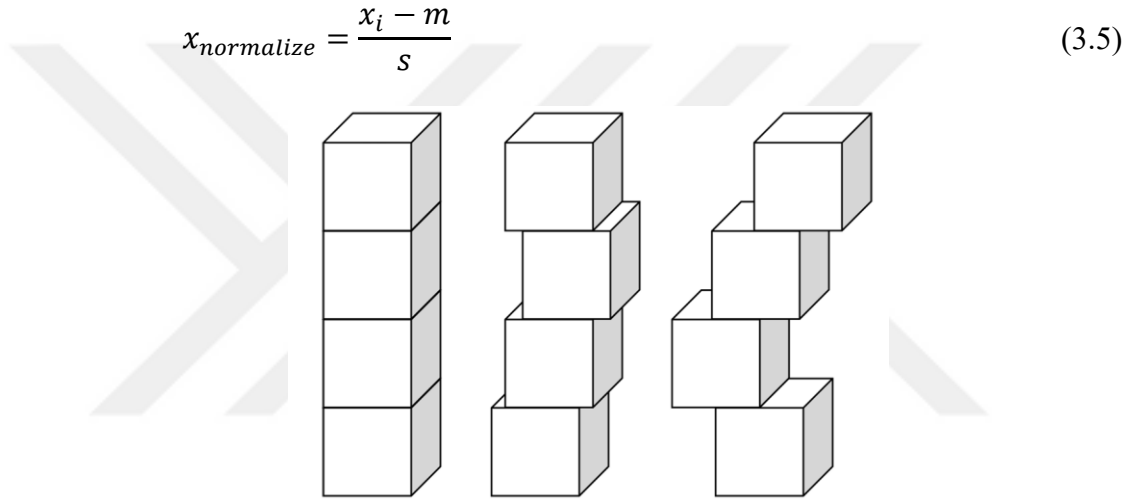
Şekil 3.7 : CNN mimarisi örneği.

(Abid ve diğerleri, 2023).

3.5 Toplu Normalleştirme (Batch Normalization)

2015 yılında Google araştırmacıları, toplu normalizasyon adı verilen bir teknik kullanarak ileri beslemeli ve evrişimli sinir ağlarını daha da hızlandırmak için bir yol

geliştirdiler (Ioffe ve Szegedy, 2015). Şekil 3.8’da gösterildiği gibi bloklardan oluşan bir kule hizada olmayacak şekilde çok büyük ölçüde yer değiştirdiğinde yapı çok dengesiz hale gelebilir. Blokları rastgele kaydırırsak yapıyı daha çok dengesiz konfigürasyonlara zorlayabiliriz. Sonunda kule dağılır. Toplu normalizasyon, her bir katmana giren girdilerin dağılımında önemli kaymaları önleyerek eğitimi hızlandırmanın yanı sıra öğrenme oranını da önemli ölçüde hızlandırmamızı sağlar. Her katmanın girişi kendinden önce gelmekte olan katmanın çıkış vektörü normalize edilerek beslenmektedir. İlgili çıkış vektöründen önce, m (*mean*) ortalamayı çıkarıp, s standart sapmaya bölerek (Eş. 3.5) partinin tüm örneklerinde her bir bileşen normalleştirilir.

$$x_{normalize} = \frac{x_i - m}{s} \quad (3.5)$$


Kuledeki bloklar büyük ölçüde yer değiştirdiğinde yapı dengesiz hale gelebilir

Şekil 3.8 : Dengesiz bloklar.

(Buduma ve Lacascio, 2017).


3.6 Öğrenme Aktarımı (ResNet Transfer Learning)

Öğrenme aktarımı, başka bir görevde öğrenmeye yardımcı olmak için bir görevde öğrenilen bilgilerin (veya temsillerin) kullanılmasına yönelik makine öğrenimi sorunudur (Kelleher, 1974). Öğrenme aktarımının işe yaraması için görevlerin birbirleriyle ilişkili alanlarda olması gerekir. Görüntü işleme, öğrenme aktarımının genellikle farklı görevler arasında modellerin eğitimini hızlandırmak için kullanıldığı bir alan örneğidir. Öğrenme aktarımı, görüntü işleme görevleri için uygundur çünkü kenarlar gibi düşük seviyeli görsel özellikler nispeten daha sabittir ve neredeyse tüm görsel kategorilerde kullanışlıdır.

Öğrenme aktarımı, eğitim ve testte kullanılan dağılımların, görevlerin ve hatta veri alanlarının farklı olmasına izin verir. Öğrenme aktarımı, insanların bir görev hakkındaki bilgilerini başka bir görevin öğrenilmesini kolaylaştırmak için kullanmalarına benzer. Örneğin flüt çalmayı biliyorsak, nota okuma ve müzik bilgilerimizi piyano çalmayı öğrenme görevini basitleştirmek için kullanabiliriz. Öğrenme aktarımı, verilerin güncelliğini yitirdiği yaygın uygulamalar için kullanışlıdır.

Çok sayıda gizli katman ve son derece derin sinir ağları kullanma fikri birçok model tarafından uygulandı, ancak daha sonra bu tür modellerin kaybolan veya patlayan gradyan probleminden muzdarip olduğu fark edildi. He ve arkadaşları bu soruna karşı ResNet mimarisini geliştirdi (Sharma, 2020).

He ve arkadaşlarının 2015 ImageNet yarışması kazananı ResNet (Residual Network), atlama bağlantılarını kullanarak kaybolan gradyan sorununu başarıyla çözmüştür (Iosifidis ve Tefas, 2022). Evrimsel katmanlar ve atlama bağlantıları tarafından oluşturulan artık bloklar, evrim katman sayısının onlarca katmandan yüzlerce katmana çıkarılmasını sağlamıştır. AlexNet'in %15,3'lük oranına kıyasla ResNet; ILSVRC 2015 yarışmasını %3,57'lik ilk beş hata oranı elde ederek kazanmıştır (Pattanayak, 2019). ImageNet veri kümesi 1000 sınıftan oluşmaktadır. ResNet ağ modeli ile eğitilen ImageNet veri kümesinde modeller, 1,28 milyon eğitim görüntüsü ile eğitilmiş ve 50 bin doğrulama görüntüsü üzerinde değerlendirilmiştir (Mikami ve diğerleri, 2018). ResNet mimari blok diyagramı Şekil 3.9'da gösterilmiştir.



Şekil 3.9 : Residual blok diyagramı.

Bu tez çalışmasında ResNet18, ResNet50, ResNet101 ve ResNet152 modelleri kullanılarak analizler gerçekleştirilmiştir. Şekil 3.11’de ResNet mimari yapısı görülmektedir. Şekil 3.10’da görüldüğü üzere ResNet18 ve ResNet34 mimarisi average pooling, fc, softmax katmanında, 512 öz nitelikten oluşmaktadır. ResNet50, ResNet101 ve ResNet152 mimarisi ise 2048 öz nitelikten oluşmaktadır (Aslan ve Sabancı, 2023). ResNet18 ağ mimarisi 1 conv1 + (2x2) conv2 + (2x2) conv3 + (2x2) conv4 + (2x2) conv5 + 1 average pooling, fc, softmax= 18 katmandan meydana gelmektedir.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 3.10 : ResNet mimarisi.



4. MODEL DEĞERLENDİRME

Bir sınıflandırma modeli oluşturduktan sonra oluşturulan modelin başarımını, ne kadar iyi veya ne kadar doğru olduğunu ölçmek için bir takım ölçütler kullanırız. Bunlar arasında doğruluk (tanıma oranı olarak da bilinir, accuracy), duyarlılık (sensitivity, recall), özgüllük (specificity), kesinlik (hassasiyet, precision), F1-skor yer alır. Doğruluk belirli bir ölçüt olmasına rağmen, “doğruluk” kelimesinin bir sınıflandırıcının ikili gruplarının sınıf etiketini tahmin etme kabiliyetine atıfta bulunmak için kullanılan genel bir terimdir. Sınıf çeşitlerinin az çok eşit dağıldığı durumların yanı sıra sınıfların dengesiz olduğu durumları da (örneğin, tıbbi testlerde olduğu gibi önemli bir sınıfın nadir olduğu durumlar) dikkate almalıyız.

4.1 Karışıklık Matrisi (Confusion Matrix)

Bir sınıflandırıcı türetmek için eğitim verilerini kullanmak ve ardından sonuçta öğrenilen modelin doğruluğunu tahmin etmek, öğrenme algoritmasının verilere aşırı uzmanlaşması (overfitting, overoptimistic) nedeniyle yanıltıcı ve aşırı iyimser tahminlere neden olabilir. Bunun yerine, sınıflandırıcının doğruluğunu, modeli eğitmek için kullanılmayan sınıf etiketi gruplardan oluşan bir test kümesi üzerinde ölçmek daha iyidir. Çeşitli ölçümleri yapmadan önce bazı terminolojileri bilmemiz gerekmektedir.

Doğru Pozitif (TP, True Positive) : Kanserli hastaya kanser demek

Yanlış Pozitif (FP, False Positive) : Kanserli olmayana kanserli demek

Doğru Negatif (TN, True Negative) : Kanserli olmayana kanserli değil demek

Yanlış Negatif (FN, False Negative) : Kanserli olana kanserli değil demek

Bu bahsedilen terminoloji karışıklık matrisi (Confusion Matrix) olarak tanımlanmaktadır. Karışıklık matrisi Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1 : Karışıklık matrisi çizelgesi.

		Gerçek (Actual)	
		Pozitif (1)	Negatif (0)
Tahmin Edilen (Öngörülen, Predicted)	Pozitif (1)	TP	FP
	Negatif (0)	FN	TN

Bu çizelgeye bakarak karmaşıklık matrisimizden modelimizin performans değerlerini, başarımını açıklayabiliriz. İdeal bir karmaşıklık matrisinde FP ve FN sıfır veya sıfıra yakındır. Yukarıdaki terimler ile aşağıdaki eşitliklerde görüleceği üzere metrikleri hesaplayabiliriz.

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

$$\text{Duyarlılık (Sensitivity, recall)} = \frac{TP}{TP+FN} \quad (4.2)$$

$$\text{Özgüllük (Specificity)} = \frac{TN}{TN+FP} \quad (4.3)$$

$$\text{Kesinlik (prec)} = \frac{TP}{TP+FP} \quad (4.4)$$

$$\text{F,F1,F-score} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (4.5)$$

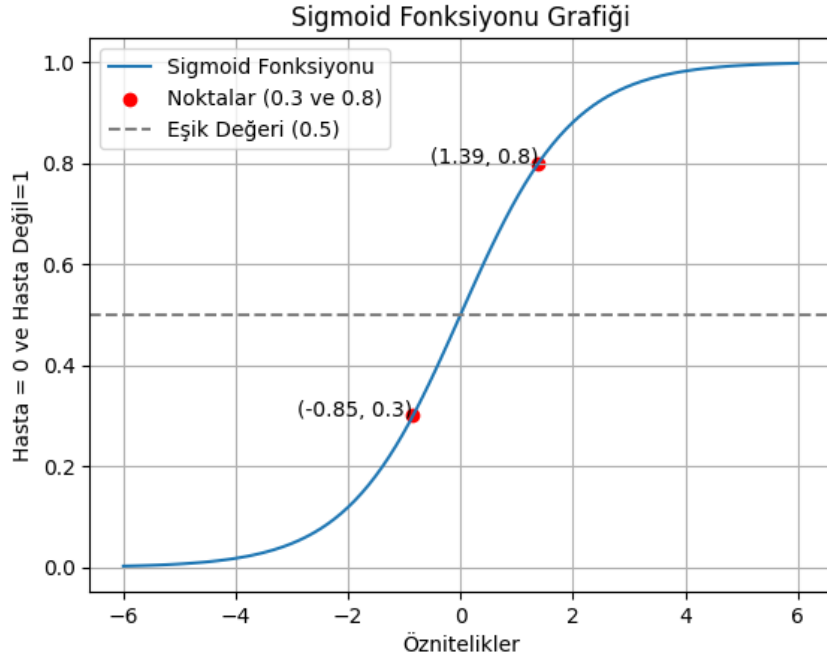
Çizelge 4.1’de gösterilen karışıklık matrisinin ikili bir matris olmasına rağmen sınıflandırma problemlerinde, karışıklık matrisi birden fazla sınıf için kolayca çizilebilir.

İlgilenilen ana sınıfın nadir olduğu sınıf dengesizliği (imbalance data set) problemini ele aldığımızda, yani, veri kümesi dağılımında negatif sınıfın önemli bir çoğunlukta olduğunu ve pozitif sınıfın azınlıkta olduğu bir koleksiyonu eğittiğimizi düşünelim. Tıbbi verilerde kanser gibi nadir bir sınıf olabilir. Örneğin bir derin öğrenme modelinde veri kümesinde görsel özniteliklerin olduğunu ve sınıf etiketi değerlerinin “kanser”, “iyi huylu” ve “normal” olduğu tıbbi veri gruplarını sınıflandırmak için bir sınıflandırıcıyı eğittiğimizi düşünelim. Diyelim ki %98’lik bir doğruluk oranı sınıflandırıcının oldukça iyi görünmesini sağlayabilir, ancak ya eğitim bölütünün yalnızca %5’i gerçekten kanser ise bu %98’lik oran doğruluk oranı olarak kabul edilebilir olmayabilir; sınıflandırıcı yalnızca kanser olmayan veri gruplarını doğru

şekilde etiketliyor ve tüm kanser gruplarını yanlış sınıflandırıyor olabilir. Bunun için sınıflandırıcının pozitif ve negatif metrikleri ne kadar iyi tanıyabildiğine erişen ölçütlere ihtiyacımız vardır. Bu amaçla duyarlılık ve özgüllük ölçütleri kullanılabilir.

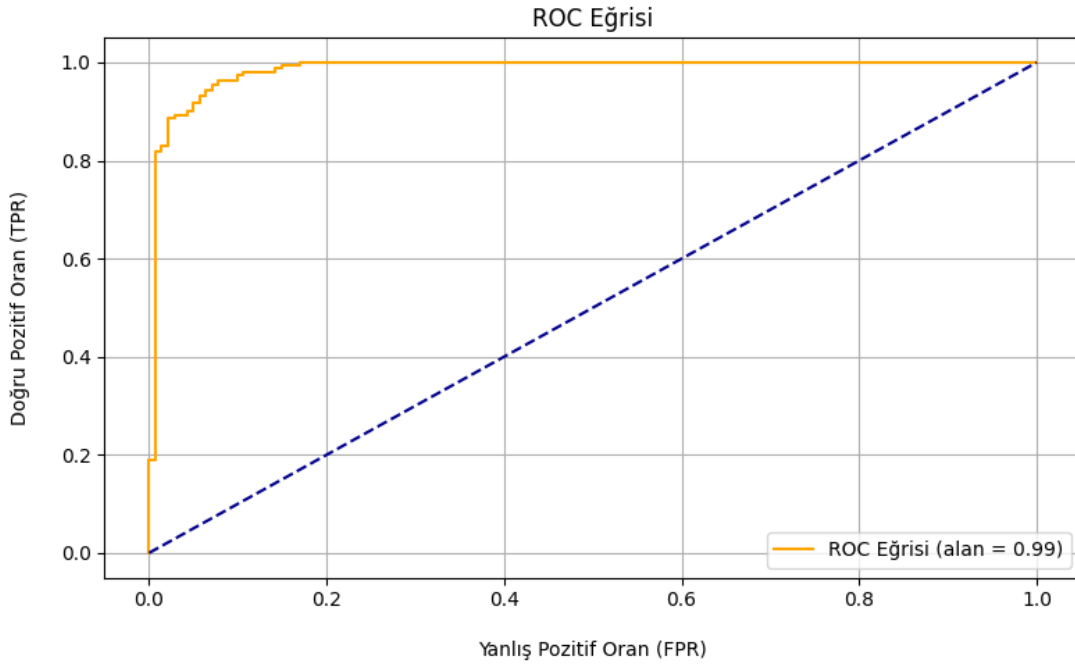
4.2 ROC Eğrisi (Receiver Operator Characteristic)

ROC eğrisi duyarlılık ve (sensitivity) ve özgüllük (specificity) arasındaki ilişkinin grafiksel yorumlanmasıdır. Eğriler yardımı ile bir tanı testi için en iyi eşik (threshold) değeri saptanabilir ve en uygun modele karar verilebilir. ROC eğrisi öngörüler için uygun kesim noktalarını belirleyerek klinik karar verme sürecine önemli ölçüde katkı sağlayan bir yöntemdir. ROC eğrileri karar verme açısından en iyi eşik değerin bulunmasını kolaylaştırır, hangi makine öğrenmesi metodunun daha iyi olduğu konusunda karar verilmesine yardımcı olur. Şekil 4.1'deki örnekte sigmoid aktivasyon çıkış olasılıkları gösterilmiştir. Y ekseninde 0 ve 1 etiketleri ve X ekseninde ise verinin öznelikleri ifade edilmekte, eşik noktası 0,5 olarak alınmaktadır. Eşik noktasının üzerindeki veriler 1 olarak etiketlenmekte, altında ise 0 olarak etiketlenmektedir. Burada optimum başarıyı sağlamak için eşik noktasının doğru seçilmesi çok önemlidir. Şekil 4.2'de örnek bir ROC eğrisi gösterilmektedir. X ekseninde, doğru pozitif oran (True Positive Rate, sensitivity) yer alırken, Y ekseninde, yanlış pozitif oran (False Positive Rate, 1-specificity) bulunmaktadır. Farklı eşik değerler için doğru pozitif oran ve yanlış pozitif oran hesaplanmaktadır. ROC eğrisi tüm bilgileri özetlemek için basit bir yol sunar.



Şekil 4.1 : Sigmoid aktivasyon çıkışları.


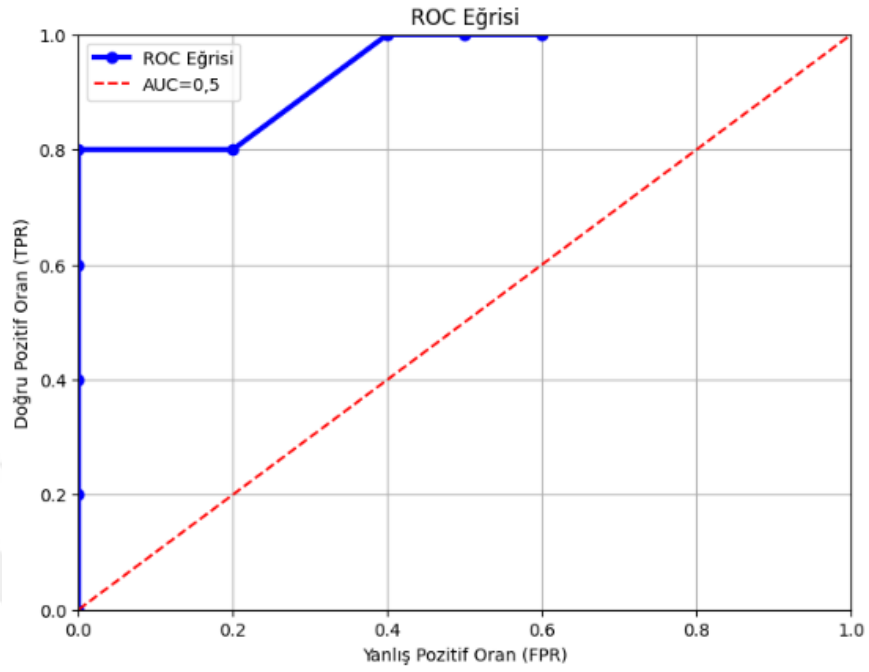
Olasılıklar 0 ve 1 arasında.



Şekil 4.2 : Örnek bir ROC eğrisi.

Analizin doğru karar verme gücünü değerlendiren bir diğer ölçüt ise ROC eğrisi altında kalan alandır. (AUC, area under the curve). Bu alanın alabileceği en büyük değer 1'dir. Şekil 4.3'te mavi alan lojistik regresyonu, kırmızı alan ise rastgele orman

metodu sonuçlarını temsil etmektedir. Bu analize göre en başarılı sonuç lojistik regresyon metodunda alınmıştır.



Şekil 4.3 : ROC eğrisi sonuçları.

ROC eğrisi en başarılı metodu seçmemize olanak sağlar. ROC eğrisinde en iyi eşik (kesim, cut off) noktasını belirlemek için, eğrinin sol üst köşesine en yakın (yani 1 noktasına) koordinat noktası, kesim noktası olarak alınmalıdır (Fawcett, 2006). Kesimi

ayarlamak için bir değer seçilmelidir, yani kesimin üstünde enfekte olmayan herkesin pozitif ve altında ise enfekte olan herkesin negatif olarak seçildiği bir eşik değeri ayarlanmalıdır. Eşik değeri Şekil 4.1’de görüldüğü üzere 0,5 olarak ayarlanmıştır.

Eşik üzerindeki tüm değerler doğru pozitif, eşik üzerindeki negatif değerler ise pozitif olarak yanlış tahmin edildikleri için yanlış pozitif olmaktadır.

Eşik altındaki tüm negatif değerler doğru negatif, eşik altındaki pozitif değerler ise negatif olarak yanlış tahmin edilen yanlış negatif değerler olmaktadır. TPR ve FPR örnekleri birbirine eşitse doğru sınıflama yapılamamış demektir. Şekil 4.4’te ROC eğrisi olasılık dağılım grafikleri görülmektedir.

Eşik düşürdüğümüzde daha pozitif değerler elde ederek hassasiyeti artırırız. Bu arada bu özgülüğü azaltacaktır. Benzer şekilde eşik yükselttiğimizde daha negatif değerler elde ederek özgülüğü artırır ve hassasiyeti azaltırız. Recall ve specificity eşitlikleri Eş. 4.2 ve Eş. 4.3’te verilmiştir.

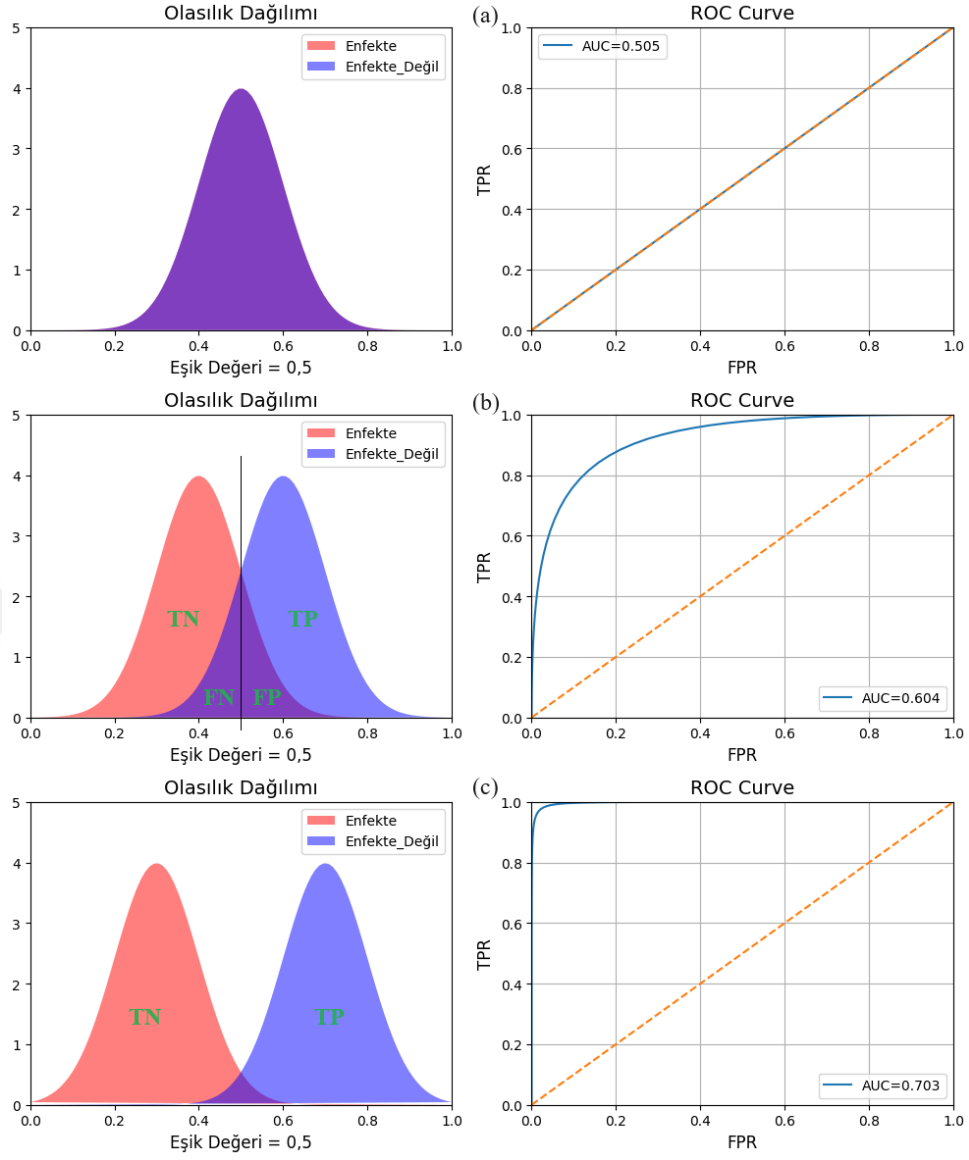
ROC eğrisi çizerken özgülük (specificity) yerine (1-specificity) kullanırız. Specificity bize doğru negatif oranı verir ve (1-specificity) bize yanlış pozitif oranı verir. Dolayısıyla duyarlılık doğru pozitif oran olarak adlandırılabilir ve 1-specificity yanlış pozitif oran olarak adlandırılabilir (Eş. 4.6-4.9).

$$Specificity = \frac{TN}{TN + TP} \quad (4.6)$$

$$1 - Specificity = 1 - \frac{TN}{TN + FP} \quad (4.7)$$

$$1 - Specificity = \frac{TN + FP - TN}{TN + FP} \quad (4.8)$$

$$1 - Specificity = \frac{FP}{TN + FP} \quad (4.9)$$



Şekil 4.4 : ROC eğrisi olasılık dağılım grafikleri

(a) $AUC=0,5$ Test sonucu fark edilebilir değil, (b) Başarılı bir testi ifade etmektedir, (c) Mükemmel bir testi ifade etmektedir (Nazrul, 2018).



5. VERİ KÜMESİNDE DÜZENLİLEŞTİRME

Makine öğrenmesinde en temel problemlerden birisi, sadece eğitim kümesinde değil yeni girdilerde de iyi performans verecek bir algoritmanın geliştirilmesidir. Makine öğrenmesinde kullanılan birçok strateji, test hatasını doğrudan azaltmayı amaçlar ancak bunu yaparken genelde eğitim hatası yükselir. Bu stratejilerin tamamı düzenlileştirme olarak bilinir. Derin öğrenme uygulayıcılarının kullanımına açık olan birçok düzenlileştirme formu mevcuttur. Bu düzenlileştirmeler düzgün seçilirse test kümesindeki performansı artması sağlanabilir. Doğru büyüklükte ve doğru sayıda model parametresini bulmak için modelin karmaşıklığını kontrol altında tutmak kolay bir yol değildir. Bunun yerine veriyi fonksiyona en iyi uyduran modeli, yani doğru şekilde düzenlileştirilmiş büyük bir modeli bulmaya çalışmak derin öğrenme senaryolarında sıklıkla kullanılan bir çalışmadır.

5.1 Veri Kümesi Çeşitleme, Sentetik Veri Artırma (Augmentation)

Bir makine öğrenmesi modelinin daha iyi genelleştirme yapabilmesini sağlamanın en iyi yolu, daha fazla veri kullanarak eğitmektir. Elbette pratikte sahip olduğumuz veri miktarı sınırlıdır. Bu sorunu aşmanın bir yolu, sentetik veriler oluşturmak ve bu verileri eğitim kümesine eklemektir. Eğitim kümemizdeki x girdilerini dönüştürerek yeni (x,y) ikililerini oluşturabiliriz. Eğitim görüntülerinin her iki yönde birkaç piksel ötelenmesi, resmi yeniden boyutlandırmak veya yeniden resim oluşturmak için kırpma ve ölçekleme gibi işlemler genelleştirmeyi büyük ölçüde geliştirebilir. Görüntüyü döndürmek veya aynalamak, kontrast derecesi, parlaklık, doygunluk gibi diğer birçok işlemin de eğitim performansını artırmada oldukça etkili olduğu görülmüştür.

Sınıflandırma modelinde YSA'nın temel görevi görüntünün piksel değerini analiz ederek resmin piksellerinin dizilişinin neye benzediğini kendi hücrelerinde tutmaktır. DL modelimizin veri kümesi görüntüsünde sola bakan bir köpek resmi olsun, eğer çeşitleme yapmadan sadece orijinal resimleri modele verirsek, YSA'nın köpeği sadece sola bakan bir cisim olarak öngörmesi gayet normal olacaktır. Çeşitleme işlemi yapıldıktan sonra yeni veri kümesinde benzer örneklerin sayısı artmış olacaktır ve sonuç olarak veri çeşitleme ile artırma modelin overfit probleminin önüne geçecektir (Anı ve Daniş, 2020).

Doğru sınıfı değiştirecek dönüşümler yapmadığımızıza dikkat etmemiz gerekir. Örneğin, optik karakter tanıma görevi, “b” ile “d” arasındaki ve “6” ve “9” arasındaki farkları tanımayı gerektirir. Yani yatay ötemeler veya 180 derece döndürmeler bu görev için uygun veri çeşitleme yolları değildir. Veri kümesi çeşitleme, konuşma tanıma görevlerinde de oldukça etkilidir (Jaitly ve Hinton, 2013).

Bir sinir ağı girdisine gürültü (deformasyon) eklemek (Sietsmave Dow, 1991), bir başka veri çeşitleme yolu olarak düşünülebilir. Çoğu sınıflandırma görevlerinde ve hatta bazı bağlanım görevlerinde girdiye biraz rastgele gürültü eklense bile görev yine de çözülebilir. Buna rağmen, sinir ağlarının gürültüye çok dirençli olmadığı gösterilmiştir (Tang ve Eliasmith, 2010). Genel olarak uygulanabilen gürültü ekleme işlemlerine örnek, Gauss gürültüsü (gaussian noise) eklenmesi verilebilir.

5.2 Erken Durdurma (Early Stopping)

Aşırı uyumu önlemek için etkili bir teknik, eğitim veri kümesinin boyutunu artırmaktır, ancak aşırı uyumu azaltmak veya önlemek için tasarlanmış, düzenlileştirme teknikleri olarak bilinen bariz yöntemlerden bir başka teknik de erken durdurmadır. Eğitim sırasında test hatasını izlemek ve artmaya başladığında durdurmak yeterlidir. Genellikle eğitim sırasında hata dalgalanır (Ekman, 2022). Erken durdurmaya etkili bir hiperparametre seçimi algoritması olarak da bakabiliriz. Erken durdurmada modelin eğitim kümesini uydurmanın kaç adım süreceğine karar vererek, modelin etkin kapasitesini kontrol edebiliriz.

6. KERAS KÜTÜPHANESİ

Keras kütüphanesi, derin öğrenme ağlarını hızlı bir şekilde oluşturmak için TensorFlow kullanımına izin veren yüksek seviyeli bir derin öğrenme kütüphanesidir. Francois Chollet tarafından geliştirilmiş olan Keras, kullanıcılara basit bir arayüz sunar. Karmaşık yapay sinir ağları modellerini tasarlama ve eğitme sürecini kolaylaştırır (Chollet, 2016). TensorFlow, derin öğrenme için geliştirilmiş açık kaynak kodlu sinir ağları yazmaya izin veren bir matematik kütüphanesidir. Geleneksel makine öğrenme algoritmalarını da desteklemektedir. Google Brain ekibi tarafından Google kullanımı için geliştirilmiştir (2015). TensorFlow, tensör olarak adlandırılan skaler, vektör veya n boyutlu diziyi girdi olarak alır ve bir çıktı üretir. Temelinde Python kullanılarak geliştirilen bu kütüphane, günümüzde Python, C++, Java, C#, Javascript ve R gibi birçok yazılım dilini desteklemektedir.

Keras kütüphanesi öğrenme kolaylığının ve model oluşturabilme kolaylığının ilerisinde, çok geniş ortamlarda kabul edilmesi, çeşitli dışa aktarma seçeneklerini desteklemesi, hızlı ve kolay kullanımı özelliklerinden dolayı kullanımı tercih edilmektedir. Keras; Google, Apple, Microsoft, Uber, Nvidia tarafından da desteklenmektedir.

Keras ile derin öğrenme modeli adımları özetle; öncelikle eğitim verisi tanımlanır, katmanlar ve model tanımlanır, veriyi x_{train} , y_{train} olarak bölmemize olanak tanır, öğrenme tur sayısı (iterasyon, epoch), kayıp fonksiyonu (loss function), optimizasyon (optimizer) gibi parametreler tanımlanır. Model, eğitim verileri yani öznitelikler (features) ile beslenir, gizli katmanlarda (hidden layer) öğrenme işlemi gerçekleştirildikten sonra öngörü (predict) oluşturulur.

Çok yüksek data örneklerinde, karmaşık problemlerin çözümünde, yapılandırılmamış veri kümelerinde, mutlak en iyi modele ihtiyaç duyulduğunda derin öğrenme metotları kullanılmaktadır. Düşük boyutlu veri kümelerinde, geleneksel makine öğrenmesi yöntemleriyle yeterince iyi performans elde edildiğinde, öznitelikler ile alan bilgisine sahip olunarak yapılandırılmış verilerin olduğu veri kümelerinde ve modelin açıklanabilir olduğunda derin öğrenme yöntemleri tercih edilmez.



7. MIAS VERİ KÜMESİ ANALİZİ İÇİN GELİŞTİRİLEN SENARYO

7.1 MIAS Veri Kümesi

Tez çalışmasında MIAS (The Mammography Image Analysis Society) mamografi veri kümesi kullanılmıştır (Suckling ve diğerleri, 2015) (Mader, 2017). 322 adet sayısal medikal görüntüden oluşmaktadır. London Royal Marsden Hastanesi, J. Suckling tarafından görüntüler tasnif edilmiştir. Görüntülerin boyutu 1024x1024 pikseldir. Veri kümesi içerisinde 61 benign (iyi huylu), 52 malignant (habis) ve 209 normal görüntü barındırmaktadır. Görüntüler deneyimli radyologlar tarafından değerlendirilmiş, anomali görüntüler etiketlenmiştir (Alruwaili ve Gouda, 2022). Her bir görüntü, portable gray map (PGM) formatındadır.

Görüntü isimleri mdbxxx olarak isimlendirilmiştir. Görüntü isimlerinde, xxx hasta numarasını belirtmektedir. Meme dokusunun yapıları F : Yağlı (Fatty), G : Yağlı-glandular (Fatty-glandular), D: Yoğun-glandular (Dense-glandular) doku yapıları ve anomali tipleri Çizelge 7.1’de verilmiştir.


Çizelge 7.1 : MIAS veri kümesi görüntü isimleri ve tipleri.

Görüntü Adı	Tanım	Tip
Mdb001	G (Fatty-glandular)	İyi huylu
Mdb002	G (Fatty-glandular)	İyi huylu
Mdb003	D (Dense-glandular)	Normal
Mdb004	D (Dense-glandular)	Normal
Mdb005	F (Fatty)	İyi huylu
Mdb023	G (Fatty-glandular)	Habis
Mdb058	D (Dense-glandular)	Habis
Mdb095	F (Fatty)	Habis
Mdb124	G (Fatty-glandular)	Habis
Mdb127	G (Fatty-glandular)	İyi huylu
Mdb204	F (Fatty)	İyi huylu
Mdb233	G (Fatty-glandular)	Habis
Mdb274	F (Fatty)	Habis

MIAS veri kümesi, yedi sütundan oluşan görüntü bilgileri ile kaggle.com sitesinde sunulmuştur (Mader, 2017). Çizelge 7.2’de veri kümesi etiket dosyası bilgileri verilmiştir. Şekil 7.1’de rastgele seçilmiş veri kümesi görüntüleri ve etiketleri görülmektedir.

Çizelge 7.2 : MIAS veri kümesi etiket dosyası bilgileri.

1. sütun	Görüntü ismi
2. sütun	Arka plan dokusu
3. sütun	Anomalilik sınıf
4. sütun	Anomaliliğin şiddeti
5. sütun	X Koordinat
6. sütun	Y Koordinat
7. sütun	Anomaliliğin yaklaşık yarıçapı



Şekil 7.1 : MIAS veri kümesi örnek medikal görüntüleri.

(a) mdb001 (iyi huylu) (b) mdb003 (normal) (c) mdb005 (iyi huylu) (d) mdb023 (habis) (e) mdb095 (habis) (f) mdb151 (normal).

Çizelge 7.2’incelendiğinde, anomalliğin şiddeti bilgilerinde normal olmayan kitlelerin iyi huylu (benign) veya habis (malign) olma durumu gösterilmektedir. Etiket dosyası bilgilerinde kitlenin x eksenini ve y eksenini olmak üzere piksel koordinatları sunulmaktadır. Aynı çizelgenin son sütununda ise anomali kitlelerin piksel olarak yarıçapları verilmektedir. Şekil 7.2’de MIAS veri kümesi görüntülerinin örnek anomali tanımlama etiketleri görülmektedir.

Etiket

mdb005


F= Yağlı (Fatty)

CIRC=İyi tanımlanmış/Sınırlı kitle
(Well defined/circumscribed masses)

B=İyi huylu (Benign)

x,y koordinat=477,133

Yarıçap=30



Etiket

mdb075


F=Yağlı (Fatty)

ASYM=Asimetri (Asimetry)

M=Habis (Malign)

x,y koordinat=468,717

Yarıçap=23



Şekil 7.2 : MIAS görüntüleri örnek anomali tanımlama etiketleri.

7.2 Veri Kümesi Ön İşleme


7.2.1 Görüntü formatı dönüştürme

Veri kümesindeki görüntüler PGM formatında olduğundan, bu görüntüler PNG formatına dönüştürülmüştür. Bu işlem, görüntü işleme ve model eğitimi aşamalarında daha yaygın olarak kullanılan bir format olan PNG'nin avantajlarından yararlanmak amacıyla gerçekleştirilmiştir.

7.2.2 Görüntü maskeleme

Görüntüler üzerindeki istenmeyen alanlar maskeleme yöntemiyle kırılmıştır. Mammogram görüntülerinin maskelenmesi için Labelme Annotations Tool (Wada, 2018) kullanılmıştır. Şekil 7.3'te maskelenmiş MIAS görüntüleri görülmektedir.

Bahsedilen adımlar, görüntü kalitesini artırmak ve modelin daha doğru sonuçlar üretmesini sağlamak amacıyla gerçekleştirilmiştir.




Şekil 7.3 : Maskeleye görüntüleri.

(a) mdb010, (b) mdb011, (c) mdb012, (d) mdb013, (e) mdb014, (f) mdb015.

7.2.3 Görüntü eşikleme

Eşikleme, görüntü işleme tekniklerinden biridir ve genellikle belirli özellikleri vurgulamak, görsel netliği ve kontrastı artırmak, veya belirli nesnelere arka plandan ayırmak için kullanılır. Eşikleme işlemi, piksel değerlerinin belirli bir eşik değerine göre değiştirilmesiyle gerçekleştirilmektedir. Temel olarak, bir piksel değeri eşik değerinin üzerinde veya altında olmasına göre belirli bir değere ayarlanır (genellikle siyah veya beyaz) (Gonzales ve Woods, 2017). Eşikleme işlemi küçük varyasyonları veya gürültüyü ortadan kaldırmak, önemli detayları korumak için kullanılır (Otsu, 1979). Mamografi görüntülerinde eşikleme, histogramı arka plan ve meme dokuları olarak ayırmaya dayanır. Eşiklemeye bağlı olarak mamografi görüntüsündeki en aydınlık alan ile en karanlık alan arasındaki fark belirir (El-Zaar ve Yassen, 2013).

Bu tez çalışmasında, meme bölgesinin tespitini iyileştirmek, görüntü kalitesini artırmak, görüntüdeki kenarları ve ayrıntıları daha belirgin hale getirmek, görüntüdeki nesnelere arka plandan ayırmak, görüntü işleme ve analizi kolaylaştırmak için görüntü eşikleme yapılmıştır. Şekil 7.4'te mdb_225.png görüntüsünün eşikleme işlemi yapılmış şekli görülmektedir.




Şekil 7.4 : Mamografi görüntüsü eşikleme.


(a) orijinal görüntü, (b) görüntü eşikleme.

7.2.4 Veri artırma


Derin öğrenmenin performansı büyük ölçüde veri kümelerinin boyutuna ve verilerin çokluklarına bağlıdır. Küçük veri kümelerinde öğrenme büyük bir zorluktur. Bununla birlikte, büyük veri kümeleri toplamak zaman alıcı ve pahalıdır. Bu soruna mevcut veriyi çoğaltarak büyütme şeklinde bir çözüm bulunmaktadır (Mitrano ve Berenson, 2022). Veri kümesini çoğaltmak, veri kümesinin genelleme yeteneğini geliştirir (Wong ve diğerleri, 2016). Bu çoğaltma ile mevcut veri değiştirilerek ek eğitim örnekleri oluşturulur. Bu tez çalışmasında tıbbi görüntü veri kümesi, görüntünün mevcut konumunu değiştirme (kaydırma, shifting), görüntüyü belli bir açı ile döndürme (90, 180, 270 derece dönüştürme), yatay çevirme (aynalama, horizontal flipping), gama etkisi (gamma effect) ve deformasyon (tuz ve biber, salt and pepper) teknikleri uygulanarak büyütülmüştür. Şekil 7.5'te orijinal bir görüntü ve veri artırma yöntemleri kullanılarak artırılmış görüntüler görülmektedir.




(a)




(b)




(c)



(d)



(e)



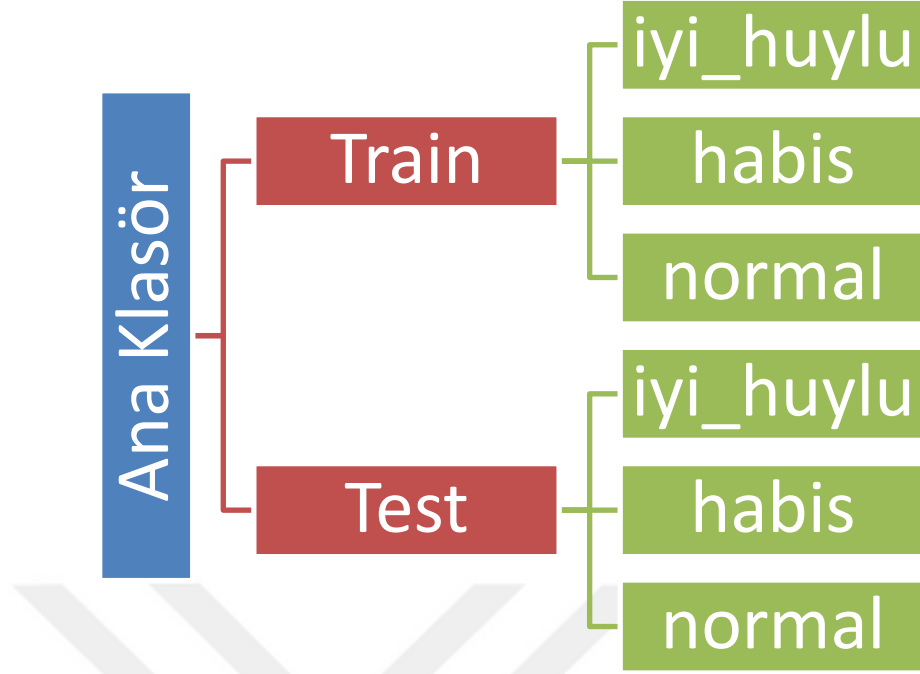
(f)

Şekil 7.5 : Habis huylu bir görüntü verisi ve artırılmış veri örnekleri.

(a) orijinal, (b) kaydırma, (c) çevirme, (d) yatay çevirme, (e) gama efekti, (f) deformasyon.

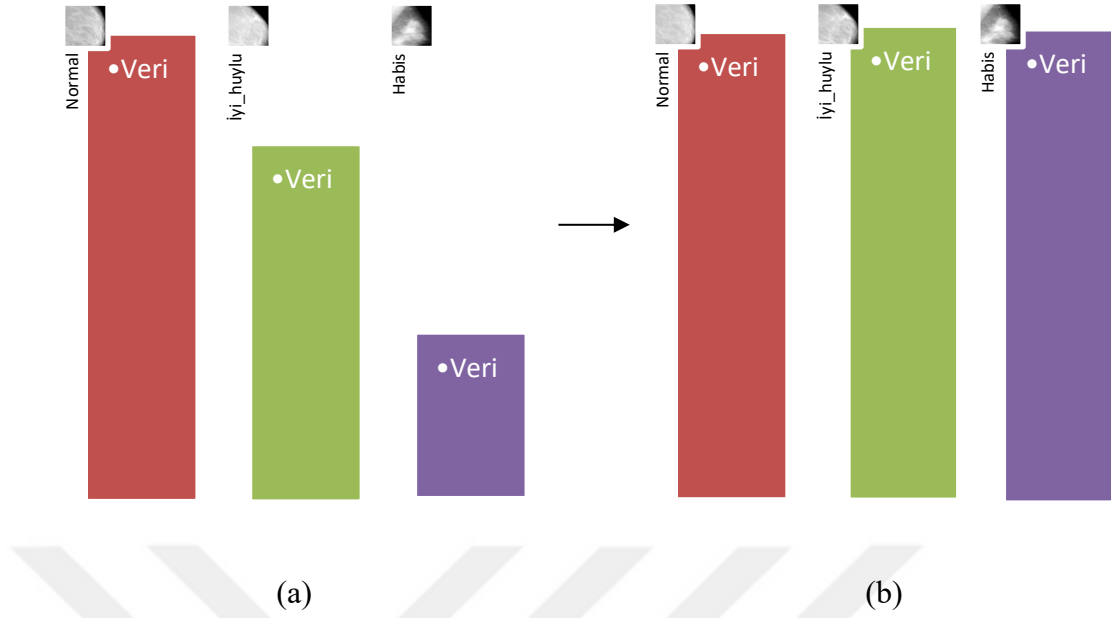
7.3 Eğitim ve Test Verilerinin Hazırlanması

Bu tezde, veri artırma ve rastgele yeniden örnekleme (re-sampling) yöntemleri birleştirilmiştir. Rastgele yeniden örneklemede, örnekler azınlık sınıflarından rastgele seçilir ve eğitim veri kümesine eklenerek artırılır. Bu yöntem, artırılmış yeniden örnekleme (over sampling) olarak bilinmektedir. Birçok çalışmada, rastgele yeniden örnekleme seçiminin veri kümesini dengelediği ve oldukça iyi performans gösterdiği gözlemlenmiştir (Kumar, 2022). Veri kümesini dengelemek için, veri artırma tekniği ve yeniden örnekleme tekniği, daha seyrek olan örneklere uygulanarak sınıf boyutları miktarları ayarlanmıştır. Bu adımlardan sonra, veri kümesi dengelenmiş, derin öğrenme eğitimi ve testi için klasörler oluşturulmuştur. Bir derin öğrenme modeli geliştirilirken karşılaşılan en büyük zorluklardan biri, modelin veri kümesine aşırı uyum sağlamasını önlemektir. Bu zorluk, modelin eğitim verilerinden aşırı öğrendiği durumdur. Böyle bir durumda model sadece ezberlediği verilerden başarı elde edebilmektedir. Eğitim verilerinde çok düşük bir tahmin hatası verirken test verilerinde ise çok yüksek bir tahmin hatası verir. Bu durum aşırı uyum (overfitting) olarak bilinir. Gerçek dünyada kullanılacak bir modeli uygularken, eğitimden sonra nasıl davranacağını bilmek isteriz. İşte bu noktada test veri kümesi devreye girmektedir. Eğitim için kullanılmayan verileri temsil etmesi amaçlanan orijinal veri kümesinin rastgele bir kısmı test kümesidir. Böylece model, görülmeyen verilere karşı nasıl davranacağını tahmin edebilir (Igerata, 2021). Veri kümesi eğitim ve test klasör yapısı Şekil 7.6'da görülmektedir.



Şekil 7.6 : Eğitim ve test klasör yapısı.

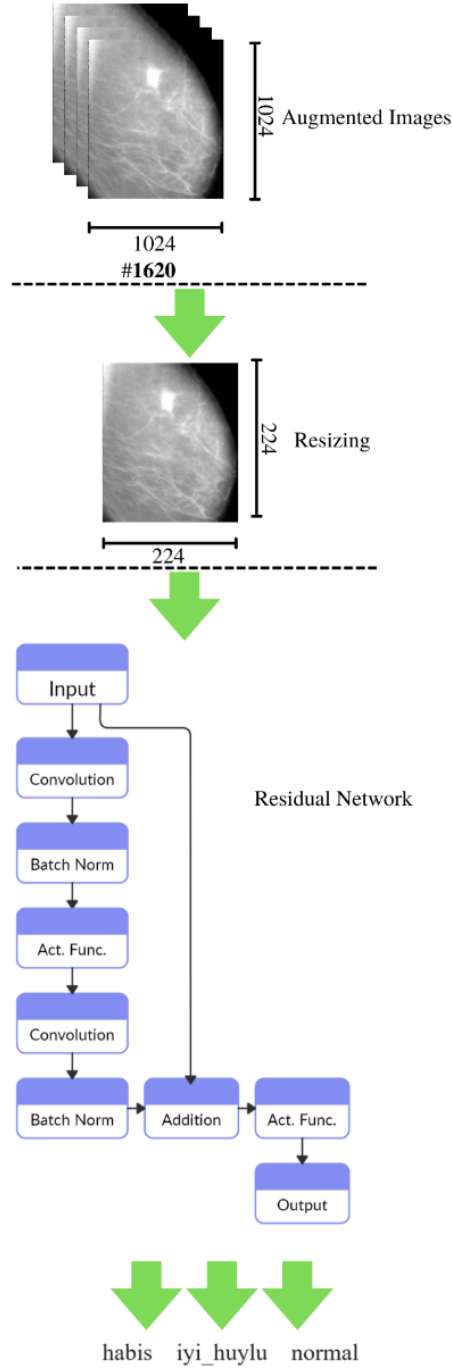
Veri çoğaltma ve yeniden örneklemeden sonra, iyi huylu, habis ve normal verilerin her biri için 540 görüntü, toplam 1620 görüntü oluşturulmuştur. Şekil 7.7’de yeniden örneklem stratejisi görülmektedir, (a) yeniden örneklemeden önce, (b) yeniden örneklemeden sonra. Yeniden örneklemeden sonra veri kümesinin dengeli olduğu görülmektedir. Bu tez çalışmasında, tüm görüntüler 224x224 piksele yeniden boyutlandırılmıştır. Veri kümesindeki görüntülerin %80’i modelin eğitimi için, %20’si test değerleri için ayrılmıştır. Eğitim kümesinin bir kısmının doğrulama (validation) için ayrılması yaygın olarak kullanılan bir yöntemdir (Boesch, 2022). Doğrulama veri kümesi, modeldeki hiper parametreleri veya düzenleme parametrelerini seçmek, modelin performansının ince ayarlarını yapabilmek için kullanılır. Bu tez yaklaşımında eğitimin veri kümesinin rastgele %20’si doğrulama için ayrılmıştır. Yapılan bu adımların ardından model oluşturma ve ResNet algoritması kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 7.7 : Yeniden örnekleme stratejisi.

7.4 ResNet Modelleri ile Sınıflandırma

ResNet mimarisi, ilk olarak Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından 2015 yılında yayımlanan “Derin Artık Öğrenme ile Görüntü Tanıma” başlıklı araştırma makalesinde yenilikçi bir sinir ağı olarak tanıtılmıştır (Boesch, 2022). ResNet mimarisinin, ImageNet veri kümesinde, 152 katmana kadar derinliğe sahip ağların değerlendirilmesi sonucunda, ILSVRC 2015 görüntü sınıflandırma yarışmasında %3,57 hata oranıyla birinci olduğu bildirilmiştir (Sachan, 2019). Farklı ResNet mimarileri, veri kümesini sınıflandırmak için kullanılmakta olup, katman sayısı 18 ile 152 arasında değişmektedir (Le, 2021). ResNet ağı, evrişim, havuzlama, aktivasyon ve tam bağlı yığın katmanlarına sahip ağlara benzemektedir. Basit bir ağı artık bir ağa dönüştürmek için gerekli olan tek yapı, katmanlar arasındaki kimlik bağlantısıdır. Bu tez çalışmasında ResNet mimari modeliyle sınıflandırma adımlarını gösteren bir akış şeması Şekil 7.8’de sunulmaktadır.




Şekil 7.8 : ResNet mimarisi sınıflandırma akış şeması.

Bu tez çalışmasında, Sequential modeli kullanılmıştır. Sequential, Keras'ta bir model katmanı oluşturmamızı sağlayan bir parametredir. ImageNet, görüntü sınıflandırma için bir standarttır. ImageNet sınıflandırma yarışmalarında, kullanılan modelin performansı ölçülür. Bu nedenle ImageNet, bir modelin ne kadar iyi olduğunu belirlemek için standart bir ölçüt sağlar. En yaygın kullanılan öğrenme aktarımı modelleri, ImageNet ağırlıklarını kullanır (Gerry, 2020). Bu yaklaşımda Keras,

TensorFlow, Pytorch kütüphaneleri ve Python dili kullanılmıştır. Derin öğrenme modelleri için yüksek hızlı bir grafik işleme birimi (GPU) kullanılmıştır. Derin öğrenme yaklaşımında GPU ihtiyacı, Google Colaboratory (Google Colab) platformu kullanılmıştır. Colab, yapay zeka ve derin öğrenme projelerinde interaktif ve tamamen bulut tabanlı ve işbirlikçi bir programlama platformudur.

Normalizasyon, verilerin [0,1] aralığında ölçeklendirilmesi işlemidir. Standardizasyon ise verilerin sıfır ortalama ve birim varyansa sahip olacak şekilde dönüştürülmesidir (Pattanayak, 2017). Bu tez yaklaşımında, ham veriler ResNet 18 modeli için normalize edilmiş ve standardize edilmiştir. ResNet modelleri 100 iterasyon (epoch) boyunca eğitilmiş, öğrenme oranı (Lr) 0,001 olarak uygulanmıştır. Görüntüleri ağa sunma yığın boyutu (batchsize) 32 olarak seçilmiştir (Şekil 7.9). Görüntüler rastgele (random) seçilmiştir.



Şekil 7.9 : Yığın boyutu rastgele 32 görüntüden oluşmaktadır.


Erken durdurma (early stopping) ayarı derin öğrenme modeline uygulanarak, bekleme adımı (patience) 15 seçilmiştir. Bu yaklaşımın iterasyon ve erken durdurma ayarları, Çizelge 7.3'te gösterilmiştir.

Çizelge 7.3 : İterasyon sayıları ve erken durdurma değerleri sonuçları.

Model Adı	İterasyon Sayısı	En İyi İterasyon	Erken Durdurma	Adım
ResNet18	100	100	100	15
ResNet50	100	16	31	15
ResNet101	100	25	40	15
ResNet152	100	100	100	15

Eğitim sırasında doğrulama hatası ile eğitim hatası arasındaki fark genişlemeye başladığında, bu modelin aşırı öğrenmeye başladığını ve gürültülü veriyi öğrendiğini gösterir. Bu durumda, modelin başarısını ve güvenilirliğini artırmak için erken durdurma yöntemi ile eğitim durdurulur (Çarkacı, 2017).

Gizli katmanalar için doğrultulmuş doğrusal birim (ReLU) aktivasyon fonksiyonu kullanılmıştır. Çıkış katmanı aktivasyonu için Softmax kullanılmıştır. Ağın ağırlıklarını güncellemek için Rastlantısal Gradyan Alçalması (Stochastic Gradient Descent, SGD) optimizasyon yöntemi kullanılmıştır. Kayıp fonksiyonu (Loss Function) olarak Kategorik Çapraz Doğrulama (Categorical Cross Entropy) kullanılmıştır. Ardından görüntüler ResNet18, ResNet50, ResNet101 ve ResNet152 evrişimli sinir ağlarına sunulmuştur. Şekil 7.10'da örnek ResNet ağı modeli gösterilmektedir. Çizelge 7.4'te örnek ResNet modeli için evrişim katmanları ayarları görülmektedir. Şekil 7.11'de ResNet 64x7x7 Filtre (Kernel) yapısı görülmektedir. Şekil 7.12'de MIAS veri kümesi mdb124.png görüntüsünün ilk katmandan Global Average Pooling (FC katmanından öncesi) katmanına kadar olan evrişim yapısı gelişimi görülmektedir. Şekil 7.13'de ise mdb148.png görüntüsünün ResNet50 64x7x7 ilk katman evrişim yapısı görülmektedir. Yapılan çalışmada tüm analizler tekrar edilmiştir.



Şekil 7.10 : ResNet18 evrişimli sinir ağı katmanları.


Çizelge 7.4 : ResNet18 evrişim katmanları ayarları.

ResNet18 Toplam Evrişim Katmanı Sayısı: 17
Son Katman FC Katmanı, Toplam 18 Katman Bulunmaktadır.


Conv2d(3, 64, kernel_size=(7, 7), stride=(2, 2), padding=(3, 3), bias=False)
Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(64, 128, kernel_size=(3, 3), stride=(2, 2), padding=(1, 1), bias=False)
Conv2d(128, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(128, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(128, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(128, 256, kernel_size=(3, 3), stride=(2, 2), padding=(1, 1), bias=False)
Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(256, 512, kernel_size=(3, 3), stride=(2, 2), padding=(1, 1), bias=False)
Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)
Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1), bias=False)



Şekil 7.11 : ResNet 64x7x7 Filtre (Kernel) yapısı.



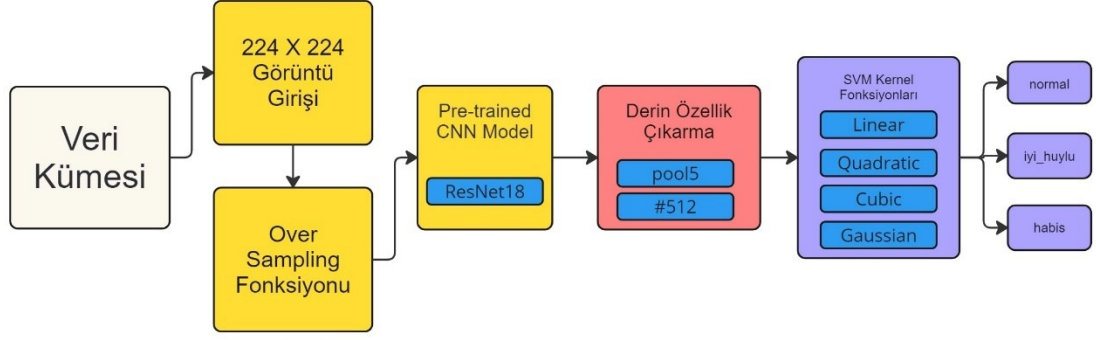
Şekil 7.12 : MIAS veri kümesi mdb124.png için ResNet18 evrişim görüntüleri.



Şekil 7.13 : MIAS veri kümesi mdb148.png için ResNet50 ilk katman.
64x7x7 evrişim görüntüsü.

7.5 Derin Özellik Çıkarma ve SVM ile Sınıflandırma

ResNet18+SVM yönteminde görüntüler, artırımlı yeniden örnekleme (over sampling) fonksiyonu (Itakura, 2024) ile artırılarak veri kümesinin daha dengeli olması sağlanmış (Fernandez ve diğerleri, 2018), ResNet18'in Global Average Pooling (pool5) katmanından çıkarılan 512 derin özellik kullanılarak SVM makine öğrenme algoritması ile sınıflandırma gerçekleştirilmiştir. Diğer bir deyişle, geleneksel makine öğrenme tabanlı çalışmalarda özellik çıkarma yöntemleri yerine burada ResNet18 kullanılmıştır. CNN ile çıkarılan özellikler, SVM algoritmasına giriş olarak verilmiştir. Bu sınıflandırmada Linear, Quadratic, Cubic ve Gaussian SVM çekirdek fonksiyonları kullanılmış ve sonuçlar elde edilmiştir. ResNet18+SVM yönteminin genel uygulama akış şeması Şekil 7.14'de gösterilmiştir.



Şekil 7.14 : ResNet18+SVM yönteminin uygulama akış diyagramı.

Bu bölümde, mamografi görüntülerinin sınıflandırılması için önerilen ve son teknoloji ürünü olan ResNet18 kullanılarak oluşturulan iki yöntemin başarısı sunulmuştur. Bu çalışmada DL modelleri, Colab ile gerçekleştirilmiştir. Bu tez çalışmasında ResNet modellerine dayanan yöntemler sunulmuştur.

ResNet18, 224x224x3 çözünürlüğünde görüntüler kullanan ve pre-trained bir CNN modelidir. ResNet18+SVM ML yönteminde 224x224x3 görüntüler giriş olarak verilmiş, over sampling fonksiyonu ile veriler sentetik olarak artırılarak dengelenmiş ve ResNet18 modeli özellik çıkarmak için kullanılmıştır. FC katmanından bir önce bulunan pool5 katmanından 5703x512 matris verileri çıkartılmıştır. Aynı katmandan çıkartılan 5703x1 matris etiket (label) verileri de çıkartılarak önceki matris verileri ile birleştirilmiştir. 5703x513 matrisi elde edilmiştir. Bu matriste son sütun etiket verileridir. Çıkarılan bu özellikler %80 eğitim verisi, %20 test verisi olarak bölünerek ResNet18+SVM yöntemi ile sınıflandırılmıştır. Bu özellikler, ResNet18 yönteminde yapıldığı üzere softmax ile doğrudan sınıflandırılmamış, SVM kullanılarak değerlendirilmiş ve sonuçlar karşılaştırılmıştır.



8. SONUÇLAR VE ÖNERİLER

8.1 Sonuçlar

8.1.1 ResNet modelleri ile sınıflandırma


Bu tez çalışmasında birinci yöntem ile elde edilen sınıflandırma başarıları Çizelge 8.1’de verilmiştir. ResNet modelleri ile elde edilen sınıflandırma performans ölçütleri Çizelge 8.2’de gösterilmiştir. En yüksek sınıflandırma başarısı, ResNet18 modeli kullanılarak %93,83 ile elde edilmiştir. ResNet50, ResNet101 ve ResNet152 ile elde edilen başarılar sırasıyla %87,24 - %87,44 ve %91,25’tir. En yüksek sınıflandırma doğruluğunun elde edildiği ResNet18 modeline ait karışıklık matrisi (CM) Şekil 8.1’de sunulmuştur. ResNet18 için elde edilen ROC analizi Şekil 8.2’de verilmektedir. Bu çalışmada üç sınıf kullanılmıştır, habis, iyi huylu ve normal sınıfları sırasıyla 0,1 ve 2 olarak etiketlenmiştir.

Çizelge 8.1 : ResNet18 modelleri için elde edilen doğruluk değerleri.


Evrişim Modeli	Doğruluk (%)
ResNet18	93,83
ResNet50	87,24
ResNet101	87,44
ResNet152	91,25

Çizelge 8.2 : ResNet modelleri ile elde edilen performans ölçütleri.

Performans Ölçütleri	ResNet18	ResNet50	ResNet101	ResNet152
Loss	0.2476	0.4770	0.4410	0.4778
Precision	0.9400	0.8164	0.8136	0.8699
Recall	0.9400	0.7962	0.8086	0.8672
AUC	0.9500	0.9430	0.9545	0.9606
F1-Score	0.9400	0.8061	0.8110	0.8685



Şekil 8.1 : ResNet18 CM değerleri.



Şekil 8.2 : ResNet18 modeli ile elde edilen ROC eğrisi.

ResNet18 modeli ile yapılan sınıflandırmada oluşturulan model, 108 kötü huylu örneğin 100'ünü doğru pozitif olarak bulmuştur. Aynı model, 108 iyi huylu örneğin 101'ini doğru pozitif ve 108 normal örneğin 103'ünü doğru pozitif olarak tespit etmiştir. Ayrıca, bu model, eğitim ve doğrulama arasındaki minimum hata kaybına sahiptir. Şekil 8.2'de ROC eğrisinin 1.0'a yakın olduğu görülmektedir.


8.1.2 ResNet18+SVM yöntemi

ResNet18+SVM yönteminde pre-trained ResNet18, özellik çıkarmak için kullanılmıştır. Global Average Pooling katmanında 512 özellik bulunmaktadır. Pre-trained ResNet18 ile çıkarılan numerik özellikler Çizelge 8.3'te görülmektedir. Bu özellikler, eğitim ve test veri kümeleri için ayrı ayrı çıkarılmıştır.

Çizelge 8.3 : ResNet18 pool5 katmanından çıkartılan numerik özellikler.


Özellik 1	Özellik 2	Özellik 512	Etiket
0,484991103	0,48979339	0,155571565	Habis
0,882499754	0,910166979	1,302203298	Habis
...
1,664017081	0,490317136	0,006551878	İyi_huylu
0,561715543	0,406298429	0,296482056	İyi_huylu
...
0,239146173	0,400330782	0,574897647	Normal
0,313327193	0,295106232	0,641032994	Normal

Bu çalışmada pre-trained ResNet18 yöntemiyle çıkarılan özellikler, SVM yönteminin Linear, Quadratic, Cubic ve Gaussian Kernel çekirdek fonksiyonları ile sınıflandırılmıştır. Veri kümesi %80 eğitim verisi ve %20 test verisi olarak bölünmüştür. SVM ile yapılan sınıflandırmada en yüksek doğruluk %99,6 ile Cubic çekirdek fonksiyonu kullanarak elde edilmiştir. Linear, Quadratic ve Gaussian çekirdek fonksiyonları ile elde edilen sınıflandırma doğrulukları sırasıyla %93,2, %99,3 ve %95,2 olarak elde edilmiştir. Şekil 8.3'te ResNet18+SVM yönteminin farklı SVM çekirdek fonksiyonları için elde edilmiş karmaşıklık matrisleri görülmektedir. Bu yöntemde üç sınıf kullanılmıştır, habis, iyi huylu ve normal sınıfları sırasıyla 0,1 ve 2 olarak etiketlenmiştir. Şekil 8.4'te ROC eğrisi görülmektedir. Çizelge 8.4'te SVM çekirdek fonksiyonları ile yapılan sınıflandırmada elde edilen performans ölçütleri görülmektedir.



(a)

(b)




(c)

(d)

Şekil 8.3 : SVM karışıklık matrisleri

(a) Linear, (b) Quadratic, (c) Cubic, (d) Gaussian.



Şekil 8.4 : ResNet18+SVM ROC eğrisi.

Çizelge 8.4 : SVM modelleri ile elde edilen performans ölçütleri.

SVM Kernel	Çekirdek fonk.	Acc(%)	Prec.	Recall	F1-score
Linear		93,2	0,9324	0,9332	0,9324
Quadratic		99,3	0,9930	0,9930	0,9930
Cubic		99,6	0,9965	0,9965	0,9965
Gaussian		95,2	0,9517	0,9878	0,9524

Karmaşık matrislerinde, sütunlar gerçek sınıfı, satırlar ise tahmin edilen sınıfı temsil eder. Özellik seçiminin, sınıflandırma performansını doğruluk açısından daha iyi hale getirdiği gözlemlenmiştir.

Literatürde meme kanseri MIAS veri kümesi ile yapılan analiz çalışmalarının karşılaştırılması Çizelge 8.5’te verilmiştir. Bu tez çalışmasında önerilen modeller ile meme kanseri analizinin başarılı bir şekilde gerçekleştirilebileceği görülmektedir. Farklı ve hibrit derin öğrenme modelleri kullanılarak doğruluk artırılabilir.

Çizelge 8.5 : İlgili çalışmalarla, yöntemlerin ve doğruluklarının karşılaştırılması.

Yapılmış Çalışmalar	Model	Başarı
(Çelik vd., 2019)	ANN	%83,33
(Alruwaili ve Gouda, 2022)	ResNet50	%89,5
(Krishna ve Rajabhushanam, 2021)	AlexNet	%92
(Görgel vd., 2015)	CWT-SVM	%91,4
(Taşdemir vd., 2020)	CNN	%81
(Zhang, Wang, vd., 2016)	SVM	%92,16
(Zhang, Wu, vd., 2016)	MLP	%92,52
(Vedalankar vd., 2021)	AlexNet	%92
(Sha vd., 2020)	CNN	%92
(Civecik, 2013)	ANN	%82
(Mubeen vd., 2023)	DenseNet121	%88
(Jafari ve Karami, 2023)	NN	%94,5
(Thwin vd., 2024)	CNN	%95,33
Önerilen Yöntem	ResNet18+SVM	%99,6

8.2 Öneriler

Çizelge 8.5'teki bazı çalışmalarda geleneksel makine öğrenimi algoritmaları kullanılmıştır. Bazı çalışmalarda ise daha az derinliğe sahip olan AlexNet modeli tercih edilmiştir. ResNet18 yönteminde, dört farklı ResNet modeli kullanılarak yüksek doğruluk elde edilmiştir. ResNet18+SVM yönteminde ise ResNet18 ile çıkartılan özellikler SVM ile analiz edilmiştir ve daha yüksek doğruluk oranları elde edilmiştir.

Son yıllarda, araştırmacılar meme kanseri ve diğer kanser türlerinin sınıflandırılmasında MR görüntüleri üzerinde DL yöntemlerini kullanmaktadır. Yüksek doğruluklu tıbbi görüntüleme sistemleri, uzmanlara tanı ve tedavide destek sağlar. Bu tez çalışmasında, MIAS veri kümesindeki görüntüleri sınıflandırmak için DL algoritmaları kullanılmıştır eğitim ve test analizleri sonucunda ResNet18 model mimarisinin en yüksek doğruluk oranına sahip olduğu görülmüştür. ResNet18, diğer ResNet mimarilerine göre daha iyi performans göstermiştir. ResNet18+SVM özellik çıkarımı yönteminde ise SVM Cubic çekirdek fonksiyonu diğer çekirdek fonksiyonlarına göre daha iyi performans sergilemiştir. MIAS veri kümesindeki görüntülere farklı veri artırma teknikleri uygulanabilir ve veri kümesindeki görüntüler daha da çoğaltılabilir.

Bu yöntemler, en iyi veri kümesini belirlemek için yapılacak analizlerde kullanılabilir. ResNet18 modeli ve ResNet18+SVM modeli, MIAS veri kümesi için en iyi seçeneklerdir. Bu yöntemler, düşük hesaplama karmaşıklığına ve daha hızlı işlem yapısına sahiptir. Diğer yöntemler ile karşılaştırıldığında, bu yaklaşımların

performansının yüksek olduđu gör÷lmektedir. ResNet18 ve ResNet18+SVM modelleri ve yöntemleri, klinik uygulamalarda uygulanabilir ve güvenilirdir.



KAYNAKLAR

- Abid, M. H., Ashraf, R., Mahmood, T. ve Faisal, C. M. N. (2023). Multi-modal medical image classification using deep residual network and genetic algorithm. *PLoS ONE*, 18(6). doi:<https://doi.org/10.1371/journal.pone.0287786>
- Alruwaili, M., ve Gouda, W. (2022). Automated Breast Cancer Detection Models Based on Transfer Learning. *Sensors (Basel)*, 22(3). doi:10.3390/s22030876
- Anı, Y., ve Daniş, Z. (2020). Veri artırımı / data augmentation. Haziran 2024 tarihinde <https://medium.com/novaresearchlab/veri-art%C4%B1r%C4%B1m%C4%B1-data-augmentation-fcc839da556b> adresinden edinilmiştir.
- Aslan, F., Unlersen, M., Fahri., Sabanci, K., ve Durdu, A. (2021). Cnn-based transfer learning–bilstm network: A novel approach for covid-19 infection detection. 98, 106912.
- Aslan, M., F., ve Sabanci, K. (2023). A Novel Proposal for Deep Learning-Based Diabetes Prediction: Converting Clinical Data to Image Data. *Diagnostics*, 13(4). doi:10.3390/diagnostics13040796
- Boesch, G. (2022). Deep residual networks (ResNet, ResNet50). Retrieved from <https://viso.ai/deep-learning/resnet-residual-neural-network/>
- Buduma, N., ve Lacascio, N. (2017). *Fundamentals of deep learning*: O'Reilly. 978-1-491-92561-4
- Chauvet, C. (2020). Giving Tuesday. *International Agency for Research on Cancer*. 20 Haziran 2022, tarihinde https://www.iarc.who.int/wp-content/uploads/2020/11/IARC_Newsletter_GivingTuesday.pdf adresinden edinilmiştir.
- Chollet, F. (2016). Introducing keras 1.0. *The Keras Blog*. Ocak 2024 tarihinde <https://blog.keras.io/introducing-keras-10.html> adresinden edinilmiştir.
- Civcık, L. (2013). *Görüntü zenginleştirme ve hücresel ysa kullanarak meme kanseri teşhisi*. (The Degree of Doctor of Philosophy in Electrical-Electronics Engineering Doktora Tezi), Selcuk University, Konya
- Çarkacı, N. (2017). Derin öğrenme uygulamalarında başarıyı iyileştirme yöntemleri. *Medium*.
- Çelik, Y., Aslan, M. F., ve Sabanci, K. (2019). *Classification of mammograms using glcm based feature extraction in artificial neural network*. Paper presented at the Multidisciplinary Academic Conference.
- Ekman, M. (2022). *Learning deep learning* (NVIDIA Corporation ed.): Addison-Wesley. ISBN-13: 978-0-13-747035-8 ISBN-10: 0-13-747035-5
- El-Zaart, A., ve Yassen, M. (2013). Mammogram Images Thresholding For Breast Cancer Detection Using Different Thresholding Methods. *Journal of Advanced Research in Breast Cancer*, 02. doi:10.4236/abcr.2013.23013
- Fawcett, T. (2006). Introduction to ROC analysis. *Pattern Recognition Letters*, 27, 861-874. doi:10.1016/j.patrec.2005.10.010

- Fernandez, A., Garcia, S., Herrera, F., ve Chawla, V. N. (2018). SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary. *Journal of Artificial Intelligence Research*, 61, 863-905.
- Gerry, P. (2020). Re: Why are keras models instantiated with imagenet weights only? Message posted to <https://stackoverflow.com/questions/62739893/why-are-keras-models-instantiated-with-imagenet-weights-only>
- Gonzales, R. C., ve Woods, R. E. (2017). *Digital image processing* (Vol. 4th): Pearson Education International. 978-0131687288
- Görgel, P., Sertbas, A., ve Uçan, O. N. (2015). Computer-aided classification of breast masses in mammogram images based on spherical wavelet transform and support vector machines. *The Journal of Knowledge Engineering*, 32(1), 155-164. doi:10.1111/exsy.12073
- Han, Z., Wei, B., Zheng, Y., Yin, Y., Li, K., ve Li, S. J. S. R. (2017). Breast cancer multi-classification from histopathological images with structured deep learning model. *Scientific Reports*, 7(1), 1-10.
- Igerata, A. (2021). How to split a tensorflow dataset into train, validation, and test sets. *Towards Data Science*.
- Ioffe, S., ve Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv Preprint*. doi:arXiv:1502.03167
- Iosifidis, A., ve Tefas, A. (2022). *Deep learning for robot perception and cognition*
- Itakura, K. (2024). Image classification using oversampling imagedatastore. 5th., Haziran 2024 tarihinde <https://github.com/KentaItakura/Image-classification-using-oversampling-imagedatastore/releases/tag/2.0> adresinden edinilmiştir.
- Jafari, Z., ve Karami, E. (2023). Breast Cancer Detection in Mammography Images: A CNN-Based Approach with Feature Selection. *Information*, 14(7). doi:10.3390/info14070410
- Joseph, A. J., Dwivedi, P., Joseph, J., Francis, S., P.N, P., P.B, J., . . . Sankaran, P. (2024). Prior-guided generative adversarial network for mammogram synthesis. *Biomedical Signal Processing and Control*, 87, 105456. doi:<https://doi.org/10.1016/j.bspc.2023.105456>
- Karakurt, M., ve İşeri, İ. (2022). Patoloji görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 33, 192-206. doi:10.31590/ejosat.1011091
- Kelleher, J. D. (1974). *Deep Learning Cambridge. MA The MIT press 2019.*
- Krishna, T. H., ve Rajabhushanam, C. (2021). Mammography image breast cancer detection using deep transfer learning. *Advances and Applications in Mathematical Sciences*(20:7), 1187-1196.
- Kumar, V. (2022). Addressing Binary Classification over Class Imbalanced Clinical Datasets Using Computationally Intelligent Techniques. *Healthcare*, 10. doi:10.3390/healthcare10071293
- Le, K. (2021). A quick overview of resnet models. Retrieved from <https://medium.com/mllearning-ai/a-quick-overview-of-resnet-models-f8ed277ae81e>
- Loizidou, K., Elia, R., ve Pitris, C. (2023). Computer-aided breast cancer detection and classification in mammography: A comprehensive review. *Computers in Biology and Medicine*, 153, 106554. doi:10.1016/j.combiomed.2023.106554
- Mader, K. S. (2017). *Mias mammography* [Image Dataset]. Meme kanseri. 19th June 2022, tarihinde <https://www.kaggle.com/datasets/kmader/mias-mammography?resource=download> adresinden edinilmiştir.

- Mandal, M. (2024). CNN for Deep Learning. Şubat 2024 tarihinde <https://www.analyticsvidhya.com/blog/2021/05/convolutional-neural-networks-cnn/> adresinden edinilmiştir.
- Mikami, H., Suganuma, H., U-Chupala, P., Tanaka, Y., ve Kageyama, Y. (2018). Massively distributed SGD: imagenet resnet-50 training in a flash. *Sony Corporation*. doi:<https://doi.org/10.48550/arXiv.1811.05233>
- Mit. (2022). Introduction to deep learning. Ekim 2023 tarihinde <http://introtodeeplearning.com/> adresinden edinilmiştir.
- Mitrano, P., ve Berenson, D. (2022). *Data augmentation for manipulation* [Sözlü bildiri]. Robotics: Science and Systems, New York City, NY, USA.
- Mubeen, T., Zain, U., Abidin., M, H., Shahbaz., P, O., Roth., ve M, A., L, Nieto. (2023, 24-27 Jan. 2023). *Analyzing the classification performance of denseNet121 on pre-processed MIAS dataset*. Paper presented at the 2023 Global Conference on Wireless and Optical Technologies (GCWOT).
- Nazrul, S. S. (2018). Receiver operating characteristic curves demystified (in python). Aralık 2023 tarihinde <https://towardsdatascience.com/receiver-operating-characteristic-curves-demystified-in-python-bd531a4364d0> adresinden edinilmiştir.
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66. doi:10.1109/TSMC.1979.4310076
- Pattanayak, S. (2017). *Pro deep learning with tensorflow: Apress*. 978-1-4842-3095-4
- Pattanayak, S. (2019). *Intelligent projects using Python: Packt publishing* 978-1-78899-692-1
- Sachan, A. (2019). Detailed guide to understand and implement resnet. *Learn Machine Learning, AI & Computer vision*. 29th Sep., 2022 tarihinde <https://cv-tricks.com/keras/understand-implement-resnets> adresinden edinilmiştir.
- Sha, Z., Hu, L., ve Rouyendegh, B. D. (2020). Deep learning and optimization algorithms for automatic breast cancer detection. *International Journal of Imaging Systems and Technology*, 30(2), 495-506. doi:<https://doi.org/10.1002/ima.22400>
- Sharma, P. (2020). Computer Vision, Deep Learning Basics. Ekim, 2023 tarihinde 7 Popular Image Classification Models in ImageNet Challenge (ILSVRC) Competition History adresinden edinilmiştir.
- Sönmez, M., Eczacioglu, N., Gümüş, N. E., Aslan, M., Sabancı, K., ve Aşikkutlu, B. (2021). Convolutional neural network - Support vector machine based approach for classification of cyanobacteria and chlorophyta microalgae groups. *Algal Research*, 61. doi:10.1016/j.algal.2021.102568
- Suckling, J., Parker, J., Dance, D., Astley, S., Hutt, I., Boggis, C., . . . Savage, J. (2015). *Mammographic Image Analysis Society (MIAS) database v1.21*. tarihinde <https://www.repository.cam.ac.uk/handle/1810/250394> adresinden edinilmiştir.
- Sunnetci, K., ve Alkan, A. (2022). Lung cancer detection by using probabilistic majority voting and optimization techniques. *International Journal of Imaging Systems and Technology*. doi:10.1002/ima.22769
- Şakar, H. G. (2021). Evrişimli sinir ağları (convolutional neural networks-cnn). Mayıs 2023 tarihinde <https://hialgozutok.medium.com/evri%C5%9Fimli->

- sinir-a%C4%9Flar%C4%B1-convolutional-neural-networks-cnn-e61470e9bdb1 adresinden edinilmiştir.
- T.C. Sağlık Bakanlığı. (2020). *Meme kanseri*. Ankara: T.C. Sağlık Bakanlığı Halk Sağlığı Müdürlüğü 20 Haziran 2022, tarihinde <https://hsgm.saglik.gov.tr/tr/kanser-turleri/kanser-turleri/meme-kanseri.html> adresinden edinilmiştir.
- Talo, M. (2022). Meme kanseri histopatolojik görüntülerinin konvolüsyonel sinir ağları ile sınıflandırılması. *31*.
doi:<https://dergipark.org.tr/en/pub/fumbd/issue/48746/517939>
- Taşdemir, S., Yengeç, B., Taşdemir, K., ve Aydın, Z. (2020). Ysa kullanılarak mamogramlardan dokusal öznelik tabanlı meme kanseri ilgi bölgesi sınıflandırılması. *Mühendislik Bilimleri ve Tasarım Dergisi*.
doi:10.21923/jesd.827131
- Thwin, S. M., Malebary, S. J., Abulfaraj, A. W., ve Park, H.-S. (2024). Attention-Based Ensemble Network for Effective Breast Cancer Classification over Benchmarks. *Technologies*, *12*(2). doi:10.3390/technologies12020016
- Tiryaki, V. M. (2022). *Meme kanseri anormalliklerinin öğrenme transferi yöntemiyle sınıflandırılması* [Sözlü bildiri]. Batman Üniversitesi Uluslararası Bilişim Kongresi, Batman.
- Vasudev, R. (2019). Understanding and calculating the number of parameters in convolution neural networks (CNNs) *Towards Data Science*.
- Vedalankar, A. V., Gupta, S. S., ve Manthalkar, R. R. (2021). Addressing architectural distortion in mammogram using AlexNet and support vector machine. *Informatics in Medicine Unlocked*, *23*, 100551.
doi:<https://doi.org/10.1016/j.imu.2021.100551>
- Wada, K. (2018). Image polygonal annotation with python. tarihinde <https://github.com/wkentaro/labelme> adresinden edinilmiştir.
- Weiderpass, E. (2021). Global cancer estimates from IARC. *International Agency for Research on Cancer*. 20 Haziran 2022, tarihinde https://www.iarc.who.int/wp-content/uploads/2021/04/IARC_Newsletter_April2021.pdf adresinden edinilmiştir.
- Wong, S. C., Gatt, A., Stamatescu, V., ve McDonnell, M. D. (2016, 30 Nov.-2 Dec. 2016). *Understanding Data Augmentation for Classification: When to Warp?* Paper presented at the 2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA).
- Zhang, Y.-D., Wang, S., Liu, G., ve Yang, J. (2016). Computer-aided diagnosis of abnormal breasts in mammogram images by weighted-type fractional Fourier transform. *Advances in Mechanical Engineering*, *8*(2).
doi:10.1177/1687814016634243
- Zhang, Y.-D., Wu, X., Lu, S., Wang, H., Phillips, P., ve Wang, S. (2016). Smart detection on abnormal breasts in digital mammography based on contrast-limited adaptive histogram equalization and chaotic adaptive real-coded biogeography-based optimization. *SIMULATION*, *92*(9), 873-885.
doi:10.1177/0037549716667834