

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI



**CİLT KANSERİ TESPİTİNDE EVRİŞİMSEL SINIR AĞLARI
MİMARİLERİNİN KARŞILAŞTIRILMASI**

Yüksek Lisans Tezi

Kazım KILIÇ

Danışman

Dr. Öğr. Üyesi Erhan ERGÜN

SAMSUN
2021

TEZ KABUL VE ONAYI

Kazım KILIÇ tarafından, Dr. Öğr. Üyesi Erhan ERGÜN danışmanlığında hazırlanan “Cilt Kanseri Tespitinde Evrimsel Sinir Ağları Mimarilerinin Karşılaştırılması” başlıklı bu çalışma, jürimiz tarafından 16.07.2021 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	İmza	Sonuç
Başkan	Dr. Öğr. Üyesi Recep Sinan ARSLAN Kayseri Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı		<input checked="" type="checkbox"/>
			Kabul
			<input type="checkbox"/>
			Ret
Üye (Danışman)	Dr. Öğr. Üyesi Erhan ERGÜN Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı		<input checked="" type="checkbox"/>
			Kabul
			<input type="checkbox"/>
			Ret
Üye	Dr. Öğr. Üyesi Gökhan KAYHAN Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı		<input checked="" type="checkbox"/>
			Kabul
			<input type="checkbox"/>
			Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY

... / ... / ...

Prof. Dr. Ali BOLAT

Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

İmza
27 /07 / 2021
Kazım KILIÇ

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı: Cilt Kanseri Tespitinde Evrişimsel Sinir Ağları Mimarilerinin Karşılaştırılması

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 09.06.2021 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 16

Tek kaynak oranı : % 1 çıkmıştır.

İmza
27 /07 / 2021
Dr.Öğr. Üyesi Erhan ERGÜN

ÖZET

CİLT KANSERİ TESPİTİNDE EVRİŞİMSEL SİNİR AĞLARI MİMARİLERİNİN KARŞILAŞTIRILMASI

Kazım KILIÇ

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Temmuz/2021

Danışman: Dr. Öğr. Üyesi Erhan ERGÜN

Cilt kanseri dünya genelinde en sık görülen kanser türleri arasındadır. En kötü huylu olan melanom cilt kanseri, az görülmesine rağmen ölüm oranı yüksektir. Cilt kanseri tespiti için dermatologlar tarafından kullanılan genel yöntem dermoskopi taraması olmakla birlikte kesin sonuç biyopsi ile elde edilmektedir. Cilt kanseri erken tespit edildiğinde hastalık büyük ölçüde tedavi edilebilmektedir. Bu çalışmada, gereksiz biyopsi işlemlerini azaltmak ve cilt kanserinin erken tespitini hızlandırmak için, bilgisayar destekli tanı (BDT) sistemi önerilmiştir. Önerilen yöntemde dermoskopi görüntülerinde bulunan lezyon bölgesinin tespitini zorlaştıran kıl ve benzeri gürültüler morfolojik işlemlerle ve Gauss bulanıklığı yöntemi ile ortadan kaldırılmıştır. Lezyon bölgesinin tespiti ve ayırıcı özelliklerinin elde edilebilmesi için Otsu eşikleme yöntemi ile görüntülerin segmentasyon maskeleri çıkarılmıştır. Kontur bulma yöntemleri ile maskede bulunan lezyon bölgesi koordinatları tespit edilerek ilgili bölge görüntüden kırılmıştır. Kırılan görüntülerin tümü 224x224 boyutuna yeniden ölçeklendirilmiştir. Çalışmada, veri setinde bulunan orjinal görüntüler ve ön-işlemlerden geçirilen görüntüler kullanılarak 3 farklı sınıflandırma görevi gerçekleştirilmiştir. Tüm sınıflandırma görevlerinde, özellik çıkarımı ve sınıflandırma için 6 farklı evrişimsel sinir ağı (CNN) mimarisi kullanılmıştır. Kötü huylu melanomların iyi huylu tüm cilt lezyonlarından ayrılması için gerçekleştirilen birinci görevde test kümesi üzerinde DenseNet-121 mimarisi ile %92 doğruluk, %91 AUC, %88 precision, %74 recall ve %80 F-Score değeri elde edilmiştir. Tüm kötü huylu cilt lezyonlarının iyi huylu lezyonlardan ayrılması için gerçekleştirilen ikinci sınıflandırma görevinde test kümesi üzerinde ResNet-152 mimarisi ile %89 doğruluk, %91 AUC, %85 precision, %81 recall ve %83 F-Score değeri elde edilmiştir. Tüm cilt lezyonlarının kendi sınıfına ayrılması için gerçekleştirilen üçüncü sınıflandırma görevinde test kümesi üzerinde ResNet-152 mimarisi ile %84 doğruluk, %78 precision, %77 recall ve %78 F-Score değeri elde edilmiştir. Tüm sınıflandırma görevlerinde ön-işlemlerle görüntüler ile orjinal görüntülerin sınıflandırma sonuçları karşılaştırmalı olarak verilmiştir. Yapılan çalışmada elde edilen sonuçlar, önerilen yöntemin cilt kanseri tespitinde istenilen düzeyde başarıyı verdiğini göstermektedir.

Anahtar Sözcükler: Cilt Kanseri, Derin Öğrenme, CNN, Melanom Tespiti, Sınıflandırma

ABSTRACT

COMPARISON OF CONVOLUTIONAL NEURAL NETWORKS ARCHITECTURES IN SKIN CANCER DETECTION

Kazım KILIÇ

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Computer Engineering

Master, July/2021

Supervisor: Assist. Prof. Dr. Erhan ERGÜN

Skin cancer is among the most common types of cancer worldwide. Although the most malignant melanoma skin cancer is rare, the mortality rate is very high. Although the common method used by dermatologists for the detection of skin cancer is dermoscopy screening, the final result is obtained by biopsy. When skin cancer is detected early, the disease is largely curable. In this study, a computer-assisted diagnosis (CBT) system is proposed to reduce unnecessary biopsy procedures and accelerate the early detection of skin cancer. In the proposed method, hair and similar noises that make it difficult to identify the lesion area in dermoscopy images were removed by morphological operations and Gaussian blur method. In order to identify the lesion area and obtain its distinctive features, the segmentation masks of the images were removed by the Otsu threshold method. The coordinates of the lesion area on the mask were determined using the contour finding methods, and the relevant region was clipped from the image. All the cropped images are rescaled to 224x224. In the study, 3 different classification tasks were carried out using the original images in the data set and images that were pre-processed. 6 different convolutional neural network (CNN) architectures are used for feature extraction and classification in all classification tasks. In the first task performed to differentiate malignant melanomas from all benign skin lesions, 92% accuracy, 91% AUC, 88% precision, 74% recall and 80% F-Score values were obtained on the test set with DenseNet-121 architecture. In the second classification task performed to distinguish all malignant skin lesions from benign lesions, 89% accuracy, 91% AUC, 85% precision, 81% recall and 83% F-Score values were obtained on the test set with the ResNet-152 architecture. In the third classification task performed to classify all skin lesions into their own class, 84% accuracy, 78% precision, 77% recall and 78% F-Score values were achieved on the test set with the ResNet-152 architecture. In all classification tasks, the classification results of pre-processed images and the original images are given comparatively. The results obtained in the study show that the proposed method gives the desired level of performance in the detection of skin cancer.

Keywords: Skin Cancer, Deep Learning, CNN, Melanoma Detection, Classification

ÖNSÖZ VE TEŞEKKÜR

Yüksek lisans eğitimim boyunca her konuda bilgi ve tecrübesini benden esirgemeyen, destek olan ve yol gösteren kıymetli danışmanım Dr. Öğr. Üyesi Erhan ERGÜN'e teşekkürlerimi sunarım.

Elde ettiğim bilgi ve tecrübeye katkısı olan hocalarıma, tez çalışmam boyunca yanımda olan ve yardımlarını esirgemeyen çalışma arkadaşlarıma, lise döneminden itibaren tüm eğitim hayatımda beni destekleyen eşime teşekkür ederim.

Kazım KILIÇ

İÇİNDEKİLER

ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
KISALTMALAR	viii
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xii
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	4
2.1. Klasik Makine Öğrenimi ile Cilt Kanseri Tespiti	4
2.2. Derin Öğrenme ile Cilt Kanseri Tespiti	6
3. CİLT KANSERİ	10
3.1. Cildin Yapısı	10
3.2. Cilt Kanseri ve Türleri	11
3.2.1. Bazal Hücreli Karsinom.....	12
3.2.2. Skuamöz Hücreli Karsinom.....	12
3.2.3. Melanom	12
3.3. Cilt Kanseri Görüntüleme Yöntemleri.....	13
3.4. Cilt Kanseri Tanı Yöntemleri.....	13
3.5. Yapay Zekâ İle Cilt Kanseri Analizi İçin Kullanılan Veri Kümeleri.....	15
4. MAKİNE ÖĞRENMESİ	18
4.1. Denetimli Öğrenme.....	20
4.2. Denetimsiz Öğrenme	22
4.3. Takviyeli Öğrenme	23
5. DERİN ÖĞRENME	25
5.1. Yapay Sinir Ağları	26
5.1.1. Yapay Sinir Ağı Yapısı.....	27
5.1.2. İleri Beslemeli Ağ Modeli	28
5.1.3. Geri Beslemeli Ağ Modeli	29
5.2. Derin Öğrenme Modelleri.....	29
5.2.1. Otomatik Kodlayıcılar	29
5.2.2. Kısıtlı Boltzman Makineleri (Restricted Boltzman Machines-RBM)	30
5.2.3. Derin İnanç Ağları (Deep Belief Network –DBN)	31
5.2.4. Tekrarlayan Sinir Ağları (Recurrent Neural Networks -RNN).....	31
5.2.5. Uzun Kısa Hafıza Ağları (Long-Short Term Memory - LSTM)	32
5.2.6. Üretken Çekişmeli Ağlar (Generative Adversarial Networks-GAN)	33
5.3. Evrimsel Sinir Ağları	34
5.3.1. Evrişim Katmanı	36
5.3.2. Aktivasyon Katmanı	37
5.3.3. Havuzlama Katmanı	37
5.3.4. Düzleştirme Katmanı	38
5.3.5. Tam Bağlı Katman.....	38
5.3.6. DropOut (Bırakma).....	39
5.3.7. Batch-Size ve Batch-Norm (Toplu Normalleştirme)	39
5.4. Optimizasyon Algoritmaları	40
5.4.1. Dereceli Alçalma	40
5.4.2. Stokastik Dereceli Alçalma (SGD).....	40
5.4.3. AdaGrad.....	41
5.4.4. AdaDelta	41
5.4.5. RMSProp	41
5.4.6. Adam.....	42

5.5. Aktivasyon Fonksiyonları.....	42
5.5.1. Sigmoid.....	42
5.5.2. Tanh.....	42
5.5.3. ReLU.....	43
5.5.4. Sızdıran ReLU ve PReLU.....	43
5.5.5. Softmax.....	44
5.6. Evrimsel Sinir Ağı Mimarileri	44
5.6.1. AlexNet.....	44
5.6.2. VGGNet.....	46
5.6.3. GoogleNet.....	47
5.6.4. ResNet.....	48
5.6.5. DenseNet.....	49
5.6.6. SqueezeNet	50
5.7. Transfer Öğrenme	51
6. MATERYAL VE YÖNTEM.....	53
6.1. Veri Seti	53
6.2. Uygulama Ortamı ve Kütüphaneler	55
6.3. Yöntem	57
6.3.1. Kıl Temizliği.....	59
6.3.2. Segmentasyon	60
6.3.3. Kırpma İşlemi	61
6.3.4. Veri Artırma.....	63
6.4. Sınıflandırma	66
6.5. Değerlendirme Ölçütleri	69
7. BULGULAR VE TARTIŞMA.....	72
7.1. Sınıflandırma Görevi 1	73
7.2. Sınıflandırma Görevi 2	77
7.3. Sınıflandırma Görevi 3	81
8. SONUÇ	90
KAYNAKLAR	92
ÖZGEÇMİŞ	100

KISALTMALAR

ABCD	Asymmetry-Border-Color-Diameter (Asimetri-Sınır-Renk-Çap)
Adam	Adaptive Momentum (Uyarlanabilir Moment)
AUC	Area Under The Curve (Eğri Altındaki Alan)
AdaGrad	Adaptive Gradient Algorithm (Uyarlanabilir Gradyan Algoritması)
BDT	Bilgisayar Destekli Tanı Sistemleri
CAD	Computer Aided Diagnosis Systems
BRNN	Bidirectional Recurrent Neural Networks (Çift Yönlü Tekrarlı Sinir Ağları)
CNN	Convolutional Neural Network (Evrşimsel Sinir Ağı)
DBN	Deep Belief Networks (Derin İnanç Ağları)
DNA	Deoksiribo Nükleik Asit
GAC	Geometric Active Contour (Geometrik Aktif Kontur)
GAN	Generative Adversarial Networks (Üretken Çekişmeli Ağlar)
GLCM	Gray Level Co-occurrence Matrix (Gri Seviye Eş-oluşum Matrisi)
GPU	Graphics Processing Unit (Grafik İşleme Birimi)
GRU	Gated Recurrent Unit (Geçişli Tekrarlayan Birim)
HOG	Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı)
ISIC	The International Skin Imaging Collaboration (Uluslararası Cilt Görüntüleme İşbirliği)
LSTM	Long Short Term Memory (Uzun-Kısa Hafıza Ağları)
LRRT	Learning Rate Range Test (Öğrenme Hızı Aralığı Testi)
NB	Naive Bayes
RAM	Random Access Memory (Rastgele Erişimli Bellek)
OCR	Optical Character Recognition (Optik Karakter Tanıma)
RBM	Restricted Boltzmann Machine (Kısıtlı Boltzmann Makinesi)
ReLU	Rectified Linear Unit (Düzleştirilmiş Doğrusal Birim)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
RF	Random Forest (Rastgele Orman)
RMSProp	Root Mean Square Error Propability (Ortalama Karesel Hata Olasılığının Karekökü)
ROC	Receive-Operation Characteristic (Alıcı İşlem Karakteristiği)

SGD	Stochastic Gradient Descent (Stokastik Gradyan İniş Metodu)
SIFT	Scale Invariant Feature Transformation (Ölçek Değişmez Özellik Dönüşümü)
SVM	Support Vector Machine (Destek Vektör Makinesi)
Tanh	Hyperbolic Tangent (Hiperbolik Tanjant)
YSA	Yapay Sinir Ağı



ŞEKİLLER DİZİNİ

Şekil 3.1. Cildin yapısı	10
Şekil 3.2. Cilt lezyonu (a) melanom (b) bazal hücreli karsinom (c) skuamöz hücreli karsinom	11
Şekil 3.3. Melanom tespiti için ABCD kuralı	14
Şekil 4.1. Yapay zeka alt kümeleri	18
Şekil 4.2. Klasik makine öğrenimi ile görüntü sınıflandırma	19
Şekil 4.3. Makine Öğrenimi türleri	20
Şekil 4.4. Denetimli makine öğrenimi türleri (a) Sınıflandırma (b) Regresyon	21
Şekil 4.5. Kümeleme yöntemi	23
Şekil 4.6. Takviyeli öğrenme yapısı	24
Şekil 5.1. Derin öğrenme ile görüntü sınıflandırma	25
Şekil 5.2. (a) insan sinir hücresi (b) yapay sinir hücresi (c) biyolojik sinaps (d) YSA sinapsları	26
Şekil 5.3. YSA sinir hücresinin matematiksel modeli	28
Şekil 5.4. Yapay sinir ağı modeli	28
Şekil 5.5. Otomatik kodlayıcı modeli	30
Şekil 5.6. Kısıtlı boltzman makinesi modeli	30
Şekil 5.7. DBN modeli	31
Şekil 5.8. RNN modeli	32
Şekil 5.9. LSTM ağının katman yapısı	33
Şekil 5.10. GAN modeli	34
Şekil 5.11. CNN mimarisi	35
Şekil 5.12. Evrişim işlemi	36
Şekil 5.13. Maksimum havuzlama işlemi	37
Şekil 5.14. Düzleştirme işlemi	38
Şekil 5.15. Dropout işlemi	39
Şekil 5.16. Aktivasyon fonksiyonları (a) sigmoid (b) tanh (c) ReLU (d) Leaky ReLU ..	44
Şekil 5.17. AlexNet mimarisi	45
Şekil 5.18. VGGNet mimarisi	46
Şekil 5.19. GoogleNet mimarisi	47
Şekil 5.20. ResNet mimarisi	48
Şekil 5.21. Residual blok yapısı	48
Şekil 5.22. DenseNet mimarisi	49
Şekil 5.23. SqueezeNet yangın modülü	51
Şekil 5.24. Transfer öğrenme işlemi	52
Şekil 6.1. Veri setinde bulunan cilt lezyonlarına ait örnek görüntüler	55
Şekil 6.2. Cilt kanseri tespiti için önerilen yöntem	58
Şekil 6.3. Kıl temizliği işlem adımları (a) orijinal kıl içeren görüntü (b) gri seviyeli renk uzayına dönüştürülen görüntü (c) siyah şapka haritası çıkarılmış görüntü (d) eşikleme yöntemi ile maskesi çıkarılmış görüntü (e) kıl temizliği gerçekleştirilen görüntü.	60
Şekil 6.4. Segmentasyon ve kırpma işlem adımları (a) orijinal cilt lezyonu görüntüsü (b) gri seviyeli görüntü (c) Gauss bulanıklığı uygulanan görüntü (d) Otsu eşikleme ile elde edilen maske görüntüsü (e) kırpılmış lezyon görüntüsü	62
Şekil 6.5. Kırpılmış görüntülerden elde edilen yapay görüntüler (a) gerçek görüntü (b) dikey döndürülmüş görüntü (c) yatay döndürülmüş görüntü (d) 180 derece döndürülmüş görüntü.	64
Şekil 6.6. Öğrenme hızı bulucu grafiği	69
Şekil 6.7. ROC eğrisi	71
Şekil 7.1. Sınıflandırma görevi 1 için CNN mimarilerinin doğru pozitif oranı	74

Şekil 7.2. DenseNet-121 mimarisi doğruluk eğrisi.....	75
Şekil 7.3. DenseNet-121 mimarisi kayıp eğrisi	75
Şekil 7.4 DenseNet-121 karmaşıklık matrisi	76
Şekil 7.5. DenseNet-121 mimarisi ROC eğrisi.....	76
Şekil 7.6. Sınıflandırma görevi 2 için CNN mimarilerinin doğru pozitif oranı	78
Şekil 7.7. ResNet-152 mimarisi doğruluk eğrisi.....	79
Şekil 7.8. ResNet-152 mimarisi kayıp eğrisi	79
Şekil 7.9. ResNet-152 karmaşıklık matrisi	80
Şekil 7.10. ResNet-152 mimarisi ROC eğrisi.....	80
Şekil 7.11. Sınıflandırma görevi 3 için CNN mimarilerinin doğru pozitif oranı	83
Şekil 7.12. ResNet-152 mimarisi doğruluk eğrisi.....	85
Şekil 7.13. ResNet-152 mimarisi kayıp eğrisi	85
Şekil 7.14. ResNet-152 karmaşıklık matrisi	86
Şekil 7.15. ResNet-152 mimarisi ROC eğrisi.....	86



TABLolar DİZİNİ

Tablo 3. 1. Deroskopi veri kümeleri.....	16
Tablo 6. 1. HAM10000 veri seti görüntü dağılımı	54
Tablo 6. 2. Sınıflandırma görevi 1 görüntü sayıları.....	65
Tablo 6. 3. Sınıflandırma görevi 2 görüntü sayıları.....	66
Tablo 6. 4. Sınıflandırma görevi 3 görüntü sayıları.....	66
Tablo 6. 5. Karmaşıklık matrisi	70
Tablo 7. 1. Sınıflandırma görevi 1 için CNN mimarilerinin performans özeti.....	73
Tablo 7. 2. Sınıflandırma görevi 2 için CNN mimarilerinin performans özeti.....	77
Tablo 7. 3. Sınıflandırma görevi 3 için CNN mimarilerinin performans özeti.....	82
Tablo 7. 4. Resnet-152 mimarisinin test kümesi üzerindeki performans özeti.....	84
Tablo 7. 5. Melanom tespitine yönelik çalışmaların performansı.....	88
Tablo 7. 6. Çok sınıflı cilt lezyonu sınıflandırma çalışmalarının performansı	89



1. GİRİŞ

Cilt kanseri, cildin epidermis tabakasında bulunan hücrelerin ultraviyole ışınlarla fazla maruz kalması sonucu DNA yapılarının bozularak aşırı büyümesi ile ortaya çıkan hastalıktır (Rey-Barroso vd, 2021a). Cilt kanserinin genel olarak 3 farklı türü bulunmaktadır. Bazal hücreli karsinom (BHK), en yaygın görülen cilt kanseri türüdür ve vakaların %80'ini oluşturmaktadır. Ölüm oranı en düşük olan bu tür erken tedavi edilmediğinde risk oluşturmaktadır. Skuamöz hücreli karsinom (SHK), cilt kanseri vakalarının %16'sını oluşturmaktadır. Cildin orta ve dış katmanlarını oluşturan skuamöz hücrelerinde gelişir. Bu cilt kanseri, kolay ve başarılı bir şekilde tedavi edilebilmesine rağmen büyümesine izin verildiğinde şekilsiz ve ölümcül lezyonlara dönüşmekle birlikte vücudun diğer bölgelerine de yayılabilir.

Melanom, tüm cilt kanseri türleri arasında nadir görülmesine rağmen en ölümcül olanıdır. Cilde rengini veren melanosit hücrelerinde oluşan hasar sonucunda ortaya çıkan melanom, erken tedavi edilmediği takdirde diğer organlara hızlı bir şekilde yayılabilir, tedavisi zorlaşır ve ölümcül hale gelir (Jerant vd,2000; Garbe vd, 2010; Siegel vd, 2021a).

Cilt kanserinin ana nedeni güneşin ultraviyole ışınları ile bronzlaşma makinelerinin ultraviyole ışınlarına fazla maruz kalmaktır (Curtin vd, 2005; Curtin vd,2006). Ozon tabakasının incilmesi sonucu cilt kanseri vakalarının artmasıyla birlikte dünya genelinde melanoma bağlı ölüm oranı da her geçen gün artmaktadır (Siegel vd, 2021b). Cilt kanserinin tespiti için dermatologlar tarafından kullanılan genel tanı yöntemi dermoskopi taramasıdır (Psaty ve Halpern, 2009; Narayanamurthy vd, 2018a). Dermoskopi, cilt yüzeyinde bulunan lezyonların 10-20 kat büyütülerek incelenmesini sağlar (Kittler vd, 2007; Thomas ve Puig, 2017). Görsel inceleme yoluyla gerçekleştirilen bu tanı yöntemi ile cilt kanserini tespit etmek uzman dermatologlar tarafından zahmetlidir ve hataya açıktır. Tanı sürecinde kesin sonuç ise biyopsi ile elde edilmektedir (Celebi vd, 2008; Abbas vd, 2013; Xie vd, 2020a).

Kötü huylu melanomların erken tespit edilerek tedavi edilmesi hastalığı tamamen ortadan kaldırmaktadır (Celebi vd, 2007; Capdehourat vd, 2011).Bu nedenle dermatologlara yardımcı ikinci bir görüş olarak geliştirilen ve gereksiz

biyopsilerin azaltılmasını sağlayan bilgisayar destekli tespit (BDT) sistemlerinin önemi giderek artmaktadır.

Yapay zekâ temelli geliştirilen BDT sistemleri, işlem kapasitesi gelişmiş ekran kartları ile birlikte daha popüler hale gelmiştir. ISIC (Uluslararası Cilt Görüntüleme İşbirliği) kötü huylu melanomun makine öğrenimi teknikleri ile erken tespit edilmesi için 2016 yılından itibaren her yıl düzenli olarak yarışmalar düzenlemektedir. Klasik makine öğrenimi teknikleri ile görüntü analizi için görüntüden elle çıkarılan özelliklere ihtiyaç vardır. Sınıflandırma performansı de çıkarılan bu özelliklere bağlıdır (Oliveira vd, 2018; Cinarer ve Emiroglu, 2020) Derin öğrenme, klasik makine öğrenimi tekniklerinin aksine verinin temsilinden öğrenerek karmaşık hesaplamalar yapabilen yapay sinir ağı (YSA) tabanlı makine öğrenimi tekniğidir (Russakovsky vd, 2015). Görüntülerden özellik çıkarma ve sınıflandırma işlemlerini gerçekleştiren evrimsel sinir ağları (CNN) en yaygın kullanılan derin öğrenme modelidir. CNN'ler 2012'de AlexNet (Krizhevsky vd, 2012a) mimarisinin ImageNet yarışmasını kazanmasıyla birlikte popüler olmuş ve günümüze kadar geliştirilmeye devam etmiştir. CNN'ler tıbbi görüntü analizinde beyin tümörü (Deepak ve Ameer,2019), meme kanseri (Khan vd, 2019), Covid-19 (Jiang vd, 2021) , diyabetik retinopati (Qiao vd, 2020) , cilt kanseri tespiti (Brinker vd, 2018) gibi birçok alanda kullanılmaktadır (Litjens vd,2017).

Bu çalışmada, cilt kanseri tespiti için bir dizi ön işleme lezyon bölgesinin doğru tespit edilebilmesi ve lezyonların ayırıcı özellikleri çıkarılarak sınıflandırma doğruluğunun artırılmasını sağlanacaktır. Bununla birlikte transfer öğrenme yaklaşımını kullanarak geliştirilen BDT sistemi ile kötü huylu cilt lezyonları tespit edilecektir.

Tez çalışması kapsamında, dermoskopi görüntülerinden oluşan HAM10000 veri seti kullanılarak cilt lezyonlarının sınıflandırılması için derin öğrenme tabanlı yöntem önerilmektedir. Önerilen yöntemde ilk olarak cilt lezyonlarında bulunan kıllar morfolojik işlemlerle tespit edilerek temizlenmektedir. Sonrasında lezyon bölgesinin tespitini zorlaştıran gürültüler Gauss bulanıklığı yöntemi ile ortadan kaldırılmaya çalışılmaktadır. Lezyon bölgesi Otsu eşikleme algoritması kullanılarak tespit edilmekte ve görüntülerin ikili maskesi çıkarılmaktadır. Maskeden lezyon bölgesinin koordinatları tespit edilerek ilgili bölgenin kırpma işlemi gerçekleştirilmektedir. Kırpılan görüntüler 224x224 boyutuna

ölçeklendirilerek yalnızca eğitim kümesi üzerinde veri artırma gerçekleştirilmektedir. Son olarak görüntülerden özellik çıkarımı ve sınıflandırma için AlexNet, VGGNet, ResNet-18, DenseNet-121, ResNet-152 ve SqueezeNet mimarileri kullanılmaktadır. Bu yöntemler kullanılarak 3 farklı sınıflandırma gerçekleştirilmektedir. Önerilen yöntem ile elde edilen sonuçlar ile görüntülerin orjinal hali ile elde edilen sonuçlar karşılaştırmalı olarak sunulmaktadır.

İlerleyen konu akışı şu şekilde düzenlenmiştir: 2.bölümde cilt kanseri tespiti için literatürde yapılan çalışmalar özetlenmiştir. 3.bölümde cilt ve cilt kanseri tanımlamaları ile dermoskopi veri kümeleri hakkında genel bilgiler verilmiştir. 4.bölümde makine öğrenimi tanımlamaları, 5. Bölümde ise derin öğrenme tanımlamaları ile derin öğrenme modelleri ve hiper-parametreler açıklanmıştır. 6.bölümde, çalışmada kullanılan veri seti, uygulama ortamı ve kullanılan kütüphaneler, ön işlem yöntemleri, özellik çıkarma ve sınıflandırma algoritmaları ile değerlendirme metrikleri açıklanmıştır. 7.bölümde elde edilen bulgular karşılaştırmalı olarak tablolarla ve grafiklerle sunulmuştur. 8.bölümde çalışmanın sonucu ve gelecek çalışmalar ile ilgili bilgiler verilmiştir.

2. LİTERATÜR ÖZETİ

Literatürde, cilt lezyon görüntülerinden cilt kanseri tespitine yönelik yapılmış çalışmalar mevcuttur. Çalışmalarda kullanılan veri setleri, ön-işlemler, özellik çıkarımı ve sınıflandırma için kullanılan yöntemler ile elde edilen sonuçlar aşağıda özetlenecektir. Cilt kanseri tespiti için yapılan klasik makine öğrenimi teknikleri ile ilgili çalışmalarda derin öğrenme tabanlı ve hibrit çalışmalar ayrı başlıklarda verilecektir.

2.1. Klasik Makine Öğrenimi ile Cilt Kanseri Tespiti

Yapay zekânın bir alt kümesi olan makine öğrenimi kendi içerisinde farklı alt kümelere ayrılmaktadır. Makine öğrenimi algoritmaları ile görüntü analizi son yıllarda popüler hale gelmiştir. Klasik makine öğrenimi ile görüntü analizi yapabilmek uzmanlık gerektiren bir süreçtir. Bu süreçte görüntüleri analiz edebilmek için görüntülerden elde edilen özelliklere ihtiyaç duyulmaktadır. Görüntü özellikleri elde edebilmek de ayrı bir uzmanlık gerektirmektedir. Görüntüden çıkarılan bu özellikler ile sınıflandırma yapmak her zaman iyi sonuç vermeyebilir. Bu nedenle anlamlı olan özellikleri belirlemek için boyut azaltma yöntemleri kullanılmaktadır. Cilt kanserinin klasik makine öğrenimi yöntemleri ile tespitinde lezyon bölgesinde bulunan kıl ve benzeri gürültüler lezyon bölgesinin tespitini zorlaştırmaktadır. Bu nedenle yapılan çalışmaların çoğunluğunda görüntülere ön işlem uygulanmakta, daha sonra lezyon bölgesi tespit edilerek arka plandan ayrılmaktadır. Cilt kanserinin klasik makine öğrenimi yöntemleri ile tespiti dermatologlar tarafından da kullanılan kötü huylu melanomun diğer lezyonlardan ayır edilmesini sağlayan ABCD kuralından dolayı son yıllarda popüler hale gelmiştir. ABCD kuralı bölüm 3.4.'de detaylı olarak açıklanmaktadır. Yapılan incelemelerde araştırmacılar genellikle lezyon bölgesinde ABCD kuralına göre özellikler çıkarmakta ve bu özellikleri sınıflandırmaya çalışmaktadırlar.

Majumder ve Ullah (2018) kötü huylu melanomu iyi huylu cilt lezyonlarından ayırmak için Ph2 veri setinde bulunan 200 dermoskopi görüntüsü üzerinde çalışma gerçekleştirmişlerdir. Görüntülere Otsu eşikleme yöntemi ile segmentasyon gerçekleştirerek sınırları çizilen bölgenin ABCD kuralı temelinde

özelliklerini çıkarmışlardır. Çıkarılan özellikleri yapay sinir ağları ile sınıflandırmışlardır. Çalışma sonucunda %98 doğruluk elde etmişlerdir.

Filali ve diğerleri (2018) cilt kanseri tespiti için ISIC 2017 veri setinde bulunan 2150 dermoskopi görüntüsünü Otsu eşikleme yöntemi kullanarak bölütlemişlerdir. Lezyon bölgesinin tespitinden sonra ilgili bölgenin doku ve renk özelliklerini çıkararak anlamlı özellikleri belirlemek için boyut azaltma işlemi uygulamışlardır. Son aşamada seçilen özellikleri destek vektör makinesi (SVM) algoritması ile sınıflandırıp %84 doğruluk değeri elde etmişlerdir.

Daghrir ve diğerleri (2020) ISIC arşivinden elde ettikleri 640 dermoskopi görüntüsünün morfolojik geometrik aktif kontur (morpGAC) yöntemi ile sınırlarını tespit edip doku ve renk özellikleri çıkarmışlardır. Elde edilen özellikleri SVM algoritması ile sınıflandırmışlardır ve %71.8 doğruluk değeri elde etmişlerdir.

Murugan ve diğerleri (2021) cilt kanseri tespiti için ISIC arşivinden 1000 dermoskopi görüntüsü kullanmışlardır. Görüntüler üzerinde mean shift algoritması ile segmentasyon gerçekleştirmişlerdir. Segmentasyonu yapılan görüntülerin Gri seviyeli eş oluşum matrisi (GLCM) yöntemi ile özelliklerini çıkarmışlardır. Özellik kümesine SVM ve random forest (RF) sınıflandırma algoritmalarını uygulayarak %89.3 doğruluğa ulaşmışlardır.

Monika ve diğerleri (2020) ISIC arşivinde bulunan 800 dermoskopi görüntüsünde bulunan ilgili cilt lezyonlarını K-Means kümeleme algoritması kullanarak bölütlemişlerdir. İlgili bölgeden ABCD kuralı ve GLCM algoritması ile özellikler çıkarmışlardır. Çıkarılan özellik kümesini çok sınıflı SVM algoritması ile sınıflandırmışlardır. Çalışma sonucunda %96.2 doğruluk oranı elde etmişlerdir.

Premaladha ve Ravichandran (2016) Med-Node ve PH2 veri setlerinde bulunan toplamda 992 görüntüye ön işlemler uyguladıktan sonra Otsu eşikleme yöntemi ile segmentasyon gerçekleştirmişlerdir. İlgili lezyon bölgesinin geometrik özellikleri ile GLCM algoritması kullanarak doku özelliklerini çıkarmışlardır. Çıkarılan özellikler derin sinir ağları ile sınıflandırılmıştır. Yapılan çalışma sonucunda %92.8 doğruluk değerine ulaşmışlardır.

Balaji ve diğeri (2021) ISIC 2017 veri setinde bulunan 2150 görüntünün graph cut (grafik kesim) tabanlı segmentasyonunu gerçekleştirmişlerdir. Segmente edilen lezyon bölgesinin ABCD kuralında bulunan doku, renk ve asimetri özelliklerini çıkararak bu özellikleri naive bayes (NB) algoritması ile sınıflandırmışlardır. Sınıflandırma sonucu %91.8 doğruluk değeri elde etmişlerdir.

Vidya ve Karki (2020) geometrik aktif kontur yöntemi (GAC) ile ISIC arşivinden elde ettikleri 1000 dermoskopi görüntüsünün lezyon bölgesini tespit etmişlerdir. Tespit edilen lezyon bölgesinin ABCD, GLCM ve yönlendirilmiş gradyanların histogramı (HOG) yöntemleri ile özelliklerini çıkarmış ve SVM algoritmasıyla sınıflandırmışlardır. Sınıflandırma sonucunda %97.8 doğruluk elde etmişlerdir.

Waheed ve diğeri (2017) Ph2 veri setinde bulunan 200 dermoskopi görüntüsünün renk ve doku özelliklerini çıkarmışlardır. Çıkarılan özellik kümesi SVM algoritması ile sınıflandırılarak %96 doğruluğa ulaşmışlardır.

İsmail ve diğeri (2020) ISIC arşivinden alınan 1635 dermoskopi görüntüsünün renk özellikleri ile birlikte HOG, ölçekle değişmeyen özellik dönüşümü (SIFT) ve GIST yöntemleri ile elde edilen özellikleri çıkarmışlardır. Bu özellikleri Random Forest algoritması ile sınıflandırarak %67.5 doğruluğa ulaşmışlardır.

2.2 Derin Öğrenme ile Cilt Kanseri Tespiti

Makine öğreniminin bir alt kümesi olan derin öğrenme 2012 yılı ImageNet yarışmasında gösterdiği başarıdan dolayı görüntü tanıma ve sınıflandırma problemlerinde oldukça popüler hale gelmiştir. AlexNet mimarisi ile popüler olan CNN mimarisi günümüzde günümüzde gelişmiş farklı versiyonları ile karşımıza çıkmaktadır. CNN'ler klasik makine öğrenimi tekniklerinin aksine sahip olduğu evrişim katmanları ile görüntüden özellikler elde ederek tam bağlı katmanda bu özelliklerden öğrenme işlemini gerçekleştirir ve görüntü sınıflandırabilir. CNN'ler genellikle görüntü analizinde kullanılmaktadır. ISIC yarışmalarında cilt kanseri tespiti için birçok makine öğrenim tekniği kullanılsa da CNN mimarilerine ilgi büyüktür.

CNN mimarilerinin eğitimi için iki farklı yaklaşım kullanılır. İlk yaklaşım CNN mimarisini sıfırdan eğitmektir. Bunun için çok fazla sayıda etiketli veri

gerekmektedir. Cilt kanseri görüntülerinin az olması sebebiyle bu yaklaşım fazla tercih edilmemektedir. İkinci yaklaşım ise transfer öğrenmedir. Transfer öğrenme yaklaşımında model başka sınıflandırma görevinde çok fazla etiketli veri ile eğitilen modellerin parametrelerini kullanarak eğitime başlatılır ve cilt lezyonu görüntüleri ile yeniden eğitilir. Cilt kanseri tespiti için genellikle transfer öğrenme yaklaşımı kullanılmaktadır.

Esteva ve diğerleri (2017) 2032 farklı hastalıktan oluşan 129.450 etiketli ve biyopsi ile kanıtlanmış cilt lezyon görüntüsü kullanarak CNN mimarisini sıfırdan eğitmişlerdir. Eğittikleri modeli 21 kurul sertifikalı uzman dermatoloğun tahmin sonuçları ile karşılaştırmışlardır. Eğitilen model, test edilen tüm uzman dermatologlarla eşit performans elde ederek cilt kanseri tespitinin uzman dermatologlarla karşılaştırılabilir düzeyde bir yetkinlikle sınıflandırabildiğini göstermiştir. Bununla birlikte, çalışmada derin sinir ağları ile donatılmış olan mobil cihazların klinik dışında dermatologlara yardımcı olabileceğini belirtmişlerdir.

Lopez ve diğerleri (2017) ISIC arşivinde bulunan dermoskopi görüntüleri kullanarak cilt kanserini iyi huylu ve kötü huylu olarak ayırmaya çalışmışlardır. Dermoskopi görüntülerine ön-işlem ve veri artırma uyguladıkları çalışmada CNN modelini sıfırdan eğiterek %66 doğruluk değeri elde etmişlerdir. Aynı modele ince ayar yaparak ve transfer öğrenme yöntemi ile ImageNet ağırlıkları kullanarak %81.33 oranında doğruluk değerine ulaşmışlardır.

Kassani ve Kassani (2019) yaptıkları çalışmada derin öğrenme mimarilerinin cilt kanseri tespitinde karşılaştırmalı analizlerini sunmuşlardır. HAM10000 veri setinde bulunan dermoskopi görüntülerine kontrast geliştirme renk uzayı dönüşümü gibi ön-işlem teknikleri uygulayıp veri artırma gerçekleştirmişlerdir. AlexNet, Xception, VGGNet16, VGGNet19 ve ResNet-50 mimarisi ile yapılan deneylerde 7 farklı sınıfın ortalamasında %92 doğruluk, melanom tespiti için ise %92.7 F-skoru ve %92 doğruluk değerine ulaşmışlardır.

Ayan ve Ünver (2018) çalışmalarında melanom tespitinde veri artırmanın doğruluğu pozitif yönde etkilediğini göstermişlerdir. Deney için ISIC arşivinden 500 melanom görüntüsü ile 500 iyi huylu lezyon görüntüsü kullanmışlardır.

Çalışma sonucunda oluşturdukları CNN mimarisi ile artırılmamış verilerle %78 doğruluk, artırılmış verilerle ise %81 doğruluk değeri elde etmişlerdir.

Rashid ve diğerleri (2019) cilt kanseri tespiti için kötü huylu örneklerin az olması sebebiyle Çekişmeli Üretici Ağlar (GAN) tabanlı sentetik veri üretimi yaklaşımını sunmuşlardır. HAM10000 veri seti üzerinde gerçekleştirdikleri deneyler sonucunda oluşturdukları GAN mimarisinin doğruluğunu ölçmek için ResNet ve DenseNet mimarileri karşılaştırmışlardır. ResNet-50 mimarisi ile 0.79 doğruluk, DenseNet mimarisi ile 0.81 ve GAN tabanlı sınıflandırma ile 0.86 doğruluk değeri elde etmişlerdir.

Quang (2017) çalışmalarında ISBI 2017 yarışmasında kullanılan dermoskopi görüntüleri üzerinde transfer öğrenimi yaklaşımını kullanarak VGGNet-16 mimari ile iki farklı sınıflandırma görevi için ikili sınıflandırma gerçekleştirmişlerdir. Birinci görevde kötü huylu melanom ile iyi huylu lezyonları ayırma çalışmışlar ve %76 eğri altında kalan alan (AUC) skoru elde etmişlerdir. İkinci göreve melanositik ve melanositik olmayan lezyonları ayırt etmeye çalışmışlar ve %86 AUC skoru elde etmişlerdir.

Kawahara ve diğerleri (2016) Dermofit görüntü kitaplığından elde ettikleri cilt lezyon görüntülerine normalleştirme ve ön işlem uygulayarak CNN tabanlı sınıflandırma gerçekleştirmişlerdir. 5 sınıfta ve 2 sınıfta gerçekleştirilen deneylerde önerdikleri CNN mimarisi ile sırası ile %85.8 ve %94.8 doğruluk değerine ulaşmışlardır.

Harangi (2017) cilt kanseri tespiti için ISBI 2017 yarışmasında kullanılan veri seti üzerinde 4 farklı CNN mimarisinin çıktılarını birleştiren yöntem sunmuştur. Veri artırma işlemi gerçekleştirilen görüntüler AlexNet, GoogleNet, VGGNET ve ResNet kullanılarak oluşturulan hibrit modeller sınıflandırılmış ve ağırlıklı ortalama %86 doğruluk değeri ve %89 AUC skoru elde etmişlerdir. Önerdikleri CNN mimarisi bilinen CNN mimarilerinden daha iyi sonuç vermiştir.

Singh ve Nwogu (2018) kötü huylu melanom tespiti için CNN mimarisi ile çıkarılan özelliklerin sınıflandırması ile renk histogram dağılımı, kenar histogramları ve ikili desenler gibi elle çıkarılan özellikleri Random Forest algoritması ile sınıflandırmışlardır. Son aşamada melanom tespiti için iki

sınıflandırıcının ortalamasını almışlardır. Ortalamada %80 doğruluk ,%69 AUC skoru ve %81 kesinlik (Precision) değeri elde etmişlerdir.

Adegun ve Viriri (2019) melanom cilt kanserinin tespiti için görüntülerde melanom tespitini engelleyen kıl ve benzeri gürültülerden etkilenmeyen ve lezyon bölgesinin tespitini sağlayan ve sonrasında kötü huylu melanomları iyi huylu lezyonlardan ayıran CNN mimarisi önermişlerdir. Deneyleri ISBI2017 ve Ph2 veri seti üzerinde gerçekleştirmişlerdir. Yapılan deneyler sonucunda her iki veri setinde de %95 oranında doğruluk elde etmişlerdir.

Xie ve diğerleri (2020b) sundukları çalışmada cilt lezyonlarının segmentasyonu ve sınıflandırılması için karşılıklı önyükleme ile çalışan yeni bir CNN mimarisi sunmuşlardır. Cilt lezyonlarının sınırlarını belirleyip kendi içerisinde bilgi akışı sağlayarak sınıflandırma gerçekleştiren CNN mimarisi ile ISBI 2017 ve Ph2 veri setleri üzerinde %93,8 ve %97,7 ortalama AUC skoru elde etmişlerdir.

Kassem ve diğerleri (2020) farklı cilt lezyonlarının tespiti için transfer öğrenme yaklaşımı ile GoogleNet mimarisini kullanmışlardır. Önerilen model ile farklı cilt lezyonlarını ayırabilme yeteneğini test etmek için deneyleri ISIC 2019 veri seti üzerinde gerçekleştirmişlerdir. Lezyonları 8 farklı kategoride sınıflandırmışlardır ve sınıflandırma sonucunda %94.92 doğruluk, %79.8 hassasiyet (Recall), %97 özgünlük (Specificity) ve %80.36 precision değeri elde etmişlerdir.


3. CİLT KANSERİ

Kanser, yaygınlığı ve yüksek ölüm oranı ile en korkutucu ve tehlikeli hastalık türü olma özelliğini taşımaktadır. Her kanser türü ölümcül olmadığı gibi, erken teşhis ve tedavi uygulanması durumunda ölümcül kanser türlerinde iyileştirilebilmektedir. Tüm bu süreçlerde, hızlı ve kolay erişilebilir teşhis araçlarının önemi tartışılmazdır.

Cilt kanseri türleri arasında en ölümcül olan melanoma yönelik tanı destek sistemine geçmeden önce bu hastalığın iyi tanınması gerekmektedir.

3.1. Cildin Yapısı

Cilt, insan vücudu çevreleyen ve örten en büyük organdır. Vücudun savunma organı olup hasar gördüğünde kendisini yenileyerek vücudu dışardan gelen tehlikelere karşı devamlı bir şekilde korumaktadır. Cilt insan ağırlığının yaklaşık olarak %16'sını oluşturmaktadır. İnsan vücudunda en ince cilt göz çevresinde en kalın cilt ise ayak tabanlarında bulunmakla birlikte tüm vücut dikkate alındığında cilt kalınlığı 1-4 mm arasında değişmektedir. Cilt yapısı epidermis, dermis ve hipodermis olarak 3 katmandan oluşmaktadır (Richardson, 2003). Şekil 3.1.'de cildin yapısı ve katmanları gösterilmektedir.



Şekil 3.1. Cildin yapısı (Yeşiloğlu, 2021)


Epidermis, cildin en dış tabakasını oluşturmaktadır. Damarlı yapılar içermeyen bu tabaka keratinosit adı verilen hücrelerden oluşmaktadır. Epidermisin kalınlığı vücut bölgelerine göre değişir. Epidermis tabakası kendi içinde 4 farklı tabakadan oluşmaktadır. Bunlar sırasıyla; Stratum Basale, Stratum Spinosum, Stratum Granulosum ve Stratum Corneum'dur. Epidermis tabakasının çoğunu keratinosit oluşturmakla birlikte epidermisde legarhans ve merkel hücreleri ile melanositlerde bulunmaktadır. Melanositler bazal tabaka bölgesinde yer alır ve melanin pigmentleri sentezler. Melanin pigmentleri cildi ultraviyole ışınlarına karşı koruyarak cilde rengini verir (Proksch vd, 2008).

Dermis, epidermis tabakasının altında bulunan cildin ikinci katmanıdır. Epidermis ile hipodermis katmanını birbirine bağlar. Cildin sağlamlığını oluşturan bu katman içerisinde yağ bezleri, kıl folikülleri ve yağ bezleri bulundurulur.

Hipodermis, cildin en alt katmanında yağ dokularından oluşan, cilde enerji ve yalıtım sağlayan tabakadır. İçerisinde zengin yağ hücreleri bulundurmakla birlikte kan ve karbonhidrat yönüsen zengindir. Cildin beslenme kaynağıdır ve dış etmenlere karşı iç organları koruma görevi görür (Lawton, 2019).

3.2. Cilt Kanseri ve Türleri

En büyük organ olan cildin hücrelerinin kontrolsüz bir şekilde büyüyerek DNA yapılarının bozulması sonucu cilt kanseri ortaya çıkmaktadır (Rey-Barroso vd, 2021b). Cilt kanserinin oluşumunda en büyük etken güneşin ultraviyole ışınlarına yüksek derecede maruz kalmaktır. Bununla birlikte solaryum cihazların da fazla vakit geçirmek de cilt kanserine neden olabilmektedir. Cilt kanseri tüm dünyada en yaygın görülen kanser türüdür. Ozon tabakasının incilmesi sonucu cilt kanserinin tüm dünyada görülme sıklığı giderek artmaktadır (Siegel vd, 2021c). Cilt kanserinin genel olarak 3 farklı türü bulunmaktadır.



Şekil 3.2. Cilt lezyonu (a) melanom (b) bazal hücreli karsinom (c) skuamöz hücreli karsinom

3.2.1. Bazal Hücreli Karsinom

BHK, cilt kanseri türleri arasında %80 görülme oranı ile en yaygın türdür. Bununla birlikte ölüm oranı en düşük olan türdür. Erken tedavisi sonucunda insan vücudunda bir risk barındırmamaktadır. Bazal hücreler cilt içerisinde ölen eski hücrelerin yerine yenilerinin üretilmesinden sorumludur. Bu hücrelerin zarar gördüğü durumda ciltte şeffaf yumrular oluşmaktadır. Oluşan bu yumrular genellikle vücudun baş ve boyun bölgesinde bulunur. BHK kabuklu bir yapıya sahip olup yayıldığı alan diğer türlere göre geniştir. Bu kanser türünün oluşmasındaki en büyük neden güneşin ultraviyole ışınlarına çok uzun süre maruz kalmaktır (İnözü vd, 2012; Anonymous, 2021a).

3.2.2. Skuamöz Hücreli Karsinom

SHK, en yaygın görülen ikinci cilt kanseri türüdür ve görülme oranı %16'dır. Bu tür, cildin orta ve dış katmanlarını oluşturan skuamöz hücrelerinde gelişir. Bazı cilt hastalıkları sonrasında da oluşabilen SHK genellikle sert ve kabuklu bir yüzeye sahip olup kırmızı bir leke şeklinde de görülebilir. Aktinik keratoz olarak bilinen cilt kanserleri skuamöz hücreli cilt kanserleri içerisinde gelişebilir. SHK yaygın olarak yüz bölgesinde kulaklarda ve ellerde görülür. SHK kolay ve başarılı bir şekilde tedavi edilebilmesine rağmen büyümesine izin verildiğinde şekilsiz ve ölümcül lezyonlara dönüşebilir. Erken tedavi edilmeyen bu lezyonlar istilacı hale gelebilir ve vücudun diğer bölgelerine yayılabilir (Madan ve Lear, 2010; Anonymous, 2021b).

3.2.3. Melanom

Tüm cilt kanseri türleri arasında nadir görülmesine rağmen en ölümcül olan türdür. Epidermis tabakasında bulunan melanosit hücreleri cilde renk veren ve melanin olarak bilinen pigmentleri üretirler. Cilt, güneş veya solaryum makinelerinden gelen ultraviyole ışınlarına maruz kaldığı takdirde melanosit hücrelerinin hasar görerek daha fazla melanin üretmesine neden olur. Melanom cilt kanseri, melanosit hücrelerinde meydana gelen bu hasar sonucu ortaya çıkar. Melanom farklı şekil boyut ve renklerde bulunabilir. Melanom cilt kanserine bağlı ölüm oranı tüm dünyada her geçen gün artmaktadır. Bu tür, erken tedavi edilmediği takdirde diğer organlara hızlı bir şekilde yayılabilir, tedavi edilmesi zorlaşır ve ölümcül olabilir. Erken tespit edilmesi durumunda büyük oranda

iyileştirilebilir ve tamamen ortadan kaldırılabilir (Thompson vd, 2005; Schadendorf vd, 2015; Kizilbey ve Akdeste, 2003).

3.3. Cilt Kanseri Görüntüleme Yöntemleri

Cilt kanserinin tespitinde ciltte bulunan tümörlü bölgeyi analiz etmek için farklı görüntüleme teknikleri bulunmaktadır. Non-invaziv (cerrahi işlem gerektirmeyen) olan bu görüntüleme teknikleri arasında fotoğrafçılık, dermoskopi taraması, ultrason, konfokal mikroskopi, raman spektroskopisi, floresans spektroskopisi, tetrahertz spektroskopisi, optik kohorens tomografi, multispektral görüntüleme, termografi, elektriksel biyo-empedans, bant sıyırma, çoklu foton taraması bulunmaktadır (Narayanamurthy vd, 2018). Cilt kanseri tespit için birçok görüntüleme yöntemi bulunmasına rağmen yaygın olarak kullanılan yöntem dermoskopi taramasıdır.

Dermoskopi, cilt lezyonlarının incelemesi için kullanılan bu yöntem dermatoskopi veya epilüminesans olarak da bilinir (Stein vd, 1987). Dermatoskopi, cilt yüzeyinde bulunan lezyonların mikroskopik incelenmesini sağlar. Ciltte bulunan benlerin büyüklüğünü 10-20 kat arası artırarak pigmentli benlerin kötü huylu cilt kanserlerinden ayrılması sağlar. Bununla birlikte polarize ışık sayesinde ciltteki yansımaları ortadan kaldırarak düzgün ve net görüntüler elde edilmesine imkân tanır. Dermatoskopi taramasından elde edilen görüntüler kötü huylu cilt kanserini tespit ederken kullanılan hesaplama işlemlerine kolaylık sağlamasına rağmen bu görüntülerden cilt kanseri tespiti uzmanlık gerektirmektedir.

3.4. Cilt Kanseri Tanı Yöntemleri

Dermoskopi görüntülerinden kötü huylu cilt kanserlerini tespit edebilmek için birçok yöntem bulunmaktadır fakat cilt kanseri için kesin tanı ancak biyopsi ile gerçekleşmektedir. Tarama sonucu hastada cilt kanseri şüphesi oluştuğunda tümörlü bölgeden bir parça örnek kesilerek alınır ve incelenmek üzere laboratuvara gönderilir. Bu işleme cilt biyopsisi denilmektedir (Anonymous, 2018). Kötü huylu melanomları dermoskopi görüntülerinden tespit etmek için patern analizi (Pehamberger vd, 1987), ABCD kuralı (Patwardhan vd, 2005), menzies yöntemi (Menzies vd, 1996), 7 noktalı kontrol listesi (Argenziano, 1998) gibi teknikler kullanılmaktadır. Bunlar içerisinde dermatologların yaygın

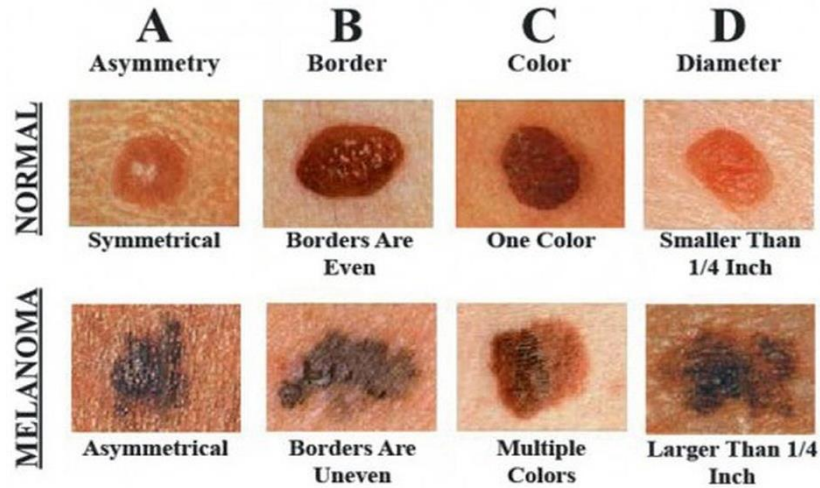
kullandığı yöntem ise ABCD kuralıdır. ABCD kuralı dermoskopi görüntülerinden makine öğrenimi ve görüntü işleme teknikleri ile geliştirilen bilgisayar destekli tanı sistemlerine de öncülük etmektedir.

A, asimetri anlamını taşımaktadır. Buna göre kötü huylu cilt lezyonları simetrik olmamalıdır. Tümörlü bölgenin tam ortasından bir çizgi çekildiğinde bir yarı diğer yarıya asimetrik olmalıdır.

B, kötü huylu cilt lezyonlarının sınır düzenini temsil eder. Buna göre tümörlü bölgenin sınırları düzensiz olmalıdır. İyi huylu cilt lezyonları düzgün, pürüzsüz ve eşit sınırlara sahipken kötü huylu cilt lezyonları taraklı, çentikli ve eşit olmayan düzensiz sınırlara sahiptir.

C, cilt lezyonunun rengini ifade eder. Bu kurala göre cilt lezyonunda görülen farklı renkler bir uyarı işaretidir. İyi huylu cilt lezyonları genellikle kahverengi tonunda tek renkten oluşurken kötü huylu lezyonlar ten renginde, kahverenginin farklı tonlarında ve siyah renkte olabilir. Kötü huylu lezyonlar büyüdükçe içerisinde mavi, kırmızı ve beyaz gibi renklerde bulundurabilir.

D, cilt lezyonunun çapını ifade eder. Bu kurala göre kötü huylu cilt lezyonlarının çapı 6mm'den büyük olmamalıdır.



Şekil 3.3. Melanom tespiti için ABCD kuralı (Anitha, 2018)

Kötü huylu cilt lezyonlarını tespit etmenin diğer bir yolu ise çirkin ördek işareti yöntemidir. Bu yöntemde göre vücudumuzda bulunan melanositik lezyonlar birbirine benzemektedir fakat melanomlar çirkin ördek yavruları gibi öne çıkmaktadır. Çirkin ördek yavrusu lezyonları kendisini çevreleyen iyi huylu

lezyonlara kıyasla daha büyük, daha küçük olabilmekle birlikte rengi daha açık veya daha koyu olabilir. Bu tür dikkat çeken lezyonlar kötü huylu olarak kabul edilir.

3.5. Yapay Zekâ İle Cilt Kanseri Analizi İçin Kullanılan Veri Kümeleri

Cilt kanserinin erken tespiti hastalığın tedavisi için önemlidir. Bu sebeple cilt kanserinin hızlı ve yüksek doğrulukla tespit edilebilmesi için BDT sistemleri geliştirilmektedir. Klasik makine öğrenimi yöntemlerini veya derin öğrenme yöntemlerini kullanarak cilt kanseri görüntülerinden özellik çıkarabilmek ve sınıflandırabilmek için halka açık ücretsiz veri kümeleri bulunmaktadır. Bu veri kümelerin çoğunluğu dermoskopi görüntülerinden oluşmakla birlikte fotoğraf yoluyla elde edilen görüntülerle de yapay zekâ tabanlı BDT sistemleri geliştirilmektedir.

ISIC (Uluslararası Cilt Görüntüleme İşbirliği) arşivi, kötü huylu cilt kanserinin erken tespiti ile melanoma bağlı ölümleri oranını azaltmak ve cilt kanseri tanısı sürecinde gereksiz biyopsilere engel olmak için tasarlanan akademi ve endüstri ortaklığıdır. ISIC 2016 yılından itibaren her yıl düzenli olarak kötü huylu cilt kanserinin sınıflandırılması ve segmentasyonu için yarışmalar düzenlemektedir. Bu arşiv dermoskopi görüntülerinden oluşan en geniş veri kümelerine sahip olmakla birlikte veri kümelerine erişim ücretsizdir. Arşivde bulunan görüntülerin çoğu, melanom tespitinde uzman dermatologlar tarafından incelenen ilişkili klinik meta verilere sahiptir. Akademik çalışmalarda yaygın olarak kullanılan bu arşiv içerisindeki veri kümeleri farklı hastalık türlerine ve görüntü boyutlarına sahiptir. Tablo 3.1.'de yıllara göre ISIC yarışmalarında kullanılan veri kümeleri ve özellikleri gösterilmektedir.

Tablo 3. 1. Dermoskopi veri kümeleri

Veri Seti	Görüntü Sayısı	Görüntü Formatı	Görüntüleme Cihazı	Görüntü Boyutu	Hastalık Türleri
ISIC 2016 (Gutman vd,2016)	1279	JPEG	Dermatoskopi	1022 x 767	Melanom Nevüs
ISIC 2017 (Codella vd, 2018)	2750	JPEG	Dermatoskopi	1022 x 767	Melanom Nevüs Seboreik Keratoz
ISIC 2018 (Tschandl vd, 2018a)	11720	JPEG	Dermatoskopi	600x450	Melanom Nevüs Bazal H. Karsinom İyi Huylu Keratoz Dermatofibroma Aktinik Keratoz Vasküler Lezyon
ISIC 2019 (Tschandl vd, 2018a; Combalia vd,2019)	33569	JPEG	Dermatoskopi	1024x1024 600x450	Melanom Nevüs Bazal Hücreli Karsinom Skvamöz Hücreli Karsinom İyi Huylu Keratoz Dermatofibroma Aktinik Keratoz Vasküler Lezyon
ISIC 2020	44108	JPEG	Dermatoskopi	1024x1024	Melanom İyi huylu Lezyonlar

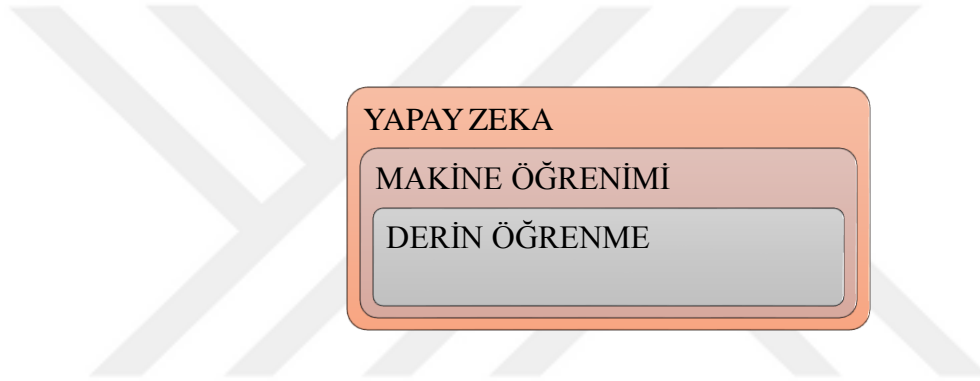
PH2 veri seti, Porto Üniversitesi ile Portekiz Matosinhos, Pedro Hispano Hastanesi Dermatoloji Servisi'nin birlikte yürüttüğü çalışmalar sonucu hazırlanmış bir veri setidir. Dermoskopik görüntüler içeren bu veri seti içerisinde 160 iyi huylu cilt lezyonu görüntüsü ile 40 adet kötü huylu cilt lezyonu görüntüsü bulunmaktadır. Veri setinde bulunan görüntüler az olması sebebiyle genellikle eğitilen modellerin testinde ve klasik makine öğrenme teknikleri ile sınıflandırma çalışmalarında kullanılmaktadır. PH2 veri setinde bulunan görüntüler 24-bit RGB renk uzayında sahip olup JPEG formatında ve 768x560 çözünürlüğüne sahiptir (Mendonca vd,2013)

MED-NODE veri seti, 70 melanom ve 100 nevüs görüntüsü olmak üzere içerisinde 170 adet klinik görüntü bulundurmaktadır. Bu veri seti araştırma amaçlı halka açık ve ücretsizdir (Giotis vd, 2015).



4. MAKİNE ÖĞRENMESİ


Makine öğrenimi terimi ilk kez 1959 yılında yapay zekânın öncüsü olarak kabul edilen Arthur Samuel tarafından ortaya atılmıştır (Luckert ve Schaefer, 2016). Makine öğrenimi, örüntü tanıma ve hesaplamalı öğrenme teorisi çalışmaları ile gelişen yapay zekâ'nın bir alt alanıdır. Makine öğrenimi, verilerden öğrenebilen ve veriler üzerinde tahminler yapabilen algoritmaların oluşturulmasını ve incelenmesini araştırır. Bu tür algoritmalar, klasik programlama yöntemindeki gibi akış takibi yapmak yerine veri kümesi üzerinden tahminler gerçekleştiren ve kararlar veren modeller oluşturulmasını sağlar (Provost ve Kohavi, 1998).



Şekil 4.1. Yapay zeka alt kümeleri

Makine öğrenimi, açık algoritmalar tasarlamamanın ve programlamamanın mümkün olmadığı bir dizi bilgi işlem görevinde kullanılır. Örnek uygulamalar arasında spam filtreleme, optik karakter tanıma (OCR), arama motorları ve bilgisayar görüşü yer alır (Wernick vd, 2010). Makine öğrenimi kavramı bazen veri madenciliği ile birleştirilir, ancak veri madenciliği daha çok keşifsel veri analizine odaklanır. Makine öğrenimi ve örüntü tanıma ise aynı alanın iki yönü olarak görülebilir. Endüstriyel bağlamlarda kullanıldığında, makine öğrenimi yöntemleri tahmine dayalı analitik veya tahmine dayalı modelleme olarak tanımlanabilir.

Son yıllarda makine öğrenimi teknikleri görüntü sınıflandırma problemlerinde yaygın olarak kullanılmaktadır. Klasik makine öğrenimi teknikleri ile görüntüleri sınıflandırabilmek kullanılan genel yöntem Şekil 4.2.'de gösterilmiştir.



Şekil 4.2. Klasik makine öğrenimi ile görüntü sınıflandırma

Giriş verisi olan görüntüleri sınıflandırabilmek için görüntüden çıkarılan ayırıcı özelliklere ihtiyaç duyulmaktadır. Elde edilen özellikler seçilecek olan sınıflandırma algoritmasına giriş olarak verilir ve model eğitilir. Daha sonrasında test verileri üzerinde tahminde bulunulur. Klasik makine öğrenimi teknikleri ile sınıflandırma görevinde kullanılan bazı terimler şunlardır;

Model: "Hipotez" olarak da bilinen bir makine öğrenimi modeli, gerçek dünyadaki bir sürecin matematiksel temsilidir. Eğitim verileriyle birlikte bir makine öğrenimi algoritması, bir makine öğrenimi modeli oluşturur.

Özellik: Veri kümesinin ölçülebilir bir özelliği veya parametresidir.

Özellik Vektörü: Birden çok özelliğe sahip olan kümedir. Makine öğrenimi modelinde girdi olarak kullanılır.

Eğitim: Bir algoritma, girdi olarak "eğitim verileri" olarak bilinen bir dizi veriyi alır. Öğrenme algoritması, giriş verilerindeki modelleri bulur ve modeli beklenen sonuçlar (hedef) için eğitir. Eğitim sürecinin çıktısı makine öğrenimi modelidir.

Tahmin: Eğitim verileriyle öğrenme işlemini tamamlayan modelin yeni verilerin özelliklerine göre sınıflarını belirleme veya çıkarımda bulunmasıdır.

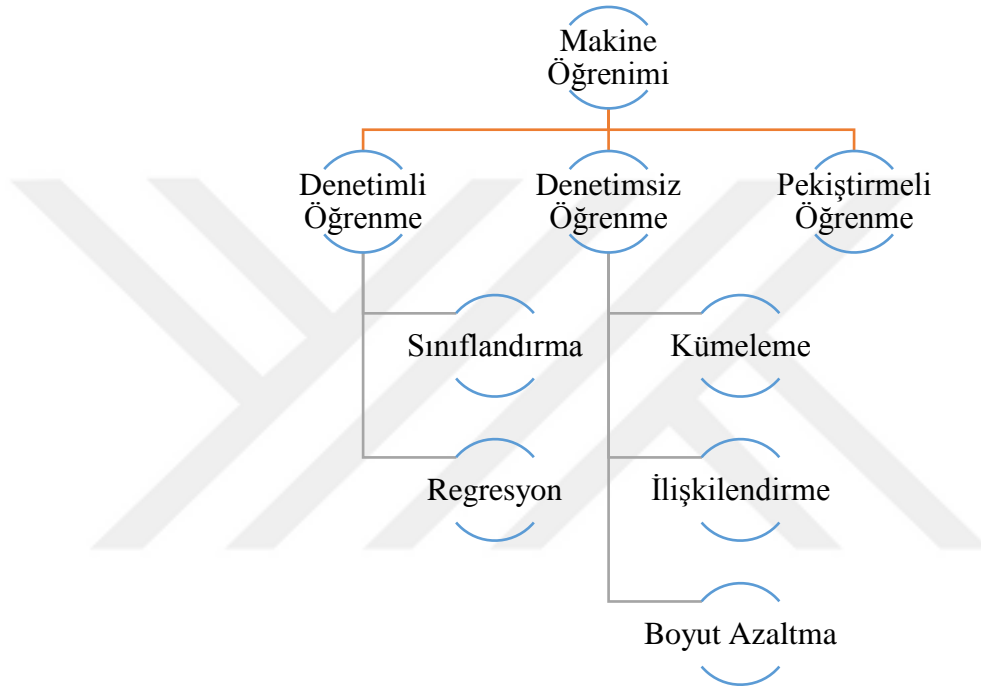
Hedef (Etiket): Makine öğrenimi modelinin tahmin etmesi gereken değere hedef veya etiket denir.

Aşırı uyum: Büyük miktarda veri bir makine öğrenimi modelini eğittiğinde, gürültüden ve hatalı veri girişlerinden öğrenme eğilimindedir. Burada model, verileri doğru bir şekilde karakterize edemez ve aşırı uyum oluşur.

Yetersiz uyum: Modelin giriş verilerindeki temel eğilimi çözemediği senaryodur.

Makine öğrenimi modelinin doğruluğunu yok eder. Basit bir ifadeyle, model veya algoritma verilere yeterince uymamaktadır.

Makine öğreniminin iki amacı vardır; biri, geliştirilen modellere göre verileri sınıflandırmak, diğer amaç ise bu modellere dayalı olarak gelecekteki sonuçlar için tahminler yapmaktır. Makine öğrenimi yaklaşımları, öğrenme sisteminde mevcut olan "sinyalin" veya "geri bildirim" doğasına bağlı olarak geleneksel olarak üç geniş kategoriye ayrılır (Sahla, 2018).



Şekil 4.3. Makine Öğrenimi türleri

4.1. Denetimli Öğrenme


Denetimli öğrenme algoritmaları, hem girdileri hem de istenen çıktıları içeren bir veri kümesinin matematiksel modelini oluşturur. Veriler eğitim verileri olarak bilinir ve bir dizi eğitim örneğinden oluşur. Her eğitim örneğinde bir veya daha fazla giriş ve aynı zamanda denetim sinyali olarak da bilinen istenen çıktı vardır. Matematiksel modelde, her eğitim örneği, bazen özellik vektörü olarak adlandırılan bir dizi veya vektör ile temsil edilir ve eğitim verileri bir matris ile temsil edilir. Bir amaç işlevinin yinelemeli optimizasyonu yoluyla, denetimli öğrenme algoritmaları, yeni girdilerle ilişkili çıktıyı tahmin etmek için kullanılacak bir işlevi öğrenir. Denetimli algoritmalar, eğitim verilerinin bir parçası olmayan girdiler için çıktıların doğru şekilde belirlenmesine imkân sağlar

(Montalt-Tordera vd, 2021). Eğitim verileriyle yapılan eğitim süreci içerisinde öğrenme işlemi optimize edilerek tahmin edilen çıktılarının doğruluğu artırılmaya çalışılmaktadır.

Denetimli öğrenme algoritması türleri arasında aktif öğrenme, sınıflandırma ve regresyon bulunur. Regresyon ve Sınıflandırma algoritmalarının her ikisinde makine öğreniminde tahmin için kullanılır ve etiketli veri kümeleriyle çalışır. Ancak ikisi arasındaki fark, farklı makine öğrenimi problemleri için nasıl kullanıldıklarıdır.

Sınıflandırma: Veri kümesini farklı parametrelere göre sınıflara ayırmaya yardımcı olan bir işlev bulma sürecidir. Sınıflandırmada, bir bilgisayar programı eğitim veri setine göre eğitilir ve bu eğitime dayanarak verileri farklı sınıflara ayırır (Ławrynowicz ve Tresp, 2014). Sınıflandırma algoritmasının görevi, girişi (x) ayrık çıkışa (y) eşlemek için eşleme fonksiyonunu bulmaktır. Örneğin, iyi huylu cilt kanseri görüntüleri ve kötü huylu cilt kanseri görüntüleri ile eğitilen model yeni girdilerle tümörün iyi veya kötü huylu olduğunu tahmin eder. Yaygın kullanılan bazı sınıflandırma algoritmaları;

- Destek vektör makinesi
- Naive Bayes
- Karar Ağaçları
- Rastgele Orman
- Logistik Regresyon
- K-NN
- Yapay Sinir Ağları



Şekil 4.4. Denetimli makine öğrenimi türleri (a) Sınıflandırma (b) Regresyon

Regresyon: Bağımlı ve bağımsız değişkenler arasındaki korelasyonları bulma sürecidir. Piyasa trendlerinin tahmini, konut fiyatlarının tahmini vb. sürekli değişkenlerin tahmin edilmesine yardımcı olur. Regresyon algoritmasının görevi, girdi değişkenini (x) sürekli çıktı değişkenine (y) eşlemek için eşleme fonksiyonunu bulmaktır. Yaygın kullanılan regresyon modelleri:


- Doğrusal Regresyon
- Doğrusal olmayan regresyon
- Regresyon Ağaçları
- Polinom Regresyon
- Bayesçi doğrusal regresyon

4.2. Denetimsiz Öğrenme

Denetimsiz öğrenme algoritmaları, yalnızca girdileri içeren bir veri kümesini alır ve veri noktalarının gruplanması veya kümelenmesi gibi verilerdeki yapıyı bulur. Bu nedenle algoritmalar, etiketlenmemiş, sınıflandırılmamış veya kategorize edilmemiş test verilerinden öğrenir. Geri bildirimle yanıt vermek yerine, denetimsiz öğrenme algoritmaları verilerdeki ortak noktaları belirler ve her yeni veri parçasında bu tür ortak özelliklerin varlığına veya yokluğuna dayalı olarak tepki verir.

Denetimsiz öğrenme algoritmaları arasında kümeleme, ilişkilendirme ve boyut azaltma algoritmaları bulunur (Louridas ve Ebert, 2016).

Kümeleme: Kümeleme, en fazla benzerliğe sahip nesnelerin bir grupta kalması ve başka bir grubun nesneleriyle daha az benzerlik göstermesi veya hiç olmaması için nesnelere kümeler halinde gruplama yöntemidir. Küme analizi, veri nesneleri arasındaki ortak noktaları bulur ve bunları bu benzerliklerin varlığı ve yokluğuna göre sınıflandırır.



Şekil.4.5. Kümeleme yöntemi (Cavaioni, 2017)

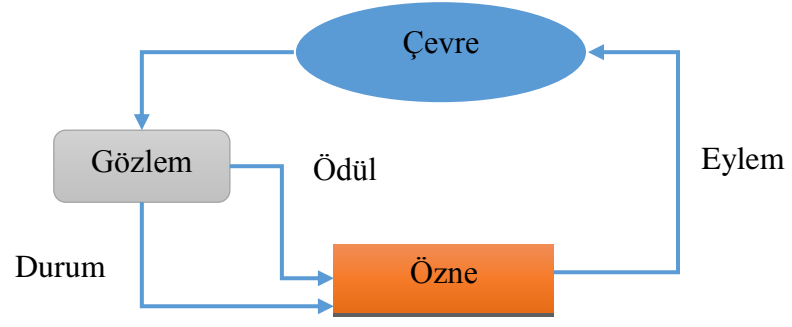
İlişkilendirme: İlişkilendirme kuralı, büyük veri tabanındaki değişkenler arasındaki ilişkileri bulmak için kullanılan denetimsiz bir öğrenme yöntemidir. Veri kümesinde birlikte oluşan öge kümesini belirler.

Boyut Azaltma: Boyut, veri setinde bulunan özellik kümelerinin sayısını belirtmektedir. Özellik kümesinin fazla olması modelin sınıflandırma performansını olumsuz etkilemektedir. Boyut azaltma işleminde en az ilgiye sahip özellik kümeleri bulunur ve veri setinde çıkarılır. Bunun için mevcut veri setinden yeni özellikler çıkarılabilir veya mevcut özelliklerden sınıflandırmaya ilgisi yüksek olan kümeler seçilir.

4.3. Takviyeli Öğrenme

Takviyeli öğrenme yöntemi, eylemler üreterek çevresi ile etkileşime giren ve hataları veya ödülleri keşfeden bir öğrenme yöntemidir (Kaelbling vd, 2016). Bu yöntemde temsilci, belirsiz, potansiyel olarak karmaşık bir ortamda bir hedefe ulaşmayı öğrenir. Deneme ve yanılma araştırması ve gecikmiş ödül, pekiştirmeli öğrenmenin en alakalı özellikleridir.

Bu yöntem, makinelerin ve yazılım araçlarının performansını en üst düzeye çıkarmak için belirli bir bağlamdaki ideal davranışı otomatik olarak belirlemesine olanak tanır. Temsilcinin hangi eylemin en iyi olduğunu öğrenmesi için basit ödül geri bildirim gereklidir; bu, takviye sinyali olarak bilinir.




Şekil 4.6. Takviyeli öğrenme yapısı

5. DERİN ÖĞRENME

Derin öğrenme büyük miktarda veriler üzerinde karmaşık hesaplamalar yapılmasını sağlayan ve temelde yapay sinir ağlarını kullanan makine öğreniminin bir alt kümesidir (Schmidhuber vd,2015). Derin öğrenme modelleri insan beyninin yapısını ve işlevini örnek alarak geliştirilmiştir. Temelde ise yapay sinir ağlarının derinleştirilmesi ile ortaya çıkmıştır ve bu sebeple derin sinir ağları olarak da adlandırılır. Temel yapay sinir ağı modelinde 2 veya 3 gizli katman bulunurken derin sinir ağlarında 100'den fazla gizli katmana sahip olabilir.

Derin öğrenme modelleri klasik makine öğrenimi tekniklerinin aksine verinin temsilinden öğrenme işlemi gerçekleştirir. Klasik makine öğrenme teknikleri ile sınıflandırma yapabilmek için ses, metin, görüntü gibi verilerden özellik çıkarmaya ihtiyaç duyulmaktadır. Eğitilen modelin performansı ise çıkarılan özellik vektörüne doğrudan bağlıdır. Özellik çıkarma işlemi model eğitiminde bağımsız olarak ayrı bir uzmanlık gerektirmektedir. Derin öğrenme modelleri ise bu özellikleri verinin temsilinden öğrenerek sınıflandırma işlemi gerçekleştirebilir (Lecun vd, 2015).



Şekil 5.1. Derin öğrenme ile görüntü sınıflandırma

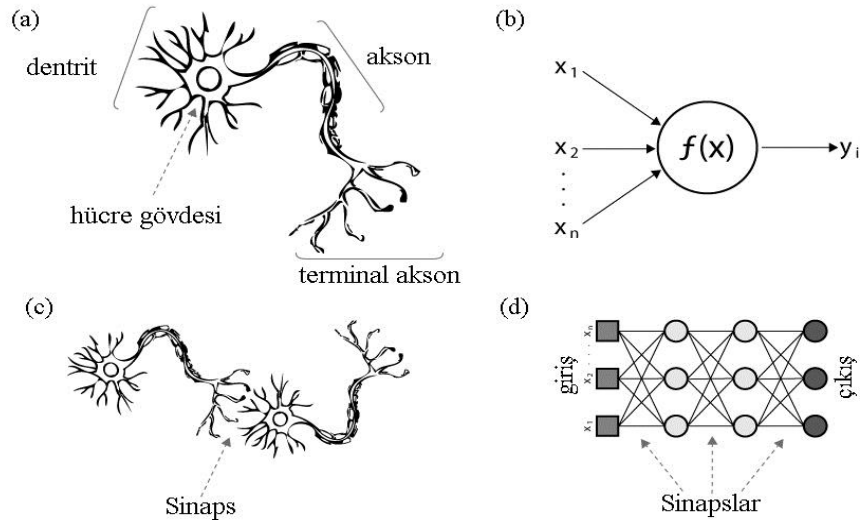
Derin öğrenme algoritmalarının performansında veri miktarı önemlidir. Fazla miktarda veri ile daha iyi eğitim performansı gösterebilir ve daha doğru tahminlerde bulunabilirler. Grafik işlemcilerin gelişimi ile bu algoritmalar çok yüksek miktarda parametreyi hesaplayabilir hale gelmiştir. Bu durum derin öğrenme algoritmalarının farklı alanlarda kullanımını yaygınlaştırmıştır (Pacal vd, 2020). Derin öğrenme günümüzde görüntü sınıflandırma, nesne tanıma, doğal dil işleme, gerçek zamanlı görüntü analizi, otonom sürüş, havacılık ve savunma, tıbbi araştırma ve endüstriyel otomasyon gibi birçok alanda kullanılmaktadır.

Teknolojinin günümüzde yaygın kullanımı görüntü, ses ve metin gibi verilere ulaşımı kolaylaştırmakla birlikte veri kümelerinin boyutunun artmasını da sağlamıştır. Derin öğrenme uygulamalarını geliştirmek ise yüksek kapasiteli donanımlar gerektirmektedir. Bu durum derin öğrenme uygulaması geliştirmek isteyen kişilerin bulut tabanlı uygulamaları kullanımını yaygınlaştırmıştır.

5.1. Yapay Sinir Ağları

YSA insan beyninin çalışma prensibinden esinlenerek oluşturulan makine öğrenme algoritmasıdır ve derin öğrenmenin de temelini oluşturmaktadır. İnsan beyni hesaplama işlemlerini aksonlar, sinapslar ve dendritlerden oluşan ve sinirsel kablolar ile birbirlerine elektriksel sinyaller göndererek iletişim kuran nöron ağı tarafından gerçekleştirir.

1943 yılında McCulloch ve arkadaşı bu nöron ağında bulunan bir nöronun başka bir nörondan girdi alarak toplam ağırlıklı girdiye göre aktif veya pasif olmasını sağlayan bir anahtar olarak modellendi (McCulloch ve Pitts, 1943).1960'lı yıllarda ise geliştirilen bu nöron ağının insan beynine benzer hareket ettiği gösterildi (Minsky, 1961). İnsan beyninin hesaplama yapısına göre oluşturulan YSA modelinde farklı bir nörondan gelen girişin çarpıldığı ağırlıklar ilgili sinapsların elektriksel etkileşimine karşılık gelmektedir. Ağda bulunan nöronlar işlemci elemana, dendritler toplama fonksiyonuna, hücre gövdesi transfer fonksiyonuna ve aksonlar ise yapay nöron çıkışına karşılık gelmektedir (Dongare vd, 2012a). Şekil 5.2.'de gerçek sinir ağı modeli gösterilmektedir.



Şekil 5.2. (a) insan sinir hücresi (b) yapay sinir hücresi (c) biyolojik sinaps (d) YSA sinapsları (Maltarollo vd, 2013)

5.1.1. Yapay Sinir Ağı Yapısı

YSA yapısı genel olarak girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere 5 bölümden oluşmaktadır.

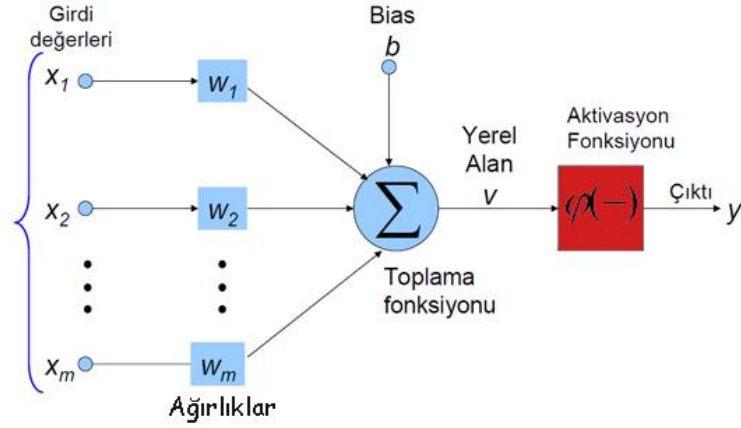
Girdiler, veri kümesinde bulunan ve ağıın öğrenmesini sağlayacak olan bilgilerdir. Girdi olarak adlandırılan bu bilgiler ilk katmanda giriş katmanına doğrudan verilen ham bilgileri ifade ederken daha sonraki katmanlarda bu bilgiler nöronlardan çıkan veriler olarak tanımlanabilir. Bu girdiler toplanmak üzere sinir hücresinin çekirdeğine gönderilir.

Ağırlıklar, sinir hücresine gönderilen bilgilerin gönderilen bağlantı yolunda bulunan bir değer ile çarpılmasını ifade eder. Ağırlıklar sayesinde girdi verilerinden elde edilecek çıktı üzerindeki etki değeri ayarlanabilmektedir. Ağırlıklar ilk eğitim döneminde sabit olup, çıktının durumuna göre eğitimin ilerleyen aşamalarında değişmektedir. Ağırlıkların son değeri öğrenmiş bir ağ yapısını temsil etmektedir ve bu açıdan öğrenme sürecinde önemi büyüktür.

Toplama fonksiyonu, sinir hücresine önceki nöronlardan ağırlıklarla çarpılarak gelen tüm değerleri birleştirme işlemini gerçekleştirir. Bu işlem sonunda ilgili hücrenin net girdisini hesaplar.

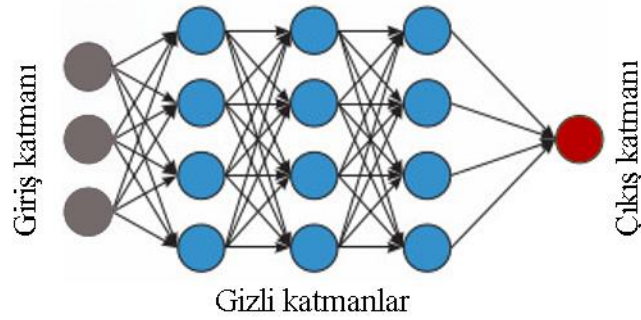
Aktivasyon fonksiyonu, sinir hücresinde hesaplanan toplam net girdi değerini bir aktivasyon işleminden geçirerek bir çıktı değeri üretir. Aktivasyon fonksiyonu bu aşamada doğrusal olmayan bir fonksiyon olarak seçilir. Aktivasyon fonksiyonunun seçimi problemin çözümü ve ağıın performansı açısından önemlidir. Yapay sinir ağları geri yayılım ile öğrenme işlemini gerçekleştirdiği için aktivasyon fonksiyonunun kolay türev alınabilir olması gereklidir. Sinir hücrelerinde aktivasyon için sigmoid fonksiyonu yaygın olarak kullanılmaktadır. Aktivasyon fonksiyonları detaylı olarak bölüm 5'de aktivasyon fonksiyonları başlığı altında anlatılmıştır.

Çıktı, toplam net girdilere bağlı olarak aktivasyon fonksiyonunun ürettiği çıkış değerini temsil eder. Sinir ağlarında hücrelerin birçok girdiyi olmasına rağmen elde edilen çıktı tekdir. Şekil 5.3.'de sinir hücresinin matematiksel modeli gösterilmektedir.



Şekil.5.3. YSA sinir hücresinin matematiksel modeli

Yapay sinir ağları katman yapısı olarak giriş katmanı, gizli katmanlar ve çıkış katmanı olarak 3 bölümden oluşmaktadır. Giriş katmanı veri kümesinde bulunan bilgileri ara katmanlara gönderme işlemini gerçekleştirir. Gizli katmanlarda giriş katmanında gelen bilgiler üzerinde işlemler gerçekleştirilir ve işlenen bilgiler çıkış katmanına gönderilir (Maind ve Wankar, 2014). Şekil 5.4.'de yapay sinir ağı modeli gösterilmektedir.



Şekil 5.4. Yapay sinir ağı modeli

5.1.2. İleri Beslemeli Ağ Modeli

İleri beslemeli yapay sinir ağı modeli giriş katmanından aldığı verileri herhangi bir değişiklik gerçekleştirmeden direkt olarak gizli katmana ulaştırır. Gizli katmanlarda işlenen veriler çıkış katmanına iletilir ve girdi değerlerine karşılık gelen çıkış değerleri üretilir. Bu ağ yapısında girişten çıkışa doğru tek yönlü işlem yapılır. Ağa giriş değeri ile birlikte elde edilmesi gereken çıkış değeri de verilir (Abiodun vd, 2018).

5.1.3. Geri Beslemeli Ağ Modeli


Geri besleme işlemi YSA'nın eğitimi süresince örnek verilerden öğrenmesi için önemlidir. Geri besleme işlemi geri yayılım algoritması ile gerçekleştirilir. Geri yayılım algoritması YSA modelinin denetimli öğrenme işlemini gerçekleştirmesine olanak sağlar. Geri yayılım gradyan iniş olarak da bilinmektedir. Bu işlemde ağın ileri işlemi sonucu elde edilen çıktı ile gerçek çıktı arasındaki fark hesaplanır. Buna hata değeri denir. Hata değerine göre gizli katman ve çıktı katmandaki tüm ağırlıklar değerlendirmeye alınarak mevcut hata geriye doğru yayılır. Geriye yayılımda modelin ağırlık katsayıları güncellenir ve optimizasyon gerçekleştirilir. Ağırlık katsayılarının güncellenerek en iyi ağırlıkların bulunması ve minimum hata değerine ulaşılması ağda öğrenme işlemini tanımlamaktadır (Dongare vd, 2012b).

5.2. Derin Öğrenme Modelleri

Derin öğrenme görüntü analizi, metin madenciliği, doğal dil işleme, boyut azaltma gibi farklı alanlarda yaygın olarak kullanılmaktadır. Her alan için büyük veriler üzerinde karmaşık hesaplamalar yapabilen ve verinin temsilinden öğrenebilen farklı modeller geliştirilmiştir. Bu bölümde farklı veri türleri üzerinde kullanılan derin öğrenme modelleri tanıtılmıştır.

5.2.1. Otomatik Kodlayıcılar


Geoffrey Hinton tarafından 1980'lerde denetimsiz öğrenme problemlerini çözmek için tasarlanan otomatik kodlayıcılar, giriş ve çıkış verisinin aynı olduğu ileri beslemeli sinir ağı modelidir. Yaygın olarak görüntü analizi ve boyut azaltma problemlerinde kullanılırlar. Otomatik kodlayıcılar veri kümesindeki girdileri alıp onları farklı temsillere dönüştürmek ve daha sonra doğru bir şekilde yeniden oluşturmak için geliştirilmişlerdir. Bu ağ yapısı kodlayıcı, kod ve kod çözücü olarak 3 bölümden oluşmaktadır. Kodlayıcı girişi daha küçük bir boyuta sıkıştırır ve kod üretir. Kod çözücü ise giriş değerini yalnızca kodu kullanarak yeniden üretir (Doğan ve Türkoğlu, 2019). Otomatik kodlayıcıların ağ yapısı Şekil 5.5'de gösterilmektedir.



Şekil 5.5. Otomatik kodlayıcı modeli

5.2.2. Kısıtlı Boltzman Makineleri (Restricted Boltzman Machines- RBM)


Hinton ve arkadaşları tarafından geliştirilen RBM modeli bir dizi girdi üzerindeki olasılık dağılımından öğrenebilen sinir ağlarıdır ve derin inanç ağlarının temelini oluşturmaktadır (Ackley vd, 1985). En yaygın kullanım alanı boyut azaltma olmakla birlikte sınıflandırma ve özellik öğrenme içinde kullanılmaktadır. RBM ağı iki katmandan oluşmaktadır. Bunlar; görünür birim ve gizli birimdir. Görünür birimler tüm gizli katmanlara bağlıdır fakat aynı katmanda bulunan düğümler birbirine bağlı değildir ve iletişim kuramazlar. Kısıtlı kavramı bu iletişimin kurulamamasını ifade etmektedir. Bu ağ yapısında gizli katmanlara bağlı bir bias (ön yargı) değeri bulunmaktadır ve çıkış katmanı bulunmamaktadır. RBM modeli ileriye ve geriye olmak üzere iki tür işleyişi vardır. İleri işlemde giriş değerleri ağırlık ve bias ile işleme alınarak gizli katmana iletilir. Geri geçiş işleminde bu değerler yeniden yapılandırılmak için aktivasyon fonksiyonunda geçirilir. Elde edilen değerler bias ve ilgili ağırlık ile birleştirilir ve yeniden yapılandırma için görünür katmana iletilir. Görünür katmanda elde edilen sonucun kalitesini ölçmek için çıktı değeri ile orijinal girdi karşılaştırılır (Sutskever vd, 2009).



Şekil 5.6. Kısıtlı boltzman makinesi modeli

5.2.3. Derin İnanç Ağları (Deep Belief Network –DBN)


DBN, her katmanın birbiri ile iletişim kurduğu RBM yığından oluşan derin sinir ağı modelidir. DBN'ler görüntü tanıma, video tanıma ve hareket yakalama gibi problemlerde kullanılır. Herhangi bir katmanda bulunan düğümler bu modelde birbiri ile iletişim kurmazlar. Bu ağ modelinde her gizli katman kendinden sonraki katmanın görünür (giriş) katmanı olarak işlev görür. Öğrenme sürecinde açgözlü algoritmalar kullanılır. Algoritma girişten sona doğru ilerlerken üretken ve verimli ağırlıkları belirleyebilmek için katman-katman adımlarda bir yaklaşım kullanılır. Sonunda en başa dönüştürülür ise elde edilen değerler katmanlar arasında bulunan en üretken ve verimli ağırlıklar ile başa doğru iletilir (Hinton, 2009). Şekil 5.7.'de DBN modeli gösterilmektedir.



Şekil 5.7. DBN modeli

5.2.4. Tekrarlayan Sinir Ağları (Recurrent Neural Networks -RNN)

Tekrarlayan sinir ağları sıralı verileri ve zaman serilerini kullanan sinir ağı modelidir. Genellikle konuşma tanıma, dil çevirisi, doğal dil işleme, resim yazısı oluşturma gibi problemlerde kullanılır. İleri beslemeli sinir ağları gibi öğrenmek için eğitim verilerinden faydalanırlar. Geleneksel sinir ağları girdilerin ve çıktılarının birbirinden bağımsız olduğunu varsayar fakat tekrarlayan sinir ağlarında çıktı dizisindeki önceki girişlere bağlıdır. Bu ağ modeli giriş ve çıkış değerlerini etiketlemek için hafızasında tuttuğu önceki katmanlardaki bilgileri kullanır. Bir sonraki adımı tahmin edebilmek için girdiler arasında ilişki kurar ve eğitim aşamasında tüm bu ilişkileri hatırlar. Şekil 5.8.'de girdiler arasındaki ilişki gösterilmektedir. X_0 ile X_1 birlikte değerlendirilerek h_0 oluşur. Sonraki adımda h_0 ile X_1 bir sonraki adım için yeni girdi oluşturur ve bu şekilde devam eder.



Şekil 5.8. RNN modeli (Olah, 2015)


Tekrarlayan sinir ağlarının 4 farklı türü bulunmaktadır. Sırasıyla bire bir, birden çoğa, çoktan bire ve çoktan çoğadır. Bire bir, vanilya sinir ağı olarak bilir ve tek girişi tek çıkışı olan makine öğrenimi problemlerinde kullanılır. Birden çoğa, tek bir girişi ve birden çok çıkışı olan problemlerde kullanılır. Çoktan bire, bir dizi girdiyi alır ve tek bir çıktı üretir bu özelliğinden dolayı duygu analizi tespiti için yaygın olarak kullanılır. Çoktan çoğa, bir dizi girdiyi alır sonuç olarak bir dizi çıktı üretir ve genellikle makine çevirisinde kullanılır. RNN modeli kaybolan gradyan ve patlayan gradyan probleminden etkilenmektedir. Bu sebeple RNN modelinden farklı modeller türetilmiştir. BRNN-Çift yönlü tekrarlayan sinir ağları, RNN mimarisini çıktıyı tahmin etmek için geçmiş verileri işlerken BRNN modeli gelecekteki verileri de işleyebilmektedir. GRU-Geçitli tekrarlayan birim, kısa süreli bellek problemine çözüm üretir ve bunun için gizli katmanında 2 kapıya sahiptir. Bunlar, ne kadar ve hangi bilgilerin saklanacağını kontrol eden güncelleme ve sıfırlama kapılarıdır (Biswal, 2021).

5.2.5. Uzun Kısa Hafıza Ağları (Long-Short Term Memory - LSTM)

LSTM (Long-Short Term Memory), RNN modelinden türetilmiştir. RNN'ler de bulunan kaybolan gradyan problemine çözüm olarak Sepp Hochreiter ve Juergen Schmidhuber tarafından 1997 yılında geliştirilmiştir (Hochreiter ve Schmidhuber, 1997). Bu ağ modeli RNN modeline kıyasla tahmini etkileyen ve yakın geçmişte bulunmayan bilgileri uzun süre hatırlayarak bağımlılıkları öğrenebilir. LSTM ağları doğal dil işleme alanında yaygın olmakla birlikte görüntü analizinde de kullanılmaktadır.

LSTM ağının bir gizli katmanında 3 kapı bulunmaktadır ve bu kapılar çıktıyı tahmin etmek için gerekli bilgi akışını kontrol etmektedir. Şekil 5.9.'da LSTM ağının katmanı gösterilmektedir. Giriş kapısı, sahip olunan hafızanın değiştirilmesi için girişin hangi değerinin kullanılacağını belirler. Unutma kapısı, bloktan hangi ayrıntıların atılması gerektiğine karar verir. Çıkış kapısı ise giriş

kapısı ve hafıza bilgileri ile birlikte çıkış değerini hesaplar. Gizli katmanlarda işlemlere karar vermek için sigmoid ve tanh aktivasyon fonksiyonları bulunmaktadır.

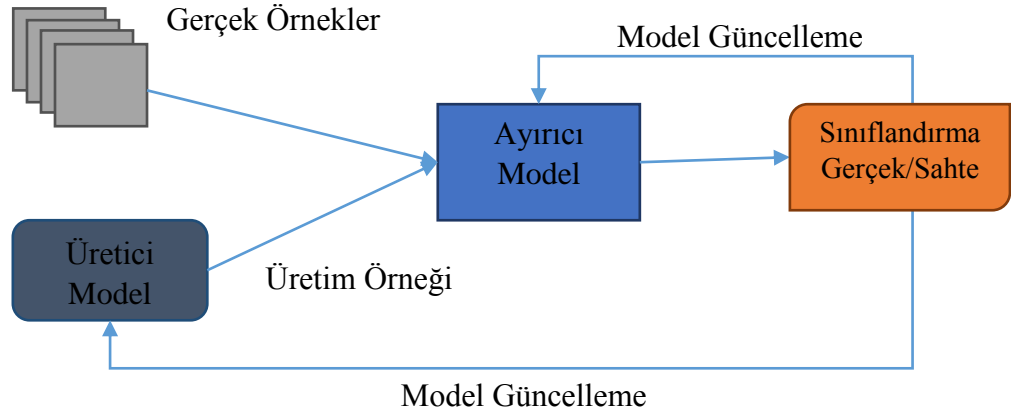


Şekil 5.9. LSTM ağının katman yapısı (Mittal, 2019)

5.2.6. Üretken Çekişmeli Ağlar (Generative Adversarial Networks-GAN)

GAN derin öğrenme modeli diğer modellerde olduğu gibi giriş verilerinden çıkışı tahmin etmek yerine gerçek verilerle öğrenme işlemini gerçekleştirerek gerçek verilere benzeyen sahte ve yapay veriler üretmektedir. Eğitimde iki sinir ağı modeli kullanan bu mimari sinir ağlarını tıpkı bir düşman gibi karşı karşıya getirmektedir. GAN yapay görüntü, ses ve video oluşturmada yaygın olarak kullanılmaktadır. Özellikle görüntü sınıflandırma problemlerinde mevcut veri setlerinin yetersiz olduğu durumlarda GAN ile veri artırma uygulamaları tercih edilmektedir.

GAN modeli üretici ve ayırıcı olarak iki bölümden oluşur. Üretici gerçek verilerden öğrenerek sahte veriler üretir. Ayırıcı ise üretici bölümünde elde edilen verilerin gerçek ya da sahte olup olmadığını sınıflandırır ve etiketler. Eğitimin her döngüsünde verilerin sahte olduğunu ayırıcı hızlı bir şekilde belirler ve üreticiye dönüt verir. Bu şekilde eğitim ilerledikçe üretici ayırıcıyı yanıltabilecek düzeyde sahte veriler üretmeye yaklaşır. Başarılı bir eğitim sonunda üretici ayırıcının gerçek ile sahte verileri ayırma doğruluğunu minimuma indirir. Bu ağ yapısında üreticinin çıkışı doğrudan ayırıcıya bağlanır. Geri yayılım yolu ile ayırıcının sınıflandırma işlemi üreticinin ağırlıklarını güncellemek için kullandığı bir sinyal sağlar (Goodfellow vd, 2014). Şekil 5.10'da GAN modeli gösterilmektedir.



Şekil 5.10. GAN modeli

GAN modelinin birçok farklı versiyonu bulunmaktadır. Bunlardan bazıları; VanillaGAN, DCGAN, InfoGAN, DiscoGAN, WassersteinGAN olarak bilinir.

5.3. Evrimsel Sinir Ağları

CNN en yaygın kullanılan ve en popüler derin öğrenme modelidir. Canlılarda bulunan görsel korteksten ilham alarak tasarlanan, biyoloji ve matematik alanlarını birleştiren ve bilgisayarla görü alanında devrim niteliğinde kabul edilen derin yapay sinir ağıdır (Gu vd, 2018a). Evrimsel ismini filtreleme ile çıkardığı özellik işlemlerinden almaktadır. Görüntülerin sahip olduğu piksel matrisleri üzerinde filtreleme işlemleri gerçekleştirilerek ayırıcı özellikleri çıkarma aşamasını otomatik gerçekleştirmektedir. Sinir ağlarının farklı bir çeşidi olan bu ağ modeli 1998 yılında Yann LeCun tarafından tanıtılmıştır ve adına LeNet denilmiştir (Le Cun vd, 1998). LeNet mimarisi 32x32 boyutundaki görüntülerde el yazısı ile yazılmış rakamları tanıyabiliyordu. O yıllarda yeterli veri ve donanımın olmaması CNN modelinin uygulanmasında sınırlılık olarak görülmekteydi. 2012 yılında Alex Krizhevsky ve arkadaşları tarafından geliştirilen AlexNet modeli ImageNet yarışmasını kazanarak CNN modelinin popüler hale gelmesini sağlamıştır (Krizhevsky vd, 2012). Grafik işlemcilerin gelişmesi ve teknolojinin yaygın kullanımıyla elde edilen görüntü boyutu CNN'lerin kullanımını daha da yaygınlaştırmıştır. Günümüzde CNN'ler özellikle görüntü sınıflandırma, nesne tanıma gibi görüntü üzerinde analiz yapılması gereken durumlarda tercih edilmektedir.

CNN modeli, klasik makine öğrenme teknikleri ile sınıflandırma işlemde gerekli olan özellik çıkarma aşamasının aksine özellikleri ham veri üzerinden elde etmesi görüntü sınıflandırma problemlerinde büyük kolaylık sağlamaktadır. Bununla birlikte CNN modellerinin eğitimi ve performansı veri miktarı ile doğrudan ilişkilidir. Modeli eğitmek ve tahmin doğruluğunu artırma için yüksek miktarda veri gerekmektedir. Bununla birlikte veri miktarının çokluğu hesaplama maliyetini artırdığı için yüksek işlem gücü sağlayan donanımlara da ihtiyaç duyulmaktadır. Bu problemlerin çözümü olarak ise günümüzde birçok şirket derin öğrenme uygulamaları geliştirilmesi için bulut tabanlı ücretsiz hizmetler sunmaktadır. Yeterli miktarda veri bulunmadığında CNN modellerini sıfırdan eğitmek yerine daha önce yüksek boyuttaki veri kümesi ile eğitilmiş olan modellerin modellerin ağırlıkları kullanılabilir. Bu işleme transfer öğrenme denilmektedir. Transfer öğrenme detaylı olarak bölüm 5’de transfer öğrenme başlığı altında anlatılmaktadır.

CNN modeli genel olarak özellik öğrenme ve sınıflandırma olarak 2 bölümden oluşur. Özellik öğrenme kısmında evrişim, aktivasyon ve havuzlama katmanları bulunmaktadır. Sınıflandırma kısmında ise düzleştirme, tam bağlı katman ve sınıflandırıcı fonksiyonu bulunmaktadır. CNN modelinin genel yapısı Şekil 5.11.’de gösterilmektedir.

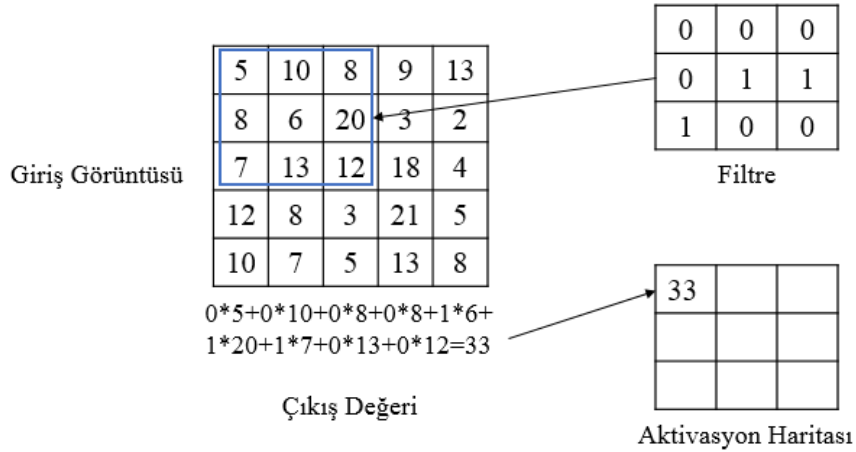


Şekil 5.11. CNN mimarisi (Anonymous, 2021)

5.3.1. Evrişim Katmanı

CNN modelinin eğitimi ve test aşamalarında görüntüler ham olarak veya sayısallaştırmış görüntü matrisi şeklinde giriş olarak verilebilir. Bu görüntü matrisleri üzerinde belirlenen filtre değerleri ile filtrenin üzerinde bulunduğu matris değerlerinin çarpılarak toplanması işlemine evrişim denir. CNN modelinin yapı taşı olan evrişim işleminin amacı görüntüde bulunan üst düzey özellikleri elde edebilmektir. Evrişim işleminde kullanılan filtreye çekirdek denmektedir. Çekirdek üzerinde bulunan sayısal değerler ağırlık matrisini ifade eder. Ağırlık matrisi görüntü matrisi üzerinde adım adım ilerler ve her adımda elde edilen toplam değer çıkış matrisine kaydedilir.

Adım sayısı, ağırlık matrisinin görüntü üzerinde tek adım ile mi yoksa daha büyük adımlar ile mi gezineceğini belirler. Bu durum çıkış matrisinin boyutunun oluşmasında önemlidir. Evrişim işlemi tek kanallı görüntülerde tek sefer yapılırken 3 kanallı olan renkli görüntülerde her kanal için bu işlemler gerçekleştirilir. Çıktı matrisinde oluşan boyut ile evrişim işleminden önceki görüntü matrisi arasında boyut farkı oluşur. Çıktı matrisinin boyutunun sabit kalması isteniyorsa matris etrafına pixel ekleme işlemi gerçekleştirilir (İnik ve Ülker, 2017). Evrişim işlemi Şekil 5.12.'de gösterilmektedir.



Şekil 5.12. Evrişim işlemi

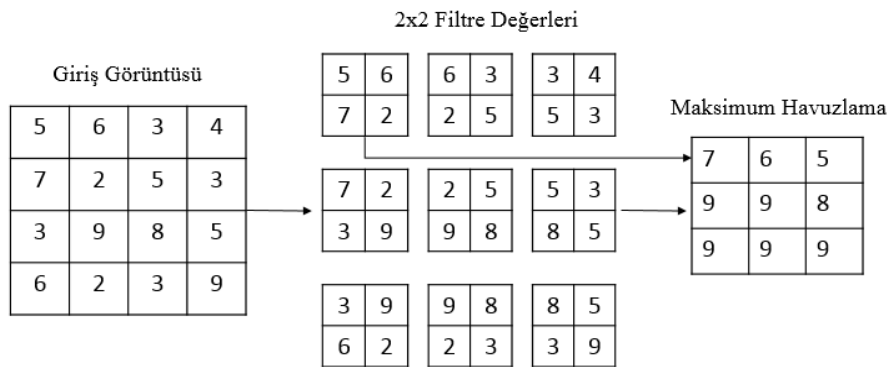
5.3.2. Aktivasyon Katmanı

Evrişim katmanlarından elde edilen çıktılara bu katmanda aktivasyon işlemi uygulanır. Aktivasyon işlemi girdi değerine karşılık bir çıktı üretir. Aktivasyon işleminin amacı modeli doğrusallıktan çıkarmak ve doğrusal olmayan bir yapıya sokmaktır. CNN modellerinin evrişim katmanlarından sonra aktivasyon işlemi için ReLU aktivasyon fonksiyonu kullanılmaktadır. Aktivasyon fonksiyonları ile ilgili detaylı bilgi bölüm 5’de aktivasyon fonksiyonları başlığı altında verilmiştir.

5.3.3. Havuzlama Katmanı

Evrişim işleminden sonra aktivasyona tabi tutulan görüntü matrisinin bu katmanda yükseklik ve genişlik değerleri azaltılmaktadır. Havuzlama işlemi mevcut görüntünün ayırıcı özelliklerini kaybetmeden boyutunun küçültülmesi işlemidir. Bu işlem aynı zamanda hesaplama maliyetinin azaltılmasını da sağlamaktadır.


Bu katmanda evrişim katmanında olduğu gibi bir filtre ile görüntü matrisi üzerinde belirlenen adım sayısı ile gezinti yapılır fakat bu katmanda kullanılan filtre sayısal değerlere sahip değildir ve boştur. Filtre, üzerinde bulunduğu görüntü değerlerini matrise kaydeder ve görüntüden alt kümeler elde eder ve sonrasında bu değerlerden yeni değerler elde edilmesini sağlar. CNN modellerinde maksimum havuzlama ile ortalama havuzlama yöntemleri kullanılmaktadır. Maksimum havuzlama işleminde filtrelerde bulunan değerlerin en büyüğü çıktı matrisinin ilgili alanına kaydedilir. Ortalama havuzlama işleminde ise filtrede bulunan değerlerin ortalaması alınır ve çıktı matrisinin ilgili alanına kaydedilir. Maksimum havuzlama işlemleri Şekil 5.13.’de gösterilmektedir.



Şekil 5.13. Maksimum havuzlama işlemi

5.3.4. Düzleştirme Katmanı

Evrişim, aktivasyon ve havuzlama işlemlerinin ardından ağda görüntülerde öğrenilen özellikler çok boyutlu bir matriste tutulur. Düzleştirme katmanında çok boyutlu matriste bulunan özellikler tek boyutlu özellik vektörü haline dönüştürülür. Şekil 5.14’de düzleştirme işlemi gösterilmektedir.



Şekil 5.14. Düzleştirme işlemi

5.3.5. Tam Bağlı Katman


Bu katman CNN modelinin son aşamasıdır. Evrişim işlemleri ile görüntülerden elde edilen üst seviye ayırıcı özellik matrisleri düzleştirme katmanında tek boyutlu özellik vektörüne çevrildikten sonra tam bağlı katmana giriş olarak verilir. Tam bağlı katman geri yayılım ile öğrenme işlemi gerçekleştiren yapay sinir ağıdır. Özellik kümesinde bulunan girdileri ağırlıklarla işleme tabi tutar ve elde edilen çıktıya göre hatayı yani kayıp değerini hesaplar. Bu kayıp değerine göre geri yayılım ile ağırlıkları güncelleyerek öğrenme işlemi sağlar. Tüm bu işlemler sonucunda özellikleri çıkarılan görüntünün sınıfını tahmin etmeye çalışır. CNN modellerinde tam bağlı katmanın sınıflandırma işlemi için genellikle softmax fonksiyonu kullanılmaktadır.

Derin öğrenme uygulamalarında geri yayılım sürecinde öğrenme hızı parametresi eğitim süresi ve modelin öğrenme performansı açısından çok önemlidir. Bu parametre başlangıçta programcı tarafından belirlenir. Öğrenme hızının yüksek olması salınma neden olmakla birlikte küçük olması da ağın uzun sürede öğrenmesine neden olabilir. Derin öğrenme modellerinin eğitiminde öğrenme işlemi bir optimizasyon problemidir ve bu sebeple öğrenme parametrelerinin güncellenmesinde optimizasyon algoritmaları kullanılmaktadır.

Optimizasyon algoritmaları ile ilgili detaylı bilgi bölüm 5’de optimizasyon algoritmaları başlığı altında verilmiştir.

5.3.6. DropOut (Bırakma)

Derin sinir ağı ile sınıflandırma işlemi çok fazla parametre içermektedir. Bununla birlikte uzun eğitim süreleri modelin aşırı uyum sağlamasına neden olmaktadır. Bu sorunu çözenin yollarından biri dropout yöntemidir. Dropout, sinir ağından bulunan düğümlerin belirlenen oranda her eğitim döngüsünde rastgele göz ardı edilmesini sağlar (Srivastava vd, 2014).



Şekil 5.15. Dropout işlemi (Srivastava, vd, 2014).

5.3.7. Batch-Size ve Batch-Norm (Toplu Normalleştirme)

Derin öğrenme mimarilerinin performansı fazla miktarda veriye ihtiyaç vardır. Fakat veri setinde bulunan tüm verileri aynı anda işlemek zaman alır ve bellek açısından sorun oluşturur. Bu nedenle veriler batch-size adı verilen parametre değeri ile belirlenen sayıda alt kümeler bölünerek bu alt kümeler üzerinde işlem gerçekleştirilir ve elde edilen sonuçlara göre ağı parametreleri güncellenir.

Normalleştirme, verileri standartlaştırmaya yarayan ön işleme tekniğidir. Batch-Norm ise girdilerin batch size parametresi ile belirlenen alt kümeleri için verileri bir katmana göndermek üzere standartlaştıran çok derin sinir ağını eğitmek için kullanılan bir tekniktir. Bu teknik aşırı uyumu engellemekle birlikte öğrenme sürecini stabilize eder ve derin ağı eğitmek için gereken eğitim tur sayısını önemli ölçüde azaltma etkisine sahiptir (Ioffe ve Szegedy, 2015).

5.4. Optimizasyon Algoritmaları

Optimizasyon algoritmaları, sinir ağından gerçekleşen kayıp işlevlerini minimum seviyeye indirmek için kullanılmaktadır. Eğitilen modelde oluşan kayıp durumlarında ağırlıkların güncellenmesi ve öğrenme hızı parametresinin değiştirilmesi gibi işlemler optimizasyon algoritmaları ile sağlanır. Bu sebeple derin öğrenme uygulamalarında seçilecek olan optimizasyon algoritması modelin performansı açısından çok önemlidir (Yazan ve Talu, 2017a). Bu bölümde derin öğrenme uygulamalarında kullanılan optimizasyon algoritmaları anlatılacaktır.

5.4.1. Dereceli Alçalma

Dereceli alçalma yöntemi bilinen en temel optimizasyon yöntemidir. Regresyon ve sınıflandırma problemlerinde yaygın olarak kullanılmaktadır. Bu yöntem yapay sinir ağlarında hatanın geriye yayılma işleminde de kullanılmaktadır. Dereceli alçalma yöntemi sinir ağında bulunan bir kayıp fonksiyonunun birinci dereceden türevini alarak fonksiyonun minimum seviyede kayıpa sahip olabilmesi için ağırlıkların hangi yönde değişmesi gerektiğini hesaplar. Geri yayılım yöntemi ile kayıp değeri katmanlar arasında aktararak sinir ağı modelinin parametreleri güncellenir. Bu işlemler ile kayıp fonksiyonu en aza indirilmeye çalışılır. Dereceli alçalma algoritmasını uygulamak ve hesaplamak kolaydır fakat büyük veri setlerinde fazla bellek gerektirdiğinde tercih edilmez (Ruder, 2006a).

5.4.2. Stokastik Dereceli Alçalma (SGD)

Dereceli alçalma optimizasyon algoritmasının farklı bir çeşididir. Bu algoritma eğitilen sinir ağı modelinin parametrelerini daha sık güncellemeye çalışır. Algoritma her eğitim döngüsü sonucu kayıp fonksiyonu hesaplandıktan sonra parametre güncellemesi gerçekleştirir. Dereceli alçalma algoritmasına göre daha az bellek tüketir ve yerel minimumlar alabilir. Bununla birlikte parametrelerin sık güncellenmesi yüksek miktarda parametre varyansına yol açabileceğinden dolayı öğrenme hızını yavaş düşürmek gerekmektedir (Ruder, 2006b).

İtme (Momentum): SGD algoritmasıyla birlikte kullanılır ve SGD algoritmasında sık parametre güncellenmesinden kaynaklı yüksek varyansı azaltmak amacıyla bulunmuştur. Yayılım yönüne doğru yakınsamayı hızlandırır

ve bununla birlikte dalgalanma problemini de çözer. Bu algoritma kullanımında momentum parametresinin de belirlenmesi gerekmektedir (Qian, 1999; Doshi, 2019b).

5.4.3. AdaGrad

Birçok optimizasyon algoritmasında öğrenme hızı tüm parametreler ve her döngü için sabittir. AdaGrad optimizasyon algoritması ise öğrenme hızını değiştirmektedir. Bu algoritma her t adımında her parametre için 'n' öğrenme hızını değiştirir. AdaGrad ikinci dereceden optimizasyon algoritmasıdır ve hata fonksiyonunun türevi üzerinde işlem yapar (Duchi vd, 2011). Öğrenme hızının manuel belirlenmemesi ve seyrek veriler üzerinde çalışabilmesi bu algoritmanın avantajlarını oluştururken, ikinci dereceden türev hesaplamaları maliyetli olabilmektedir (Doshi, 2019c).

5.4.4. AdaDelta

AdaDelta optimizasyon algoritması, AdaGrad'da bulunan öğrenme hızı düşürülmesi problemine çözüm olarak geliştirilmiştir. AdaDelta önceki döngülerde kareleri hesaplanarak saklanan tüm gradyanları biriktirmez. Bunun yerine geçmiş gradyan hesaplamalarının boyutunu sabit bir w boyutuyla sınırlandırır. Bu sınırlama işlemi üstel olarak hareketli ortalama tüm gradyanların toplamı yerine kullanılır. Bu algoritmayla öğrenme hızının azalması sonrasında oluşan eğitim kesintisi engellenmiştir (Zeiler, 2012).

5.4.5. RMSProp

RMSProp, Hinton tarafından AdaDelta ve AdaGrad algoritmalarındaki öğrenme hızındaki azalma problem için tanıtılan optimizasyon algoritmasıdır. Diğer iki optimizasyon algoritmasından bağımsız olarak geliştirilmiştir. Bu algoritma önceki gradyanların karesini hesaplar fakat önceki gradyanların karesinin büyümesini engeller ve eğitim süresince azalmasını sağlar. Kare gradyanların toplamı bir bozunma oranı 'a' ile çarpılır ve (1-a) ile ağırlıklandırılan mevcut gradyana eklenir. Güncelleme adımında bir boyut boyunca hareketi hızlandırma ve diğer boyut boyunca hareketi yavaşlatmak için mevcut gradyan değeri kare gradyanların toplamına bölünür (Ruder, 2006c; Yazan ve Talu, 2017b)

5.4.6. Adam

Adam optimizasyon algoritması derin öğrenme uygulamalarında yaygın olarak tercih edilmektedir. Bu algoritma diğerleri gibi her parametre için öğrenme oranını değiştirmektedir. Adam algoritması momentum hızı biraz düşürerek doğru parametrelerin bulunması için detaylı arama işlemi yapılmasını sağlar. Adam optimizasyon algoritması çok hızlıdır ve alt kümelerin birleşim işlemini hızlı gerçekleştirir. Kaybolan öğrenme oranı ve yüksek varyans problemini çözer. Adam algoritması AdaDelta ve RMSprop algoritmaları gibi geçmiş kare gradyanların üssel olarak azalan ortalamasını depolamaya ek olarak, geçmiş gradyanlarının üssel olarak azalan ortalamasını da tutar (Kingma vd,2015; Ruder, 2006d)

5.5. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları derin öğrenme uygulamalarında çok önemli bir yer tutar. Aktivasyon fonksiyonlarının amacı sinir ağı modellerinde giriş değerlerini çıkışa dönüştürmektir. Çok yüksek parametreye sahip olan derin sinir ağlarına aktivasyon işlemi uygulanmadığı takdirde giriş bilgileri doğrusal bir şekilde ilerler ve bu durum veri kümesinde bulunan ayırıcı özelliklerin bulunamamasına yol açar. Aktivasyon fonksiyonunun seçimi sinir ağının öğrenme performansı ve kapasitesi üzerinde etkilidir (Gu vd, 2018b). Sinir ağı modeli içerisinde birden fazla ve farklı aktivasyon fonksiyonları kullanılabilir.

5.5.1. Sigmoid

0-1 aralığında bulunan aktivasyon fonksiyonudur (Wang vd, 2019a). İkili sınıflandırma problemlerinde çıktının olasılığını hesaplamak için tercih edilir. Çıktı negatif değerler aldığıda 0'a yakınsar ve daha yüksek değerlerde tahmini 1 olarak gerçekleştirir. Sigmoid fonksiyonu derin ağlarda kaybolan gradyan probleminden etkilenir ve bu yüzden daha az gizli katmana sahip olan ağ yapılarında kullanılması uygundur.

5.5.2. Tanh

Hiperbolik tanjant aktivasyon fonksiyonu sigmoid fonksiyonuna çok benzer ve ikili sınıflandırma problemlerinde kullanılır fakat bu aktivasyon fonksiyonu -1 ile 1 aralığında bulunur (Wang vd, 2019b). Giriş değeri ne kadar büyük ise çıkış 1'e aynı oranda yakın iken, giriş değeri ne kadar küçük ve negatif ise çıkış -1'e

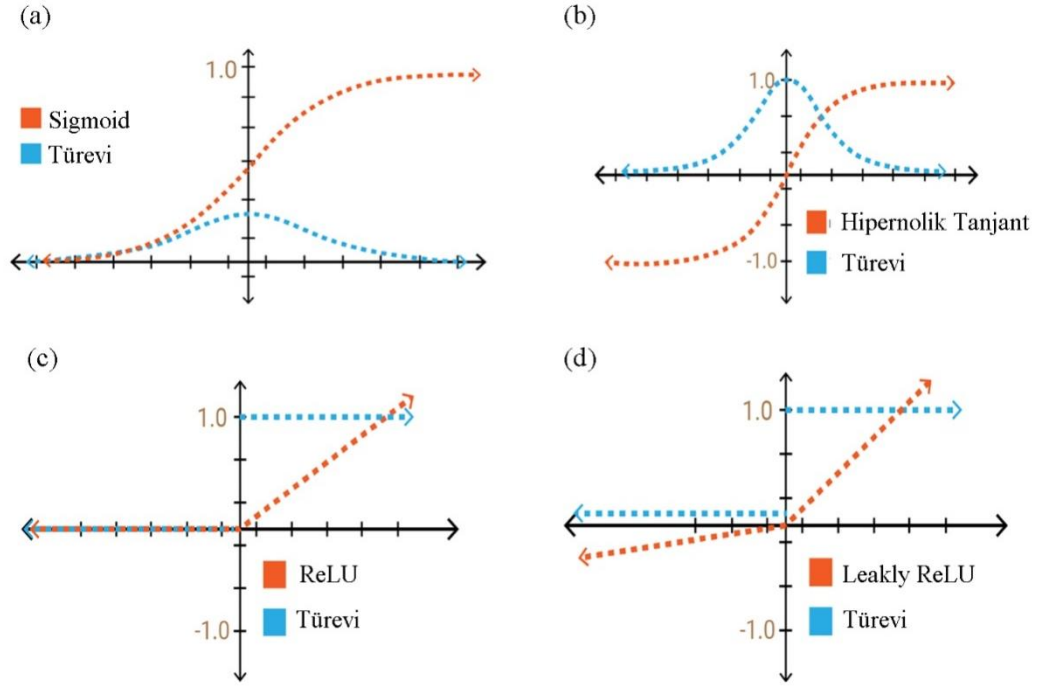
aynı oranda yakındır. Tanh fonksiyonu derin sinir ağlarında kaybolan gradyan problemine yol açar.

5.5.3. ReLU

ReLU (Düzleştirilmiş doğrusal birim), derin öğrenme uygulamalarında en yaygın kullanılan aktivasyon fonksiyonudur. Çoğu evrimsel sinir ağı mimarisi ReLU aktivasyon fonksiyonunu kullanmaktadır. Basit ve etkili bir aktivasyon fonksiyonudur. ReLU negatif değerler için 0 değeri üretir ve aktivasyon işlemi gerçekleştirmez. Giriş pozitif ise aynı değere çıkışa dönüştürür. Bu aktivasyon fonksiyonunun en büyük avantajı tüm nöronlardaki toplam giriş değerini aynı anda aktivasyona tabi tutabilmesidir. Diğerlerinin aksine ReLU aktivasyon fonksiyonu derin sinir ağlarında kaybolan gradyan problemine daha az duyarlıdır (Nair ve Hinton, 2010 ; Gu, 2018d).

5.5.4. Sızdıran ReLU ve PReLU

ReLU fonksiyonunun negatif değere sahip olan nöronları aktif etmemesi ve ilgili nöron girişlerinin sürekli negatif değere sahip olmaması o nöronda öğrenme işleminin gerçekleşmemesine sebep olmaktadır. Bu probleme “ölmekte olan ReLU” sorunu denmektedir. Bu problemi aşmak için ReLU fonksiyonunun farklı versiyonları geliştirilmiştir. Sızdıran ReLU fonksiyonu negatif değerleri 0 yerine 0,01 olarak döndürür ve x ekseninin küçük bir doğrusal bileşeni olarak tanımlar. Bu işlem ilgili nöronda öğrenme işlemi gerçekleştirilmesini sağlar. PReLU (Parametrik ReLU) fonksiyonu 0,01 gibi sabit deper yerine değişen ve öğrenilebilen “a” parametresi ile bu problemi çözmektedir (Sharma ve Sharma, 2017).



Şekil 5.16. Aktivasyon fonksiyonları (a) sigmoid (b) tanh (c) ReLU (d) Leaky ReLU (Kızrak, 2019)

5.5.5. Softmax

Softmax aktivasyon fonksiyonu sigmoid fonksiyonunun genişletilmiş halidir. Bu aktivasyon fonksiyonu 0-1 aralığında bulunur ve çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılır (Nwankpa vd, 2018). Popüler evrimsel sinir ağı modellerinin son sınıflandırma katmanlarında softmax fonksiyonu bulunmaktadır.

5.6. Evrimsel Sinir Ağı Mimarileri

5.6.1. AlexNet


AlexNet mimarisi ilk defa Alex Krizhevsky, Ilya Sutskever ve Geoffrey E. Hinton'un yazdığı "Derin Evrimsel Sinir Ağları ile ImageNet Sınıflandırması" adlı makalede tanıtılmıştır. Bu mimari, 2012 yılında gerçekleştirilen ImageNet yarışmasında en yakın rakibinin elde ettiği hata oranını %10.3 düşürerek elde ettiği %15.3'lük hata oranı ile birinci olmuştur. Yarışmada yüksek çözünürlüklü 1.2 milyon eğitim, 50 bin doğrulama ve 50 bin test görüntüsü bulunmaktadır. Bu yarışmada elde edilen başarı derin öğrenme algoritmalarının görüntü sınıflandırma problemlerinde popüler olmasını sağlamıştır.

5.6.2. VGGNet

VggNet mimarisi, Oxford Üniversitesi'nden K. Simonyan ve A. Zisserman tarafından 2014 yılında yayınlanan "Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağlar" adlı makalede tanıtılmıştır. Adını Visual Geometry Group (Görsel Geometri Grubu)'dan almaktadır. ImageNet yarışmasında kullanılan 11,16,19 katmanlı olmak üzere 3 farklı mimarisi bulunmaktadır. Bu mimari 2014 yılı ImageNet yarışmasında hata oranını %7.3'e düşürmüştür.

VggNet mimarisi diğerlerinden farklı olarak ağın katmanların çoğaltılması yerine derinleştirilmesine odaklanmıştır. Bu yapıdan dolayı görüntü sınıflandırma problemlerinde özellik çıkarımı için yaygın olarak kullanılmaktadır. 16 katmanlı mimaride 13 adet evrişim katmanı ile 3 adet tam bağlı katman bulunmaktadır.

138 milyon parametre içeren bu mimari AlexNet'e benzemekle birlikte, AlexNet'de kullanılan filtre boyutları küçültülerek evrişim katmanlarında 3x3 boyutunda sabit filtreler kullanılmıştır. Ağın giriş görüntü boyutu 224x224x3'dür. Genel yapısında art arda gelen evrişim katmanlarından sonra maksimum havuzlama katmanları kullanılmıştır. Aktivasyon fonksiyonu olarak ise ReLU kullanılmıştır. Sınıflandırma aşamasında, tam bağlı olan her katmanda 4096 nöron bulunmaktadır. Son katmanda ise sınıfları ayırmak için Softmax fonksiyonu bulunmaktadır (Simonyan ve Zisserman, 2014).



Şekil 5.18. VGGNet mimarisi (Simonyan ve Zisserman, 2014)

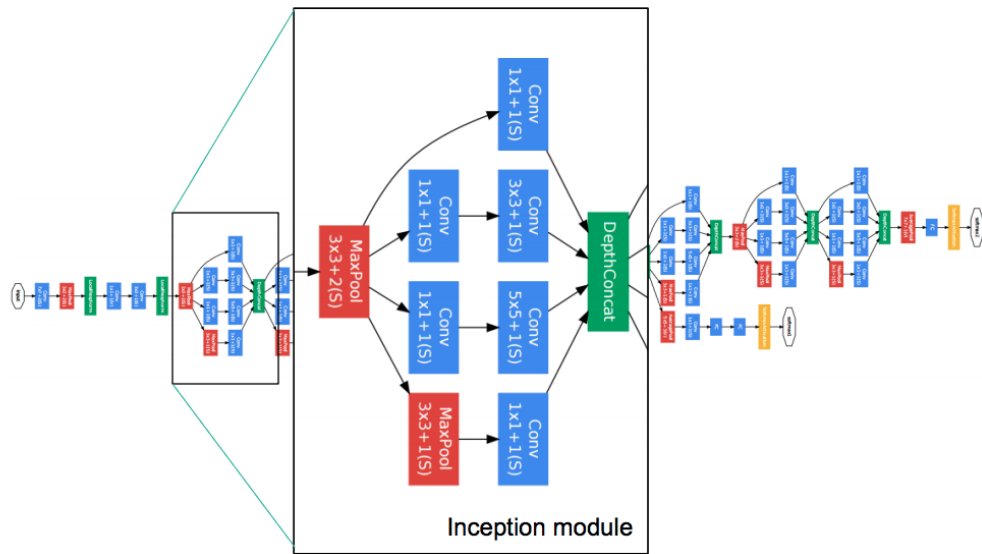
5.6.3. GoogleNet

Google firmasında çalışan arařtırmacılar tarafından geliştirilen mimari, 2014 yılında yapılan ImageNet yarışmasında hata oranını %6,7'ye düşürerek müthiş performans sergilemiş ve yarışmanın kazananı olmuştur. AlexNet mimarisine göre daha fazla katman içermesine rağmen parametre sayısı 12 kat daha düşüktür.

GoogleNet mimarisi havuzlama katmanları ile birlikte toplamda 27 katmandan oluşmaktadır ve bu katmanların bazıları 9 başlangıç (inception) modülü bulundurmaktadır. Ağın görüntü giriş boyutu 224x224'dür. Önceki modellerden farklı olarak bu mimaride 1x1 boyutunda filtreler kullanılmıştır. Bunun amacı işlem yükünü azaltmak ve daha derin özelliklere odaklanabilmektir.

Başlangıç (inception) modülleri kullanan mimaride, 1x1 filtrelerle elde edilen görüntüler modül içinde daha büyük filtrelerden geçirilerek görüntüdeki farklı anlamlar çıkarılmaya çalışılmıştır. Başlangıç modülü, farklı filtrelere sahip evrişimler yoluyla farklı ölçeklerde özellik algılamasından yararlanan ve boyutsal küçültme yoluyla kapsamlı bir ağı eğitmenin hesaplama maliyetini azaltan bir sinir ağı mimarisidir.

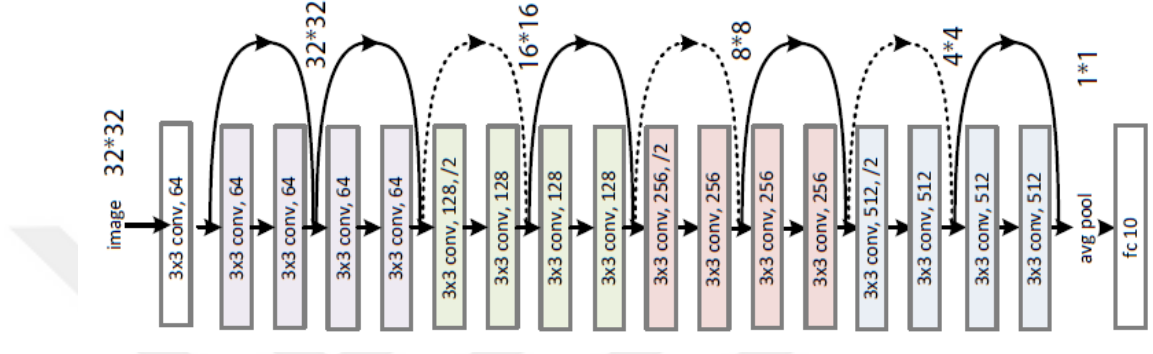
Evrişim katmanlarında maksimum havuzlama kullanılırken tam bağı katmandan önce ortalama havuzlama katmanı yer almaktadır. Aktivasyon fonksiyonu olarak ReLU, sınıflandırma için ise softmax fonksiyonu kullanılmaktadır (Szegedy vd, 2015).



Şekil 5.19. GoogleNet mimarisi (Szegedy vd, 2015)


5.6.4. ResNet

2015 yılında Kaiming He ve arkadaşları tarafından geliştirilen ResNet mimarisi sahip olduğu artık (residual) bloklar ile ImageNet yarışmasında mükemmel performans sergileyip yarışmanın kazananı olmuştur. İnsan görme hata oranı ortalama %5 olarak kabul edilirken, ResNet mimarisi nesnelere ayırt etmede hata oranını %3.57'ye düşürmüştür.



Şekil 5.20. ResNet mimarisi (He vd, 2016)

Evrimsel sinir ağı mimarilerinde katman sayısını artırmak bir noktadan sonra hata oranını artırmaktaydı ve ağı aşırı uyumuna neden oluyordu. Kendisinden önceki mimarilere göre çok daha fazla katmana sahip olan ResNet mimarisi bu problemleri artık (residual) bloklarla çözmüştür.



Şekil 5.21. Residual blok yapısı (He vd, 2016)


Artık (residual) bloklarda x giriş bilgileri evrişim işlemi ve ReLU aktivasyon fonksiyonundan geçirildikten sonra elde edilen F(x) fonksiyon sonucuna işlenmemiş x giriş bilgileri tekrar eklenerek H(x)= F(x)+x sonucu elde edilmektedir. Bu işlem katmana giren bilgilerin evrişim ve aktivasyon fonksiyonundan geçtikten sonra artık kalan özelliklerin tekrar işleme alınarak göz ardı edilmemesini sağlamaktadır.

Bu mimari residual bloklar olmadığında VggNet mimarisinin aynı özelliklerini taşımaktadır. Ağın giriş görüntü boyutu 224x224, evrişim katmanlarında kullanılan filtre boyutu ise sabit olarak 3x3'dür. Aktivasyon fonksiyonu olarak ReLu, havuzlama katmanlarında ise maksimum havuzlama kullanılmıştır. Sınıflandırma işlemi için ise softmax fonksiyonu kullanılmıştır (He vd, 2016).

ResNet mimarisinin görüntü sınıflandırma, nesne tanıma problemlerinde yaygın olarak kullanılan 18-34-50-101-152 katmanlı versiyonları bulunmaktadır.

5.6.5. DenseNet

Son yıllarda yaygın olarak kullanılan DenseNet mimarisi, evrişimsel sinir ağı mimarilerinin derinleştirilmeye çalışılması sonucu ortaya çıkmıştır. Bu mimari 2016 yılında Gao Huang ve arkadaşları tarafından "Densely Connected Convolutional Networks" adlı makalede tanıtılmıştır.



Şekil 5.22. DenseNet mimarisi (Huang vd, 2017)

Geleneksel CNN mimarileri her evrişim katmanından çıkan bilgileri bir sonraki evrişim katmanına bağlayarak ilerler. DenseNet mimarisinde ise her katmanın çıktıları kendinden sonraki katmanlara doğrudan bağlanır. Bu işlem her katmanın çıktılarının daha sonraki katmanlarda birleştirilmesini sağlar. Farklı katmanlar tarafından öğrenilen özellik haritalarının birleştirilmesi, sonraki katmanların girdisindeki çeşitliliği ve verimliliği artırır. Bu durum, DenseNet'i kendinden önceki ResNet ve Inception ağlarına karşı daha basit ve daha üstün kılmaktadır.

DenseNet'in önemli avantajları; kaybolan gradyan problemini hafifletir, özellik yayılımını güçlendirir, özelliğin yeniden kullanılmasına olanak sağlar ve parametre sayısını önemli ölçüde azaltır.

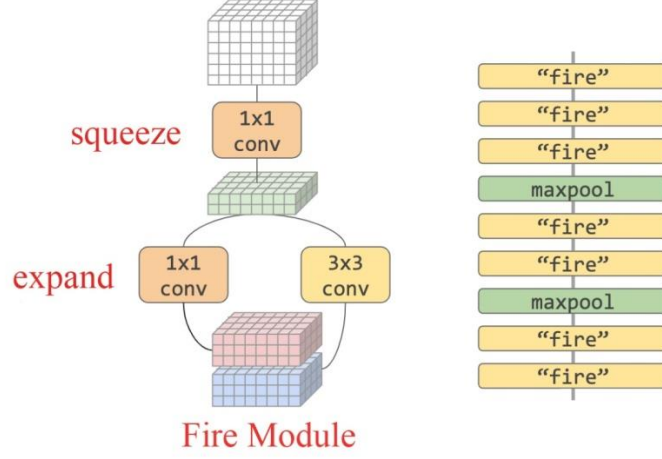
DenseNet mimarisinin yaygın olarak kullanılan 121-169-201 katmanlı mimarileri bulunmaktadır. Ağın giriş görüntü boyutu 224x224'dür. Yoğun bloklarda 1x1 ve 3x3 evrişim filtreleri kullanılmaktadır. İlk katmanda havuzlama işlemi için 3x3 boyutunda maksimum havuzlama kullanılırken, geçiş katmanlarında 2x2 boyutunda ortalama havuzlama kullanılmıştır. Adım sayısı tüm katmanlarda sabit 2 olarak belirlenmiştir.

Sınıflandırma aşamasında tam bağlı katman ile softmax fonksiyonu kullanılmıştır (Huang vd, 2017).

5.6.6. SqueezeNet

Bu mimari Forrest N. Iandola ve arkadaşları tarafından 2016 yılında " SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size" adlı makalede tanıtılmıştır. Son yıllarda ortaya çıkan CNN mimarileri genellikle doğruluğu artırmaya odaklanmıştır. SqueezeNet mimarisinin amacı daha az parametre ve daha az bellek tüketimi ile rakiplerinin elde ettiği doğruluğa ulaşabilmektir.

Bu amaç doğrultusunda, SqueezeNet mimarisinde uygulanan strateji 3 adımdan oluşmaktadır. Birinci adımda 3x3 boyutundaki filtreler 1x1 boyutundaki filtreler ile değiştirilerek parametre sayısı 9 kat azaltılır. İkinci adımda giriş kanalı sayısı 3x3 boyutundaki filtrelerden oluşan evrişim katmanlarına dönüştürülür. Bu işlemler yangın modülü adı verilen katmanlarda gerçekleşir. Üçüncü adımda ise ağda geç örnekleme yapılması sağlanmaktadır. Bu durum ise evrişim katmanlarının daha büyük etkinleştirme haritalarına sahip olmasını sağlamaktadır. Daha az parametre ile doğruluk artırılmaya çalışılır (Iandola vd, 2016).



Şekil 5.23. SqueezeNet yangın modülü (Iandola vd, 2016)

SqueezeNet mimarisi bağımsız bir evrişim katmanı ile başlar ve sonrasında 8 adet yangın modülü ile devam eder. Yangın modüllerinde kullanılan filtre sayısı ağın başından sonuna kadar kademeli olarak artırılır. Havuzlama işlemi için maksimum havuzlama, aktivasyon için ise ReLU kullanılmaktadır.

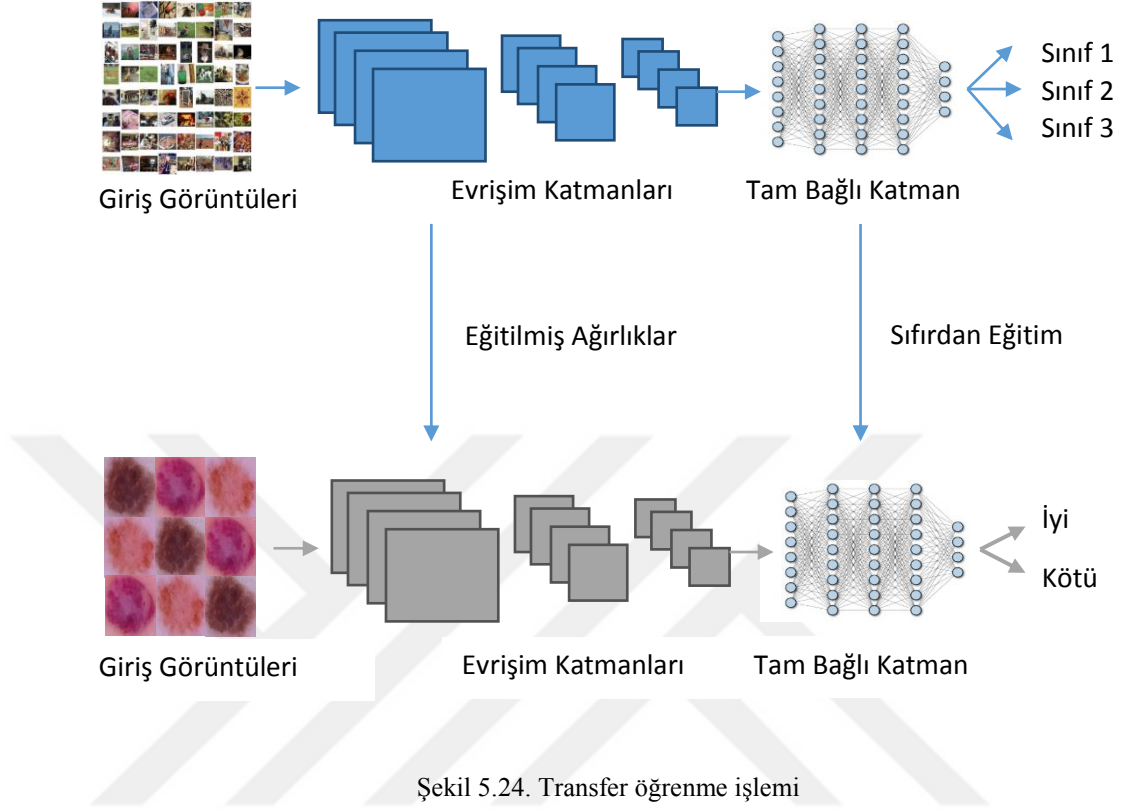
5.7. Transfer Öğrenme

Bu yaklaşım belirli bir görevde eğitilen derin öğrenme modelinin sahip olduğu parametrelerin başka bir görevde kullanılmasıdır. Aynı zamanda ikinci görevde kullanılan modelin hızlı ilerlemesini ve yüksek doğruluk performansı elde etmesini sağlayan optimizasyon yöntemi olarak da görülür (Fırıldak ve Talu, 2019). Derin öğrenme modelleri eğitilirken sıfırdan eğitim veya transfer öğrenme yöntemleri kullanılır.

Sıfırdan bir derin öğrenme modelini eğitmek ve geliştirmek bazı durumlarda iyi sonuçlar versede modelin sıfırdan eğitimi için büyük miktarda veri gerekmektedir. Sıfırdan modeli eğitiminde yeterli miktarda veriye sahip olunmadığında model yeterli öğrenme sağlayamayabilir ve bu durum ise modelin tahmin doğruluğunu düşürür. Aynı zamanda sıfırdan model eğitimi transfer öğrenimine göre daha uzun süren bir işlemdir.

ImageNet 1000 sınıflı görüntü sınıflandırma yarışmasında 1 milyondan daha fazla görüntü ile eğitilen modellerin birçok CNN modeli bulunmaktadır. Bu durum transfer öğrenme yöntemini görüntü sınıflandırma ve nesne tanıma

problemlerinde oldukça popüler hale getirmiştir. Transfer öğrenme işlemi Şekil 5.24.'de gösterilmektedir.



6. MATERİYAL VE YÖNTEM

Tezin bu bölümünde cilt kanseri tespiti için kullanılan veri seti ve özellikleri açıklanmaktadır. Veri seti üzerinde ön-işlem için ve sınıflandırma işleminde kullanılan uygulama ortamı ile kullanılan programlama dili ve kütüphaneler belirtilmektedir. Sınıflandırma işlemi öncesi ön işlem aşamasında kıl temizliği için kullanılan metot ve lezyon bölgesinin tespiti için kullanılan teknikler ile tespit edilen bölgenin görüntüden kırılması için uygulanan yaklaşım anlatılmaktadır. Son aşamada ise özellik çıkarımı ve sınıflandırma için kullanılan CNN mimarileri ile kullanılan hiperparametreler ve modeli değerlendirmek için kullanılan metrikler sunulmaktadır.

6.1. Veri Seti

Bu çalışmada, cilt kanserinin tespitine yönelik yapılan ISIC 2018 yarışmasında eğitim verisi olarak kullanılan HAM10000 veri seti kullanılmıştır (Tschandl vd, 2018b). Pigmentli cilt lezyonlarının sinir ağları ile otomatik tespit edilebilmesinde kullanılan veri setlerinin boyutunun küçük olması sebebiyle HAM10000 veri seti oluşturulmuştur. Veri setinde bulunan görüntüler dermatoskopi yöntemi ile elde edilmiş ve farklı ırklardaki kişilere ait cilt lezyonlarını içermektedir. Makine öğrenimi teknikleri ile yapılan analizlerin uzmanlar ile karşılaştırılmasını amaçlayan bu veri setinde vakalar, pigmentli lezyonlara sahip önemli hastalık türlerini içermektedir. Lezyonların büyük miktarı patoloji ile doğrulanmıştır.

Makine öğrenimi teknikleri ile akademik çalışmalar yapılmasına imkân veren ve cilt kanseri tespiti için yaygın kullanılan HAM10000 veri seti ücretsiz ve halka açıktır. Veri seti içerisinde toplamda 10015 adet dermatoskopi görüntüsü bulunmaktadır. Görüntüler veri dağılımı olarak eşit değildir ve dengesiz veri kümesi olarak nitelendirilebilir. Kırmızı yeşil ve mavi renk kanallarına sahip olan cilt lezyon görüntüleri 600x450 boyutunda JPEG formatında bulunmaktadır. Veri setinde melanositik ve melanositik olmayan pigmentlere sahip iyi ve kötü huylu farklı cilt lezyonu türleri bulunmaktadır. Tablo 6.1. 'de pigment türüne ait iyi ve kötü huylu cilt lezyonları ile görüntü sayıları gösterilmektedir.

Tablo 6.1. HAM10000 veri seti görüntü dağılımı

HAM10000 VERİ SETİ						
MELANOSİTİK		MELANOSİTİK OLMAYAN				
İYİ HUYLU	KÖTÜ HUYLU	İYİ HUYLU			KÖTÜ HUYLU	
NV	MEL	VL	DF	İHK	AK	BHK
6705	1113	142	115	1099	327	514

Melanom (MEL), melanositik pigmentlere sahip kötü huylu cilt kanseri türüdür. Cilt kanseri türleri arasında en az görülmesine rağmen ölüm oranı en yüksek olan türdür. Sahip olduğu pigmentlerden ötürü bazı lezyonlar nevüslere benzemektedir.

Nevüs (NV), iyi huylu cilt lezyonu olan nevüsler melanositik pigmentlere sahiptir ve melanomun aksine daha az renk içerir ve simetriklerdir. Yaygın görülen bu lezyonlar çeşitli şekillerde bulunabilir.

Bazal Hücreli Karsinom (BHK), melanositik olmayan pigmentlere sahip en yaygın görülen kötü huylu cilt kanseri türüdür. Vakaların %80'ini oluşturmaktadır. Ölüm oranı düşük olmasına rağmen erken tespit edilemediğinde tehlikeli olabilmektedir.


Aktinik Keratoz (AK), skuamöz hücreli karsinomların yaygın görülen varyantlarıdır. Melanositik olmayan pigmentlere sahiptir ve kötü huyludur.

Dermatofibroma (DF), melanositik pigmentlere sahip olmayan ve yaygın olarak görülen iyi huylu cilt lezyonudur.

Vasküler Lezyon (VL), iyi huylu olan vasküler lezyonların veri seti içerisinde farklı çeşitleri bulunmaktadır. Bu lezyonlar melanositik pigmentlere sahip değildir.

İyi Huylu Keratoz (İHK), içerisinde seboreik keratoz, solar lentigo gibi farklı türleri içeren melanositik pigmentlere sahip olmayan iyi huylu cilt lezyonlarıdır.

Şekil 6.1.'de veri setinde bulunan 7 farklı cilt lezyonuna ait orijinal görüntüler gösterilmektedir.



Şekil 6.1. Veri setinde bulunan cilt lezyonlarına ait örnek görüntüler

6.2. Uygulama Ortamı ve Kütüphaneler

Derin öğrenme uygulamalarının son 20 yılda popüler olmasının nedenlerinden biri gelişmiş donanımlardır. Derin öğrenme modellerinin performansı fazla miktarda veri ile doğru orantılıdır. Fazla miktarda veriyi işlemek için yüksek kapasiteli işlemci ve ekran kartlarına ihtiyaç duyulmaktadır.

Derin öğrenme ile görüntü sınıflandırma için gelişmiş ekran kartlarına ihtiyaç vardır. Bu durum maliyet açısından bir sınırlılık oluşturmaktadır. Bu sebeple web ortamında yapay zeka tabanlı uygulamalar geliştirebilmek için bulut tabanlı hizmetler sunulmaktadır. Bu çalışmada görüntüler üzerinde yapılan ön işlemler Intel 2.nesil I5 işlemci, 2gb ekran kartı ve 8 GB ram boyutuna sahip dizüstü bilgisayarda gerçekleştirildi. Ön işlemde geçirilen görüntüler bulut ortamına yüklendi ve sınıflandırma modelinin eğitimi için yapılan tüm işlemler bulut ortamında K80 Tesla ekran kartı üzerinde gerçekleştirildi. Ön işlem ve sınıflandırma aşamalarında gerçekleştirilen tüm işlemler için python programlama dili kullanıldı.

Os, bu kütüphane klasörler ve klasörler içinde bulunan dosyalara erişmek ve üzerinde işlem yapabilmek için kullanılır. Yapılan tüm işlemlerde görüntüleri okuma, yazma işlemleri için bu kütüphane kullanılmıştır.

Numpy, derin öğrenme uygulamaları yüksek miktarda matris işlemi içerir. Numpy kütüphanesi matrisler üzerinde kolay ve hızlı işlem yapmamızı sağlayan çeşitli fonksiyonlara sahiptir. Özellikle sınıflandırma modelinin elde ettiği tahmin değerleri ile görüntülerin gerçek etiketlerinin bulunduğu matrisler ile değerlendirme yapabilmek ve grafik çizdirebilmek için bu kütüphaneden yararlanılır.

Opencv, görüntü işleme konusunda en yaygın kullanılan açık kaynak kodlu kütüphanedir. Bu kütüphane C, C++, Java ve Python gibi birçok dili desteklemektedir. Opencv kütüphanesinde makine öğrenimi ile görüntü analizi için birçok algoritma bulunmaktadır. Tez kapsamında yapılan tüm ön işlemler bu kütüphanede bulunan fonksiyonlar aracılığıyla gerçekleştirilmiştir. Görüntülerin sayısallaştırılması, renk uzayı dönüşümleri, gürültü kaldırma işlemleri, segmentasyon işlemleri, kırpma işlemleri, görüntüye filtre uygulama gibi işlemler için opencv kütüphanesi kullanılmıştır.

Fast.ai, güncel, açık kaynak kodlu ve kod yazımı açısından optimize edilmiş derin öğrenme kütüphanesidir (Howard ve Gugger, 2020). Python dilini destekleyen bu kütüphane pytorch alt yapısını kullanmaktadır. Verilere kolay ulaşım sağlayabilir ve veri etiketlerini otomatik tanıyabilmektedir. Bununla birlikte derin öğrenme modelinin optimizasyonu için kullanılan hiper-

parametrelerin seçimi konusunda büyük kolaylık sağlamaktadır. Sahip olduğu fonksiyonlarla eğitimin her aşamasında elde edilen değerleri gösterirken eğitim ve doğrulama sonucunda elde edilen performansı görselleştirmeye imkan sağlamaktadır. Görüntü ve doğal dil işleme alanlarında sunduğu kolaylıklardan ötürü derin öğrenme araştırmacılarının ilgisini çekmektedir.

Sklearn, bu kütüphane klasik makine öğrenimi teknikleri ile model eğitmek ve sınıflandırma yapmak için yaygın olarak kullanılmaktadır. Tez kapsamında yapılan çalışmalarda derin öğrenme modelinin elde ettiği tahminlerin değerlendirme metrikleri kullanarak hesaplanması için bu kütüphane kullanılmıştır.

Matplotlib, python programlama dilinde verileri görselleştirmek için kullanılır. Tez kapsamında yapılan çalışmalarda ön işlem aşamalarında elde edilen sayısal görüntü piksellerinin görselleştirmesinde ve sınıflandırma modelinin çıktılarının grafikleştirilmesinde kullanılmıştır. Bu kütüphane içerisinde bulundurduğu fonksiyonlarla verileri görselleştirmeyi kolaylaştırdığı için veri biliminde yaygın olarak kullanılmaktadır.

6.3.Yöntem

Bu çalışmada, cilt lezyonlarını sınıflandırma doğruluğunu artırmaya yönelik yöntem önerilmektedir. Önerilen yöntemde cilt lezyon görüntülerinde bulunan kıllar temizlenmektedir ve gürültülerden arındırılmaktadır. Lezyon bölgesi tespit edilerek kırpma işlemi gerçekleştirilmektedir. Kırpılan görüntüler 224x224 boyutuna yeniden ölçeklendirilerek sınıflandırma için hazır hale getirilmektedir. Özellik çıkarma ve sınıflandırma işlemleri için transfer öğrenme yaklaşımı ile popüler CNN mimarileri cilt lezyon görüntüleri ile yeniden eğitilmektedir. Çalışmada, üç farklı sınıflandırma gerçekleştirilmektedir. Yapılan sınıflandırma çalışmaları sırasıyla Sınıflandırma Görevi 1, Sınıflandırma Görevi 2 ve Sınıflandırma Görevi 3 olarak adlandırılacaktır.

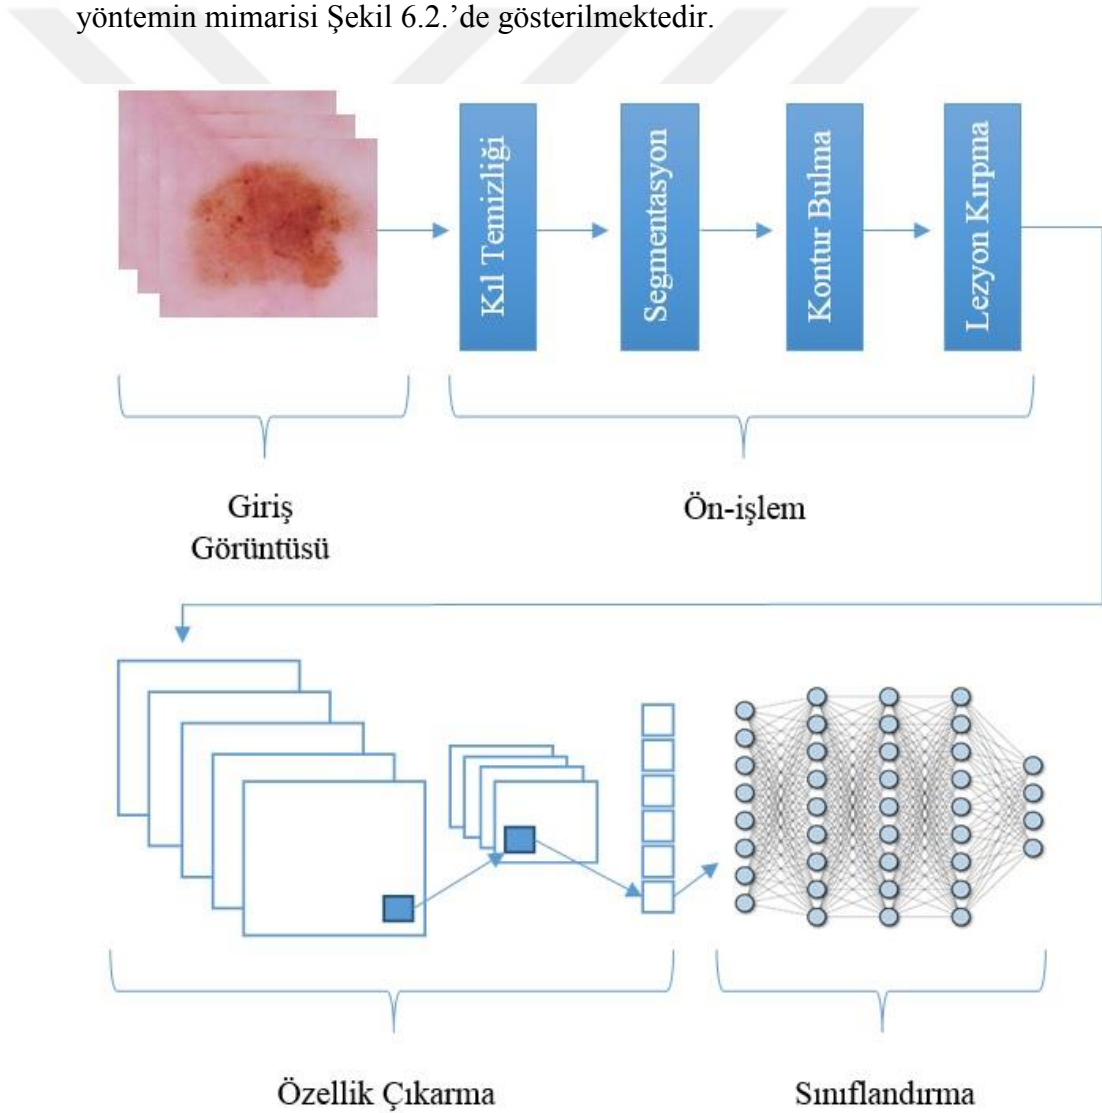
Sınıflandırma Görevi 1: Melanom cilt kanseri en az görülmesine rağmen ölüm oranı en yüksek olan türdür. Melanomun erken tespiti hastalığın tedavisi için önemlidir. Bu amaçla bu sınıflandırma görevinde melanom veri setinde bulunan iyi huylu tüm cilt lezyonları içerisinde tespit edilmeye çalışılmıştır. İlk sınıfta yalnızca melanom görüntüleri bulunurken iyi huylu lezyonların bulunduğu normal

sınıfında dermatofibroma, iyi huylu keratoz, vasküler lezyon ve nevüs yer almaktadır.

Sınıflandırma Görevi 2: Bu sınıflandırma görevinde tüm iyi huylu cilt lezyonları ile kötü huylu cilt lezyonlarının sınıflandırılması gerçekleştirilecektir. Bu ikili sınıflandırma görevinde kötü sınıfında melanom, bazal hücreli karsinom ve aktinik keratoz bulunmaktadır. İyi sınıfında ise dermatofibroma, iyi huylu keratoz, vasküler lezyon ve nevüs lezyonları bulunmaktadır.

Sınıflandırma Görevi 3: Bu sınıflandırma görevinde veri setinde bulunan 7 farklı cilt lezyonu 7 farklı sınıfa ayrılmaya çalışılacaktır.

Cilt kanserinin tespiti için yapılan tüm sınıflandırma görevleri için önerilen yöntemin mimarisi Şekil 6.2.'de gösterilmektedir.




Şekil 6.2. Cilt kanseri tespiti için önerilen yöntem

6.3.1. Kıl Temizliđi

Veri setinde bulunan dermatoskopi görüntüleri farklı yöntemlerle farklı ırlardan elde edilmiştir. Bu durum birçok görüntüde lezyon bölgesini tespiti zorlaştıran gürültüye sebep olmaktadır. Cilt lezyon görüntülerinde lezyonun üstünde ve kenarlarında bulunan kıllar bu gürültülerin tespit performansını etkileyen en önemli unsurdur (Kang vd, 2018). Lezyon üzerinde bulunan kanserli bölgenin tespit edilebilmesini engellemektedir. Aynı zamanda lezyon üzerinden çıkarılacak olan özelliklere olumsuz etki yaratmaktadır. Bu durum lezyon bölgesinin doğru tespit edilememesine ve dolayısıyla sınıflandırma modelinin performansının düşmesine neden olur (Mahmood vd, 2015). Cilt lezyonlarında bulunan kılları temizlemek için birçok yöntem bulunmaktadır (Celebi vd, 2015a). Bu çalışmada dermatoskopi görüntülerinde bulunan kılları ortadan kaldırmak için morfolojik dönüşüm tekniđi uygulanmıştır.

Bu işlemden öncelikle opencv kütüphanesi kullanılarak görüntüleri okuma işlemi gerçekleştirilmiştir. RGB renk uzayına sahip olan görüntüler bir sonraki aşamada gri seviyeli renk uzayına dönüştürülmüştür. Gri seviye görüntüler üzerinde işlem yapabilmek için 17x17 boyutunda filtre kullanarak morfolojik filtreleme işlemi gerçekleştirilmiştir. Morfolojik işlemler görüntü şekline dayanan basit işlemlerdir ve genellikle ikili görüntüler üzerinde uygulanırlar. Morfolojik dönüşüm uygulamak için iki bileşene ihtiyaç vardır; birincisi orijinal görüntüdür, ikincisi ise filtreleme uygulayan çekirdektir. Morfolojik işlem ile birlikte görüntülerin siyah şapka haritası çıkarılmıştır. Bir sonraki aşamada siyah şapka haritası çıkarılan görüntülere eşikleme yöntemi uygulanarak segmentasyon maskeleri çıkarılmıştır. Maske çıkarabilmek için opencv kütüphanesinde farklı eşikleme yöntemleri bulunmaktadır. Bu işlem için THRESH_BINARY fonksiyonu kullanılmıştır. Bu fonksiyon belirlenen bir eşik değerine göre görüntüyü siyah ve beyaz olarak bölütlemektedir. Son adımda maskesi elde edilen görüntülerde kıl ve benzeri gürültüleri kaldırmak için opencv kütüphanesinde bulunan ve Alexandru Telea tarafından geliştirilen INPAINT_TELEA fonksiyonu kullanılmıştır (Telea, 2004). Kıl temizliđi için yapılan tüm bu işlemler Şekil 6.3.'de gösterilmektedir.



Şekil 6.3. Kıl temizliği işlem adımları (a) orijinal kıl içeren görüntü (b) gri seviyeli renk uzayına dönüştürülen görüntü (c) siyah şapka haritası çıkarılmış görüntü (d) eşikleme yöntemi ile maskesi çıkarılmış görüntü (e) kıl temizliği gerçekleştirilen görüntü.

6.3.2. Segmentasyon

Segmentasyon, görüntü içerisinde buluna ilgili bölümlerin arka plandan ayrılması işlemidir ve görüntü bölütleme olarak da geçmektedir (Salido ve Ruiz JR, 2018). Bu işlem makine öğrenimi teknikleri ile sınıflandırma görevinde önemli bir yere sahiptir. Sınıflandırma işleminin performansı görüntüden çıkarılan özelliklere doğrudan bağlıdır. Arka plandan ayrılarak bölütlenmemiş görüntüler farklı özelliklere sahip olabileceğinden sınıflandırma modelinin performansını artırmak için ve ayırıcı özellikleri elde edebilmek için segmentasyon işlemi

yapılmaktadır. Tıbbi görüntülerde tümörlü bölgenin tespit edilebilmesi sınıflandırma işleminden bağımsız ayrı bir çalışma alanıdır. Görüntülerde bulunan gürültüler ilgili bölgelerin tespit edilerek sınırlarının çizilmesini zorlaştırmaktadır. HAM10000 veri setinde bulunan dermatoskopi görüntüleri lezyon bölgesinin tespitini zorlaştıran hava kabarcığı, jel, kıllar, kan damarları, cilt çizgileri, cetvel izleri birçok farklı etkene sahiptir. Bu sebeple görüntüler üzerinde gürültü giderme işlemi uygulanmasına gerek duyulmaktadır. Gürültü giderme işlemi için genellikle Gauss, Median ve Mean filtreleme teknikleri uygulanmaktadır (Saravanan vd, 2020). Cilt lezyonlarının segmentasyon işlemi için kullanılan birçok yöntem bulunmaktadır (Celebi vd, 2015b). Bu çalışmada cilt lezyon bölgelerini tespit için Otsu eşikleme yöntemi kullanılmıştır.


Otsu eşikleme yöntemi, uyarlanabilir ikilileştirme sağlayan görüntü bölütleme algoritmasıdır (Huang vd, 2021) Bu yöntem Nobuyuku Otsu tarafından 1979 yılında tanıtılmıştır (Otsu,1979). Eşikleme yöntemleri ile segmentasyon yapabilmek için ilgili eşik değerini belirlemek zordur ve deneyerek bulunması gerekebilir. Otsu yöntemi bu probleme çözüm olarak görüntüler üzerinde otomatik eşikleme yapılmasını sağlamaktadır. Görüntüdeki eşik değerini seçimi için arka plan ile ilgili bölge arasındaki maksimum sınıf varyansı kullanılır. Bu algoritma maksimum sınıflar arası varyansa erişebilmek için sınıf içi varyansları minimuma indirmeyi amaçlar. Otsu eşikleme yöntemi tıbbi görüntülerin bölütlenmesi için yaygın olarak kullanılmaktadır.

Yapılan çalışmada segmentasyon işlemi için ilk aşamada görüntüler gri seviyeli renk uzayına dönüştürülmüştür. Gri seviyeli görüntülere opencv kütüphanesinde bulunan GaussianBlur fonksiyonu kullanılarak gürültü giderme uygulanmıştır. Filtre boyutu olarak 7x7 belirlenmiştir. Sonraki aşamada ise Otsu eşikleme yöntemi ile görüntülerin maskeleri çıkarılmıştır. Cilt lezyonlarının segmentasyonu için yapılan işlem adımları Şekil 6.4.'de gösterilmektedir.

6.3.3.Kırpma İşlemi

Çalışmada, cilt lezyonlarının bölütlenmesi sonucu elde edilen görüntüler kullanılarak ilgili bölgenin kırpma işlemi gerçekleştirilmiştir. Bu işlem ile amaçlanan sınıflandırma modelinin cilt görüntüsünde bulunan ayırıcı özelliklerin elde edilmesini zorlaştıran yapıların görüntüden atılması sağlamaktır. Görüntü

kırpma işlemi için segmentasyon maskeleri üzerinden kontur bulma tekniği kullanılmıştır. Kontur bulma tekniği ile maske görüntüsünden lezyon bölgesinin sınırlarını temsil eden x ve y koordinatlarını veren matris elde edilmiştir. Bu matriste birden fazla bölgenin koordinatlarını gösteren diziler bulunmaktadır. İki boyutlu düzlemde maksimum x ve y noktalarını veren noktalar elde edilerek kırpma işlemi gerçekleştirilmiştir. Kırpılan görüntüler 224x224 boyutuna yeniden ölçeklendirilmiştir. Segmentasyon ve kırpma işlemleri adımları Şekil 6.4.'de gösterilmektedir.



Şekil 6.4. Segmentasyon ve kırpma işlem adımları (a) orijinal cilt lezyonu görüntüsü (b) gri seviyeli görüntü (c) Gauss bulanıklığı uygulanan görüntü (d) Otsu eşikleme ile elde edilen maske görüntüsü (e) kırpılmış lezyon görüntüsü

6.3.4. Veri Artırma

Derin öğrenme algoritmaları görüntü sınıflandırmada çok iyi performans göstermektedirler. Elde edilen bu performans görüntü boyutuyla doğrudan ilişkilidir. Eğitilen modelin aşırı uyum göstermemesi için farklı ve çok miktarda görüntüye ihtiyaç duymaktadır. Veri artırma işlemi ile veri setinin boyutunun artırılması ile çeşitlilik sağlanmaktadır. Veri artırma işlemi modelin aşırı uyumunu engellemek ve eğitim esnasında ihmal edilen özelliklerin öğrenilmesini sağlamak amacıyla gerçekleştirilmektedir. Orijinal görüntünün farklı versiyonları içeren veri setinden öğrenen modelin sınıflandırma aşamasında ayırım yeteneği daha gelişmiştir (Wong vd, 2016).

Veri artırma işleminde genellikle açısal değişim, parlaklık azaltma ve artırma, yatay ve dikey kaydırmalar, rastgele kırpma, kontrast artırma, yatay ve dikey döndürme, rastgele yakınlaştırma gibi teknikler kullanılmaktadır (Shorten ve Khoshgoftaar, 2019). Yapılan çalışmada kırpılmış cilt lezyon görüntüleri üzerinde yatay ve dikey döndürme, parlaklık azaltma ve artırma, kontrast artırma, açısal değişim teknikleri uygulanmıştır. Görüntüler segmentasyon maskelerinden elde edilen koordinatlara göre kırıldığı için yakınlaştırma ve rastgele kırpma teknikleri ile yatay ve dikey kaydırmalar veri artırma işleminde kullanılmamıştır.

HAM10000 veri setinde bulunan farklı cilt lezyonlarına ait sayılar oldukça dengesizdir. Bu durum eğitilen sınıflandırma modelinin performansını olumsuz yönde etkilemektedir. Özellikle cilt kanseri türleri arasında %4 oranla en az görülen ve en ölümcül olan melanomun tespiti için fazla miktarda görüntüye ihtiyaç vardır. Bununla birlikte tüm kötü huylu cilt kanserlerinin veri seti içerisindeki oranı %19'dur. Kırpılmış gerçek görüntülerden elde edilen yatay ve dikey döndürülmüş görüntüler ile 180 derece döndürülmüş yapay görüntüler Şekil 6.5.'de gösterilmektedir.



(a) (b) (c) (d)

Şekil 6.5. Kırpılmış görüntülerden elde edilen yapay görüntüler (a) gerçek görüntü (b) dikey döndürülmüş görüntü (c) yatay döndürülmüş görüntü (d) 180 derece döndürülmüş görüntü.

Veri artırma, modelin sınıflandırma performansını yükseltmek ve farklı özellikleri öğrenmesini sağlamak amacıyla eğitim kümesi üzerinde uygulanmaktadır. Model özellik çıkarımı ve öğrenme işlemini eğitim kümesi üzerinde gerçekleştirmektedir. Doğrulama kümesiyle ise öğrendikleri ile

sınıflandırma gerçekleştirir. Bu sınıflandırma sonucuna göre parametrelerini optimize ederek eğitimi tekrar başlatır. Test veri kümesi ile son aşamada görüntülerin sınıfı tahmin edilmeye çalışılır ve modelin performansı değerlendirilir. Bu nedenle doğrulama ve test kümelerinde artırılmış veri kullanmak yanıltıcı sonuçlara sebep olabilir. Veri artırma uygulamasından sonra sınıflandırma görevleri için artırılmış yapay görüntülerde içeren yeni setleri oluşturulmuştur. Veri setinin gerçek sayıları her kategoride %70 eğitim,%15 doğrulama ve %15 test olarak bölünmüştür. Artırılmış görüntüler yeni oluşturulan doğrulama ve test kümelerinde kullanılmamıştır. Doğrulama ve test kümeleri eğitim kümesinde farklı ve benzersiz görüntülerden oluşmaktadır. Artırılmış görüntüler yalnızca eğitim kümesinde kullanılmıştır. Veri kümesinde bulunan artırılmış görüntüler ise yalnızca eğitim kümesindeki gerçek görüntülerin artırılmış halleridir. Doğrulama ve test kümesinin artırılmış yapay görüntüleri hiçbir sınıflandırma görevinin veri setindeki eğitim kümesinde bulunmamaktadır. Tablo 6.2.'de sınıflandırma görevi 1 de kullanılan artırılmış veri setine ait görüntü sayıları verilmiştir.

Tablo 6.2. Sınıflandırma görevi 1 görüntü sayıları

	Melanom	Normal
Eğitim	779	5645
Artırılmış Eğitim	8569	8695
Doğrulama	167	1208
Test	167	1208

Tablo 6.2.'de gösterilen görüntü sayıları melanom sınıfında yalnızca melanom vakalarını içerirken normal sınıfında bulunan görüntü sayıları nevüs, dermatofibroma, iyi huylu keratoz ve vasküler lezyon vakalarını içermektedir. Tablo 6.3.'de sınıflandırma görevi 2 de kullanılan artırılmış veri setine ait görüntü sayıları verilmiştir.

Tablo 6.3. Sınıflandırma görevi 2 görüntü sayıları

	Kötü Huylu	İyi Huylu
Eğitim	1366	5645
Artırılmış Eğitim	10184	9662
Doğrulama	294	1208
Test	294	1208

Tablo 6.3.'de gösterilen görüntü sayıları kötü huylu sınıfta melanom, bazal hücreli karsinom ve aktinik keratoz vakalarını içerirken iyi huylu sınıfta bulunan görüntü sayıları nevüs, dermatofibroma, iyi huylu keratoz ve vasküler lezyon vakalarını içermektedir.

Tablo 6.4'de sınıflandırma görevi 3 de kullanılan artırılmış veri setine ait görüntü sayıları verilmiştir.

Tablo 6. 4. Sınıflandırma görevi 3 görüntü sayıları

	AK	BHK	M	DF	NV	İHK	VL
Eğitim	227	360	779	81	4695	769	100
Artırılmış Eğitim	2270	3240	4675	891	4695	3076	1000
Doğrulama	50	77	167	17	1005	165	21
Test	50	77	167	17	1005	165	21

Tüm sınıflandırma görevlerinde kullanılan veri setlerinde yapılan veri artırma ile sınıflar arası dengesizlik azaltılmaya çalışılmıştır. Görüntü sayısı az olan sınıflarda ortalama 10 kat artış sağlanırken görüntü sayısı fazla olan sınıflarda ortalama 5 kat artış sağlanmıştır. Nevüs görüntüleri veri setinin büyük bir kısmını oluşturduğundan nevüs görüntülerine artırma işlemi uygulanmamıştır.

6.4. Sınıflandırma

Sınıflandırma aşaması özellik çıkarımı ve özelliklerden öğrenme olarak iki aşamadan oluşmaktadır. Yapılan çalışmada cilt lezyonlarının sınıflandırılması için CNN mimarisi kullanılmaktadır. CNN mimarisi ilk aşamasında görüntüden evrişim katmanları sayesinde özellikler elde edilir. Bu aşamaya özellik çıkarma aşaması denir. Sınıflandırma performansı bu özelliklerle doğrudan ilişkilidir. CNN mimarisinin ikinci aşamasında ise çıkarılan özellikler tam bağlı katman adı

verilen derin sinir ağı modeli ile eğitime tabi tutulur ve öğrenme işlemi gerçekleşir.

Yapılan çalışmada cilt lezyon bölgesinden ayırıcı özelliklerin evrişim katmanları ile elde edilmesi için görüntülere ön işlemler uygulanmıştır. Görüntülerdeki gürültü ve kıl gibi etmenler temizlenmiş daha sonra lezyon bölgesi tespit edilerek kırpma işlemi gerçekleştirilmiştir. Kırpılmış lezyon görüntüleri 224x224 boyutuna ölçeklendirilerek özellikleri çıkarılması için CNN mimarilerine giriş olarak verilmiştir. CNN mimarilerinin eğitimde iki temel yaklaşım kullanılmaktadır. Birincisi veri setindeki görüntüler ile modeli sıfırdan eğitmektir. Bu işlem için yüksek miktarda veri gerekmektedir. İkincisi ise daha önce başka bir sınıflandırma görevinde eğitilen modelin ağırlıklarını kullanmaktır. Bu yaklaşıma transfer öğrenme adı verilmektedir. Yapılan çalışmada transfer öğrenme yaklaşımı kullanılmıştır. CNN mimarileri ImageNet ağırlıkları kullanılarak eğitim başlatılmış ve veri setinde bulunan görüntülerle yeniden eğitilmiştir.

Özellik çıkarma ve sınıflandırma işlemleri için her sınıflandırma görevinde 6 farklı CNN mimarisi kullanılmıştır. Bunlar; AlexNet, Vggnet-16, SqueezeNet, Densenet-121, ResNet-18, ve ResNet-152 mimarileridir. Her mimari her sınıflandırma görevinde orijinal ön işlemsiz ve ön işlemlili görüntülerle ayrı ayrı eğitilmiştir.

AlexNet mimarisi, evrişim ReLU katmanlarından sonra evrişim ReLU ve maksimum havuzlama katmanları ile toplamda 12 katmandan oluşmaktadır. Şekil 5.17.'de AlexNet mimarisinin yapısı gösterilmektedir. İlk evrişim katmanında 11x11 boyutunda filtreler kullanılır ve adım sayısı 4'dür. İkinci evrişim katmanında 5x5 ve daha sonraki katmanlarda ise 3x3'lük filtreler kullanılırken adım sayıları 2 olarak belirlenmiştir. İlk iki evrişim katmanı ile birlikte maksimum havuzlama kullanılmaktadır. Daha sonraki 3 katman doğrudan birbirine bağlanmaktadır. Beşinci katman sonunda tekrar maksimum havuzlama yapılmaktadır.

VggNet-16 mimarisi, evrişim+ReLU katmanlarından sonra evrişim+ReLU+ maksimum havuzlama katmanları ile toplamda 16 katmandan oluşmaktadır. Şekil 5.18.'de VGGNet mimarisinin yapısı gösterilmektedir. Tüm evrişim

katmanlarında 3×3 boyutunda sabit filtreler kullanılmıştır. Havuzlama katmanlarında ise 2×2 boyutunda filtreler kullanılmaktadır. Evrişim katmanlarında adım sayısı 1 havuzlama katmanlarında ise 2 olarak belirlenmiştir.


SqueezeNet mimarisinin evrişim ve maksimum havuzlama katmanlarında 3×3 boyutunda filtreler 2 adım sayısı ile kullanılmıştır. Aktivasyon fonksiyonu olarak ise ReLU kullanılmıştır. Modelde 8 adet yangın modülü kullanılmaktadır. Yangın modülünde kullanılan filtre boyutları 1×1 ve 3×3 adım sayısı ise 1'dir. Şekil 5.23.'de SqueezeNet mimarisinin yangın modüllerinin yapısı gösterilmektedir.

DenseNet-121 mimarisinin ilk evrişim katmanında 7×7 ve onu takip eden maksimum havuzlama katmanında 3×3 filtreler kullanılırken adım sayısı 2'dir. Yoğun bloklarda 1×1 ve 3×3 boyutunda filtreler kullanılmıştır adım sayısı ise 1'dir. Geçiş katmanlarında kullanılan filtre boyutu 1×1 adım sayısı 1 olmakla birlikte boyut azaltma için ortalama havuzlama kullanılmaktadır. Ortalama havuzlama katmanında filtre boyu 2×2 adım sayısı ise 2'dir. Tüm katmanlarda aktivasyon işlemi için ReLU kullanılmaktadır. Şekil 5.22.'de DenseNet mimarisinin yapısı gösterilmektedir.

ResNet mimarisinin 18 katmanlı ve 152 katmanlı iki versiyonu kullanılmıştır. 18 ve 152 katmanlı mimarilerin ilk evrişim katmanında filtre boyutu 7×7 adım sayısı ise 2'dir. Boyut azaltma işlemi için maksimum havuzlama kullanılmıştır. Maksimum havuzlama katmanlarında filtre boyutu 3×3 adım sayısı 2'dir. ResNet-18 mimarisinin residual bloklarında 3×3 sabit filtre boyu kullanılırken ResNet 152 mimarisinin residual bloklarında 1×1 ve 3×3 boyutunda filtreler kullanılmıştır. Her iki mimari için residual bloklarda kullanılan adım sayısı 2'dir. Her iki mimaride aktivasyon fonksiyonu için ReLU kullanılmıştır. ResNet mimarisinin genel yapısı Şekil 5.20.'de gösterilmektedir.

Özellik çıkarımı ve sınıflandırma için kullanılan CNN mimarilerinde batch-size boyutu 64 olarak ayarlanmıştır. Aktivasyon fonksiyonu olarak ReLU optimizasyon algoritması olarak ise Adam kullanılmıştır. Tam bağlı katmanlarda bırakma oranı sırasıyla 0.25 ve 0.50 olarak belirlenmiştir. Her eğitim için döngü sayısı 25 olarak belirlenmiştir.

Öğrenme hızı, sinir ağının ağırlıklarını kayıp fonksiyonuna bağlı olarak ne kadar değiştirileceğini kontrol eden hiperparametredir. Bu parametre derin öğrenme uygulamalarında belirlenen en önemli parametre olarak kabul edilmektedir. Derin sinir ağlarını eğitmenin en büyük problemlerinden biri olan öğrenme hızı için 2015 yılında öğrenme hızı aralığı testi (LRRT) adında yöntem sunulmuştur (Smith ,2017).Bu yöntem fast.ai kütüphanesinde öğrenme hızı bulucu adında bir fonksiyon olarak bulunmaktadır. Bu fonksiyon görüntüler üzerinde sahte bir eğitim gerçekleştirerek en iyi öğrenme hızını grafikte sunar ve bu değerin eğitimde uygulanmasına olanak tanır.



Şekil 6.6. Öğrenme hızı bulucu grafiği

6.5. Değerlendirme Ölçütleri

Makine öğrenimi yöntemleri ile sınıflandırma işlemlerinde eğitilen modelin tahmin ettiği sınıflar ile gerçek sınıflar bir çıktı matrisinde tutulmaktadır. Sınıflandırma performansını ölçmek için bu matristen oluşturulan karmaşıklık matrisi kullanılmaktadır. Bu matrise hata matrisi de denilmektedir. Karmaşıklık matrisinin yorumlanması modelin performansını değerlendirme açısından önemlidir. Tablo 6.5.'de karmaşıklık matrisi gösterilmektedir.

Tablo 6. 5. Karmaşıklık matrisi

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek	Pozitif	DP	YN
	Negatif	YP	DN

Tablo 6.5.'de verilen karmaşıklık matrisinde satırlar verilerin gerçek sınıflarını sütunlar ise modelin tahmin ettiği sınıfları göstermektedir. Modelin pozitif olarak tahmin ettiği ve gerçekte pozitif olan veriler DP olarak adlandırılır. YP modelin pozitif olarak tahmin ettiği ama gerçekte negatif olan verileri ifade eder. DN modelin negatif olarak tahmin ettiği ve gerçekte negatif olan doğru negatif verileri ifade eder. YN ise modelin negatif olarak tahmin ettiği ve gerçekte pozitif olan yanlış negatif veri sayısını ifade eder.

Doğruluk (Accuracy - Acc): Modelin her sınıfta doğru tahmin ettiği verilerin toplamının tüm veri sayısına bölümü ile elde edilir. Modelin genel başarısını ölçmek için kullanılır.

$$\frac{DP + DN}{DP + YP + DN + YN}$$

Kesinlik (Precision): Bu metrik karmaşıklık matrisinde doğru tahmin edilen pozitif örneklerin pozitif olarak tahmin edilen tüm örneklere oranını vermektedir. Bu oran her iki sınıf içinde uygulanabilir. Bu metrik ile modelin bir sınıf için yaptığı tahminlerin başarı oranı bulunmaktadır.

$$\frac{DP}{DP + YP}$$

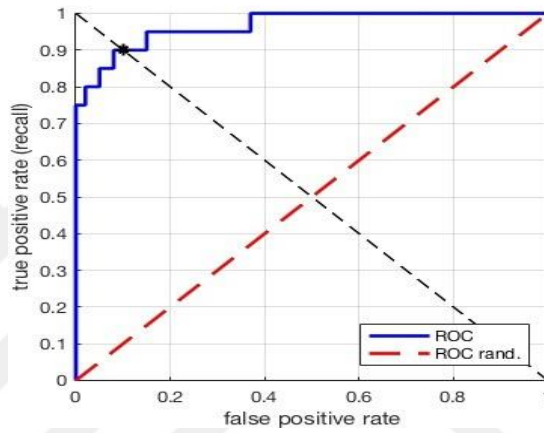
Hassasiyet (Recall): Modelin doğru tahmin ettiği pozitif verilerin gerçekte var olan pozitif veri sayısına bölümü ile edilir. Bu metrik modelin doğru pozitif oranı olarak da bilinir. Her iki sınıf için uygulanabilir.

$$\frac{DP}{DP + YN}$$

F-Skoru (F-Score): Hassasiyet değeri ile kesinlik değerinin ağırlıklı ortalamasını verir

$$\frac{2 \times \text{Kesinlik} \times \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}}$$

Alıcı İşlem Karakteristiği Eğrisi (Receiver Operating Characteristic – ROC Curve): Sınıflandırma modelinin doğru pozitif oranı ve yanlış pozitif oranını gösteren grafikdir. Doğru pozitif oranı Recall değerini vermektedir ve grafiğin y eksenini temsil eder. Yanlış pozitif oranı ise özgüllük (specificiy) değerini vermektedir ve grafiğin x eksenini temsil eder.



Şekil 6.7. ROC eğrisi

Eğri Altındaki Alan (Under Curve Area- AUC): Bu metrik ROC eğri grafiğinde eğri altında kalan alanı temsil eder. Sınıflandırma modelinin pozitif ve negatif örnekleri ayırabilme yeteneğini gösterir. Eğri altında kalan alan büyüdükçe modelin ayırım yeteneği gelişmektedir.

7. BULGULAR VE TARTIŞMA

Yapılan çalışmada, 3 farklı sınıflandırma gerçekleştirilmiştir. Sınıflandırma işlemleri sırasıyla Sınıflandırma Görevi 1, Sınıflandırma Görevi 2 ve Sınıflandırma Görevi 3 olarak adlandırılmıştır. Tüm sınıflandırma görevleri için HAM10000 veri seti kullanılmıştır. Ön işleme tabii tutulan görüntüler ile işlem görmemiş orijinal görüntüler 2 farklı veri seti olarak kullanılmıştır. Veri setleri tüm sınıflandırma görevleri için %70 eğitim,%15 doğrulama ve %15 test olarak bölünmüştür. Her 3 veri setinde de eğitim doğrulama ve test görüntüleri aynı görüntülerden oluşmaktadır. Sınıflandırma doğruluğunu artırmak için görüntülere ön işlemler uygulanmıştır. Yapılan ön işlemler bölüm 6'da detaylı olarak anlatılmaktadır. 600x450 boyutuna sahip olan görüntüler ön işlemlerden sonra 224x224 boyutuna yeniden ölçeklendirilmiştir. Eğitilen modellerin aşırı uyumunu engellemek ve performansını artırmak amacıyla veri artırma tekniği uygulanmıştır. Veri artırma yalnızca eğitim görüntüleri üzerinde gerçekleştirilip, doğrulama ve test kümesine veri artırma tekniği uygulanmamıştır. Doğrulama ve test kümelerinde bulunan görüntüler eğitim kümesinden benzersiz görüntülerdir.

Özellik çıkarma ve sınıflandırma işlemleri için AlexNet, VGGNet-16, ResNet-18, DenseNet-121, ResNet-152 ve SqueezeNet mimarileri kullanılmıştır. Mimariler sıfırdan eğitilmemiş ve transfer öğrenme yaklaşımı kullanılmıştır. Mimarilerin eğitimi ImageNet ağırlıkları ile başlatılmış ve veri setinde bulunan görüntülerle yeniden eğitilmiştir. Derin Öğrenme uygulamaları K80 Tesla ekran kartı üzerinde gerçekleştirilmiştir. Eğitilen modellerin iterasyon sayısı 25, batch-size boyutu 64 olarak belirlenmiştir. Modellerin optimizasyonu ve parametrelerin güncellenmesi için Adam optimizasyon algoritması, evrişim katmanlarında ise ReLU aktivasyon fonksiyonu kullanılmıştır. CNN mimarilerinin her sınıflandırma görevinde doğrulama kümesi ve test kümesi için ön işlem uygulanmayan orijinal veriler ile ön işleme tabii tutulan veriler üzerinde gösterdikleri sınıflandırma performansı tablo ve grafiklerle karşılaştırılmıştır. Aynı zamanda her sınıflandırma görevi için en iyi sınıflandırma performansını gösteren CNN mimarisinin performansı eğitim ve doğrulama kaybı grafiği, eğitim esnasında doğrulama kümesi üzerinde gösterdiği doğruluk değerinin eğri grafiği, karmaşıklık matrisi ve ayırım yeteneğini gösteren ROC eğrisi ile gösterilmiştir.

7.1. Sınıflandırma Görevi 1

Bu sınıflandırma görevinde en kötü huylu olan melanom cilt kanserinin melanositik pigmentlere sahip olan nevüs ve diğer iyi huylu cilt lezyonlarından ayrılması için veri setinde bulunan cilt lezyon görüntüleri Melanom ve Normal olarak iki sınıfa ayrıldı. Melanom sınıfında eğitim kümesi için 8569, doğrulama kümesi için 167 ve test kümesi için 167 görüntü bulunmaktadır. Normal sınıfında eğitim kümesi için 8695, doğrulama kümesi için 1208 ve test kümesi için 1208 görüntü bulunmaktadır. 6 farklı mimari ile gerçekleştirilen sınıflandırma işlemlerinin doğrulama ve test kümesi üzerinde gösterdikleri performans Tablo 7.1.'de verilmiştir.


Tablo 7. 1. Sınıflandırma görevi 1 için CNN mimarilerinin performans özeti

		Acc	AUC	Pre	Rec	F-Sc
AlexNet (İşlemsiz)	Doğrulama	0.88	0.85	0.75	0.61	0.67
	Test	0.87	0.78	0.70	0.54	0.61
AlexNet (Ö.Yöntem)	Doğrulama	0.89	0.89	0.74	0.78	0.76
	Test	0.90	0.87	0.78	0.73	0.75
VGGNet-16 (İşlemsiz)	Doğrulama	0.89	0.88	0.75	0.61	0.67
	Test	0.88	0.83	0.75	0.55	0.63
VGGNet-16 (Ö.Yöntem)	Doğrulama	0.92	0.92	0.84	0.81	0.82
	Test	0.92	0.88	0.85	0.74	0.79
ResNet-18 (İşlemsiz)	Doğrulama	0.88	0.87	0.74	0.59	0.66
	Test	0.87	0.79	0.69	0.53	0.60
ResNet-18 (Ö.Yöntem)	Doğrulama	0.93	0.91	0.84	0.82	0.83
	Test	0.92	0.87	0.86	0.74	0.79
DenseNet-121 (İşlemsiz)	Doğrulama	0.89	0.88	0.79	0.60	0.68
	Test	0.88	0.82	0.66	0.53	0.59
DenseNet-121 (Ö.Yöntem)	Doğrulama	0.94	0.93	0.88	0.83	0.85
	Test	0.92	0.91	0.88	0.74	0.80
ResNet-152 (İşlemsiz)	Doğrulama	0.88	0.87	0.72	0.59	0.65
	Test	0.88	0.84	0.72	0.58	0.64
ResNet-152 (Ö.Yöntem)	Doğrulama	0.94	0.93	0.87	0.84	0.85
	Test	0.91	0.90	0.84	0.74	0.79
SqueezeNet (İşlemsiz)	Doğrulama	0.88	0.88	0.74	0.58	0.65
	Test	0.87	0.82	0.70	0.53	0.60
SqueezeNet (Ö.Yöntem)	Doğrulama	0.83	0.88	0.68	0.80	0.73
	Test	0.80	0.82	0.64	0.72	0.67

Tablo 7.1’de verilen ön işlemlili ve ön işlemsiz sınıflandırma sonuçları her iki sınıfın makro ortalamalarını göstermektedir. 25 devir sonucunda test kümesi üzerinde AlexNet mimarisi ile %0.87, VGGNet-16 mimarisi ile %88, ResNet-18 mimarisi ile %87, DenseNet-121 mimarisi ile %91, ResNet-152 mimarisi ile %90 ve SqueezeNet mimarisi ile %82 AUC skoru elde edildi.


Önerilen yöntem ile kötü huylu melanom tespiti için yapılan Sınıflandırma Görevi 1 için 6 farklı CNN mimarisi aynı veri seti üzerinde eğitildiğinde ve aynı test kümesi ile test edildiğinde DenseNet-121 mimarisi %92 doğruluk, %88 precision, %74 recall ve %80 F-Score değeri ile en iyi performansı sergilemiştir. En başarısız performansı ise SqueezeNet mimarisinin gösterdiği gözlemlenmiştir. Tüm mimarilerin önerilen ön işlemlilerle yapılan sınıflandırmada kötü huylu melanomun tespiti için elde ettiği değerler ön işlemsiz görüntülerle yapılan sınıflandırma değerlerinden daha yüksek olduğu gözlemlenmiştir.

Şekil 7.1’de CNN mimarilerinin melanom tespiti için ön işlemlili sınıflandırma ve ön işlemsiz sınıflandırmada test kümesi üzerinde elde ettiği doğru pozitif oranı gösterilmektedir.



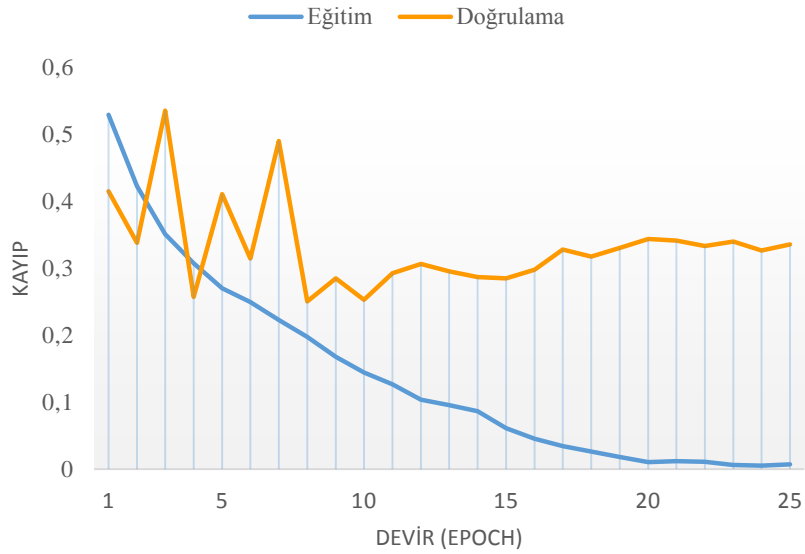
Şekil 7.1. Sınıflandırma görevi 1 için CNN mimarilerinin doğru pozitif oranı

Şekil 7.2’de DenseNet-121 mimarisinin 25 iterasyonluk eğitim sürecinde doğrulama kümesi üzerinde elde ettiği doğruluk değerlerinin eğrisi gösterilmektedir. Her iterasyonda elde edilen değerler makro ortalamaları göstermektedir.



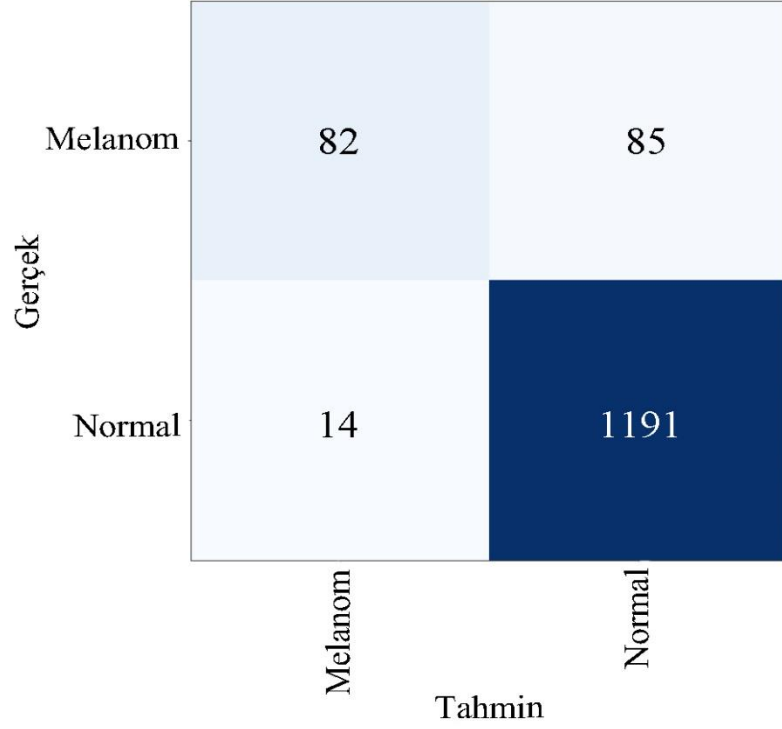
Şekil 7.2. DenseNet-121 mimarisi doğruluk eğrisi

Şekil 7.3.'de DenseNet-121 mimarisinin 25 iterasyonluk eğitim sürecinde elde ettiği eğitim ve doğrulama kayıp değerlerinin eğrisi gösterilmektedir.



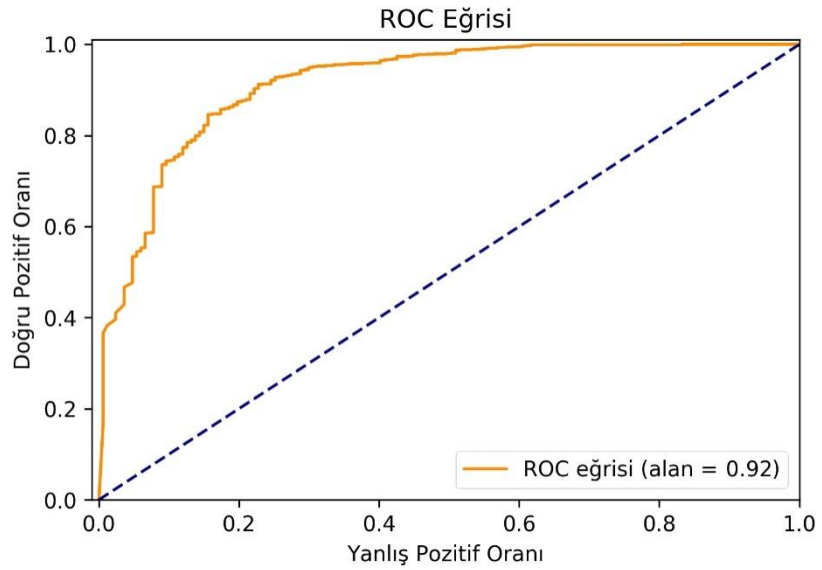
Şekil 7.3. DenseNet-121 mimarisi kayıp eğrisi

Şekil 7.4.'de DenseNet-121 mimarisinin doğru ve yanlış tahmin ettiği görüntülerin sınıflarını ve sayılarını gösteren karmaşıklık matrisi gösterilmektedir. Karmaşıklık matrisinin satırları görüntülerin gerçek sınıfını sütunları ise modelin tahmin ettiği sınıfları göstermektedir.



Şekil 7.4 DenseNet-121 karmaşıklık matrisi

Şekil 7.5.'de DenseNet-121 mimarisinin her iki sınıfı ayırma yeteneğini gösteren ROC eğrisi gösterilmektedir. ROC eğrisinin y eksenini doğru pozitif oranını x eksenini yanlış pozitif oranını göstermektedir. Eğri altında kalan alan ise sınıflandırma modelinin AUC skorunu vermektedir.



Şekil 7.5. DenseNet-121 mimarisi ROC eğrisi

7.2. Sınıflandırma Görevi 2

Bu sınıflandırma görevinde kötü huylu olan melanom, bazal hücreli karsinom ve aktinik keratoz cilt lezyonlarının iyi huylu olan cilt lezyonlarından ayrılması için veri setinde bulunan cilt lezyon görüntüleri Kötü Huylu ve İyi Huylu olarak iki sınıfa ayrıldı. Kötü Huylu sınıfında eğitim kümesi için 10184, doğrulama kümesi için 294 ve test kümesi için 294 görüntü bulunmaktadır. İyi Huylu sınıfında eğitim kümesi için 9662, doğrulama kümesi için 1208 ve test kümesi için 1208 görüntü bulunmaktadır. 6 farklı mimari ile gerçekleştirilen sınıflandırma işlemlerinin doğrulama ve test kümesi üzerinde gösterdikleri performans Tablo 7.2.'de verilmiştir.

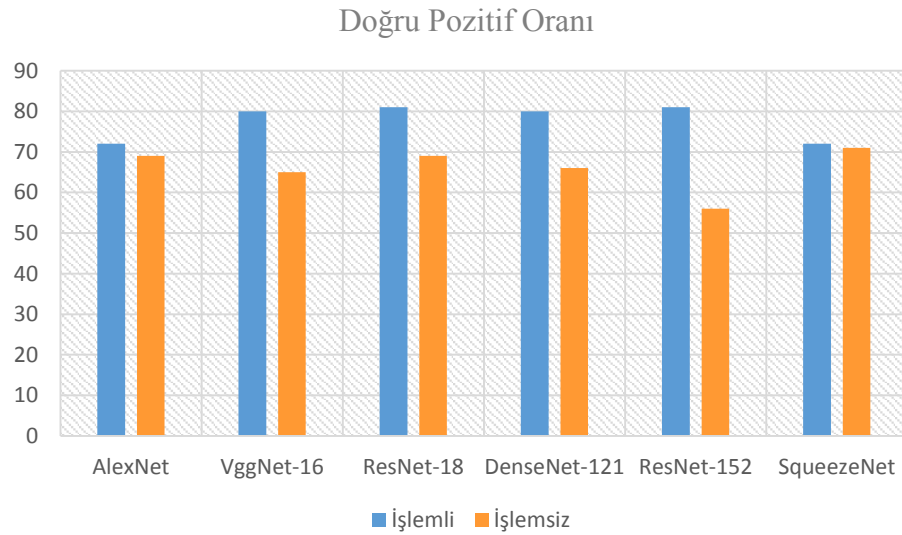
Tablo 7. 2. Sınıflandırma görevi 2 için CNN mimarilerinin performans özeti

		Acc	AUC	Pre	Rec	F-Sc
AlexNet (İşlemsiz)	Doğrulama	0.83	0.87	0.74	0.73	0.73
	Test	0.76	0.79	0.65	0.69	0.67
AlexNet (Ö.Yöntem)	Doğrulama	0.84	0.88	0.76	0.77	0.76
	Test	0.77	0.82	0.67	0.72	0.69
VGGNet-16 (İşlemsiz)	Doğrulama	0.84	0.87	0.75	0.72	0.73
	Test	0.79	0.80	0.66	0.65	0.65
VGGNet-16 (Ö.Yöntem)	Doğrulama	0.91	0.93	0.87	0.85	0.86
	Test	0.88	0.90	0.82	0.80	0.81
ResNet-18 (İşlemsiz)	Doğrulama	0.82	0.87	0.72	0.71	0.71
	Test	0.80	0.80	0.69	0.69	0.69
ResNet-18 (Ö.Yöntem)	Doğrulama	0.89	0.93	0.83	0.84	0.83
	Test	0.87	0.90	0.80	0.81	0.80
DenseNet-121 (İşlemsiz)	Doğrulama	0.84	0.88	0.76	0.70	0.73
	Test	0.81	0.80	0.71	0.66	0.68
DenseNet-121 (Ö.Yöntem)	Doğrulama	0.91	0.93	0.86	0.86	0.86
	Test	0.88	0.90	0.83	0.80	0.81
ResNet-152 (İşlemsiz)	Doğrulama	0.82	0.82	0.72	0.61	0.66
	Test	0.73	0.68	0.57	0.56	0.57
ResNet-152 (Ö.Yöntem)	Doğrulama	0.92	0.94	0.88	0.86	0.87
	Test	0.89	0.91	0.85	0.81	0.83
SqueezeNet (İşlemsiz)	Doğrulama	0.76	0.82	0.68	0.75	0.71
	Test	0.70	0.76	0.64	0.71	0.67
SqueezeNet (Ö.Yöntem)	Doğrulama	0.81	0.86	0.71	0.77	0.74
	Test	0.74	0.78	0.66	0.72	0.69

Tablo 7,2’de verilen ön işlemlili ve işlemsiz sınıflandırma sonuçları her iki sınıfın makro ortalamalarını göstermektedir. 25 devir sonucunda test kümesi üzerinde AlexNet mimarisi ile %0.82, VGGNet-16 mimarisi ile %90, ResNet-18 mimarisi ile %90, DenseNet-121 mimarisi ile %90, ResNet-152 mimarisi ile %91 ve SqueezeNet mimarisi ile %78 AUC skoru elde edildi.

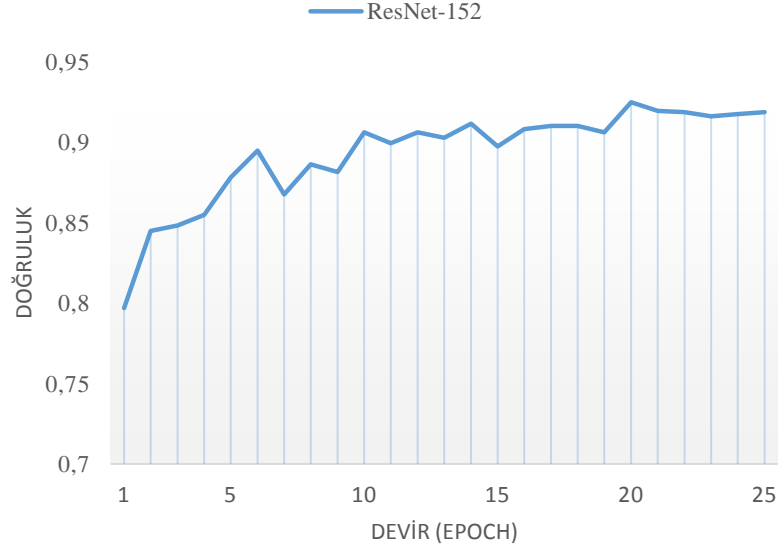
Önerilen yöntem ile kötü huylu cilt lezyonlarının tespiti için yapılan Sınıflandırma Görevi 2 için 6 farklı CNN mimarisi aynı veri seti üzerinde eğitildiğinde ve aynı test kümesi ile test edildiğinde ResNet-152 mimarisi %89 doğruluk, %85 precision, %81 recall ve %83 F-Score değeri ile en iyi performansı sergilemiştir. En başarısız performansı ise SqueezeNet mimarisinin gösterdiği gözlemlenmiştir. Tüm mimarilerin önerilen ön işlemlilerle yapılan sınıflandırmada kötü huylu cilt lezyonları tespiti için elde ettiği değerler ön işlemsiz görüntülerle yapılan sınıflandırma değerlerinden daha yüksek olduğu gözlemlenmiştir.

Şekil 7,6’da CNN mimarilerinin kötü huylu lezyon tespiti için ön işlemlili sınıflandırma ve ön işlemsiz sınıflandırmada test kümesi üzerinde elde ettiği doğru pozitif oranı gösterilmektedir.




Şekil 7.6. Sınıflandırma görevi 2 için CNN mimarilerinin doğru pozitif oranı

Şekil 7.7’de ResNet-152 mimarisinin 25 devir eğitim sürecinde doğrulama kümesi üzerinde elde ettiği doğruluk değerlerinin eğrisi gösterilmektedir. Her iterasyonda elde edilen değerler makro ortalamaları göstermektedir.




Şekil 7.7. ResNet-152 mimarisi doğruluk eğrisi

Şekil 7.8.'de ResNet-152 mimarisinin 25 devir eğitim sürecinde elde ettiği eğitim ve doğrulama kayıp değerlerinin eğrisi gösterilmektedir.




Şekil 7.8. ResNet-152 mimarisi kayıp eğrisi

Şekil 7.9.'da ResNet-152 mimarisinin test kümesi için doğru ve yanlış tahmin ettiği görüntülerin sınıflarını ve sayılarını gösteren karmaşıklık matrisi gösterilmektedir. Karmaşıklık matrisinin satırları görüntülerin gerçek sınıfını sütunları ise modelin tahmin ettiği sınıfları göstermektedir.



Şekil 7.9. ResNet-152 karmaşıklık matrisi

Şekil 7.10.'da ResNet-152 mimarisinin test kümesi için her iki sınıfı ayırma yeteneğini gösteren ROC eğrisi gösterilmektedir. ROC eğrisinin y eksenini doğru pozitif oranını x eksenini ise yanlış pozitif oranını göstermektedir. Eğri altında kalan alan ise sınıflandırma modelinin AUC skorunu vermektedir.



Şekil 7.10. ResNet-152 mimarisi ROC eğrisi

7.3. Sınıflandırma Görevi 3

Bu sınıflandırma görevinde veri setinde 7 farklı sınıfa ait cilt lezyon görüntüleri kendi sınıflarına ayrıldı. Diğer sınıflandırma görevlerinden farklı olarak bu görevde ikili sınıflandırma gerçekleştirilmemiştir. AK sınıfında eğitim kümesi için 2270, doğrulama veri kümesi için 50, test kümesi için 50 görüntü bulunmaktadır. BHK sınıfında eğitim kümesi için 3240, doğrulama veri kümesi için 77, test kümesi için 77 görüntü bulunmaktadır. İHK sınıfında eğitim kümesi için 3076, doğrulama veri kümesi için 165, test kümesi için 165 görüntü bulunmaktadır. DF sınıfında eğitim kümesi için 891, doğrulama veri kümesi için 17, test kümesi için 17 görüntü bulunmaktadır. MEL sınıfında eğitim kümesi için 4674, doğrulama veri kümesi için 167, test kümesi için 167 görüntü bulunmaktadır. NV sınıfında eğitim kümesi için 4695, doğrulama veri kümesi için 1005, test kümesi için 1005 görüntü bulunmaktadır. VL sınıfında eğitim kümesi için 1000, doğrulama veri kümesi için 21, test kümesi için 21 görüntü bulunmaktadır. 6 farklı mimari ile gerçekleştirilen sınıflandırma işlemlerinin doğrulama ve test kümesi üzerinde gösterdikleri performans Tablo 7.3.'de verilmiştir.

Tablo 7. 3. Sınıflandırma görevi 3 için CNN mimarilerinin performans özeti


		Acc	AUC	Pre	Rec	F-Sc
AlexNet (İşlemsiz)	Doğrulama	0.81	0.97	0.71	0.62	0.66
	Test	0.68	0.91	0.57	0.56	0.56
AlexNet (Ö.Yöntem)	Doğrulama	0.83	0.98	0.77	0.78	0.77
	Test	0.74	0.96	0.64	0.70	0.69
VggNet-16 (İşlemsiz)	Doğrulama	0.82	0.98	0.67	0.64	0.65
	Test	0.74	0.95	0.56	0.64	0.60
VggNet-16 (Ö.Yöntem)	Doğrulama	0.87	0.99	0.82	0.81	0.81
	Test	0.79	0.97	0.70	0.75	0.72
ResNet-18 (İşlemsiz)	Doğrulama	0.82	0.99	0.72	0.64	0.68
	Test	0.77	0.95	0.67	0.61	0.64
ResNet-18 (Ö.Yöntem)	Doğrulama	0.88	0.99	0.83	0.82	0.82
	Test	0.81	0.98	0.74	0.74	0.74
DenseNet-121 (İşlemsiz)	Doğrulama	0.85	0.98	0.78	0.68	0.73
	Test	0.76	0.97	0.62	0.68	0.65
DenseNet-121 (Ö.Yöntem)	Doğrulama	0.89	0.99	0.85	0.82	0.83
	Test	0.82	0.98	0.78	0.76	0.77
ResNet-152 (İşlemsiz)	Doğrulama	0.80	0.97	0.65	0.61	0.63
	Test	0.69	0.91	0.49	0.50	0.49
ResNet-152 (Ö.Yöntem)	Doğrulama	0.90	0.99	0.86	0.83	0.84
	Test	0.84	0.98	0.78	0.77	0.77
SqueezeNet (İşlemsiz)	Doğrulama	0.73	0.90	0.30	0.27	0.28
	Test	0.54	0.84	0.28	0.23	0.25
SqueezeNet (Ö.Yöntem)	Doğrulama	0.81	0.98	0.75	0.80	0.77
	Test	0.68	0.96	0.56	0.71	0.63

Tablo 7.3.'de verilen ön işlemlili ve işlemsiz sınıflandırma sonuçları tüm sınıfların makro ortalamalarını göstermektedir. 25 devir sonucunda test kümesi üzerinde AlexNet mimarisi ile %0.74, VGGNet-16 mimarisi ile %79, ResNet-18 mimarisi ile %81, DenseNet-121 mimarisi ile %82, ResNet-152 mimarisi ile %84 ve SqueezeNet mimarisi ile %68 doğruluk değeri elde edildi.

Önerilen yöntem ile yapılan Sınıflandırma Görevi 3 için 6 farklı CNN mimarisi aynı veri seti üzerinde eğitildiğinde ve aynı test kümesi ile test edildiğinde ResNet-152 mimarisi %84 doğruluk, %78 precision, %77 recall ve %78 F-Score değeri ile en iyi performansı sergilemiştir. En başarısız performansı

ise SqueezeNet mimarisinin gösterdiği gözlemlenmiştir. Tüm mimarilerin önerilen ön işlemlerle yapılan sınıflandırmada elde ettiği değerler ön işlemsiz görüntülerle yapılan sınıflandırma değerlerinden daha yüksek olduğu gözlemlenmiştir.

Şekil 7.11’de CNN mimarilerinin lezyon tespiti için ön işlemlerle yapılan sınıflandırma ve ön işlemsiz sınıflandırmada test kümesi üzerinde elde ettiği doğru pozitif oranı gösterilmektedir



Şekil 7.11. Sınıflandırma görevi 3 için CNN mimarilerinin doğru pozitif oranı

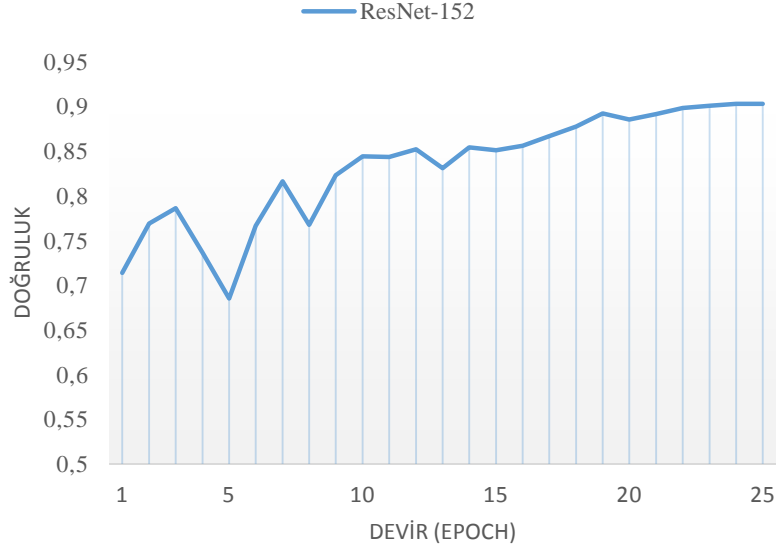
Tablo 7.4.’de ResNet-152 mimarisinin 7 farklı sınıf için ön işlem uygulanan ve işlemsiz görüntüler üzerinde elde ettiği precision, recall ve F-Score değerleri verilmektedir.

Tablo 7. 4. Resnet-152 mimarisinin test kümesi üzerindeki performans özeti

		Pre	Rec	F-Sc
ResNet-152 (İşlemsiz)	AK	0.38	0.40	0.30
	BHK	0.30	0.61	0.40
	İHK	0.43	0.72	0.54
	DF	0.10	0.18	0.13
	MEL	0.48	0.26	0.34
	NV	0.90	0.79	0.84
	VL	0.80	0.57	0.67
	ResNet-152 (Ö.Yöntem)	AK	0.74	0.56
BHK		0.74	0.83	0.78
İHK		0.53	0.90	0.67
DF		0.82	0.82	0.82
MEL		0.76	0.54	0.64
NV		0.95	0.89	0.92
VL		0.95	0.86	0.90


ResNet-152 mimarisi ile kötü huylu cilt lezyonlarında melanom için %76 precision, %54 recall, %64 F-Score değeri elde edildi. Aktinik keratoz için %74 precision, %56 recall, %64 F-Score değeri elde edildi. Bazal hücreli karsinom için %74 precision, %83 recall, %78 F-Score değeri elde edildi.

Şekil 7.12’de ResNet-152 mimarisinin 25 devir eğitim sürecinde doğrulama kümesi üzerinde elde ettiği doğruluk değerlerinin eğrisi gösterilmektedir. Her devirde elde edilen değerler makro ortalamaları göstermektedir.




Şekil 7.12. ResNet-152 mimarisi doğruluk eğrisi

Şekil 7.13.'de ResNet-152 mimarisinin 25 devir eğitim sürecinde elde ettiği eğitim ve doğrulama kayıp değerlerinin eğrisi gösterilmektedir.



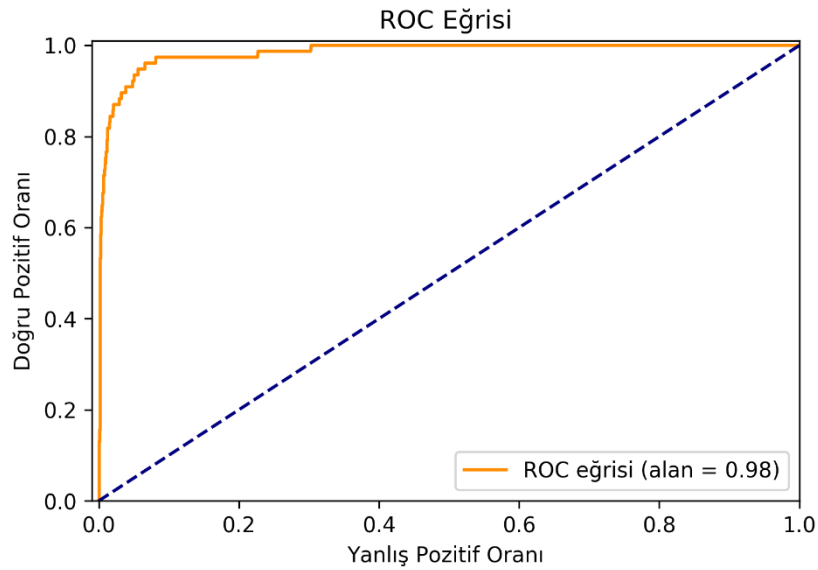
Şekil 7.13. ResNet-152 mimarisi kayıp eğrisi

Şekil 7.14.'de ResNet-152 mimarisinin test kümesi için doğru ve yanlış tahmin ettiği görüntülerin sınıflarını ve sayılarını gösteren karmaşıklık matrisi gösterilmektedir. Karmaşıklık matrisinin satırları görüntülerin gerçek sınıfını sütunları ise modelin tahmin ettiği sınıfları göstermektedir.



Şekil 7.14. ResNet-152 karmaşıklık matrisi

Şekil 7.15.'de ResNet-152 mimarisinin test kümesi için her iki sınıfı ayırma yeteneğini gösteren ROC eğrisi gösterilmektedir. ROC eğrisinin y eksenini doğru pozitif oranını x eksenini yanlış pozitif oranını göstermektedir. Eğri altında kalan alan ise sınıflandırma modelinin AUC skorunu vermektedir.



Şekil 7.15. ResNet-152 mimarisi ROC eğrisi

Tez kapsamında yapılan çalışmada 3 farklı sınıflandırma gerçekleştirilmiştir. Her sınıflandırma görevinde cilt lezyonlarının tespiti için ön işlem ve segmentasyona dayalı yöntem önerilmiştir. Önerilen yöntemin amacı cilt lezyonlarında bulunan ve sınıflandırma doğruluğunu olumsuz etkileyen gürültüleri ortadan kaldırmaktır. Önerilen yöntemle elde edilen sınıflandırma sonuçları işlemsiz görüntülerle elde edilen sonuçlardan çok daha başarılıdır. Lezyon görüntüsünde bulunan kılların temizlenmesi ve lezyon bölgesinin tespit edilerek kırılması deneylerde kullanılan tüm CNN mimarilerinin ilgili bölgenin ayrıntı özelliklerini elde etmesini ve cilt lezyonlarını daha iyi ayırt etmesini sağlamıştır.

3 farklı sınıflandırma görevinde kullanılan test ve doğrulama kümeleri aynı verilerden oluşmakta ve eğitim kümesinden benzersiz görüntüleri içermektedir. Test ve doğrulama kümesinde bulunan sınıf dağılımları aşırı dengesizdir. Bunun sebebi kötü huylu cilt lezyonu görüntülerinin az olmasında kaynaklanmaktadır. CNN mimarileri iyi huylu cilt lezyonlarını büyük oranda doğru tespit etmektedir. Test ve doğrulama kümesinde iyi huylu lezyonlarının sayısının fazla olması ağırlıklı ortalama ve mikro ortalama değerlerini yükseltmektedir. Bu nedenle CNN mimarilerinin precision ve recall değerleri için ağırlıklı ortalama ve mikro ortalama değerleri kullanılmayıp tüm sınıfların ortalamasını veren makro ortalama değerleri kullanılmıştır.

Kötü huylu melanomun tespiti için yapılan çalışmalarda Lopez vd. (2017) kötü %81.33 doğruluk oranına ulaşmışlardır. Ayan ve Ünver (2018) ise artırılmış görüntülerle eğittikleri modelin testinde %81 doğruluk elde etmişlerdir. Rashid vd. (2019) GAN tabanlı sınıflandırma ile %86 doğruluk elde etmişlerdir. Quang (2017) VGGNet mimarisi ile %76 AUC skoruna ulaşmışlardır. Singh ve Nwogu (2018) kötü huylu melanom tespiti için %80, Harangi (2017) ağırlıklı ortalama %86 doğruluk elde etmiştir. Tez kapsamında önerilen yöntem ile yapılan çalışmada melanom tespiti için yapılan Sınıflandırma Görevi 1'de DenseNet-121 mimarisi ile %92 doğruluk, %91 AUC skoru elde edilmiştir. Bununla birlikte en başarısız sonucu veren SqueezeNet mimarisi ile %80 doğruluk ve %82 AUC skoruna ulaşılmıştır. Önerilen kıl temizliği ve segmentasyona dayalı yöntem ile kötü huylu melanom tespiti için elde edilen bu sonuçların literatürde yapılan çalışmalarla karşılaştırıldığında başarılı olduğu görülmektedir.

Tablo 7. 5. Melanom tespitine yönelik çalışmaların performansı

Yazar	Veri Kümesi	Ön İşlem	Veri Artırma	Sınıflandırıcı	Doğruluk
Lopez vd. (2017)	ISIC 2016	+	+	CNN	% 81.33
Quang (2017)	ISIC 2017	+	+	CNN	% 83.7
Harangi (2017)	ISIC 2017	-	+	CNN	% 86
Ayan ve Ünver (2018)	ISIC Arşivi	+	+	CNN	% 81
Singh ve Nwogu (2018)	ISIC 2017	+	+	CNN	% 80.3
Rashid vd. (2019)	ISIC 2018	+	+	GAN	% 86
Sınıflandırma Görevi 1	ISIC 2018	+	+	CNN	% 92
Sınıflandırma Görevi 2	ISIC 2018	+	+	CNN	% 89

Cilt lezyonlarının sınıflandırılması için yapılan çalışmalarda Kassani ve Kassani (2019) HAM10000 veri setinde bulunan lezyonları 7 farklı sınıfa ayırmış ve doğrulama veri seti üzerinde %92 ortalama doğruluk elde etmişlerdir. Kawahara vd. (2016) Dermofit görüntü kitaplığında bulunan farklı cilt lezyonlarını 5 sınıfa ayırmış ve %85,8 doğruluk elde etmişlerdir. Kassem vd. (2020) cilt lezyonları 8 farklı kategoride sınıflandırmışlardır ve %80.36 precision ile %79.8 recall değerine ulaşmışlardır. Tez kapsamında yapılan çalışmada ise önerilen yöntem ile cilt lezyonları 7 farklı kategoride sınıflandırılarak doğrulama kümesi üzerinde %90 doğruluk,%99 AUC , %86 precision ve %83 recall değeri elde edildi. Test kümesi üzerinde ise %84 doğruluk, %98 AUC , %78 precision ve %77 recall değeri elde edildi.

Tablo 7. 6. Çok sınıflı cilt lezyonu sınıflandırma çalışmalarının performansı

Yazar	Veri Kümesi	Ön İşlem	Veri Artırma	Sınıflandırıcı	Doğruluk
Kawahara (2016)	Dermofit	+	+	CNN	% 85.8
Kassani ve Kassani	ISIC 2018	+	+	CNN	% 92
Kassem vd. (2020)	ISIC 2019	-	+	CNN	% 94
Sınıflandırma Görevi 3	ISIC 2018	+	+	CNN	% 90

Elde edilen sonuçlar literatürde yapılan çalışmalarla benzer sonuçlar gösterirken tez kapsamında yapılan çalışmada ön işlemsiz yapılan sınıflandırma işlemi sonuçlarına göre büyük oranda atış göstermektedir.

Önerilen yöntem ile tüm sınıflandırma görevlerinde elde edilen değerler ön işlemsiz sınıflandırma sonuçlarına göre daha iyi sonuç vermiş olup çalışma sonucunda elde edilen değerler dermatologlara cilt kanseri tespitinde kötü huylu cilt lezyonlarının tespiti için umut verici olmakla birlikte gereksiz biyopsilerin azaltılmasında ikinci bir görüş olarak kullanılabileceğini göstermektedir.

8. SONUÇ

Cilt kanserinin görülme sıklığı dünya genelinde hızla artmaktadır. Cilt kanseri türleri arasında en az görülmesine rağmen ölüm oranı en yüksek olan melanomun erken tespit edilmesi hastalığın tamamen ortadan kaldırılması açısından çok önemlidir. Melanom tespiti için uzman dermatologlar tarafından kullanılan yöntem dermoskopi taraması olsa da kesin sonuç biyopsi ile elde edilmektedir. Bu çalışmada kötü huylu cilt lezyonlarının tespit edilmesi için yapay zekâ temelli BDT sistemi önerilmiştir.

Tez kapsamında 3 farklı sınıflandırma görevi ile önerilen yöntemin performansı değerlendirilmiştir. Sınıflandırma Görevi 1’de kötü huylu melanomları iyi huylu tüm cilt lezyonlarından ayırmaya çalışılmıştır. Önerilen yöntem ile veri setinde bulunan görüntüler üzerinde test kümesi için DenseNet-121 mimarisi ile en başarılı sonuçlar olan %92 doğruluk, %91 AUC, %88 precision, %74 recall ve %79 F-Score değeri elde edilmiştir. Sınıflandırma Görevi 2’de kötü huylu cilt lezyonları ile iyi huylu cilt lezyonları ayırmaya çalışılmıştır. Önerilen yöntem ile veri setinde bulunan görüntüler üzerinde test kümesi için ResNet-152 mimarisi ile en başarılı sonuçlar olan %89 doğruluk, %91 AUC, %85 precision, %81 recall ve %83 F-Score değeri elde edilmiştir. Sınıflandırma Görevi 3’de veri setinde bulunan cilt lezyonları 7 kategoride sınıflandırılmıştır. Önerilen yöntem ile veri setinde bulunan görüntüler üzerinde test kümesi için ResNet-152 mimarisi ile en başarılı sonuçlar olan %84 doğruluk, %98 AUC, %78 precision, %77 recall ve %78 F-Score değeri elde edilmiştir.

Tüm sınıflandırma görevlerinde önerilen yöntem ile ön işlem uygulanan görüntüler ve ön işlem uygulanmayan orijinal görüntüler üzerinde gerçekleştirilen sınıflandırma işlemleri karşılaştırılmıştır. Kötü huylu cilt lezyonlarının tespiti için önerilen yöntemin büyük oranda daha başarılı olduğu ve sınıflandırma doğruluğunu artırdığı görülmüştür. Elde edilen sonuçlar, cilt kanseri için önerilen BDT sisteminin, teşhis aşamasında dermatoloji uzmanlarına süreci hızlandırıcı, yardımcı bir bilgi kaynağı olarak kullanılabileceğini göstermektedir.

Veri seti incelendiğinde, hasta görüntülerinin tamamının beyaz tenli insanlardan elde edildiği anlaşılmaktadır. Bu nedenle farklı ten rengine sahip ırklar için yöntemin başarımının testi zorlaşmaktadır. Öte yandan elde var olan

veri setlerinin bu konuda sunabileceđi kaynaklar da sınırlıdır. Bu durumda gelecek alıřması olarak, yapay veri üretim yöntemlerinin ten rengi farklı ırklarda da veri kümesi oluřturma amaçlı kullanımı ile önerilen yöntemin etki alanının genişletilmesi önerilebilir.



KAYNAKLAR

- Abbas, Q., Celebi, M. E., Serrano, C., Garcia, I. F., Ma, G. (2013). Pattern classification of dermoscopy images: A perceptually uniform model. *Pattern Recognition*, 46(1), 86-97.
- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938.
- Ackley, D. H., Hinton, G. E., Sejnowski, T. J. (1985). A learning algorithm for Boltzmann machines. *Cognitive science*, 9(1), 147-169.
- Adegun, A. A., Viriri, S. (2019). Deep learning-based system for automatic melanoma detection. *IEEE Access*, 8, 7160-7172.
- Anitha, J. (2018), March. Identification of Melanoma in Dermoscopy Images Using Image Processing Algorithms. In *2018 International Conference on Control, Power, Communication and Computing Technologies (ICCPCT)* (pp. 553-557). IEEE.
- Anonymous, (2021). Cilt (Deri) Kanseri Belirtileri, Tedavisi Ve Korunma Yöntemleri. <https://www.memorial.com.tr/hastaliklar/cilt-deri-kanseri-belirtileri-tedavisi-ve-korunma-yontemleri#cilt-deri-kanserinin-belirtileri-nelerdir> (Erişim Tarihi: 11.05.2021)
- Anonymous, (2021). MathWorks. Convolutional Neural Networks. <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html> (Erişim Tarihi: 10.04.2021)
- Anonymous, (2021). Skin Cancer Foundation. Skin Cancer Information. <https://www.skincancer.org/skin-cancer-information/> (Erişim Tarihi: 08.02.2021)
- Argenziano, G., Fabbrocini, G., Carli, P., De Giorgi, V., Sammarco, E., Delfino, M. (1998). Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions: comparison of the ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis. *Archives of dermatology*, 134(12), 1563-1570.
- Ayan, E., Ünver, H. M. (2018). Data augmentation importance for classification of skin lesions via deep learning. In *2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)* (pp. 1-4). IEEE.
- Balaji, V. R., Suganthi, S. T., Rajadevi, R., Kumar, V. K., Balaji, B. S., Pandiyan, S. (2020). Skin disease detection and segmentation using dynamic graph cut algorithm and classification through Naive Bayes classifier. *Measurement*, 163, 107922.
- Biswal, A. (2021). Recurrent Neural Network (RNN) Tutorial for Beginners. <https://www.simplilearn.com/tutorials/deep-learning-tutorial/rnn> (Erişim Tarihi: 21.04.2021)
- Brinker, T. J., Hekler, A., Utikal, J. S., Grabe, N., Schadendorf, D., Klode, J., Von Kalle, C. (2018). Skin cancer classification using convolutional neural networks: systematic review. *Journal of medical Internet research*, 20(10), e11936.
- Capdehourat, G., Corez, A., Bazzano, A., Alonso, R., Musé, P. (2011). Toward a combined tool to assist dermatologists in melanoma detection from dermoscopic images of pigmented skin lesions. *Pattern Recognition Letters*, 32(16), 2187-2196.
- Cavaioni, F. (2017). Machine Learning: Unsupervised Learning — Clustering <https://medium.com/machine-learning-bites/machine-learning-unsupervised-learning-clustering-d686af2466e1> (Erişim Tarihi:05.04.2021).

- Celebi, M. E., Iyatomi, H., Stoecker, W. V., Moss, R. H., Rabinovitz, H. S., Argenziano, G., Soyer, H.P. (2008). Automatic detection of blue-white veil and related structures in dermoscopy images. *Computerized Medical Imaging and Graphics*, 32(8), 670-677.
- Celebi, M. E., Kingravi, H. A., Uddin, B., Iyatomi, H., Aslandogan, Y. A., Stoecker, W. V., Moss, R. H. (2007). A methodological approach to the classification of dermoscopy images. *Computerized Medical imaging and graphics*, 31(6), 362-373.
- Celebi, M. E., Wen, Q., Iyatomi, H., Shimizu, K., Zhou, H., Schaefer, G. (2015). A state-of-the-art survey on lesion border detection in dermoscopy images. *Dermoscopy image analysis*, 10, 97-129.
- Cinarer, G., Emiroglu, B. G. (2020). Classification of brain tumours using radiomic features on MRI. *New Trends and Issues Proceedings on Advances in Pure and Applied Sciences*, (12), 80-90.
- Codella, N. C., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., Halpern, A. (2018). Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC). In *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)* (pp. 168-172). IEEE.
- Combalia, M., Codella, N. C., Rotemberg, V., Helba, B., Vilaplana, V., Reiter, O., Malvey, J. (2019). BCN20000: Dermoscopic lesions in the wild. *arXiv preprint arXiv:1908.02288*.
- Curtin, J. A., Busam, K., Pinkel, D., Bastian, B. C. (2006). Somatic activation of KIT in distinct subtypes of melanoma. *Journal of clinical oncology*, 24(26), 4340-4346.
- Curtin, J. A., Fridlyand, J., Kageshita, T., Patel, H. N., Busam, K. J., Kutzner, H., Bastian, B. C. (2005). Distinct sets of genetic alterations in melanoma. *New England Journal of Medicine*, 353(20), 2135-2147.
- Daghrir, J., Tlig, L., Bouchouicha, M., Sayadi, M. (2020). Melanoma skin cancer detection using deep learning and classical machine learning techniques: A hybrid approach. In *2020 5th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)* (pp. 1-5). IEEE.
- Deepak, S., Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in biology and medicine*, 111, 103345.
- Doğan, F., Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
- Doshi, S. (2019). Various Optimization Algorithms For Training Neural Network <https://towardsdatascience.com/optimizers-for-training-neural-network-59450d71caf6> (Erişim Tarihi: 03.04.2021)
- Duchi, J., Hazan, E., Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7).
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
- Fırıldak, K., Talu, M. F. (2019). Evrimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Bilgisayar Bilimleri*, 4(2), 88-95.

- Filali, Y., Ennoui, A., Sabri, M. A., Aarab, A. (2018). A study of lesion skin segmentation, features selection and classification approaches. In *2018 International Conference on Intelligent Systems and Computer Vision (ISCV)* (pp. 1-7). IEEE.
- Garbe, C., Peris, K., Hauschild, A., Saiag, P., Middleton, M., Spatz, A., Eggermont, A. (2010). Diagnosis and treatment of melanoma: European consensus-based interdisciplinary guideline. *European journal of cancer*, 46(2), 270-283.
- Giotis, I., Molders, N., Land, S., Biehl, M., Jonkman, M. F., Petkov, N. (2015). MED-NODE: A computer-assisted melanoma diagnosis system using non-dermoscopic images. *Expert systems with applications*, 42(19), 6578-6585.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Bengio, Y. (2014). Generative adversarial networks. *arXiv preprint arXiv:1406.2661*.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354-377.
- Gupta, N. (2013). Artificial neural network. *Network and Complex Systems*, 3(1), 24-28.
- Gutman, D., Codella, N. C., Celebi, E., Helba, B., Marchetti, M., Mishra, N., Halpern, A. 2016. Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (ISBI) 2016, hosted by the international skin imaging collaboration (ISIC). *arXiv preprint arXiv:1605.01397*.
- Harangi, B. (2018). Skin lesion classification with ensembles of deep convolutional neural networks. *Journal of biomedical informatics*, 86, 25-32.
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hinton, G. E. (2009). Deep belief networks. *Scholarpedia*, 4(5), 5947.
- Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Howard, J., Gugger, S. (2020). Fastai: A layered API for deep learning. *Information*, 11(2), 108.
- Huang, C., Li, X., Wen, Y. (2021). AN OTSU image segmentation based on fruitfly optimization algorithm. *Alexandria Engineering Journal*, 60(1), 183-188.
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- Ioffe, S., Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456). PMLR.
- Ismail, K. E., AbouRizka, M. A., Maghraby, F. A. (2020, October). Machine Learning Model for Multiclass Lesion Diagnoses. In *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)* (pp. 397-402). IEEE.
- İnik, Ö., Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.

- İnözü, E., Eryılmaz, A. T., Arpacı, E., Durgun, M., Horoz, U., Telliöğlü, A. T. (2012). Bazal Hücreli Karsinom: 5 Yıllık Deneyim. *Ortadoğu Medical Journal/Ortadoğu Tıp Dergisi*, 4(2).
- Jerant, A. F., Johnson, J. T., Sheridan, C. D., Caffrey, T. J. (2000). Early detection and treatment of skin cancer. *American family physician*, 62(2), 357-368.
- Jiang, H., Tang, S., Liu, W., Zhang, Y. (2021). Deep learning for COVID-19 chest CT (computed tomography) image analysis: A lesson from lung cancer. *Computational and Structural Biotechnology Journal*, 19, 1391-1399.
- Kaelbling, L. P., Littman, M. L., Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- Kang, D., Kim, S., Park, S. (2018). Flow-guided hair removal for automated skin lesion identification. *Multimedia Tools and Applications*, 77(8), 9897-9908.
- Kassani, S. H., Kassani, P. H. (2019). A comparative study of deep learning architectures on melanoma detection. *Tissue and Cell*, 58, 76-83.
- Kassem, M. A., Hosny, K. M., Fouad, M. M. (2020). Skin lesions classification into eight classes for ISIC 2019 using deep convolutional neural network and transfer learning. *IEEE Access*, 8, 114822-114832.
- Kawahara, J., BenTaieb, A., Hamarneh, G. (2016, April). Deep features to classify skin lesions. In *2016 IEEE 13th international symposium on biomedical imaging (ISBI)* (pp. 1397-1400). IEEE.
- Khan, S., Islam, N., Jan, Z., Din, I. U., Rodrigues, J. J. C. (2019). A novel deep learning based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recognition Letters*, 125, 1-6.
- Kızrak, A. (2019). Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması <https://ayyucekizrak.medium.com/derin-öğrenme-için-aktivasyon-fonksiyonlarının-karşılaştırılması-cee17fd1d9cd> (Erişim Tarihi: 15.04.2021).
- Kingma, D. P., Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kittler, H., Pehamberger, H., Wolff, K., Binder, M. J. T. I. O. (2002). Diagnostic accuracy of dermoscopy. *The lancet oncology*, 3(3), 159-165.
- Kizilbey, K., Akdeste, Z. M. (2013). Melanoma Cancer. *Sigma: Journal of Engineering & Natural Sciences/Mühendislik ve Fen Bilimleri Dergisi*, 31(4).
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- Ławrynowicz, A., Tresp, V. (2014). Introducing machine learning. *Perspectives on Ontology Learning*, 12, 19.
- Lawton, S. (2019). Skin 1: The structure and functions of the skin. *Nurs. Times*, 115, 30-33.
- LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-444 doi: 10.1038/nature14539
- LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.

- Lopez, A. R., Giro-i-Nieto, X., Burdick, J., Marques, O. (2017). Skin lesion classification from dermoscopic images using deep learning techniques. In *2017 13th IASTED international conference on biomedical engineering (BioMed)* (pp. 49-54). IEEE.
- Louridas , P., Ebert, C. (2016). Machine Learning. *IEEE Software*, 33(5), pp. 110-115.
- Luckert, M., Schaefer-Kehnert, M. (2016). Using machine learning methods for evaluating the quality of technical documents. Master Thesis, Linnaeus University, Faculty of Technology, Department of Computer Science, Kalmar, Sweden.
- Madan, V., Lear, J. T., Szeimies, R. M. (2010). Non-melanoma skin cancer. *The lancet*, 375(9715), 673-685.
- Mahmood, D., Ahlam, F., & Mahmood, H. A. (2015). Artifact Removal from Skin Dermoscopy Images to Support Automated Melanoma Diagnosis. *Al-Rafidain Engineering Journal (AREJ)*, 23(5), 22-30.
- Maind, S. B., Wankar, P. (2014). Research paper on basic of artificial neural network. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2(1), 96-100.
- Majumder, S., Ullah, M. A. (2018, December). Feature extraction from dermoscopy images for an effective diagnosis of melanoma skin cancer. In *2018 10th International Conference on Electrical and Computer Engineering (ICECE)* (pp. 185-188). IEEE.
- Maltarollo, V. G., Honório, K. M., & da Silva, A. B. F. (2013). Applications of artificial neural networks in chemical problems. *Artificial neural networks-architectures and applications*, 203-223.
- McCulloch, W. S., Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Mendonça, T., Ferreira, P. M., Marques, J. S., Marcal, A. R., & Rozeira, J. (2013). PH 2-A dermoscopic image database for research and benchmarking. In *2013 35th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 5437-5440). IEEE.
- Menzies, S. W., Ingvar, C., Crotty, K. A., McCarthy, W. H. (1996). Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features. *Archives of Dermatology*, 132(10), 1178-1182.
- Minsky, M. (1961). Steps toward artificial intelligence. *Proceedings of the IRE*, 49(1), 8-30.
- Mittal, A. (2019). Understanding RNN and LSTM. <https://aditi-mittal.medium.com/understanding-rnn-and-lstm-f7cdf6dfc14e> (Erişim Tarihi: 20.04.2021)
- Monika, M. K., Vignesh, N. A., Kumari, C. U., Kumar, M. N. V. S. S., Lydia, E. L. (2020). Skin cancer detection and classification using machine learning. *Materials Today: Proceedings*, 33, 4266-4270.
- Montalt-Tordera, J., Muthurangu, V., Hauptmann, A., Steeden, J. A. (2021). Machine learning in Magnetic Resonance Imaging: Image reconstruction. *Physica Medica*, 83, 79-87.
- Murugan, A., Nair, S. A. H., Preethi, A. A. P., Kumar, K. S. (2021). Diagnosis of skin cancer using machine learning techniques. *Microprocessors and Microsystems*, 81, 103727.

- Nair, V., Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In Proceedings of the International Conference on Machine Learning (ICML), 807-814
- Narayanamurthy, V., Padmapriya, P., Noorasafin, A., Pooja, B., Hema, K., Nithyakalyani, K., Samsuri, F. (2018). Skin cancer detection using non-invasive techniques. *RSC advances*, 8(49), 28095-28130.
- Nwankpa, C., Ijomah, W., Gachagan, A., Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- Olah, C. (2015). Understanding LSTM Networks. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (Erişim Tarihi: 11.05.2021)
- Oliveira, R. B., Papa, J. P., Pereira, A. S., Tavares, J. M. R. (2018). Computational methods for pigmented skin lesion classification in images: review and future trends. *Neural Computing and Applications*, 29(3), 613-636.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Pacal, I., Karaboga, D., Basturk, A., Akay, B., Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, 104003.
- Patwardhan, S. V., Dai, S., Dhawan, A. P. (2005). Multi-spectral image analysis and classification of melanoma using fuzzy membership based partitions. *Computerized Medical Imaging and Graphics*, 29(4), 287-296.
- Pehamberger, H., Steiner, A., Wolff, K. (1987). In vivo epiluminescence microscopy of pigmented skin lesions. I. Pattern analysis of pigmented skin lesions. *Journal of the American Academy of Dermatology*, 17(4), 571-583.
- Premaladha, J., Ravichandran, K. S. (2016). Novel approaches for diagnosing melanoma skin lesions through supervised and deep learning algorithms. *Journal of medical systems*, 40(4), 1-12.
- Proksch, E., Brandner, J. M., Jensen, J. M. (2008). The skin: an indispensable barrier. *Experimental dermatology*, 17(12), 1063-1072.
- Provost, F., Kohavi, R. (1998). Glossary of terms. *Journal of Machine Learning*, 30(2-3), 271-274.
- Psaty, E. L., Halpern, A. C. (2009). Current and emerging technologies in melanoma diagnosis: the state of the art. *Clinics in dermatology*, 27(1), 35-45.
- Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), 145-151.
- Qiao, L., Zhu, Y., Zhou, H. (2020). Diabetic retinopathy detection using prognosis of microaneurysm and early diagnosis system for non-proliferative diabetic retinopathy based on deep learning algorithms. *IEEE Access*, 8, 104292-104302.
- Quang, N. H. (2017). Automatic skin lesion analysis towards melanoma detection. In *2017 21st Asia Pacific Symposium on Intelligent and Evolutionary Systems (IES)* (pp. 106-111). IEEE.
- Rashid, H., Tanveer, M. A., Khan, H. A. (2019). Skin lesion classification using GAN based data augmentation. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 916-919). IEEE.

- Rey-Barroso, L., Peña-Gutiérrez, S., Yáñez, C., Burgos-Fernández, F. J., Vilaseca, M., Royo, S. (2021). Optical Technologies for the Improvement of Skin Cancer Diagnosis: A Review. *Sensors*, 21(1), 252.
- Richardson, M. (2003). Understanding the structure and function of the skin. *Nursing times*, 99(31), 46-48.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Fei-Fei L. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3): 211-252.
- Sahla, N. (2018). A Deep Learning Prediction Model for Object Classification. Master Thesis, Delft University of Technology, Faculty of Mechanical, Maritime and Materials Engineering, Delft, Netherlands.
- Salido, J. A., Ruiz JR, C. (2018). Hair artifact removal and skin lesion segmentation of dermoscopy images. *Asian Journal of Pharmaceutical and Clinical Research*, 11(3).
- Saravanan, S., Heshma, B., Shanofar, A. A., Vanithamani, R. (2020). Skin cancer detection using dermoscope images. *Materials Today: Proceedings*, 33, 4823-4827.
- Schadendorf, D., Fisher, D. E., Garbe, C., Gershenwald, J. E., Grob, J. J., Halpern, A., Hauschild, A. (2015). Melanoma. *Nature reviews Disease primers*, 1(1), 1-20.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Sharma, S., Sharma, S. (2017). Activation functions in neural networks. *Towards Data Science*, 6(12), 310-316.
- Shorten, C., Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1-48.
- Siegel, R. L., Miller, K. D., Fuchs, H. E., Jemal, A. (2021). Cancer Statistics, 2021. *CA: a Cancer Journal for Clinicians*, 71(1), 7-33.
- Simonyan, K., Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Singh, V., Nwogu, I. (2018). Analyzing Skin Lesions in Dermoscopy Images Using Convolutional Neural Networks. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 4035-4040). IEEE.
- Smith, L. N. (2017). Cyclical learning rates for training neural networks. In *2017 IEEE winter conference on applications of computer vision (WACV)* (pp. 464-472). IEEE.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Steiner, A., Pehamberger, H., Wolff, K. (1987). In vivo epiluminescence microscopy of pigmented skin lesions. II. Diagnosis of small pigmented skin lesions and early detection of malignant melanoma. *Journal of the American Academy of Dermatology*, 17(4), 584-591.
- Sutskever, I., Hinton, G. E., Taylor, G. W. (2009). The recurrent temporal restricted boltzmann machine. In *Advances in neural information processing systems* (pp. 1601-1608).

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Telea, A. (2004). An image inpainting technique based on the fast marching method. *Journal of graphics tools*, 9(1), 23-34.
- Thomas, L., Puig, S. (2017). Dermoscopy, Digital Dermoscopy and Other Diagnostic Tools in the Early Detection of Melanoma and Follow-up of High-risk Skin Cancer Patients. *Acta dermato venereologica*, 97.
- Thompson, J. F., Scolyer, R. A., Kefford, R. F. (2005). Cutaneous melanoma. *The Lancet*, 365(9460), 687-701.
- Tschandl, P., Rosendahl, C., Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific data*, 5(1), 1-9.
- Vidya, M., Karki, M. V. (2020, July). Skin Cancer Detection using Machine Learning Techniques. In *2020 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)* (pp. 1-5). IEEE.
- Waheed, Z., Waheed, A., Zafar, M., Riaz, F. (2017). An efficient machine learning approach for the detection of melanoma using dermoscopic images. In *2017 International Conference on Communication, Computing and Digital Systems (C-CODE)* (pp. 316-319). IEEE.
- Wang, H. X., Zhou, J. Q., Gu, C. H., Lin, H. (2019). Design of activation function in CNN for image classification. *Journal of Zhejiang University (Engineering Science)*, 53(7), 1363-1373.
- Wernick, M. N., Yang, Y., Brankov, J. G., Yourganov, G., Strother, S. C. (2010). Machine learning in medical imaging. *IEEE signal processing magazine*, 27(4), 25-38.
- Wong, S. C., Gatt, A., Stamatescu, V., McDonnell, M. D. (2016). Understanding data augmentation for classification: when to warp?. In *2016 international conference on digital image computing: techniques and applications (DICTA)* (pp. 1-6). IEEE.
- Xie, Y., Zhang, J., Xia, Y., Shen, C. (2020). A mutual bootstrapping model for automated skin lesion segmentation and classification. *IEEE transactions on medical imaging*, 39(7), 2482-2493.
- Yazan, E., Talu, M. F. (2017). Comparison of the stochastic gradient descent based optimization techniques. In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-5). IEEE.
- Yeşiloğlu, N., (2021). Kanser Nedir. <https://www.derikanseri.org/kanser-nedir> (Erişim Tarihi: 10.05.2021)
- Zeiler, M. D. (2012). Adadelata: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*.

ÖZGEÇMİŞ

Adı ve Soyadı: Kazım KILIÇ

Yabancı Dili: İngilizce

ORCID ID: <https://orcid.org/0000-0003-2168-1338>

Eğitim Durumu

Ön Lisans: Ondokuz Mayıs Üniversitesi / Samsun Meslek Yüksekokulu / Bilgisayar Programcılığı (2009)

Lisans: Yakın Doğu Üniversitesi / Atatürk Eğitim Fakültesi / Bilgisayar ve Öğretim Teknolojileri Öğretmenliği (2013)

Lisans: Ahmet Yesevi Uluslararası Türk-Kazak Üniversitesi / Mühendislik Fakültesi / Bilgisayar Mühendisliği (2018)

Yüksek Lisans: Ondokuz Mayıs Üniversitesi / Mühendislik Fakültesi / Bilgisayar Mühendisliği (2021)

Yayımlar

1. Ergün, E., Kılıç, K. (2021). Dermoskopi Görüntülerinin Klasik Makine Öğrenmesi Teknikleri ile Sınıflandırılması. 6. Çukurova Uluslararası Bilimsel Araştırmalar Kongresi, 5-6 Mart, 194-207, Adana, Türkiye. (Tam Metin Bildiri/Sözlü Sunum)
2. Ergün, E., Kılıç, K. (2021). Dermoskopi Görüntülerine Transfer Öğrenme Yöntemi Uygulanarak Melanomun Ayırt Edilmesi. 6. Çukurova Uluslararası Bilimsel Araştırmalar Kongresi, 5-6 Mart, 208- 219, Adana, Türkiye. (Tam Metin Bildiri/Sözlü Sunum)
3. Ergün, E., Kılıç, K. (2021). Derin Öğrenme ile Artırılmış Görüntü Seti üzerinden Cilt Kanseri Tespiti. Black Sea Journal of Engineering and Science. (Yayın sürecinde)