

T.C
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

DERMOSKOPİK GÖRÜNTÜLERDEN MELANOMANIN DERİN EVRİŞİMSEL
SİNİR AĞLARI İLE TEŞHİSİ

Enes AYAN

Aralık 2019

Bilgisayar Mühendisliği Anabilim Dalında Enes AYAN tarafından Dermoskopik Görüntülerden Melanomanın Derin Evrişimsel Sinir Ağları ile Teşhisi adlı Doktora Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Doç. Dr. Atilla ERGÜZEN

Anabilim Dalı Başkanı



Bu tezi okuduğumu ve tezin Doktora Tezi olarak bütün gereklilikleri yerine getirdiğini onaylarım.



Doç. Dr. Halil Murat ÜNVER

Jüri Üyeleri

Başkan : Doç. Dr. Necaattin BARIŞÇI



Üye (Danışman) : Doç. Dr. Halil Murat ÜNVER



Üye : Doç. Dr. Güvenç ARSLAN



Üye : Doç. Dr. Hüseyin POLAT



Üye : Dr. Öğr. Üyesi Bülent Gürsel EMİROĞLU



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

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Doktora derecesini onaylamıştır.



Prof. Dr. Recep ÇALIN

Fen Bilimleri Enstitüsü Müdürü



Aileme

ÖZET

DERMOSKOPİK GÖRÜNTÜLERDEN MELANOMANIN DERİN EVRİŞİMSEL SİNİR AĞLARI İLE TEŞHİSİ

AYAN, Enes

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi

Danışman: Doç. Dr. Halil Murat ÜNVER

Aralık 2019, 148 sayfa

Deri kanseri dünya genelinde son yıllarda oldukça sık karşılaşılan bir halk sağlığı sorunudur. Güneş ışınlarının zararlı etkisi sonucunda onarılamayan DNA hasarına bağlı olarak deri hücrelerinin kontrolsüz büyümesi ile ortaya çıkmaktadır. Farklı türleri bulunan deri kanserinin en tehlikelisi olan ve insan yaşamını tehdit eden türü melanomadır. Diğer deri kanserlerinin yayılma kapasiteleri sınırlı iken, melanomanın esas tehlikesi çok hızlı yayılmasıdır. Neyse ki melanoma erken teşhis edildiğinde %99 oranında tedavi edilebilir bir hastalıktır. Hastalığın teşhisi için dermoskop cihazı ile elde edilen dermoskopik görüntüler kullanılmaktadır. Hekimler tarafından incelenen görüntüler üzerinden elde edilen bilgiler ışığında lezyon şüpheli görülürse biyopsi yapılarak kesin teşhis konulmaktadır. Teşhis başarısı çoğunlukla hekim deneyimine bağlı olmakla birlikte öznelidir. Yanlış teşhisler sonucu gereksiz biyopsi sayılarında artış görülmektedir. Ayrıca hastalığın geç teşhis edilmesi de ortaya çıkan olumsuz durumlardan bir tanesidir. Bu nedenle, güvenilir otomatik melanoma tarama

sistemleri, hekimlerin kötü huylu cilt lezyonlarını mümkün olduğunca erken tespit etmeleri için çok yardımcı olacaktır.

Son beş yıl içinde derin öğrenme yöntemleri klasik görüntü işleme metotlarını geride bırakarak sınıflandırma problemlerinde büyük başarılar elde etmiştir. Özellikle evrişimsel sinir ağları medikal görüntüler üzerinden birçok hastalığın teşhisini başarı ile gerçekleştirmiştir. Bununla birlikte derin öğrenme yöntemlerinin başarı oranı kullanılan veri setinin büyüklüğü ile doğru orantılıdır. Bu çalışmada derin öğrenme yöntemlerinden evrişimsel sinir ağları vasıtası ile dermoskopik görüntülerden oluşan kısıtlı bir veri seti kullanılarak melanom olan lezyonların tespitine odaklanılmıştır. Bu amaçla üç aşamadan oluşan bir boru hattı mimarisi oluşturulmuştur. Önerilen mimarinin ilk aşaması lezyon üzerindeki kılların tespiti ve yok edilmesidir. Bu aşamada aktarım öğrenme yönteminden faydalanılarak Vgg tabanlı bir evrişim ağı ile üzerinde kıl olan lezyon tespit edildikten sonra üzerindeki kıllar çeşitli görüntü işleme yöntemleri ile temizlenmiştir. İkinci aşamada lezyonun sağlıklı dokudan ayrılmasıdır. Bu aşamada Yolov3 derin ağı görüntü içinde lezyonun bulunduğu bölgeyi tespit için düzenlenerek yeniden eğitilmiştir. Elde edilen yer bilgisi GrabCut algoritmasında kullanılarak lezyon bölgesi arka plandan ayrılmıştır. Son aşama ise lezyonun sınıflandırılmasıdır. Bu aşamada MobileNet, ResNet-50, Xception ağları aynı veri üzerinde ayrı ayrı eğitilerek test aşamasında oylama yöntemi ile sınıflandırma gerçekleştirilmiştir. Önerilen yöntemin ilk aşaması olan kılları tespit etme silmede %98 hassasiyet elde edilmiştir. Segmentasyon kısmında %90 hassasiyet ve en son sınıflandırmada ise %91 hassasiyet elde edilmiştir.

Anahtar kelimeler: Deri Lezyonları, Deri Kanseri, Melanoma, Derin Öğrenme, Evrişimsel Sinir Ağları, Bilgisayarlı Görü, Medikal Görüntü İşleme.

ABSTRACT

DIAGNOSIS OF MELANOMA IN DERMOSCOPIC IMAGES WITH DEEP CONVOLUTIONAL NEURAL NETWORKS

AYAN, Enes

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, Ph. D. Thesis

Supervisor: Assoc. Prof. Halil Murat ÜNVER

December 2019, 148 pages

Skin cancer is a common worldwide public health problem in recent years. It is caused by the uncontrolled growth of skin cells due to irreparable DNA damage as a result of the harmful effect of sunlight. Melanoma is the most dangerous type of different skin cancers that threaten human life. While the spreading capacity of other skin cancers is limited, the main danger of melanoma is its rapid spread. Fortunately, melanoma is a 99% curable disease when diagnosed in early stages. Dermoscopic images obtained with dermoscopic devices are used for the diagnosis of the disease. If the lesion is suspected in the light of the information obtained from the dermoscopic images examined by physicians, a definitive diagnosis is made by biopsy. The success of diagnosis depends on the experience of the physician and is subjective. The number of unnecessary biopsies increases due to misdiagnosis. In addition, late diagnosis of the disease is one of the emerging adverse conditions. Therefore, reliable automated melanoma screening systems will help physicians to detect malignant skin lesions as early as possible. In the last five years, deep learning methods have achieved great success in classification problems, leaving classical image processing methods behind.

Especially convolutional neural networks have successfully performed the diagnosis of many diseases through medical images. However, the performance of deep learning methods is directly proportional to the size of the used data set. This study focused on the detection of lesions with melanoma using a limited data set of dermoscopic images via convolutional neural networks, one of the deep learning methods. For this purpose, a pipeline architecture consisting of three phases has been created. The first stage of the proposed architecture is the detection and removing of the hairs on the lesion. At this stage, after the lesion on the hair was detected with a Vgg based convolutional neural network by using transfer learning method, the hairs on it were cleaned with various image processing methods. The second stage is the segmentation of the lesion from healthy tissue. At this stage, the Yolov3 deep network was rearranged and trained to detect the location of the lesion. Using the obtained location information of the lesion area, GrabCut algorithm segmented skin lesion from the background. The final stage is the classification of the lesion. At this stage, MobileNet, ResNet-50, Xception networks were trained separately on the same data and at the test stage, classification was performed by using a voting method. The first step of the proposed method is to detect hairs and remove, obtained 98% accuracy on ISBI 2017 dataset. In the same dataset, 90% sensitivity was achieved in the segmentation part. And finally, in the classification stage, 91% sensitivity was obtained.

Key words: Skin Lesions, Skin Cancer, Melanoma, Deep Learning, Convolutional Neural Networks, Computer Vision, Medical Image Processing.

TEŞEKKÜR

Tezimin hazırlanması esnasında hiçbir yardımı esirgemeyen ve biz genç araştırmacılara büyük destek olan, her zaman önümüzü açan, tez yöneticisi hocam, Sayın Doç. Dr. Halil Murat ÜNVER'e, tez çalışmalarım esnasında, bilimsel konularda yardımlarını gördüğüm hocalarım Sayın Doç. Dr. Necaattin BARIŞÇI ve Sayın Doç. Dr. Hüseyin POLAT'a teşekkür ederim.

Bu günlere gelmemde üzerimde emeği olan bütün öğretmenlerime ve hocalarıma, maddi manevi desteklerini üzerimden hiç eksik etmeyen her konuda beni destekleyen babama, anneme ve aileme, tez sürecinde gösterdikleri sabır ve destekten ötürü kızım Elif Naz'a ve eşim Rabia'ya sonsuz teşekkür ederim.

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	vi
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xiv
SİMGELER DİZİNİ	xv
KISALTMALAR DİZİNİ	xvi
1. GİRİŞ	1
1.1 Amaçlar	2
1.2 Araştırma Soruları	2
2. DERİN ÖĞRENME	5
2.1 Makine Öğrenmesi	5
2.1.1 Model İnşa Etme	8
2.1.2 Model Seçimi ve Değerlendirme	8
2.1.3 Aşırı Uyum ve Yetersiz Uyum (Overfitting ve Underfitting).....	9
2.1.4 Düzenlileştirme (Regularization)	10
2.1.5 Özellik Seçimi ve Çıkarımı	10
2.1.6 Neden Derin Öğrenme	11
2.2 Yapay Sinir Ağları	11
2.2.1 Sigmoid Nöronları.....	19
2.2.2 Geri Yayılım (Back Propagation)	21
2.2.3 Yapay Sinir Ağlarında Eğitim Türleri.....	26
2.3 Evrimsel Sinir Ağları (ESA)	27
2.3.1 Biyolojik Görsel Algı.....	27

2.3.2	Biyolojik Görsel Algıdan Bilgisayarlı Görüye Geçiş	30
2.4	Bilgisayarlı Görüde Evrişimsel Sinir Ağları	32
2.5	ESA'ların Temel Kavramları	32
2.5.1	Evrişimsel Katman (Convolutional Layer)	32
2.5.2	ESA'larda Aktivasyon ve Hata Fonksiyonları	37
2.5.3	Havuzlama (Pooling)	38
2.5.4	Tam Bağlı Katmanlar (Fully Connected Layers).....	39
2.5.5	Evrişimsel Sinir Ağlarında Aşırı Uyum ve Engelleme Yöntemleri.....	39
2.6	ESA Mimarisindeki Son Gelişmeler ve Tasarım Öğeleri	47
2.6.1	Sınıflandırıcı ESA	48
2.6.2	ESA'ların Segmentasyonda Kullanımı	56
2.7	GrabCut.....	64
3.	DERİ KANSERİ	68
3.1	Deri Lezyonları ve Deri Kanseri	68
3.1.1	Derinin Yapısı	68
3.1.2	Deri Kanseri Patolojisi	71
3.1.3	Tehlikeli Olmayan Deri Kanseri	72
3.1.4	Melanoma Deri Kanseri	74
3.1.5	Deri Kanseri Risk Faktörleri ve Korunma	75
3.1.6	Melanomanın Diğer Lezyonlardan Ayrılması	76
3.2	Deri Kanserinin Teşhisinde Kullanılan Makine Öğrenmesi Yöntemleri...	79
3.2.1	Veri Setleri	79
3.2.2	Klasik Makine Öğrenmesi Yöntemleri	80
3.2.3	Literatür: Derin Öğrenme Tabanlı Metotlar.....	83
3.2.4	Zorluklar.....	90
4.	MELANOMA TESPİTİ İÇİN ÖNERİLEN MODEL	91
4.1	Uygulama Ortamı.....	91
4.1.1	Programlama Dili ve Kütüphaneler	91
4.1.2	Donanımsal İhtiyaçlar	91
4.2	Çalışmada Kullanılan Veri Setleri	91

4.3	Deri Lezyonlarının Sınıflandırılması İçin Önerilen Boru Hattı Mimarisi .	93
4.4	Kılların Tespiti ve Temizlenmesi.....	93
4.4.1	Kılların Tespit Edilmesi	94
4.4.2	Kılların Temizlenmesi.....	96
4.5	Deri Lezyon Görüntülerinin Segmentasyonu.....	97
4.5.1	Lezyonlu Bölgenin Tespit Edilmesi.....	98
4.5.2	Lezyonlu Bölgenin Arka Plandan Ayrılması	101
4.6	Sınıflandırma.....	102
5.	ARAŞTIRMA SONUÇLARI	107
5.1	Değerlendirme Kriterleri.....	107
5.2	Kılların Doğru Tespit Edilme Sonuçları	110
5.3	Lezyon Segmentasyon Sonuçları	111
5.3.1	Görüntü İçerisinde Lezyon Yeri Tespit Sonuçları	112
5.3.2	Lezyon Segmentasyon Sonuçları	113
5.4	Sınıflandırma Sonuçları	114
6.	TARTIŞMA	119
7.	SONUÇ VE ÖNERİLER.....	124
	KAYNAKLAR	126
	ÖZGEÇMİŞ.....	147

ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
2.1 K- parça çapraz doğrulama yöntemi	9
2.2 Modelin uyum türleri	10
2.3 Sinir hücresinin yapısı [23]	12
2.4 Sinir hücresinde iletim aşamaları	13
2.5 Basit bir algılayıcı nöron	15
2.6 Çok katmanlı algılayıcılar	18
2.7 Sigmoid nöron	20
2.8 Yapay sinir ağlarında kullanılan bazı aktivasyon fonksiyonları	21
2.9 Sinir ağlarında geri yayılım [30]	21
2.10 Gösterilen w_{jk}^l ağırlık değeri $(l-1)$ katmandaki k . nöronundan l . katmadaki j . nörona bağlantı ağırlığını değerini temsil etmektedir [30].	23
2.11 Eşik değeri ve çıktı parametrelerinin gösterimi [30]	23
2.12 Beyinde yer alan nereden ve ne yolları [34]	27
2.13 İki görsel akışın basitleştirilmiş gösterimi: dorsal yol ve ventral yol [37]	28
2.14 İki görsel yolun organizasyonunun karşılaştırmalı gösterimi ve S ve C hücrelerinin istiflenmesi [38]	28
2.15 Fukushima'nın neocognitron mimarisi [48]	30
2.16 LeNet ESA mimarisi [49]	31
2.17 Evrişim operasyonu	33
2.18 Eğri bulmak için detektör filtre [50]	34
2.19 Örnek fare resmi [50]	35
2.20 Evrişim işleminin matematiksel hesabı [50]	35

2.21 Negatif sonuç [50].....	36
2.22 Eğitilmiş bir ağdan elde edilen filtreler [51]	37
2.23 ReLU fonksiyon grafiği	38
2.24 Havuzlama İşlemi [18].....	39
2.25 İletim sönümü yönteminin gösterimi, solda normal ağ sağda ise iletim sönümü uygulanmış bir ağ gösterilmektedir.....	40
2.26 Temel bir ESA mimari yapısı	42
2.27 Farklı katmanlarda yer alan öğrenilmiş filtreler [56]	43
2.28 ESA aktarım öğrenme stratejileri.....	45
2.29 Aktarım öğrenme veri seti ilişkisi.....	47
2.30 ESA modellerinin farklı kullanım alanları	47
2.31 AlexNet mimarisi [32]	48
2.32 Vgg-16 mimarisi [57].....	49
2.33 Inception modülü [58].....	50
2.34 Solda normal sağda ise GOH yöntemi [59]	51
2.35 ResNet'in artık bağlantıları [60]	52
2.36 Farklı ResNet mimarileri [60].....	53
2.37 Xception modelinde kullanılan derinlemesine ayrılabilir evrişim yaklaşımı [61]	53
2.38 Xception model mimarisi [61]	54
2.39 Derinlemesine ayrılabilir evrişim [62]	55
2.40 MobileNet mimarisi [62]	55
2.41 Segmentasyon işlemi (a) orijinal görüntü (b) lezyonun arka plandan yarılmış ikili görüntüsü(etiketi), (c) orijinal görüntü ile iki görüntünün birleştirilmesi sonucu elde edilen segmentasyon görüntüsü	56

2.42 FCN model mimarisi [63]	57
2.43 U-Net mimarisi [64].....	57
2.44 SegNet mimarisi [65]	58
2.45 Yolo lezyon yerini tespit aşamaları [67]	60
2.46 Kesişme yüzdesi hesaplama formülü	61
2.47 Sınırlayıcı kutuların içerdikleri parametreler [67]	62
2.48 DarkNet 53 mimarisi [68]	64
2.49 GrabCut yöntemi [71]	66
3.1 Derinin katmanları [72].....	69
3.2 Epidermisin katmanları [75]	70
3.3 Bronzlaşma yoluyla UV radyasyonuna maruz kalma, melanin üretimini artırarak cildin pigmentasyonunda değişikliklere neden olur [81]	71
3.4 Deri kanseri türleri [93].....	73
3.5 Melanoma yayılma süreci [100].....	75
3.6 ABCDE yöntemi [106]	77
3.7 Dermoskopik görüntü örneği [114].....	78
3.8 Dermoskopik görüntüler üzerinde bulunan; bulunan kıllar, mürekkep, siyah daire, cetvel, jel baloncukları ve aşırı aydınlatma gibi gürültüler [67]	81
3.9 Lezyon segmentasyonu	82
3.10 (a) gerçek görüntüleri temsil ederken (b) DCGAN, (c) LAPGAN, (d) PGGAN tarafından oluşturulmuş yapay görüntüleri göstermektedir [148].....	84
4.1 (a) ISBI 2017 veri setinden orijinal görüntü ve ikili segmentasyonu (b) PH2 veri setinden orijinal görüntü ve ikili segmentasyonu.....	92
4.2 Önerilen boru hattı mimarisinin adımları.....	93
4.3 Üzerinde kıl bulunan lezyonların temizlik işleminden sonraki durumları.....	94

4.4 Kılların tespit edilmesi için kullanılan aktarım öğrenme mimarisi.....	95
4.5 Kıl tespiti için eğitilen ESA'nın doğruluk ve hata eğrileri	96
4.6 Görüntü üzerinde bulunan kılların temizlenme adımları ve her bir adım sonrası görüntünün işlenmiş hali	97
4.7 Lezyonun görüntü içerisinde tespit edilmesi ve segmentasyonu	98
4.8 Yolov3 veri etiketleme işlemi	99
4.9 Görüntü içerisinde lezyon bölgesini tespit etmek için modifiye edilmiş Yolov3	100
4.10 Yolov3 tarafından yeri doğru tespit edilmiş örnekler.	101
4.11 Segmentasyon sonuçları.....	101
4.12 Sınıflandırma için önerilen oylama modeli.....	103
4.13 Çeşitli görüntü işleme yöntemleri ile orijinal görüntüden elde edilmiş yeni örnekler.	104
4.14 ResNet-50, MobileNet, Xception modellerinin eğitim sırasındaki doğruluk ve hata eğrileri.....	106
5.1 ROC eğrisi grafiği.....	108
5.2 Karmaşıklık matrisi.....	109
5.3 Eğitilen ESA ağının (a) ISBI 2017 ve (b) PH2 veri setlerinde kıl tespitinde elde ettiği karmaşıklık matrisleri ve ROC eğrileri.....	111
5.4 Yolov3 tarafından lezyon yerinin doğru tespit edildiği (a), (c) ve tespit edilemediği durumlar (b), (d) [67]	113
5.5 Önerilen yöntemin segmentasyon sonuçları (a) orijinal resim, (b) Yolov3 tarafından yeri tespit edilen lezyon, (c) istenilen segmentasyon, (d) önerilen yöntem ile elde edilen segmentasyon, (e) sonuç [67]	114
5.6 ResNet-50 ve Xception mimarilerinin ISBI 2017 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri.....	115

5.7 MobileNet ve Birleşim Modelin ISBI 2017 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri	116
5.8 ResNet-50 ve Xception mimarilerinin PH2 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri	117
5.9 MobileNet ve Birleşim Modelin mimarilerinin PH2 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri.....	118
6.1 (a) ve (c) üzerinde kıl bulunan bir görüntünün orijinal ve segmente edilmiş halini temsil ederken, (b) ve (d) aynı görüntülerin kıllardan arındırılmış hallerinin ve segmentasyon sonuçlarını temsil etmektedir.	119
6.2 (a) PH2 test verisinde ResNet-50 karmaşıklık matrisi (b) aynı veri setinde MobileNet karmaşıklık matrisi	121
6.3 Oylama yöntemi sayesinde doğru tespit edilmiş melanoma (a), (b), (c) ve normal (e), (f), (g) lezyon örnekleri.....	122

ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
4.1 ISBI 2017 ve PH2 veri setleri sınıf dağılımları.....	92
4.2 Modellere ait aktarım öğrenme detayları	105
5.1 Vgg tabanlı ESA'nın ISBI 2017 ve PH2 veri setlerinde kılıklı lezyonları tespit yüzdeleri.....	111
5.2 Yolov3'ün lezyon yeri tespit başarı oranı (%)	112
5.3 Önerilen yöntemin yüzde üzerinden segmentasyon sonuçları	114
5.4 Modellerin ISBI 2017 veri seti değerlendirmesi.....	115
5.5 Modellerin PH2 veri seti performans yüzdeleri	116
6.1 ISBI 2017 veri seti test edilmiş literatürdeki çalışmalar ile önerilen segmentasyon yönteminin karşılaştırılması	120
6.2 Önerilen yöntemin ISBI 2017 veri setindeki başarı oranının literatürdeki çalışmalar ile karşılaştırılması	122
6.3 ISBI 2017 veri setinde modellerin segmentasyon ve aktarım öğrenme yapılmadan elde ettikleri başarı oranları.....	123

SİMGELER DİZİNİ

λ Düzenleştirme parametresi

σ Aktivasyon fonksiyonu

Ω Düzenleştirme fonksiyonu

$\sum$ Toplam fonksiyonu

δ Sinir ağlarında hata

$\odot$ Hadamart ürünü



KISALTMALAR DİZİNİ

BDTS	Bilgisayar Destekli Teşhis Sistemi
MÖ	Makine Öğrenmesi
ESA	Evrişimsel Sinir Ağı/ Convolutional Neural Network
TBA	Temel Bileşen Analizi
GKM	Gaussian Karışım Modelleri
UVR	Ultraviyole Radyasyon
UV	Ultraviyole
ISIC	Uluslararası Deri Görüntüleme İş birliği / International Skin Imaging Collaboration
ISBI	Uluslararası Biyomedikal Görüntüleme Sempozyumu ISBI/ International Symposium on Biomedical Imaging
ILSVRC	ImageNet Büyük Ölçekli Görsel Tanıma Yarışması / ImageNet Large Scale Visual Recognition Competition
GOH	Global Ortalama Havuzlamaya/ Global Average Pooling
FCN	Tam Evrişimli Ağ/ Fully Convolutional Network
NMDK	Melanom Olmayan Deri Kanseri
AKD	Amerikan Kanser Derneği

RBE	Radyal Büyüme Evresi
DBE	Dikey Büyüme Evresi
DPO	Doğru Pozitif Oranı
YPO	Yanlış Pozitif Oranı
DRN	Derin Artık Ağ / Deep Residual Network
AUC	Eğri Altında Kalan Alan / Area Under Curve
ROC	ROC Eğrisi / Receiver Operating Characteristics
IOU	Intersection Over Union
CDNN	Evrişimsel Evrişimsel olmayan Sinir Ağı/ Convolutional-Deconvolutional Neural Network
FrCN	Tam Çözünürlük Evrişim Ağı/ Full Resolution Convolutional Network
DNN	Yoğun Evrişimsel olmayan Ağ/ Dense Deconvolutional Network
PI	Paralel Entegrasyon / Parallel Integration
MSE	Ortalama Kareler Hatası / Mean Square Error

1. GİRİŞ

Sürekli gelişip değişmekte olan teknoloji hayatımızın vazgeçilmez bir parçası haline gelmiştir. Gelişen teknoloji ile birlikte sürekli ilerlemeye ve araştırmaya açık olan tıp alanında, hekimler teşhis ve tedavi becerilerini geliştirmek için sonsuza kadar sürecek olan bir öğrenme süreci içerisindeyler. Doğru bir teşhis hastalığın tedavi sürecinde yer alan en önemli faktörlerden bir tanesidir. Bu süreçte ortaya çıkabilecek hatalar, yanlış tedaviye, tedavinin gecikmesine veya psikolojik hasarlara neden olmaktadır. Bu amaçla teşhis oluşumunun ve erişilebilirliğinin iyileştirilmesi tedavi sürecinde anahtar rol oynamaktadır [1]. Teşhis, iş birliğinin hayati bir önem taşıdığı karmaşık ve çok disiplinli bir süreçtir. Bu süreç içerisinde teşhise yardımcı olacak çeşitli araçlar ve yöntemlerden faydalanılmaktadır. Zaman içerisinde bilgisayarların oldukça yaygınlaşması ile birlikte medikal alanında kullanılmaları da kaçınılmaz hale gelmiştir. İlk örnekler 1960'lı yıllarda X-ray görüntülerini analiz eden bir bilgisayarın kullanılması ile ortaya çıkmıştır [2-4]. Ancak bu sistemlerin o yıllarda bilgisayarların sahip olduğu sınırlı görme yetenekleri, görüntü işleme kabiliyetleri ve donanımsal kısıtlar sebebi ile bir hekimin yerini alamayacağı ortaya çıkmıştır. Çeşitli etik ve ahlaki nedenler sebebi ile araştırmacılar bilgisayarlı otomatik teşhis yöntemleri yerine hekimlere teşhis sürecinde yardımcı olacak bilgisayar destekli teşhis sistemleri (BDTS) üzerinde yoğunlaşmışlardır [5].

Günümüzde farklı makine öğrenmesi yöntemleri ile tasarlanan BDTS birçok tıbbi alanda aktif olarak kullanılmaktadır. Söz konusu sistemler, bu örneklerle sınırlı olmamakla birlikte meme kanseri [6], akciğer kanseri [7], bazı beyin hastalıkları [8] ve diyabetik retinopati [9] gibi çeşitli hastalıkların tespitinde kullanılmaktadır. Makine öğrenmesi yöntemleri sadece teşhis süreci ile sınırlı kalmamakla birlikte, görüntü işleme, kişisel tedavi, elektronik sağlık kayıtları, büyük veri çalışmaları (gen haritaları), ilaç keşfi, robotik cerrahi gibi birçok alanda kullanılmaktadır. Makine öğrenmesinin bir alt dalı olarak ortaya çıkan derin öğrenme görüntülerin çok aşamalı işlenmesinden faydalanarak daha karmaşık özelliklerini ortaya çıkaran bir yöntemdir. Bu özellikler sayesinde yüksek başarıya sahip görüntü sınıflandırıcılar tasarlamak mümkün olmaktadır. Son beş yıl içinde derin öğrenme yöntemleri klasik görüntü işleme yöntemlerini geride bırakarak sınıflandırma problemlerinde büyük başarılar

elde etmiştir. Özellikle evrimsel sinir ağları medikal görüntüler üzerinden birçok hastalığın teşhisinde başarılı olmuştur.

1.1 Amaçlar

Bu çalışmada deri kanserinin teşhisi için derin öğrenme yöntemlerinin kullanımına odaklanılmaktadır. Deri kanserleri içerisinde en tehlikeli ve ölümcül kanser türü olan melanomanın görülme oranı son yıllarda oldukça artmıştır. Amerika Birleşik Devletleri'ndeki Amerikan Kanser Derneğinin yıllık raporuna göre 2019 yılında yaklaşık 96480 yeni melanoma vakası olması beklenirken, aynı yıl için de 7230 kişinin bu hastalıktan öleceği tahmin edilmektedir [10]. Melanoma %1,26 ölüm oranı ile diğer deri kanserleri içinde en ölümcül olanıdır [11]. Neyse ki erken teşhis edildiğinde %99 oranında tedavi edilebilir bir hastalıktır. Günümüzde deri lezyonlarının teşhisinde hekimler lezyonların bazı özelliklerini baz alan öznel yöntemler kullanmaktadır. Doğru teşhis koyma hekimin eğitimi, mesleki deneyimi ve vakayı yorumlamasına yüksek oranda bağlıdır. Kesin teşhis biyopsi işlemi ile anlaşılmakla birlikte, yanlış teşhisler sonucu gereksiz yere biyopsiler yapılmaktadır. Bu bilgiler ışığında gereksiz biyopsilerin önüne geçmek ve erken teşhis ile ölümleri engellemek için BDTS'ler önemli fırsatlar sunmaktadır.

Makine öğrenmesi yöntemleri kullanılarak deri lezyonlarının sınıflandırılması popüler bir çalışma alanıdır [12]. Geçmiş yaklaşımlar iki adımdan oluşmaktadır; birincisinde görüntü işleme yöntemleri kullanılarak el ile dizayn edilmiş özellikler çıkarılır. İkincisinde ilk adımda çıkarılan özellikler ile sınıflandırıcı algoritma eğitilmektedir. Bu yaklaşımlardaki darboğaz sonuçların tasarlanan özellik çıkarıcının başarısına bağlı olarak değişmesidir. Bu yöntemler hekimleri teşhis aşamasında kullandıkları görsel teşhis özelliklerini taklit etme eğilimindedirler. Buradan yola çıkarak bu tez çalışmasında kendi özelliklerini kendisi öğrenen derin öğrenme temelli bir melanoma tespit sistemi geliştirilmesi hedeflenmektedir.

1.2 Araştırma Soruları

Bu çalışmanın amacı derin öğrenme yöntemlerinden faydalanılarak az sayıda ve dengesiz veri seti ile deri kanserinin tespiti için kullanılacak bir boru hattı mimarisi oluşturmaktır. Oluşturulan mimari üç temel adımdan oluşmaktadır. Bunlar lezyon

üzerindeki gürültülerin temizlenmesi, lezyonun sağlıklı deriden ayrılması ve sınıflandırmanın yapılmasıdır. Bu çalışmanın amacını irdelemek için bazı araştırma soruları sormak gereklidir ve bu sorular aşağıdaki gibidir.

- 1- Hangi aktarım öğrenme konfigürasyonu deri kanserinin sınıflandırılmasında daha iyi sonuçlar vermektedir?

Daha önce ImageNet verisi ile eğitilmiş ve başarılı sonuçlar elde etmiş Vgg, ResNet, IncetionV3, Xception, MobileNet gibi derin ağların ağırlıklarını kullanarak deri kanseri verisi üzerindeki başarımların farklı konfigürasyonlar denenerek bir karşılaştırma yapılacaktır. Söz konusu ağların evrimsel katmanlarının özellik çıkarıcı olarak kullanıldığında elde edilen sonuçlar doğrultusunda ince ayarlar yapılarak en iyi aktarım öğrenme konfigürasyonunun elde edilmesi planlanmaktadır.

- 2- Medikal alanda veri elde etmenin zorluğunun sonucu olarak yetersiz veri veya veri içindeki sınıflara ait örneklerin dengesizliğinin sınıflandırmaya olan olumsuz etkisi (ezberleme) ve bu etkiyi azaltmak için alınması gereken önlemler nelerdir?

Dengesiz veri seti ile başa çıkmak için kullanılan yöntemlerden en önemlisi yapay veri çoğaltmadır. Eğitimde önce kullanılan bu yöntemde hem veri hem de özellik uzayı yapay olarak çoğaltılabilmektedir. Bu yöntem ile sayıca az olan sınıfın örnekleri temel alan kopyalar veya yapay örnekler ile veri seti dengelenmeye çalışılmaktadır. Ayrıca bu yöntem tüm veri seti üzerinde uygulanarak daha büyük bir veri seti elde etmek için de kullanılmaktadır. Eğitimden sonra test aşamasında değerlendirme kriterleri iyi seçilmeli, bu kriterler seçilirken dengesiz veri seti kullanıldığı göz önünde bulundurulmalıdır. Bu bağlamda deri lezyonlarının sınıflandırılmasında kullanılacak uygun veri çoğaltma yöntemleri ve değerlendirilme kriterleri belirlenerek kullanılacaktır.

Derin öğrenme yöntemlerinde çok sık ortaya çıkan aşırı uyum yani ezberlemeye dikkat edilmelidir. Özellikle önceden eğitilmiş derin ağlarda aşırı uyumun ne zaman ortaya çıkacağı ve engellemek için alınacak önlemler belirlenmelidir. Bu amaçla rastgele veri çoğaltma, iletim sönümü ve düzenlileştirme gibi yöntemlere başvurulacaktır.

- 3- Deri lezyon görüntülerinde ön işleme aşamalarının segmentasyon için önemi var mıdır?

Görüntü üzerindeki gürültülerden biri olan kılların segmentasyon performansına olan etkisi incelenecek, söz konusu kılların temizlenmesi için bir yöntem geliştirilecektir. Ayrıca segmentasyon yapılmış görüntüler ile yapılmamış görüntülerin sınıflandırma sonuçları karşılaştırılacaktır.

- 4- Farklı derin ağ mimarilerinin deri lezyonları veri seti üzerinde farklı özellikleri ayırma gücü var mıdır, bu güç tüm modellerin birleştirilerek deri lezyonlarının sınıflandırılmasında olumlu yönde kullanılabilir mi?

Farklı evrimsel ağların deri lezyonlarının sınıflandırmadaki performansları göz önünde bulundurularak her birinin güçlü yanı alınıp birleştirilmek sureti ile daha iyi bir sınıflandırıcının tasarlanması planlanmaktadır.

2. DERİN ÖĞRENME

Yirminci yüzyılın ortalarında Alan Turing tarafından makine öğrenmesi hakkında ileri sürülen fikirler hız kazanarak gerçekleşmeye devam etmektedir. Turing testi yapay bir sistemin insan ile etkileşime girmesi halinde akıllı olacağını varsayarken, başarı durumunu ise etkileşimde bulunan insanın bunun farkında olmamasına bağlamaktadır [13]. Böylelikle makine öğrenmesi sistemleri toplum içine entegre edilmiş halde, çevrim içi aramalardan, kişiselleştirilmiş pazarlama amaçlarına, finansal ve ekonomik tahminlere kadar birçok alanda kullanılabilir. Dahası makine öğrenmesi tıp dünyasına girmeye başlamıştır [14]. Makine öğrenmesi BDTS ve kişisel tedavi planlaması alanlarında ileriye dönük açık bir yol izlemektedir. Mevcut yöntemlerin popülaritesi göz önüne alındığında, tıp dünyasında inkâr edilemez derecede güçlü teknikler dikkat çekmektedir. Bu sebepten ötürü söz konusu alanda çalışanların da yöntemlerin çalışma prensipleri hakkında fikir sahibi olmaları önemlidir. Bu yüzden tezin bu bölümü okuyucunun derin öğrenme konseptini anlamasını, makine öğrenmesi tekniklerini kullanırken dikkat etmesi gereken kritik noktaları fark etmesini amaçlamaktadır. Bu bölümde temel makine öğrenmesi kavram ve terimlerinin açıklaması yapılmaktadır. Problemin biyolojik doğası ile birlikte sinir bilim ile makine öğrenmesi arasındaki etkileşim ele alınmaktadır. Bu kavramlar ile birlikte derin sinir ağlarının ortaya çıkış sürecine değinilmiştir. Farklı yapılarıdaki derin sinir ağları gözlemlenerek mimarileri ve çalışma prensipleri incelenmiştir. Bu nedenle bu bölüm deri lezyonlarının sınıflandırılması için kullanılan BDTS’lerde faydalanan sinir ağlarını temel seviyede tanıtmayı amaçlamaktadır. Hedeflenen sistem bir görüntü sınıflandırma problemi olduğu için bütün anlatımlar görüntüler üzerinden yapılacaktır.

2.1 Makine Öğrenmesi

Makine öğrenmesi, gerçek dünyadan elde edilen verilerin bilgisayara öğretilmesi veya bilgisayarın gerçek dünya ile etkileşimi sonucunda elde ettiği verileri işleyerek karar verme, anlama, yorumlama yeteneği kazanmasını sağlayan bir araştırma alanıdır [15]. T. Mitchell tarafından yapılan hesaplamalı öğrenme tanımına göre: “Bir bilgisayar programı deneyimlerinden (D) öğrendiği aynı sınıfa ait görevlerde (G) performansı (P)

ölçebilir. Eğer T görevlerindeki performansı P olarak ölçülürse, deneyimleri (D) gelişme gösterecektir” [16].

Görev: Eldeki bir verinin sahip olduğu bir dizi özellik kullanılarak istenilen çıktıya göre haritalandırılmasıdır. Daha somut bir örnek vermek gerekirse, bir görüntü sınıflandırma probleminde özellikleri ifade eden piksel değerleri, bazı görsel karakteristikler (kenar, köşe, şekiller) kullanılarak, sınıflandırmanın hedefini yani arzu edilen etiket ya da sınıf değerini elde etmektir. Makine öğrenmesi esas gücünü girişler ve çıkışlar arasında bulunan ve insan tarafından analiz edilemeyecek ilişkileri fark edip kullanabilmesinden almaktadır [15]. Klasik makine öğrenmesi yöntemlerinde problemlerin çözülmesi için veriden elde edilmesi gereken özellikler araştırmacı tarafından belirlenmektedir, bu durum problemin çözümünde araştırmacının deneyimini ön plana çıkarmaktadır. Derin öğrenme ile birlikte veri üzerinden kendi özelliklerini öğrenen öğrenme algoritmaları ortaya çıkarak araştırmacının deneyim faktörünü ortadan kaldırmıştır [17].

Performans: Makine öğrenmesi algoritmaları genel olarak N adet örnekten oluşan $x = \{x_1, \dots, x_N\}$ bir veri üzerinde eğitilir ve bu veriye eğitim seti denilmektedir. Bu verileri parametre olarak alan bir $f(x)$ fonksiyonu sayesinde girdi ve çıktı arasında bir ilişki elde edilir. Eğitim setindeki her bir verinin algoritma tarafından işleme alınması sonucu bir sonuç elde edilmektedir. Beklenen sonuç ile elde edilen sonuç arasındaki fark algoritmanın doğru çalışma performansını ortaya koymaktadır. Bu performansı ölçmek için nicel bir değerlendirme yapılması gerekmektedir. Bu değerlendirme için genellikle doğruluk yani algoritmanın doğruluk oranı tahmin ettiği sonuçlar ve hata oranı, algoritmanın yanlış tahmin ettiği sonuçlar kullanılmaktadır. Ancak bu ölçütlerin seçilmesi algoritmadan istenilen göreve göre de değişebilmektedir. Performans değerlendirmesinde diğer önemli bir noktada ise, algoritmanın performansının daha önce görmediği bir test verisi üzerinde yapılmasıdır.

Öğrenme: Bir makine öğrenmesi (MÖ) algoritmasının belirli bir görevi öğrenebileceği "deneyim", eğitim süreci boyunca sunulan mevcut verilere bağlı olarak değişebilmektedir [18]. Bu nedenle bir MÖ algoritmasının bir görevi yerine getirmesi için farklı öğrenme yöntemleri geliştirilmiştir.

Denetimli Öğrenme: Son yıllarda oldukça popüler olan bu öğrenme türünde MÖ sistemi girdilere karşılık etiketli çıktıları olan bir veri ile eğitilmektedir. Denetimli öğrenmede görev, bir x girdisinin istenilen hedef olan y çıktısı ile eşleştirilmesinden ibarettir. MÖ sistemi bu eşleşmeyi kendisine verilen bir x girdisi için daha önceki deneyimlerinden yola çıkarak bir y çıktısı üreterek elde etmektedir. Denetimli öğrenme problemleri sınıflandırma ve regresyon olmak üzere iki grup altında toplanmaktadır. Bir regresyon probleminde algoritmanın girdiye karşılık çıktısı gerçek veya sürekli bir değer olmaktadır. Bir kişinin yaşını tahmin etme, kilosunu tahmin etme veya satılık bir arabaya değer biçme regresyon problemine ait bazı örneklerdir. Sınıflandırma problemlerinde ise algoritmaya verilen girdi karşılığında algoritmanın cevabı bir kategori (sınıf) olmaktadır. Bir görüntü içinde belirlenen hastalığın varlığı ya da yokluğu veya bir mailin spam veya spam değil şeklinde ayrılması sınıflandırma problemlerine örnek olarak gösterilebilir.

Denetimsiz Öğrenme: Bu öğrenme türünde MÖ algoritması etiketi olamayan bir veri ile beslenerek bu verinin sahip olduğu gizli yapıyı ve ilişkileri keşfederek veri üzerinden bilgi elde eder. Popüler uygulamaları arasında kümeleme (benzer verileri bir arada gruptama), yoğunluk tahmini (girdi uzayında verinin olasılık dağılımının keşfedilmesi) yer almaktadır.

Pekiştirmeli Öğrenme: Pekiştirmeli öğrenmede sistem yalnızca etiketlenmemiş verileri alır. Ancak sistem, çevre ile etkileşimi sonucunda kendi performansı hakkında pozitif veya negatif geri bildirimler elde eder. Bu geri bildirimleri kullanarak öğrenir ve kendini adapte eder. Bir labirent robotunun labirent içini öğrenerek çıkışı bulması bu öğrenmeye örnek olarak gösterilebilir.

Yarı Denetimli Öğrenme ve Kendi Kendine Öğrenme: Denetimli ve denetimsiz öğrenmenin arasında kalan öğrenme yöntemidir. Bu öğrenme türünde kısmen etiketlenmiş veri seti kullanılmaktadır. Etiketlenmiş veri kümelerinin elde edilmesi zaman alıcı ve maliyetli bir işlemdir. Kullanıma açık olan etiketli veri setleri ise sınırlıdır. Bu nedenle, yarı denetimli öğrenmenin amacı, sınırlı bir etiketli veriyi öğrenmeyi geliştirmek için etiketlenmemiş verilerle desteklemektir. Bu öğrenme türünün daha gelişmiş versiyonu kendi kendine öğrenmede ise etiketli veri sınıflarının herhangi birinden olduğu tahmin edilmeyen etiketsiz verilerle destelenmektedir [19].

2.1.1 Model İnşa Etme

Bir MÖ algoritmasının oluşturulması için çeşitli adımlar vardır. Bu adımlar sırası ile şöyledir. İlk olarak bir model oluşturulur, oluşturulan model probleme ait veri ile beslenir, sonra bir maliyet fonksiyonu belirlenir ve bu maliyet fonksiyonu ile model içindeki parametreler değiştirilerek optimize edilmesi sağlanır. Bu sayede model probleme adapte olur. Genellikle denetimsiz öğrenmede amaç olasılık fonksiyonunu maksimize ederek modelin veri üzerinde başarısının artması veya girdi ve çıktılar arasında sağlıklı bir ilişki kurmasıdır. Bu durum denetimli öğrenmede, negatif log-olasılık maliyet fonksiyonun minimize edilmesi ile elde edilebilmektedir. Alternatif bir maliyet fonksiyonu olan ortalama kareler hatası (mean square error, MSE) ile beklenen çıktı ile modelin verdiği çıktı arasındaki farkın kareler toplamını hesaplar. Hesaplanan değerler minimize edilmeye çalışılarak modelin veri üzerindeki hakimiyetini artırılması amaçlanmaktadır. Farklı problemler için özel maliyet fonksiyonu seçilmesi modelin efektif eğitimi için önemli bir etmedir.

2.1.2 Model Seçimi ve Değerlendirme

Genel olarak bir model sadece kendi içinde bulunan parametrelerden p (ortalamalar, ağırlıklar, kovaryans matrisleri vb.) oluşmamaktadır. Bu parametrelerin yanında model için önemli olan modelin kurulumunda kullanılan hiper parametreler h (modelin türü, veri giriş özellikleri, boyut vb.) bulunmaktadır. Bu durumu bir fonksiyon ile ifade edecek olursak $f(p, h)$ olarak tanımlayabiliriz. Tüm hiper parametreler ayarlandığında, model eğitim esansında kendi parametrelerini optimize eder ve kendini test veri setini kullanarak değerlendirir. Modelin değerlendirilmesi aşamasında eğitim setinden tamamı ile farklı bir veri seti kullanabileceği gibi veri setinin küçük olduğu durumlarda çapraz doğrulama adı verilen bir yöntem ile eldeki az verinin mümkün olduğunca verimli kullanılması önerilmiştir [20]. Bu yöntemde veri seti k adet parçaya bölünür (k -parça çapraz doğrulama), her bir iterasyonda bir parça k eğitim dışı tutularak model $k-1$ parça ile eğitilir. Eğitim sonunda hariç tutulan veri parçası ile modelin doğruluğu test edilir. Bu durumu özetleyen bir görsel Şekil 2.1 'de gösterilmiştir.

İterasyon 1	Test	Eğitim	Eğitim	Eğitim	Eğitim
İterasyon 2	Eğitim	Test	Eğitim	Eğitim	Eğitim
İterasyon 3	Eğitim	Eğitim	Test	Eğitim	Eğitim
İterasyon 4	Eğitim	Eğitim	Eğitim	Test	Eğitim
İterasyon 5	Eğitim	Eğitim	Eğitim	Eğitim	Test


Şekil 2.1 K- parça çapraz doğrulama yöntemi

Devam eden iterasyonlar sonucu elde edilen doğruluk değerlerinin ortalamaları alınarak modelin veri seti üzerindeki performansı elde edilir. Daha sonra model tüm veri seti üzerinde eğitilebilir, daha önce elde edilen ortalama performans ise test performansı olarak değerlendirilir. Model belirleme aşamasında problem için belirlenen birden fazla model var ise ve bu modellerin biri seçilmek isteniyorsa, veri seti içerisinde doğrulama verisi olarak kullanılacak bir kısım eğitim verisinden hariç olarak ayrılması gerekmektedir. Bu durumda veri seti; eğitim, doğrulama ve test olmak üzere üçe ayrılarak kullanılır. Doğrulama veri seti sayesinde modellerin eğitim esnasında gösterdiği performans değerlerine bakılarak hiper parametreler düzenlenerek veriye uygun model seçilebilir. En son aşamada model test verisi üzerinde denenerek modelin veri üzerindeki performansı elde edilir.

2.1.3 Aşırı Uyum ve Yetersiz Uyum (Overfitting ve Underfitting)

Öğrenmenin temel amacı, eğitim seti ile eğitilen bir modelin eğitim sonunda test veri seti üzerinde başarılı sonuçlar elde etmesini sağlamaktır. Eğitilmiş bir modelin daha önce görmediği bir veri üzerinde başarı elde etmesi o modelin genelleme kapasitesinin ne kadar yüksek olduğunu göstermektedir. Modelin sahip olduğu parametrelerin sınırlı sayıda veri seti ile eğitilmesi sonucunda, iki istenmeyen durum ortaya çıkabilir. Bunlardan ilki aşırı uyum modelin eğitim verisi üzerinde gösterdiği başarıyı test verisi üzerinde gösterememesinden ortaya çıkan bir durumdur. Kısaca modelin eğitim verisini ezberlemesi olarak tanımlanabilir. Diğer bir istenmeyen durum olan yetersiz

uyum ise modelin eğitim setinde bile iyi sonuçlar vermemesine denilmektedir. Şekil 2.2 söz konusu durumları temsil eden bir görsel paylaşılmıştır.



Şekil 2.2 Modelin uyum türleri

Bu nedenle tasarlanan modelin verinin altında yatan eğilimleri yakalayacak kadar karmaşık, fakat veri içerisinde bulunan gürültüyü göz ardı edecek kadar esnek ve yeterli olması hedeflenmektedir.

2.1.4 Düzenleştirme (Regularization)

Aşırı uyumu önlemek için kullanılan yöntemlerden biri modelin karmaşıklığını kontrol altına almaktır. Model karmaşıklığını kontrol altına almak için modelin optimize edilmesi için kullanılan maliyet fonksiyonuna (M) bir ceza terimi eklenmektedir. Maliyet fonksiyonuna eklenecek düzenleştirme miktarı bir hiper parametre olan λ ile belirlenmektedir. Bununla birlikte yeni maliyet fonksiyonu ($M' = M + \lambda * \Omega$) ortaya çıkmaktadır [21]. En sık kullanılan düzenleştirme yöntemlerinin başında L1 ve L2 düzenleştirme yer almaktadır. Tezin ileriki bölümlerinde bu düzenleştirme yöntemlerine detaylıca değinilecektir.

2.1.5 Özellik Seçimi ve Çıkarımı

Aşırı uyumu engellemenin diğer bir yolu da modele verilecek olan veriden elde edilen, veriyi en iyi şekilde temsil eden özelliklerdir. Bu sayede girdi uzayı azaltılmış ve model gereksiz bilgiden arındırılmış olur. Özellik seçimi veri içerisindeki istenilen hedefe ulaşmak için gerekli olan bilgilerin çıkarılmasını amaçlamaktadır. Özellik çıkarımının diğer bir faydası da büyük boyutlardaki eğitim verisinden çıkarılan ve

veriyi temsil eden güçlü özellikler sayesinde hem verinin boyutunun düşürülmesi hem de girdiyi daha iyi temsil eden düşük boyutlu yeni bir eğitim verisi elde edilmesidir. Genellikle denetimsiz öğrenme yöntemleri Temel Bileşen Analizi (TBA) [22] yöntemi ile veri boyutunu düşürerek veriyi probleme uygun özellikler ile temsil etmek için kullanılırlar. TBA orijinal veri ile yansıma veri arasındaki farkın karelerini minimize ederek verinin boyutunu düşürmektedir. Herhangi bir makine öğrenmesi algoritmasına verilecek olan çok boyutlu verinin normalize edilmesi büyük önem arz etmektedir.


2.1.6 Neden Derin Öğrenme

Klasik MÖ yöntemleri şimdiye kadar çok sayıda problemde başarılı sonuçlar elde etmişlerdir. Fakat problemlerin karmaşıklığı ile birlikte veri boyutunun da artması ile birlikte bu yöntemlerin genelleme kabiliyeti düşmeye başlamıştır. Bilgisayarlı görmede yer alan bir problem olan nesne tanıma gibi daha karmaşık problemler söz konusu olduğunda klasik MÖ yöntemleri görüntüde yer alan çok boyutlu özellik uzayını genellemede başarılı olamamıştır. Nesne tanıma, ham piksel verilerine bakmak yerine artık daha yüksek seviye özelliklere bakmak; örneğin görüntü içindeki kenar, köşe, şekiller, yer bilgisi sınıflandırmada kullanılmaktadır. Geçmişte nesne sınıflandırma problemi iki aşama halinde çözüme kavuşturulmaktaydı. İlk aşamada akıllı bir özellik çıkarma algoritması tasarlanarak veriden özellik çıkartılırdı. Bu özellik çıkarma işlemi problem bağımlı olmakla birlikte uzman bilgisi gerektirmekteydi. İlk adıma göre daha kolay bir adım olan ikinci adımda ise veriden elde edilen özellikler bir sınıflandırıcıya verilerek süreç tamamlanmış olmaktadır. Fakat derin öğrenme ile birlikte herhangi bir uzman bilgisi gerektirmeden problemin çözümü için gerekli özellikleri veriden öğrenen sistemler ortaya çıkmaya başladı. Temsil öğrenme olarak da ismi geçen bu sistemler derin öğrenmenin altında yatan esas gücü barındırmaktadır [17]. Derin öğrenmeyi iyi kavrayabilmek için ilk olarak yapay sinir ağlarının iyi anlaşılması gerekmektedir.

2.2 Yapay Sinir Ağları

Nöronlar beyin yapı taşlarını oluşturarak temel bilgi taşıma görevini yerine getiren sinir hücrelerdir. Şekil 2.3' te gösterildiği gibi bir nöron üç ana parçadan oluşmaktadır. Bunlar dentrit, akson ve hücre gövdesidir. Bilgi nöron boyunca bir elektriksel sinyal olarak iletilmektedir. Bu elektriksel sinyale aksiyon potansiyeli denilir (AP). Hücreye


gelen girişler dentritler tarafından toplanarak hücre gövdesinde birleştirilir. Bu birleştirme sonucunda ortaya çıkan AP'ye bakılarak bir çıkış sinyali üretilip üretilmeyeceğine karar verilir. Eğer bir çıkış yapılacaksa AP sinyali aksonlar boyunca taşınarak diğer nöronlara iletilir. Nöronlar arasındaki bağlantılar ise sinaps adı verilen ve dentritlerde meydana gelen geçişlerle olmaktadır. Beyinde bir bilginin öğrenilmesi veya saklanması sinir hücreleri arasında gerçekleşen bir dizi elektriksel ve kimyasal olaylarla gerçekleştirilir. Nöronlar bilgi iletimi için kullandıkları AP'yi hücre duvarındaki voltajı değiştirerek oluştururlar. Söz konusu voltajı ise hücre içinde ve dışında dağılmış olan sodyum (Na), potasyum (K), kalsiyum (Ca) ve klor (Cl) gibi iyonları kullanarak elde ederler.



Şekil 2.3 Sinir hücresinin yapısı [23]

Sinir hücresine herhangi bir uyarı gelmemiş ise hücre dinlenme halindedir (polarizasyon). Bu durumda hücrede Na^+ iyonları dışarda K^+ iyonları içerde bulunmaktadır. Hücrenin dışı (+) yük ile, içi ise (-) yük ile yüklüdür ve bu haldeki elektriksel potansiyeli -70 mV'dur. Sinir hücresinin iki tarafındaki yük dağılımını ayarlayan mekanizmaya Na-K pompası denilmektedir. Dinlenme halinde iken bu pompa Na^+ 'yı içten dışa K^+ 'yı ise dıştan içe doğru pompalamaktadır. Bu değişim sonucu hücre içinde ve dışında elektriksel farklılıklar ortaya çıkar.

Polarize halde olan sinir hücresi iletme hazır demektir. Sinir hücresi uyarıldığında iç tarafa çok sayıda Na iyonu geçerken, az sayıda K iyonu hücre dışına çıkmaktadır. Bu durumda hücre içi pozitif, hücre dışı ise negatif yüklenir. Kutuplaşma bozulur ve bu sayede elektriksel yük değişimi oluşur. Oluşan bu yük değişimi eşik şiddetini aştı ise AP oluşturur ve iletim gerçekleştirilir. Bu duruma depolarizasyon denilmektedir. İletim bittiğinde ise hücre dinlenme haline geri döner ve bu duruma yeniden kutuplaşma (repolarizasyon) denir. Şekil 2.4'te iletim aşamaları sırası ile gösterilmiştir.



Şekil 2.4 Sinir hücresinde iletim aşamaları

Bilgisayar ortamında yapay bir sinir hücresi oluşturmak için biyolojik sinir hücrelerinin kilit noktaları göz önünde bulundurularak söz konusu kilit noktaların en uygun şekilde taklit edilmesi gerekmektedir. Bir nöronu, bilgi işlem birimi haline getirmek ve veriyi AP vasıtasıyla iletmek için aşağıdaki adımlar takip edilmelidir.

Giriş: Bir sinir hücresi diğer sinir hücrelerinden ortalama 10^3 ile 10^4 arasında giriş almaktadır [24]. Bu giriş sinyallerini bir vektör ile temsil edecek olursak $x = [x_1, x_2, \dots, x_n]$, olmak üzere n vektör içinde bulunan eleman sayısını temsil etmektedir.

Ağırlıklandırma: Sinapslar, postsinaptik terminalin zar potansiyelini etkileyen AP'nin değerini çeşitli yollarla değiştirir; nörotransmitter türü, değişken miktarda nörotransmitter salınımı, dendritik omurganın değişken büyüklüğü ve hacmi bu yollara örnek olarak gösterilebilir. Bu nedenle sinaptik bağlantının gücünü göstermek için her bir sinyal belirli bir ağırlıkla çapılır [25]. Bir nöronun n adet nörondan gelen

k adet girdiyi aldığını göz önünde bulundurursak ağırlık vektörümüz $w = [w_{1k}, w_{2k}, \dots, w_{nk}]$ olacaktır.

Birleştirme: Dendritik arborizasyonlar boyunca oluşan dağıtık sinyallerin ağırlıklılar ile çarpılıp toplanması işlemidir.


$$\mu_k = \sum_{i=1}^n w_{ik} x_i \quad (2.1)$$

Aktivasyon: Birleştirme işleminde elde edilen akım değeri akson boyunca hareket eder. Eğer membran potansiyelindeki uyarılma düzeyi belirli bir eşik değeri geçerse, bir AP değeri ateşlenir. Buradan yola çıkarak, aktivasyon fonksiyonu φ bir nöronun ne zaman ateşleneceğini ve çıkışın değer aralığını belirlemektedir. Genellikle aktivasyon fonksiyonuna eşik değer (bias) adı verilen b_k bir terim daha eklenerek aktivasyon fonksiyonu düzenlenir ve $v_k = \mu_k + b_k$ haline gelmektedir. Eşik değer teriminin eklenmesi ile birlikte v_k fonksiyonu k 'nci nöronun aktivasyon değerini temsil etmektedir [25]. Aktivasyon fonksiyonun diğer bir amacı ise nöron çıkışlarında var olan doğrusal olmayan (non-linear) yapının elde edilmesini sağlamaktır. Bu doğrusal olmayan çıktının elde edilmesi için sigmoid, tanh vb. gibi doğrusal olmayan çıktı üreten fonksiyonlar kullanılmaktadır. Ayrıca, aktivasyon fonksiyonun verdiği olasılık değerine göre nöronun aktif ya da pasif olduğu anlaşılabilir. Bir stokastik ikili nöronun iki durumu bulunmaktadır (aktif (durum+1) veya pasif (durum-1)). Bu amaçla yapay sinir ağlarında farklı aktivasyon türleri kullanılmaktadır Şekil 2.8'de en sık tercih edilen aktivasyon fonksiyonları ve bu fonksiyonlara ait grafikler gösterilmektedir [25].

Çıktı: Sonuç çıktısı formüle $y_k = \varphi(\mu_k + b_k) = \varphi(\sum_{i=1}^n w_{ik} x_i + b_k)$ göre elde edilen sayısal bir değerdir. Bu formüle alternatif olarak eşik değeri yerine ekstra bir giriş terimi $x_0 = 1$ ve ağırlık terimi $w_{0k} = b_k$ olarak eklendiğinde yeni çıktı formülü 2.2 elde edilmektedir.

$$y_k = \varphi\left(\sum_{i=0}^n w_{ik} x_i\right) \quad (2.2)$$

Özetle en basit hali ile bir algılayıcı birden fazla ikili (1-0) girdisi olan $x_1, x_2, \dots, x_n$ ve tek bir ikili çıktı üreten yapıdır. Şekil 2.5'te gösterilen algılayıcının x_1, x_2, x_3 olmak üzere üç girdisi ve bir adet çıkışı bulunmaktadır. Girdi sayısı çözülmek istenilen probleme göre artırılabilir veya azaltılabilir.



Şekil 2.5 Basit bir algılayıcı nöron

Bir sinir ağını denetimli makine öğrenmesi problemlerinde kullanmak için ağıın çıkıtısı problemin olası çözümlerinden oluşmalıdır. Ağıın çözmeye gereken problem türüne göre çıkış biriminde farklı aktivasyon fonksiyonları tercih edilmektedir. Bu problem türlerine yakından bakacak olursak:

Regresyon: Regresyon problemini açıklamadan önce sürekli değişken ve kesikli değişken kavramlarını açıklamak gerekmektedir. Sürekli değişken sonsuz değer kümesinden herhangi bir değeri alabilmek manasına gelirken kesikli değişken sonlu olası değerler kümesi içinden herhangi bir değerin alınmasıdır. Bu durumda regresyon problemleri sonsuz olası değerler kümesi içinden bir değerin tahmin edilmesine dayanmaktadır. Bunun sonucunda çıkış birimi doğrusal bir nöron olarak seçilir, belirleyici fonksiyon çıktının herhangi bir değere ulaşmasını sağlar. Örneğin satılık ev fiyatlarını tahmin eden bir ağı bir regresyon problemine çözüm üretiyor demektir.

İkili sınıflandırma: Tanımlanan bir görev için verilen x girdisine göre $C1$ ve $C2$ olmak üzere iki çıktı üreten sınıflandırma türüdür. Bu durumda ağıın sonunda tek çıkış doğrusal olmayan bir adet nöron ile temsil edilir. Yaygın olarak sigmoid nöronu seçilir. Çıktı olarak varsayılan $y=1$, sonucun $C1$ sınıfını işaret ettiğini belirtir. Sigmoid

fonksiyonun çıktısı C1 sınıfına ait girişin olasılığı olarak yorumlanmaktadır ($y(x, w) = p(C1, x)$). Bu çıkış birimlerinin sayısı artırılarak bu yöntem k adet ikili sınıflandırma görevi için kullanılabilir. Bu durumda k çıkış birimlerinin her birinin aktivasyon fonksiyonu sigmoid olur.

Çoklu Sınıflandırma: Sınıflandırma görevinde k adet sınıf bulunuyorsa, verilen bir x girdisi için sinir ağının çıkışında k adet nöron olacak şekilde ayarlanır. Söz konusu çıkış nöronları için sinir ağının k adet sınıf içi yapmış olduğu tahmin olasılıklarını veriler ve bu olasılıkların toplamı 1'e eşit olmalıdır. Bu durumu elde etmek için aktivasyon fonksiyonu olarak softmax kullanılır.

$$\sigma(z) = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}} \quad (2.3)$$


Yukarıda belirtilen kurallar çerçevesinde sinir ağlarının gelişim süreci şu şekilde olmuştur. İlk yapay sinir hücresi McCullogh ve Pitts tarafından 1943 yılında uygulamıştır [26]. Girdilerin doğrusal kombinasyonun belli bir eşik değeri geçmesi ile aktif hale gelen nöron yapısı basit bir elektrik devre ile gerçekleştirilmiştir. Daha sonra 1949 yılında Donald Hebb tarafından yapılan bir çalışmada nöronların algılama seviyelerinin kullanımlarına ve birlikte aktif hale gelmelerine bağlı olarak pozitif yönde bir artış gösterdiği kanıtlanmıştır [27]. McCullogh, Pitts ve Hebb tarafından yapılan çalışmaların teşviki ile birlikte ilk algılayıcı Rosenblatt tarafından 1957 yılında modellenmiştir. İkili sınıflandırma görevleri için tasarlanan bu modelde, gerçek girdiler ve ağırlıklar, belirlenen öğrenme kuralları ile birlikte görüntü sınıflandırma görevleri için kullanılmıştır. 1969 yılında Minsky ve Papert tek katman algılayıcı bir katman giriş düğümleri, bir katman çıkış düğümleri olmak üzere en basit sinir ağı mimarisini önermişlerdir [28]. Ancak daha sonra yapılan çalışmalar tek ünite algılayıcıların sadece doğrusal sınıflandırma problemlerinde başarılı olduklarını ortaya çıkarmıştır [24]. Tek katmanlı algılayıcıların (perceptron) sınıflandırma gücü, girdi olarak aldığı özelliklerden çok büyük ölçüde etkilenmektedir. Tek katmanlı algılayıcıların söz konusu dezavantajlarını aşmak için doğrusal olmayan gizli nöronlardan oluşan gizli katmanlar ağ mimarilerine eklenmiştir [29]. Bununla birlikte

çok katmanlı algılayıcılar veya derin ağlar ortaya çıkmıştır. Rosenblatt tarafından çıktıyı hesaplamada basit bir kural önerilmiştir. Bu kurala göre ilgili girdilerin çıktıya olan önemini ifade etmek için ağırlıklar, $w_1, w_2, \dots, w_n$ kullanılmıştır. Nöronun çıktı değeri olan 0 ya da 1 ağırlık değerlerinin girdiler ile çarpılıp toplanması $\sum_j w_j x_j$ sonucu elde edilen çıktının belirli bir eşik değerini geçmesi ile belirlenmektedir. Ağırlıklar gibi söz konusu eşik değeri de gerçek bir sayı ile temsil edilmektedir. Bir algılayıcının en basit hali ile matematiksel modeli formül 2.4 ile ifade edilebilir.

$$çıkı = \begin{cases} 0, & \text{eğer } \sum_j w_j x_j \leq \text{eşikdeğer} \\ 1, & \text{eğer } \sum_j w_j x_j > \text{eşikdeğer} \end{cases} \quad (2.4)$$

Ağırlık kavramını çok basit bir örnekle açıklanacak olursa: Bulduğumuz şehirde bir müzik festivali yapıldığını farz edelim. Müziği de çok sevdiğimizi düşünürsek bu festivale katılmak istiyoruz. Fakat katılma durumumuzu etkileyecek üç faktör var. Bunlar hava durumu, katılacak arkadaş ve festival yerine olan ulaşımın kolaylığı. Bu durumlara x_1, x_2, x_3 diyelim ve bunları temsilen ikilik sayı sistemini kullanalım. Örneğin hava yağmurlu ise $x_1 = 0$ olsun, güzel ise $x_1 = 1$ olsun, aynı şekilde festivale birlikte katılacak arkadaşımız var ise $x_2 = 1$, yok ise $x_2 = 0$ olsun ve son olarak festival yerine ulaşım kolay ise $x_3 = 1$ zor ise $x_3 = 0$ olsun. Giriş değerleri belirlendikten sonra sıra bu değerlere verilen önemi belirlemeye geldi. Örneğin kötü havalardan hiç hoşlanmıyorsunuz ve bu havalarda dışarı çıkmak istemiyorsunuz. Bu nedenle her bir durum için bir ağırlık değeri belirlemeniz gerekiyor. Bu durumda hava durumu için ağırlık değerimiz $w_1 = 6$ olsun diğer iki durum için ise $w_2 = 2$ ve $w_3 = 2$ değerlerini kullanalım. Burada kullandığımız ve en büyük ağırlık değerimiz olan w_1 hava durumunu çok önemsedığımızı diğer durumları hava durumuna göre daha az önemsedığımızı göstermektedir. Son olarak bir eşik değeri belirliyoruz örneğin eşik değerimiz 5 olsun. Bu parametrelere göre algılayıcı modelimiz hava güzel ise sonucu 1 değilse sonucu 0 gösterecektir. Festival için arkadaş olup olmaması ya da ulaşımın bir önemi yoktur. Buradan yola çıkıldığında, ağırlıkları ve eşik değerlerini değiştirerek

farklı karar verme modelleri elde edebiliriz. Örneğin festivale gitmek için oluşturduğumuz modelde eşik değerini 5 değil de 3 yapsaydık. Hava kötü olsa bile gidecek bir arkadaş ve ulaşım kolaylığı festivale gitmemiz için vereceğimiz kararda yeterli olacaktı. Başka bir değişle farklı bir karar verme modeli elde edilmiş olacaktı. Eşik değerini düşürmemiz festivale gitmeye daha istekli olduğumuz anlamına gelmektedir. Açıkçası, algılayıcı tam bir insan karar verme modeli değildir. Ancak, örneğin gösterdiği şey, bir algılayıcının karar vermek için farklı kanıt türlerini nasıl kullandığıdır. Bu sayede daha karmaşık ağlarda bulunan algılayıcıların davranışları hakkında fikir sahibi olmak mümkündür [30].



Şekil 2.6 Çok katmanlı algılayıcılar

Şekil 2.6' incelendiğinde, ilk katman algılayıcıları, girdiler ve ağırlıklarına bakarak üç basit karar vermektedir. İkinci katman algılayıcıları ise ilk katman algılayıcılarından gelen kararlar ve ağırlıklar doğrultusunda dört karar vermektedir. Bu şekilde ikinci seviyedeki algılayıcılar birinci seviyedekilere göre daha karmaşık ve daha soyut kararlar vermektedir. En son katmanda ise en karmaşık kararlar alınmaktadır. Bu yapı sayesinde çok katmanlı algılayıcılar karmaşık karar verme süreçlerinde kullanılabilir. Algılayıcılarda eşik değer (bias) b diye tabir edilen ve algılayıcının 1 çıktısını vermesini kolaylaştıran bir terim bulunmaktadır. Daha biyolojik bir ifade ile eşik değer; algılayıcının aktifleşmesinin ne kadar kolay olduğunun bir ölçüsüdür. Büyük eşik değerine sahip bir algılayıcının 1 çıktısı vermesi oldukça kolaydır. Bununla birlikte eğer eşik değeri büyük bir negatif değer ise algılayıcının 1 çıktısı vermesi oldukça zordur [30].


2.2.1 Sigmoid Nöronları

Yapılan araştırmalar sonucu algılayıcıların doğrusal sınıflandırma problemlerinde başarılı sonuçlar elde etmesine karşın, doğrusal olmayan problemlerde aynı başarıyı gösteremedikleri gözlemlenmiştir. Daha önce de bahsedildiği üzere ağırlıklar ve eşik değerlerdeki küçük değişimler sınıflandırmayı doğrudan etkilemektedir. Bazen bu değişim miktarı çok az bile olsa bir algılayıcının karar verme durumunu değiştirmekte 0 dediğine 1 diyebilmektedir. Bu durum bütün ağırlık davranışında değişikliğe neden olabilmektedir. Bu problemi çözmek için sigmoid nöron adı verilen yeni bir nöron türü önerilmiştir. Sigmoid nöronlar algılayıcılar ile benzer özellikler taşımalarına karşın bu nöronların ağırlık ve eşik değerlerinde yapılan küçük değişimlerin çıktılarına etkisi de küçük olmasını sağlayan bazı modifikasyonlar içermektedirler [30]. Sigmoid nöronlara biraz değinirsek; algılayıcı nöronlar gibi girdileri $x_1, x_2, \dots$ bulunmaktadır. Ancak bu girdilerin değerleri 0 ya da 1'den ziyade 0 ile 1 arasındaki değerlerden oluşmaktadır. Algılayıcı nöronlar gibi sigmoid nöronları da ağırlıklar ve eşik değere sahiptir. Sigmoid nöronlarının çıktısı 1 ya da 0 yerine σ sigmoid fonksiyonun çıktısıdır $\sigma(w.x + b)$. Bu fonksiyona aktivasyon fonksiyonu denilmektedir ve formül 2.5 ile ifade edilmektedir [30].

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.5)$$

$$\frac{1}{1 + e^{(-\sum_j w_j x_j - b)}} \quad (2.6)$$

Formüle biraz daha yakından bakacak olursak $z \equiv w.x + b$ sonucunun büyük bir pozitif sayı olduğunu varsayalım. $e^{-z} \approx 0$ olduğunda $\sigma(z) \approx 1$ olacaktır. Buradan yola çıkarak $z = wx + b$ büyük ve pozitif bir sayı olduğunda sigmoid nöronun çıktısı 1'e yaklaşırken tersi durumda 0'a yaklaşmaktadır. Sigmoid fonksiyonuna ait bir görsel Şekil 2.7'de verilmiştir.




Şekil 2.7 Sigmoid nöron

Ağırlıklarda ve eşik değerde meydana gelen küçük değişimler Δw_j ve Δb çıkışta $\Delta \text{Çıkış}$ değişiklikleri ortaya çıkarır.

$$\Delta \text{Çıkış} = \sum_j \frac{\partial \text{Çıkış}}{\partial w_j} \Delta w_j + \frac{\partial \text{Çıkış}}{\partial b} \Delta b \quad (2.7)$$


Çıktı fonksiyonun ağırlık ve eşik değerlerine göre kısmi türevleri toplamı kullanılarak elde edilen $\Delta \text{Çıkış}$ ağırlık ve eşik değerlerinin güncellenmesinde kullanılmaktadır. Formüle göre $\Delta \text{Çıkış}$ ağırlık Δw_j ve eşik değerdeki Δb değişikliklerin doğrusal bir fonksiyonudur. Bu doğrusallık sayesinde çıktıda elde edilmek istenen herhangi bir küçük değişiklik, ağırlıklar ve eşik değerlerde yapılacak küçük değişiklikler sayesinde elde edilebilir. Bu yüzden sigmoid nöronlar normal algılayıcı nöronlarla aynı niteliksel davranışa sahip olmasına rağmen ağırlıklar ve eşik değerlerdeki değişimlerin çıktıyı nasıl etkileyeceğini bulmak daha kolay hale gelmektedir. Burada σ sigmoid olarak tanımladığımız fonksiyona aktivasyon $f(\cdot)$ denilmektedir. Yapılan çalışmalar neticesinde yıllar boyunca farklı aktivasyon fonksiyonları kullanılmıştır. Şekil 2.8’de en popüler bazı aktivasyon fonksiyonları gösterilmektedir. Farklı bir aktivasyon fonksiyonu kullanıldığında değişen tek şey formül 2.7’de ki aktivasyon fonksiyonuna göre alınan kısmi türevler olacaktır.



Şekil 2.8 Yapay sinir ağlarında kullanılan bazı aktivasyon fonksiyonları

2.2.2 Geri Yayılım (Back Propagation)

Farz edelim ki elimizde çözülmesi gereken bir problem var ve bunu algılayıcılardan oluşan bir sinir ağını kullanarak yapmak istiyoruz. Bunu yapmak için ağ içindeki uygun ağırlık ve eşik değerlerini bulmak gerekmektedir. Ağırlık ve eşik değerlerini güncellemek için geri yayılım algoritması denilen bir algoritma kullanılmaktadır [30]. Geri yayılım algoritması ilk olarak 1970'li yıllarda önerilmesine karşın esas önemi David Rumelhart ve arkadaşları tarafından 1986 yılında yapılan bir çalışma ile ortaya çıkmıştır [31]. Geri yayılım algoritması sinir ağlarında öğrenme gücünün arkasında yatan en önemli faktördür (Şekil 2.9).




Şekil 2.9 Sinir ağlarında geri yayılım [30]

Geri yayılım algoritmasına detaylı bakıldığında: Oluşturulan yapay sinir ağından beklenti girdilere karşılık olarak bir çıktı üretmesidir, arzu edilen bu çıktıya $y(x)$ diyelim. Oluşturmuş olduğumuz ağın verdiği çıktı değeri ile beklenen çıktı değerini değerlendirecek bir maliyet (M) (kayıp) fonksiyonu belirleyelim, en bilinen örneği MSE'dir


$$M(w,b) = \frac{1}{2n} \sum_x \|y(x) - a\|^2 \quad (2.8)$$

Bu kayıp fonksiyonunda W ağdaki bütün ağırlıkları, b bütün eşik değerlerini, n toplam eğitim örneği sayısını ve a ise bir X girdisine karşı ağın üretmiş olduğu çıktıyı temsil etmektedir. Maliyet fonksiyonun negatif sonuç üretmediği görülmektedir. Eğer $M(w,b) \approx 0$ eşit olursa öğrenme algoritmamız iyi bir iş çıkarmakla birlikte uygun W ve b değerlerini bulmuş demektir. Maliyet fonksiyonu daha büyük değerler veriyorsa bu durumda amacımız maliyet fonksiyonunu minimize ederek hatayı düşürmektir [30]. Diğer bir değişle amaç en az hatayı verecek ağırlıkları ve eşik değerlerini bulmaktır. Mümkün olan en iyi sınıflandırma sonuçlarını elde etmek için model parametrelerinin optimizasyonu önemlidir. Bu optimizasyon sayesinde elde edilen bir dizi ağırlık W ve eşik değerleri b hata fonksiyonunu $M(w,b)$ minimize ederek istenilen sınıflandırma sonuçlarının elde edilmesini sağlamaktadır. Analitik olarak, bu durum hatayı en aza indiren ağırlık ve eşik değerleri bulmaktan geçer. Maliyet fonksiyonun minimize etmek için kullanılan en yaygın optimizasyon algoritmalarından biri gradyan inişidir (gradient descent). Geri yayılım algoritmasını detaylı olarak ele almadan önce formüllerde kullanılan bazı gösterimlere açıklık getirmek uygun olacaktır. Herhangi bir ağırlık değerini temsil etmek için w_{jk}^l gösterimini kullanacaktır. Bu gösterim $(l-1)$ 'inci katmanda bulunan k nöron ile l . katmanda bulunan j . nöron arasındaki ağırlığı temsil etmektedir. Şekil 2.10'da örneği gösterilmektedir.



Şekil 2.10 Gösterilen w_{jk}^l ağırlık değeri $(l-1)$ katmandaki k . nöronundan l .katmadaki j . nörona bağlantı ağırlığını değerini temsil etmektedir [30].

Aynı gösterim türünü eşik değeri için belirtecek olursak b_j^l , l . katmanda bulunan j . nörona ait eşik değerini temsil etmektedir. Nöronların çıkışlarını temsilen a_j^l , bu da l . katmanda bulunan j . nöronun aktivasyon değerini temsil etmektedir. Şekil 2.11 bu durumu temsil etmektedir.



Şekil 2.11 Eşik değer ve çıktı parametrelerinin gösterimi [30]

Herhangi bir katmandaki bir nöronun aktivasyon çıktısı a_j^l kendisinden önceki $(l-1)$ katmanda bulunan nöronların aktivasyon çıktıları ile ilişkilidir. Bu durum formül 2.9 ile ifade edilebilir.

$$a_j^l = \sigma \left(\sum_k w_{jk}^l a_k^{l-1} + b_j^l \right) \quad (2.9)$$

Yukarıdaki fonksiyonda her bir katmanda birden fazla nöron olduğu için girdiler, çıktılar, ağırlıklar ve eşik değerleri vektörel olarak düşünülmelidir. Bu durumda formül 2.9'u $a^l = \sigma(w^l a^{l-1} + b^l)$ şeklinde ifade edebiliriz. Yeni formüle göre a^l değeri hesaplanırken $z^l \equiv w^l a^{l-1} + b^l$ 'de hesaplanmaktadır. z^l bir katmanda yer alan tüm nöronların ağırlıklı giriş toplamalarını temsil eden vektördür. Herhangi bir katmandaki herhangi bir nöronun ağırlıklı giriş toplamı formülü 2.10'daki gibidir.

$$z_j^l = \sum_k w_{jk}^l a_k^{l-1} + b_j^l \quad (2.10)$$

Bu durumda aktivasyon vektörü $a^l = \sigma(z^l)$ formülüne göre de ifade edilebilmektedir. Geriye yayılım, bir ağdaki ağırlıklar ve önyargıların maliyet fonksiyonundaki değişim ile nasıl değiştiğini anlamakla ilgilidir. Geri yayılım algoritmasının arkasında bilinmesi gereken dört önemli formül bulunmaktadır. Geri yayılım algoritması beklenen çıktı ile ağın verdiği çıktı arasındaki hatayı kullanarak ağdaki ağırlıkları ve önyargıları güncellemektedir. Hata δ_j^l olarak temsil edilecek olursa, bu ifade l . katmanındaki j . nörona ait hatayı göstermektedir. Geri yayılım algoritması bu hatayı δ_j^l hesaplamak ve onu $\partial M / w_{jk}^l$ ve $\partial M / b_j^l$ ile ilişkilendirmek için bazı prosedürleri takip etmektedir [30].

$$\delta_j^l = \frac{\partial M}{\partial a_j^l} \sigma'(z_j^l) \quad (2.11)$$

Formül 2.11'de sağ taraftaki ilk terim $\partial M / a_j^l$, j . aktivasyon fonksiyonun maliyete göre nasıl değiştiğini ölçmektedir. İkinci terim $\sigma'(z_j^l)$ ise aktivasyon fonksiyonun z_j^l deki değişim hızını ölçmektedir. Formül 2.11'i matris formunda gösterecek olursak 2.12 gösterimi kullanabiliriz.

$$\delta^L = (a^L - y) \odot \sigma'(z_j^L) \quad (2.12)$$

Formülde gösterilen $\nabla_a M$ terimi kısmi türevlerin $\partial M / a_j^L$ vektörel gösterimini temsil etmektedir. $\nabla_a M = (a^L - y) = \partial M / a_j^L$ ile temsil edildiğinde formülün son hali 2.13'teki gibi olacaktır

$$\delta^L = \nabla_a M \odot \sigma'(z_j^L) \quad (2.13)$$

Bir sonraki katmandaki hatayı hesaplamak için bir önceki katmandaki hatalar kullanılmaktadır:

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z_j^l) \quad (2.14)$$

Formül 2.14'e göre çıkış katmanında ortaya çıkan hata ağda geriye doğru hareket ettirilmektedir. 2.11 ve 2.14 formüllerinin birleştirilmesi ile birlikte ağda istenilen katmandaki hatalar hesaplanmaktadır. Bir sonraki formülde ise ağdaki herhangi bir önyargıya bağlı olarak maliyet değişim oranını hesaplamak için kullanılan formül 2.15'dir.

$$\frac{\partial M}{\partial b_j^l} = \delta_j^l \quad \frac{\partial M}{\partial b} = \delta \quad (2.15)$$

Hata δ_j^l , $\partial M / b_j^l$ deki değişim oranına eşittir. Söz konusu hata formül 2.11 ve 2.14'te hesaplanmıştır. Bir sonraki denklem ise maliyet fonksiyonundaki değişim oranına göre ağırlıkların güncellenmesi için kullanılan formüldür.

$$\frac{\partial M}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad (2.16)$$

Formülde δ^l ve a^{l-1} kullanılarak $\partial M / \partial w_{jk}^l$ kısmı türevler hesaplanarak ağırlıklar güncellenmektedir.

Geri yayılım formüllerinin özeti

$$\begin{aligned} \delta^L &= (a^L - y) \odot \sigma'(z_j^L) \\ \delta^l &= ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z_j^L) \\ \frac{\partial M}{\partial b_j^l} &= \delta_j^l \\ \frac{\partial M}{\partial w_{jk}^l} &= a_k^{l-1} \delta_j^l \end{aligned} \quad (2.17)$$

Geri yayılım algoritmasının formülleri incelendiğinde neden geri yayılım denildiği daha net anlaşılmaktadır. Son katmandan başlayarak hata vektörleri geriye doğru hesaplanmaktadır. Bu hesaplama yöntemine zincir kuralı denilmektedir. Hesaplanan hata vektörleri kullanılarak ağırlıklar ve eşik değerleri güncellenmektedir [30].

2.2.3 Yapay Sinir Ağlarında Eğitim Türleri

Eğitim verilerinin kullanılma şekillerine göre farklı eğitim türleri bulunmaktadır.


- *Yığın öğrenme (Batch learning)*: Bütün eğitim örnekleri işlenerek amaç fonksiyonu ile değerlendirilir sistem parametrelerinde ayarlamalar yapılır.
- *Online öğrenme (Online learning)*: Bu eğitim türünde her bir örnek amaç fonksiyonu tarafından tek tek değerlendirilerek sistem parametreleri her bir örneğe göre yeniden ayarlanmaktadır.
- *Mini yığın öğrenme (Mini-batch learning)*: Bu yöntemde tek bir örnek kullanmak yerine veri seti içinden rastgele bir örnek grubu kullanılarak sistem parametreleri ayarlanmaktadır. Rastgele alınan bu örnek veri grubuna mini-yığın adı verilmektedir.

2.3 Evrişimsel Sinir Ağları (ESA)

Bilgisayarlı görme alanında karşılaşılan sorunların üstesinden gelebilmek için araştırmacılar insan görsel algısından ilham alarak ESA'ları keşfettiler [32]. Son yıllarda ortaya çıkan ESA'lar özellikle girdisi görüntü olan problemlerde büyük başarılar elde etmiştir. ESA'ları daha iyi kullanabilmek için çıkış noktalarını bilmek faydalı olacaktır.

2.3.1 Biyolojik Görsel Algı

Görme, duyuusal sistemler arasında en karmaşık yapıya sahip olanıdır. Örneğin optik sinir bir milyon lif içerirken, işitme siniri yaklaşık otuz bin lif içermektedir. Biyolojik görsel algı klasik olarak iki ayrı retino-cortikal yoldan meydana geldiği düşünülmektedir. Bu kapsamda yapılan bir çalışmada Newcombe ve Russell ikinci dünya savaşında beyin hasarı almış gaziler ile yaptıkları bir çalışmada beyinde “ne” ve “nerede” olmak üzere iki yol bulunduğunu keşfettiler [33]. Diğer bir çalışmada parietal lobdaki lezyonlar, hastaların labirent öğrenme performansını olumsuz etkilerken, temporal lobdaki lezyon, görsel tamamlama yeteneğinin azalmasına, yani zihinsel olarak eksik bilgilere dayanan görüntünün yeniden oluşturulmasını olumsuz etkilediği gözlemlenmiştir. [34].




Şekil 2.12 Beyinde yer alan nerede ve ne yolları [34]

Ortaya atılan bu modeli kanıtlayan nitelikte bir çalışma Ungerleider ve Mishkin tarafından yapılmıştır. Çalışmada makak maymunlarının beyinciklerine focal lezyonlar ile zarar verilerek anatomik ve elektrofizyolojik etkileri gözlemlenmiştir [35]. Elde ettikleri sonuçlar, birincil görsel korteks V1'den çıkan iki yol arasında bir

A lateral view of the human brain with color-coded lobes and sulci. The Frontal lobe is light brown, the Parietal lobe is pink, the Temporal lobe is yellow, and the Occipital lobe is blue. The Dorsal sulcus is highlighted in red, and the Ventral sulcus is highlighted in green. Arrows point from the labels to the corresponding parts of the brain.

Şekil 2.14 'te gösterildiği gibi, her iki yol da girişlerini retinadaki foto reseptörlerden alır ve uzamsal yollara ayrılmadan önce aynı cortikal alanların çoğundan geçmektedir.



Gerekli çıkışlara göre yollar arasında başka ayrımlar yapılabilir. Parietal lob'a çıkıntı yapan dorsal yol, bir eylemi yürütmek için gereken bilgiyi, yani söz konusu yolun


yüksek zamansal hassasiyeti ile desteklenen sahnenin uzamsal bir tanımını (pozisyon, oryantasyon ve yapı) iletir. Arka parietal lob, her ikisine de duyarlı olan girişı alır. Nesnelerin ve kendiliğinden başlatılan hareketlerin mekânsal sahnesi, vücudun çevresine olan pozisyonunu ilişkilendirir ve ön lobuna yansıtır. Böylece uzuvların hareket etmelerinde rol oynar örneğın el ve ayak hareketleri ve oküler kontrol [39]. Öte yandan ventral yol, objektif olarak ayrıntılı algılanan temporal lob için daha yavaş çözünürlük bilgileri sağlar. Ventral akışta yer alan yapılar görsel algı, hafıza ve öğrenmede rol oynar [34, 38, 40].

Ventral akışın işleyişine daha derinden bakmak için, biyolojik görüntü işleme ile ilgili temel keşifler, 1960'lı yıllarda nörofizyologlar D. Hubel ve T. Wiesel tarafından yapılmıştır [41, 42]. Kediler üzerinde yaptıkları deneylerde, kedilerin görsel korteksindeki nöronlarının, alıcı alan olarak tanımladıkları bölgedeki bazı hücrelerin belirli yönelimdeki ışığa tepki verdiklerini keşfettiler. Basit hücre olarak adlandırdıkları bu hücreler ile birlikte keşfettikleri ve karmaşık hücre adını verdikleri hücreler görme sistemimize dair önemli bilgiler sunmuştur. Bununla birlikte bu buluş, retina ve korteks arasındaki algılama farklılıklarının yanı sıra girdi nöronların alıcı alanlarını çevreleyen engelleyici alanların olası önemini göstermiştir. İkinci olarak görsel korteksin topografik bir yapısını kurmuşlar, bu yapıda retina algı haritaları kortekste benzer topografik haritalarda temsil edilerek, burada sütun yapıları aynı bilgiyi işleyen hücreleri temsil etmişlerdir. Üçüncü olarak görsel yoldaki hücrelerin organizasyonunda hiyerarşik bir yapı gözlemlediler. Basit, karmaşık, daha düşük dereceli ve daha yüksek dereceli hiper kompleks hücrelerin ayırt edilmesiyle, bilgi işlemenin giderek daha karmaşık hücrelerin bu sekansı boyunca hiyerarşik olduğu varsayılmıştır. Daha karmaşık hücrelerin, çizgilerin kesin konumuna daha az duyarlı oldukları, bilgi entegrasyonuna dayandıkları ve bir nokta kaynağı hattına çok fazla cevap vermedikleri için daha büyük alıcı alanlara sahip oldukları görülmüştür. Böylece, Hubel ve Wiesel, farklı hücre tiplerinde birincil görsel korteks V1'de bilgilerin hiyerarşik olarak alıcı alanlarına ve toleranslarına göre ayrılarak işlendiğini göstermişlerdir [43-45].

2.3.2 Biyolojik Görsel Algıdan Bilgisayarlı Görüye Geçiş


Yukarıda bahsedilen temel araştırmaların sonucunda elde edilen bulgular bilgisayarlı görü için ilham kaynağı olmuştur. Biyolojik görsel algıdan alınan temel fikir, ventral yol gibi, ham görüntüleri çeşitli aşamalardan geçirerek, değişken olan girdiden bağımsız kompakt, ancak açıklayıcı ve farklı bir gösterime dönüştürmektir [46]. Buradan yola çıkılarak ileri yayılım esnasında “tek bakışta görüş” kavramına odaklanılarak hücrelerin artan seçicilik ve tolerans özelliklerini birleştirmeyi hedefleyen hiyerarşik bir model fikri ortaya atılmıştır. Bu modeli oluşturmak için, V1’de bulunan basit ve karmaşık hücreler kavramını, modellerde kendi davranışlarını simüle eden alternatif hücre katmanları oluşturularak taklit edilmiştir. Özetle görme merkezinde bulunan hücreler tüm görseli kapsayacak şekilde alt bölgelere ayrılarak, basit olan hücreler kenar, köşe benzeri özelliklere karmaşık hücreler ise daha geniş alıcılarla, tüm görsele yoğunlaştığı mantığıyla hareket edilmiştir. Buradaki matematiksel evrişim işlemi, bir nöronun kendi uyarı alanından uyarılara verdiği cevap olarak düşünülebilir.

Bunu gerçekleştiren ilk yapay sinir ağı Neocognitron, Fukushima tarafından 1980 yılında oluşturulmuştur [47]. Önerilen çok katmanlı sinir ağı, alternatif S-hücreleri ve C-hücreleri katmanlarından oluşmaktadır. Modelin mimarisi Şekil 2.15’te verilmiştir.



Şekil 2.15 Fukushima'nın neocognitron mimarisi [48]

Modern evrişimsel sinir ağlarının atası olan LeNet, Fukushima'nın neocognitron'una benzeyen bir mimari ile Y.LeCun tarafından 1998 yılında geliştirilmiştir [49]. LeNet ESA tüm parametreler üzerinde geri yayılım algoritması yoluyla global minimumları bulması için eğitilmiştir. LeNet, ABD'de banka çeklerinde elle yazılmış rakamları otomatik olarak sınıflandırmak için kullanılmıştır. Bu mimari üç ana fikir etrafında oluşturulmuştur, yerel algılayıcı bölgeler, paylaşılan ağırlıklar ve alt örnekleme. Paylaşılan ağırlıklara sahip yerel algılayıcı alanlar, evrişim katmanının özüdür ve aşağıda açıklanan mimarilerin çoğu, evrişim katmanlarını farklı yapılarla kullanmaktadırlar. LeNet'in önemli bir mimari olmasının diğer bir nedeni ise, LeNet'ten önce karakter tanıma işleminin, el ile belirlenmiş özelliklerinin çıkarılmasının ardından bu özelliklerin sınıflandırılmasını bir makine öğrenme modelinin kullanılarak yapılmasıydı. LeNet ile birlikte kendi özelliklerini kendisi öğrenen ve bu özellikleri kullanarak sınıflandırma yapan bir ESA modeli geliştirilmiştir. LeNet basit bir mimariye sahiptir, sadece yedi katmanı bulunan LeNet'te bu katmanların üç tanesi evrişimsel katman, iki tanesi havuzlama katmanı, bir tane tam bağlı katman ve buna bağlı bir çıkış katmanıdır. Evrişimsel katmanlar 5x5 filtreleri 1 adım sayısı ile kullanırken, 2x2 ortalama havuzlama yöntemi kullanılmaktadır. Aktivasyon fonksiyonu olarak tanh ve sigmoid tercih edilmiştir. LeNet mimarisinin detayları Şekil 2.16'da gösterilmektedir.



Şekil 2.16 LeNet ESA mimarisi [49]

2.4 Bilgisayarlı Görüde Evrişimsel Sinir Ağları


ESA'ların klasik ve tartışmasız en popüler kullanım yeri, görüntü işleme alanındadır. ESA'lar 1998 yılında kullanılmasına karşın bilgisayarlı görüde esas popülaritesini 2012 yılından sonra elde etmişlerdir. Bu popülaritenin ortaya çıkmasının üç temel sebebi bulunmaktadır. Bunlardan ilki, gelişen teknoloji ile birlikte üretim teknolojilerinin de gelişmesi, bu sayede ekran kartlarının hesaplama gücünün artması, ikincisi büyük verinin toplanması ve bu veriye ulaşımın kolaylaşması, üçüncüsü geliştirilen güçlü algoritmaların ortaya çıkmasıdır. Temel bir ESA iki parçadan oluşmaktadır. Bunlar evrişimsel katmanlar ve sınıflandırıcı katmanlardır. Evrişimsel katmanlar bir dizi evrişim ve biriktirme işleminden oluşmaktadır. Bu katmanın amacı görüntüden özellikler çıkartmaktır. Sınıflandırıcı ise bir dizi tam bağlı katmandan oluşmaktadır. Evrişimsel katmanlar tarafından çıkarılan özellikler sınıflandırıcı tarafından kullanılarak probleme uygun kategori değeri üretmektedir. Tezin bu bölümünde ESA'nın temel bileşenlerinden bahsedilecektir.

2.5 ESA'ların Temel Kavramları

2.5.1 Evrişimsel Katman (Convolutional Layer)

Daha önce değinildiği üzere görme merkezinde bulunan hücrelerin tüm görseli kapsayacak şekilde alt bölgelere ayrılarak, basit olan hücrelerin kenar, köşe benzeri özelliklere karmaşık hücrelerin ise daha geniş alıcılarla, tüm görsele yoğunlaştığı mantığından yola çıkılarak matematiksel bir model oluşturulmuştur. Bu modelde evrişim işlemi, bir nöronun kendi uyarı alanından uyarılara verdiği cevap olarak düşünülebilir. Normal bir sinir ağında bir görüntüyü ağa girdi olarak verebilmek için bu görüntüyü vektörel hale getirmek gerekmektedir. Vektörel hale getirilen görüntülerde şekiller arası uzamsal ilişkiler kaybolmaktadır. Bu durum görüntü tabanlı problemlerde sınıflandırma sonucunu olumsuz etkileyebilmektedir. Beyinin görsel korteks bölgesinden ilham alınarak tasarlanan evrişimsel katmanlar sayesinde girdi olarak verilen görüntülerin uzamsal ilişkileri kaybolmamakta, bu sayede özellikle girdisi görüntüler olan problemlerin çözümünde olumlu sonuçlar elde edilmektedir. Evrişimsel katmanı daha somut bir örnek ile ifade edecek olursak. Elimizde bir el feneri olduğunu ve bu fener ile bir görüntünün sol üst köşesini aydınlattığımızı düşünelim. Aydınlatılan bölgenin ise 5x5 piksellik bir alan olduğunu varsayalım.

Fenerin tüm resim üzerinde kaydırılarak hareket ettirilmesi ile her seferinde resimde fenerin denk geldiği kısım aydınlanmakta ve detayları ortaya çıkmaktadır. Bu örnekte fenerin aydınlattığı kısma alıcı alan (receptive field) fenere ise filtre ya da kernel gibi isimler verilmektedir. Söz konusu filtre de bir sayı dizisinden oluşmaktadır. Bu sayılar ağırlıkların temsil etmektedir. Fenerin aydınlattığı alıcı alanda bulunan pikseller ile fenerin yani filtrenin sahip olduğu ağırlık değerleri çarpılıp toplanarak bir piksel değeri elde edilmektedir. Toparlayacak olursak en basit tabiri ile evrişim işlemi görüntü üzerinde dolaştırılan bir filtre ile filtrenin örtüştüğü kısımdaki piksellerin çarpılıp toplanması ile yeni bir piksel değeri elde edilmesidir. Şekil 2.17’de bu durumu özetleyen bir görsel paylaşılmıştır.



Şekil 2.17 Evrişim operasyonu

Evrişim işlemi sonucu elde edilen yeni görüntüye aktivasyon haritası veya özellik haritası (feature map) denilmektedir. Filtre sayısı arttıkça özellik haritalarının sayısı da bu oranda artacaktır. Kullanılan her bir filtreye özellik tanımlayıcı denilmektir. Herhangi bir görüntüde özellik denildiğinde akla gelen, düz kenarlar, renkler, köşeler, eğriler vb. gelmektedir. Burada dikkat edilmesi gereken bir konu eğer girdi resmi (32x32x3) RGB ise kullanılacak filtrenin de aynı derinliğe (5x5x3) sahip olması gerekmektedir. Evrişim işleminde dikkat edilmesi gereken diğer bir husus Şekil 2.17’de görüldüğü gibi çıktı görüntüsünün küçülmesidir. Bu durum filtrenin adım

(stride) sayısına bağlıdır. Filtre boyutu (f), resim boyutu (r), adım sayısı (s), ve kenarlık (padding) (p) gibi parametreler kullanılarak formül 2.18'e göre çıktının boyutlarını (uzunluk, yükseklik) hesaplamak mümkündür.

$$(w, h) = \frac{r + 2p - f}{s} + 1 \quad (2.18)$$

Yukarıdaki formüle göre 32x32x3 lük bir görüntü üzerinde 5x5x3 lük bir filtre adım sayısı 1 kenarlık değeri 0 olacak şekilde gezdirildiğinde elde edilen çıktı görüntüsü 28x28x1 olmaktadır. Bazı durumlarda girdi görüntüsünün sabit boyutta kalması istenebilir. Bunun için görüntü etrafında kenarlık (padding) denilen 0 rakamları eklenerek boyut indirgenmesinin önüne geçilmiş olmaktadır. Evrişimsel katmanı daha somut bir örnek ile ifade edecek olursak; 7x7x3 boyutlarında eğri tespiti için eğittiğimiz filtre Şekil 2.18'de gösterilmiştir. Bir eğri detektörü olarak, filtrenin bir eğri şekli olan alan boyunca daha yüksek sayısal değerler olacağı bir piksel yapısı olacaktır.

0	0	0	0	0	30	0
0	0	0	0	30	0	0
0	0	0	30	0	0	0
0	0	0	30	0	0	0
0	0	0	30	0	0	0
0	0	0	30	0	0	0
0	0	0	0	0	0	0


Filtrenin piksel bazıda temsili



Eğri tespit eden filtrenin görseli

Şekil 2.18 Eğri bulmak için detektör filtre [50]

Matematiksel olarak bakacak olursak filtrenin çalışma mantığı şu şekildedir. Bu filtreyi, giriş resminin sol üst köşesinde bulundurduğumuzda, o bölgedeki filtre ve piksel değerleri arasındaki çarpımları hesaplanır. Şekil 2.19'daki fare resminden yola çıkılacak olursa:



Şekil 2.19 Örnek fare resmi [50]

Filtredeki değerler ile görüntüdeki orijinal pikseller çarpılarak toplanır. Şekil 2.20’de bu durum gösterilmektedir.



$$\text{Çarpım ve toplam} = (50 \cdot 30) + (50 \cdot 30) + (50 \cdot 30) + (20 \cdot 30) + (50 \cdot 30) = 6600$$


Şekil 2.20 Evrişim işleminin matematiksel hesabı [50]

Temelde, giriş görüntüsünde, genellikle bu filtrenin temsil ettiği eğri andıran bir şekil varsa, bir araya getirilen çarpımların hepsinin büyük bir değere neden olacağı görülmektedir. Filtremizi resmimizin farklı bölgelerine doğru kaydırduğımızda ise sonuç Şekil 2.21’deki gibi olacaktır.



Şekil 2.21 Negatif sonuç [50]

Görüldüğü gibi işlem sonucunda çok küçük bir değer elde edildi. Bunun nedeni, görüntünün ilgili bölümünde eğri detektör filtresine yanıt veren herhangi bir şey olmamasıdır. Bu filtreleme işleminin sonucunun bir özellik haritası olduğunu daha önce belirtmiştik. Bu nedenle, basit bir filtre ile yapılan evrişim işlemi (bu filtre bir eğri detektörüysen) sonucunda aktivasyon haritasında görüntüdeki eğrilerin büyük olasılıkla bulunduğu alanları ortaya çıkarmaktadır. Bu örneğe göre $28 \times 28 \times 1$ aktivasyon haritamızın sol üst değeri 6600 olacaktır. Bu yüksek değer, girdi görüntüde filtrenin etkinleştirilmesine neden olan bir çeşit eğri bulunması olasılığı olduğu anlamına gelmektedir. Örnekteki filtremiz sadece dışarıya ve sağa doğru eğri çizgileri algılayacak bir filtredir. Filtreler ne kadar çok olursa, aktivasyon haritasının derinliği o kadar artar ve girdi görüntüsü ile ilgili daha fazla bilgi elde edilir. Örnekte kullanılan filtre basit bir filtredir. Şekil 2.22’de eğitilmiş bir ağın ilk evrişimsel katmanda yer alan filtrelerin görselleştirmelerine ilişkin örnekler gösterilmiştir.



Şekil 2.22 Eğitilmiş bir ağdan elde edilen filtreler [51]

Evrişimsel katmandaki diğer önemli bir konu ise paylaşılan ağırlıklar kavramıdır. Bu sayede ağdaki parametre sayısı düşürülerek az parametre ile daha iyi sonuçlar elde edilmesi sağlanmıştır. $28 \times 28 \times 1$ boyutlara sahip bir görüntümüz olduğunu farz edelim. Bu görüntüyü normal bir yapay sinir ağına girdi olarak verdiğimizde 784 adet girişimiz olması gerekir. Üç nörondan oluşan bir gizli katmanımız olduğunu varsayarsak toplamda $784 \times 3 = 2352$ adet ağırlık değerine ihtiyaç duyulmaktadır. Bunun yanında bir adet eşik değeri (bias) terimi ile 2353 adet parametreyi güncellemek gerekmektedir. Böylesine küçük bir ağ için bile bu kadar parametreyi eğitmek zor olabilmektedir. Evrişimsel katmanda ağırlıklar filtreler ile temsil edilmektedir. 3×3 lük bir ağırlık tüm resim üzerinde kullanılarak yeni bir özellik haritası elde edilmektedir. Girdi katmanının görüntünün düzlemsel boyutu bozulmadığı için ortak kullanılabilen ağırlıklar sayesinde daha az parametre ile hesaplama yapıp daha iyi sonuçlar elde edilmektedir.

2.5.2 ESA’larda Aktivasyon ve Hata Fonksiyonları

Tezin önceki bölümlerinde aktivasyon ve hata fonksiyonlarının görevlerinden ve öneminden detaylıca bahsedilmişti. Bu bölümde özellikle ESA’larda kullanılan aktivasyon ve hata fonksiyonlarına değinilecektir. Aktivasyon fonksiyonlarının bilinen en basit hali hiçbir değişim uygulanmayan doğrusal aktivasyon fonksiyonlarıdır. Bu aktivasyon fonksiyonlarına sahip bir ağın eğitimi oldukça kolay olmasına karşın verideki karmaşık özellikleri keşfedemezler. Ancak doğası gereği regresyon problemlerinde kullanımları devam etmektedir. Bununla birlikte sigmoid, tanh gibi doğrusal olmayan aktivasyon fonksiyonları verideki karmaşık ilişkileri daha

iyi belirleyebilmektedir. Fakat bu fonksiyonlarında ağırlık katmanlarına doğru türevleri sıfır olduğu için ağırlıklarda güncelleme yapılamaması gibi dezavantajları bulunmaktadır. Bu nedenle ESA’larda sıklıkla tercih edilen aktivasyon fonksiyonu düzeltilmiş doğrusal birim fonksiyonu bilinen adı ile (Rectified Linear Unit) ReLU’dur. Fonksiyon negatif bir değer aldığıda sıfır sonucu üretirken, pozitif bir değer aldığıda ise alınan değeri geri döndürmektedir. Formülü 2.19’deki gibidir. Grafikselsel olarak gösterimi ise Şekil 2.23’te verilmiştir.


$$f(x) = \max(0, x) \quad (2.19)$$



Şekil 2.23 ReLU fonksiyon grafiği

2.5.3 Havuzlama (Pooling)

Evrişimsel katmandan sonra genellikle havuzlama katmanı gelmektedir. Bu katman aşağı örnekleme katmanı olarak da bilinir. Global ortalama havuzlama, ortalama havuzlama gibi farklı havuzlama yöntemleri olmasına karşın en sık kullanılan havuzlama yöntemi maksimum havuzlamadır (max pooling). Genellikle 2x2’lik bir filtre görüntü üzerinde dolaştırılır. Fitrenin oturduğu kısımdaki maksimum değer dikkate alınarak diğer pikseller ihmal edilir. Şekil 2.24’te ortalama ve maksimum havuzlama yöntemlerinin örnekleri verilmiştir.



Şekil 2.24 Havuzlama İşlemi [18]

Görüldüğü gibi bu katman, girdi hacminin uzamsal boyutunu (uzunluk ve genişlik değişikliği değil derinlik) büyük ölçüde azaltır. Bu işlem iki temel amaca hizmet etmektedir. Birincisi, parametrelerin veya ağırlıkların miktarının %75 oranında azaltılması, böylece hesaplama maliyetinin azaltılmasıdır. İkincisi, gereğinden fazla uyumu kontrol ederek azalmasında rol oynamaktadır.

2.5.4 Tam Bağlı Katmanlar (Fully Connected Layers)


ESA'ların sonunda bulunan katman veya katmanlardır. Normal bir yapay sinir ağından bir farkı bulunmamaktadır. Genellikle sınıflandırıcı görevi görmektedir. Bir dizi evrişimsel katmandan sonra elde edilen özellikler tam bağlı katmanlara vektörel hale getirilerek yollanmaktadır. Tam bağımlı katmanlar bu özellikleri kullanarak ilgili probleme dair bir sonuç üretmektedir.

2.5.5 Evrişimsel Sinir Ağlarında Aşırı Uyum ve Engelleme Yöntemleri

Derin ağların en büyük problemlerinden bir tanesi aşırı uyum veya ezberleme problemidir. Aşırı uyum problemi eğitim sırasında yüksek oranlarda doğruluk oranı elde eden ağın test esnasında düşük doğruluk oranı vermesidir, kısaca ağımızın verimizi ezberlemesidir. Bu durum genelde eğitim için yeterli verinin olmadığı problemlerde ortaya çıkmaktadır. Az veri ile yüksek doğruluk oranı elde etmek için çalışmalar devam etmektedir. Özellikle tıbbi alanlarda yüksek boyutlarda veri elde etmek zor ve zahmetli bir süreçtir. Bu yüzden çeşitli veri çoğaltma yöntemleri derin ağlarda kullanılmakta ve başarılı sonuçlar elde edilmektedir.

Veri Çoğaltma (Data Augmentation): Özellikle girdisi görüntüler olan ağlarda oldukça başarılı sonuçlar elde eden bir yöntemdir. Bu yöntem ile baz alınan görüntüden; döndürme, kesme, kırpma, kontrast artırma vb. gibi çeşitli görüntü işleme yöntemleri ile yeni görüntüler üretilerek eğitim için kullanılan veri seti genişletilmektedir. Yukarıda belirtilen çoğaltma işlemlerinin temeli çeşitli görüntü işleme yöntemlerine dayanmaktadır. Veriye özel çoğaltma yöntemleri geliştirilebileceği gibi bu yöntemleri bir araya getiren hazır kütüphaneler de bulunmaktadır. Bu kütüphanelerden bir tanesi olan Keras ImageDataGenerator kullanım kolaylığı ve sunduğu avantajlı özellikler sayesinde en popüler olanlardan bir tanesidir. Kütüphanenin içeriği ve kullanım detayları web sayfasında bulunmaktadır [52].

İletim Sönümü (Dropout): Aşırı uyum önleme yöntemlerinden bir tanesi olan iletim sönümü yöntemi, eğitim sırasında gerçekleşen geri yayılım sürecinde daha önce belirlenen oranda rastgele bazı nöronların ağırlık güncelleme işlemine dahil edilmemesidir. Her geri yayılım sürecinde farklı nöronlar seçildiği için bu yöntem sıkça kullanılmakta ve başarılı sonuçlar elde etmektedir. Yöntemin uygulanmasına ilişkin bir görsel Şekil 2.25'te gösterilmektedir.



Şekil 2.25 İletim sönümü yönteminin gösterimi, solda normal ağ sağda ise iletim sönümü uygulanmış bir ağ gösterilmektedir.

Düzenleştirme Yöntemleri L1, L2 (Regularization Methods): Aşırı uyum probleminin diğer çözümlerinden bir tanesi de ağı boyutlarını küçültmektir. Fakat büyük ağlar küçük ağlara göre daha iyi sonuçlar vermektedir. Bu yüzden bu yöntem pek kullanılan bir yöntem değildir. Bunun yerine düzenleştirme yöntemleri bulunmaktadır. Bu yöntemlerden en popüler olanlardan bir tanesi ağırlık azalımı

(weight decay) ya da diğer adıyla L2 düzenlileştirmesidir. Bu yöntemde maliyet fonksiyonuna ekstra terim eklenmesi yapılmaktadır. Bu terime düzenlileştirme terimi denilmektedir. Aşağıda çeşitli M fonksiyonlarında ve genelleştirilmiş hali ile L2 düzenlileştirme yönteminin kullanımı gösterilmektedir.

$$M = -\frac{1}{n} \sum_{xj} [y_j \ln a_j^L + (1 - y_j) \ln(1 - a_j^L)] + \frac{\lambda}{2n} \sum_w w^2 \quad (2.20)$$

$$M = -\frac{1}{2n} \sum_x \|y - a^L\|^2 + \frac{\lambda}{2n} \sum_w w^2 \quad (2.21)$$


$$M = M_0 + \frac{\lambda}{2n} \sum_w w^2 \quad (2.22)$$

Formüle göz atacak olursak L2 düzenlileştirme yönteminde ağ içindeki o anki mevcut ağırlıkların karelerin toplamının $\lambda / (2n)$ ile çarpılması ile ortaya çıkan değer maliyet fonksiyonuna eklenmesidir. Burada λ , 0-1 arasında düzenlileştirme parametresi, n ise kullanılan veri setindeki örnek sayısını temsil etmektedir. Diğer bir düzenlileştirme yöntemi olan L1 düzenlileştirme ise L2 den farklı olarak formül 2.23'te görüldüğü üzere ağıdaki ağırlıkların mutlak toplamının $\lambda/(2n)$ ile çarpılıp maliyet fonksiyonuna eklenmesi ile elde edilmektedir.

$$M = M_0 + \frac{\lambda}{2n} \sum_w |w| \quad (2.23)$$


Aktarım Öğrenme (Transfer Learning): Aktarım öğrenme, belirli bir problemi çözmek için elde edilen bilginin, başka bir problemin çözümünde kullanılmasıdır [53]. Bunu günlük hayattan bisiklet süren birinin motosiklet öğrenmeyi daha kolay öğrenmesine benzetebiliriz. Aktarım öğrenme bilgisayarlı görü problemlerinde doğru modelleri hızlı bir şekilde uygulamaya olanak sağlayan oldukça popüler bir yöntemdir [54]. Aktarım öğrenme de öğrenme sürecini baştan başlatmak yerine önceden öğrenilmiş filtreler kullanılarak farklı bir problemin çözümünde kullanılmaktadır.

ImageNet [55] tarafından sağlanan 1,2 milyon görüntü ve 1000 kategoriden oluşan veri üzerinde eğitilen farklı evrişimsel derin ağlar (Vgg, Inception, MobileNet, ResNet vb.) araştırmacılar tarafından yeni problemlerin çözümünde kullanılmaktadır. Temel bir ESA'da evrişimsel katmanlar özellik çıkarmak için, tam bağlı ise çıkarılan özellikleri sınıflandırarak probleme uygun kategori değeri üretmek için çalışmaktadır. Şekil 2.26'da basitleştirilmiş bir ESA mimarisi görseline yer verilmiştir.



Şekil 2.26 Temel bir ESA mimari yapısı

ESA'nın en büyük avantajı eğitim verisini kullanarak veriye ait ayırt edici özellikleri kendi kendilerine öğrenmeleridir. Bunu yaparken ilk katmanlarda daha genel özellikler olan kenarlar, çizgiler, renkleri algılamak ileri katmanlara doğru daha veri spesifik özellikleri gizli bağlantıları ortaya çıkarmaktadırlar. Bu durum sayesinde evrişimsel ağlar aktarım öğrenmeye oldukça uygundur. Şekil 2.27'den de görüleceği üzere ImageNet verisi ile eğitilmiş bir ağın farklı katmanlarındaki filtrelerinin ve özellik haritalarının görselleştirilmiş halleri verilmiştir.




Şekil 2.27 Farklı katmanlarda yer alan öğrenilmiş filtreler [56]

Evrişimsel bir sinir ağını kendi amaçlarımız için eğitirken aktarım öğrenmeyi kullanmanın bazı stratejileri bulunmaktadır. İlk olarak ağın sonunda bulunan sınıflandırıcıyı kaldırıp kendi sınıflandırıcımız eklenir. Daha sonra ise ağ üzerinde üç

farklı hassas ayar (fine-tuning) stratejisinden birini kullanarak eğitim yapılır. Bu stratejileri yakından inceleyecek olursak.

- 1- Tüm modeli eğitmek: Daha önce eğitilmiş modeli ağırlıklarını başlangıç noktası kabul ederek kendi veri setimiz ile tüm ağı eğitiriz. Bu seçenekte yüksek boyutlarda veriye ve hesaplama gücüne ihtiyaç duyulmaktadır. Aksi takdirde istenilen sonuçlar elde edilemez.
- 2- Bazı katmanları dondurup bazılarını eğitmek: Yukarıda bahsedildiği gibi bir evrişimsel sinir ağına ilk katmanlar veri bağımsız özellikleri öğrenirken son katmanlara doğru daha veriye bağımlı özellikleri ortaya çıkarmaktadır. Bu bağlamda bazı evrişim katmanlarını deneme yanılma yolu ile dondurarak yani eğitim esnasında ağırlıklarının değişmesini engelleyerek kendi problemimize uyarlamak mümkündür. Eğer küçük bir veri setimiz varsa ve seçtiğiniz modelin parametre sayısı çok fazla ise ezberlemeyi önlemek için donmuş katman sayısını fazla tutmak faydalı olacaktır. Bununla birlikte eğer veri setimiz büyük ve modelinizdeki parametre sayısı az ise yeni katmanlar ekleyebilir veya daha fazla evrişimsel katmanı eğitime katabilirsiniz.
- 3- Tüm evrişimsel katmanları dondurmak: Bu seçenekte tüm evrişimsel katmanlar dondurularak sadece sınıflandırıcı kısmında bulunan tam bağlı katmanlar eğitilmektedir. Bu seçeneğin uygulaması için genelde daha önce eğitilmiş modelin veri seti ile verimizin benzerlik oranının yüksek olduğu ayrıca veri setimizin ve hesaplama gücümüzün yeterli olmadığı durumlardır. Şekil 2.28’de üç farklı durumu gösteren bir görsel verilmiştir.



Şekil 2.28 ESA aktarım öğrenme stratejileri

Strateji 3'ün aksine strateji 1 ve 2'de eğitim esansında evrişimsel katmanlardaki öğrenme oranına dikkat edilmesi gerekmektedir. Bu oran ağda yer alan parametrelerin hangi oranda değişeceğini belirleyen önemli bir hiper parametredir. Daha önceden eğitilmiş bir ESA modelini eğitirken bu oranı düşük tutmak yeni eğitim için önemli bir etmendir, eğer bu oran yüksek olursa daha önce eğitilmiş modelin elde ettiği bilgilerin de kaybolma ihtimali yüksektir.


Pratikte aktarım öğrenme süreci aşağıda belirtilen sıra ile gerçekleştirilmelidir.

- 1- Eğitilmiş model seçimi: Probleme uygun olarak daha önceden eğitilmiş bir model seçilir. Eğer Keras gibi bir derin öğrenme kütüphanesinden faydalanılıyorsa eğitilmiş birçok evrişimsel modeli hazır olarak elde edilebilmektedir (Vgg, ResNet, Inception, Xception vb.).
- 2- Veri analizi: Problemin veri setinin büyüklüğü ve daha önce eğitilmiş olan modelde kullanılan veri seti ile benzerlik oranı aktarım öğrenmede önemli bir etmendir. Genel bir kural olarak veri setinizde sınıf başına 1000 görüntüden az veriniz var ise veri setinizin küçük olduğu kabul edilir. Veri setlerinin benzerliği noktasında ise eğer probleminiz kedi köpek sınıflandırmak ise ve

ImageNet alt yapısını kullanıyorsanız zaten bu veri içinde kedi köpek olduğu için çok az bir eğitimle iyi sonuçlar elde edilebilir. Fakat problem kanser sınıflandırma ise ImageNet verisi ile benzerlik söz konusu değildir.

3- Hassas ayar: Burada veri yapısı ve seçilen modelin parametre sayısı göz önüne alındığında dört durum ortaya çıkmaktadır. Şekil 2.29'da verilen benzerlik matrisine göre bu durumlardan birisi tercih edilerek eğitime başlanır. Bu durumlara kısaca değinilirse:


- Eğer probleme ait veri seti büyük fakat daha önceden eğitilmiş ağın veri seti ile benzerliği yoksa bu durumda strateji 1 uygulanmaya alınabilir. Elde büyük veri seti varsa model sıfırdan eğitilebilir. Bununla birlikte her ne kadar veriler arası benzerlik olmasa da eğitime daha önce eğitilmiş modelin ağırlıkları ile başlamak yararlıdır.
- Probleme ait yeterli veri var ve modelin daha önce eğitildiği veri ile benzerlik oranının yüksek ise en iyi yol strateji 2 olacaktır. Veri setinin büyüklüğü ağın ezberlemesini engeller. Ayrıca veri benzerliği sayesinde uzun eğitim sürecine ihtiyaç kalmamaktadır. Bu nedenle sınıflandırıcı ve evrişimsel katmanların üst katmanlarını eğitmek yeterli olacaktır.
- Probleme ait veri seti küçük ve daha önce eğitilmiş model ile benzerlik taşımıyorsa yine en uygun yol strateji 2 olarak görülmektedir. Eğitilmesi ve dondurulması gereken katman sayısını ayarlamak oldukça güçtür. Burada veri çoğaltma yöntemleri kullanılarak örnek sayısını arttırmanın yanında daha çok evrişimsel katman eğitime katılmaktadır.
- Probleme ait veri seti küçük fakat daha önce eğitilmiş ağ ile benzerlik oranı yüksek ise strateji 3'ü kullanmak daha mantıklıdır. Sadece sınıflandırıcı eğitilip evrişimsel katmanlar dondurularak kısa süre başarılı sonuçlar elde edilebilir.



Şekil 2.29 Aktarım öğrenme veri seti ilişkisi

2.6 ESA Mimarisindeki Son Gelişmeler ve Tasarım Öğeleri


Her ne kadar evrişimsel sinir ağları, LeNet'in tanıtımını takiben bilgisayarlı görü ve makine öğrenim topluluklarında iyi bilinse de hemen sahaya hâkim olmadılar. Bilgisayarlı görü problemlerinin çözümünde ESA'lar 2012 yılından sonra yükselişe geçmiş ve klasik makine öğrenmesi yöntemlerinin yerini almışlardır. Sınıflandırma, segmentasyon, nesne yer tespiti ve yapay veri üretme gibi görüntü temelli problemler için farklı ESA mimarileri geliştirilmiştir (Şekil 2.30). Dolayısı ile bu bölümde son birkaç yıl boyunca geliştirilen ve bu çalışma esnasında faydalanılan güçlü ESA modellerinden bahsedilecektir.



Şekil 2.30 ESA modellerinin farklı kullanım alanları

2.6.1 Sınıflandırıcı ESA


AlexNet: Alex Krizhevsky ve arkadaşları tarafından tasarlanan AlexNet 2012 yılında (ImageNet Large Scale Visual Recognition Competition) ILSVRC tarafından yıllık olarak düzenlenen 1,2 milyon görüntünün 1000 kategoride sınıflandırılmasını amaçlayan ImageNet yarışmasında bir önceki yılda elde edilen %26'lık top-5 hata oranını %15'e çekmeyi başarmıştır [32]. Top-5 hata oranı modelin yaptığı en yüksek oranlı ilk 5 tahmin arasında doğru sınıfın olmasıyla sonucun doğru kabul edilmesidir. Aynı yarışmada ikinci olan klasik makine öğrenmesi yöntemi top-5 hata oranında %26,2'de kalmıştır. AlexNet yapı olarak daha önce değinilen LeNet'e benzemektedir. Ancak daha derin bir mimariye sahiptir. Beş adet evrişimsel katman ve üç tam bağlı katmandan oluşmaktadır. Evrişimsel katmanlarda 11x11, 5x5 ve 3x3 filtreler, maksimum havuzlama, iletim sönümü, yapay veri çoğaltma, ReLU aktivasyon fonksiyonu ve SGD ile birlikte momentum kullanımı gibi pek çok yenilik ilk kez AlexNet'te kullanılmıştır [32]. AlexNet mimarisi Şekil 2.31'de detaylı olarak verilmiştir.



Şekil 2.31 AlexNet mimarisi [32]

AlexNet bilgisayarlı görüde bir dönüm noktasıdır. 2012 yılından itibaren düzenlenen bütün ImageNet yarışmalarını her yıl derin öğrenme temelli ağlar kazanmakla birlikte bununla da kalmayıp hata oranını insan hata oranının altına indirmeyi başarmışlardır.


VggNet: VggNet 2014 yılında Simonyan ve arkadaşları tarafından tasarlanmıştır. Vgg mimarisi ile birlikte ilk kez ESA'larda derinlik algısına vurgu yapılmış, derinlik arttırıldığında sınıflandırma başarısının da artacağını 2014 yılında katıldıkları ImageNet yarışmasında top-5 hata oranında %7,3 değerini elde ederek kanıtlamışlardır [57]. Vgg ağında büyük filtreler kullanmak yerine 3x3 lük küçük filtreler birer adımlık ilerlemeler ile kullanılmıştır. Bu sayede AlexNet'den daha fazla derinliğe sahip olmasına karşın Vgg'nin daha az parametresi bulunmaktadır. Evrişim işlemlerinden sonra ReLU aktivasyon fonksiyonu kullanılmış ardından maksimum havuzlama yönteminden faydalanılmıştır. Farklı varyasyonları olan VggNet'in en sık kullanılan mimarileri Vgg-16 ve Vgg-19'dur. 16 ve 19 sayıları sahip oldukları katman sayısını temsil etmektedir [57]. Örneğin Şekil 2.32'de yer alan Vgg-16 mimarisi 13 evrişimsel, 3 tam bağlı katmandan oluşmaktadır.



Şekil 2.32 Vgg-16 mimarisi [57]

GoogleNet (Inception V1): Vgg, ImageNet veri setinde olağanüstü bir doğruluk elde etse de o yıllarda en mütevazı büyüklükteki GPU'larda bile kullanımı hem bellek hem de zaman açısından büyük hesaplama gereksinimleri nedeniyle bir sorun oluşturmaktaydı. Standart bir ESA mimarisinde peş peşe gelen bir dizi evrişim katmanları ve havuzlama katmanları ve en son tam bağlı katmanlar bulunmaktadır. Bu


model yapısı, yüksek miktarda hafıza ihtiyacı, yüksek miktarda hesaplama gücü, aşırı uyuma meyil etme, kaybolan gradyan problemi gibi bazı dezavantajları da beraberinde getirmekteydi. GoogLeNet söz konusu problemlere çözüm üretmek için 2014 yılında Christian Szegedy ve arkadaşları tarafından tasarlanmıştır. Toplamda 22 katmandan oluşan ağ aynı yıl düzenlenen ImageNet yarışmasında %6,67 top-5 hata oranını elde ederek birinci olmuştur [58]. GoogLeNet diğer bir adıyla Inception V1 beraberinde birçok yeniliği getirmiştir. Bunlardan bazıları şunlardır. GoogLeNet'te 1×1 evrişim, hesaplamayı azaltmak için boyut küçültme modülü olarak kullanılmıştır. Bu sayede hesaplama darboğazı azaltılarak derinlik ve genişlik artırılmıştır. 1×1 evrişimin diğer bir faydası ise aşırı uyumu engellemesidir. GoogLeNet ile gelen başka bir yenilik ise inception modülüdür. Daha önce bahsi geçen AlexNet, VggNet gibi ağlarda evrişim katmanında filtre boyutları sabitti. Bu modül ile birlikte 1×1 , 3×3 , 5×5 filtreler ve 3×3 maksimum havuzlama girdi görüntüsüne aynı anda uygulanıp sonuçlar birleştirilmiştir. Şekil 2.33'te görseli bulunan bu yapıya inception modül adı verilmiştir. Görüntüye uygulanan farklı filtreler sayesinde farklı özellik haritaları elde edilmektedir. Elde edilen özellik haritaları birleştirilerek bir sonraki modülün girişi oluşturulmaktadır.



Şekil 2.33 Inception modülü [58]

GoogLeNet ile birlikte gelen başka bir yenilik ise global ortalama havuzlama yöntemidir. Bu yöntemden önce tam bağlı katman öncesinde tüm veriler vektörel hale

getirilmekteyken kullanılan 1×1 filtre ile daha çok özellik daha az parametre ile temsil edilir hale getirilmiştir. Şekil 2.34'te global ortalama havuzlamaya (GOH) ait bir görsel paylaşılmıştır.




Şekil 2.34 Solda normal sağda ise GOH yöntemi [59]

Araştırmacılar Inception V1 üzerinde yaptıkları bazı geliştirmeler ile birlikte Inception V2, Inception V3, Inception V4 gibi daha yeni versiyonlarını geliştirmişlerdir.

ResNet: 2015 yılında Microsoft ekibi, Kaiming He ve arkadaşları tarafından geliştirilen (Deep Residual Network) 152 katmanlı ResNet aynı yıl düzenlenen ILSVRC yarışmasında %3,57'lik top-5 hata oranı ile birinci olmuştur [60]. Aldığı bu başarı ile %5 olan insan hata oranını geçerek büyük bir başarı elde etmiştir. ResNet sahip olduğu bazı avantajları sıralayacak olursak; mimarisinin hızlı eğitilmesi, geniş bir ağ yerine derin bir mimari kullanmasının bir sonucu daha az parametrelili bir yapıya

sahip olması, gradyan yok olması problemini çözmesi ve özellikle görüntü sınıflandırma alanında büyük bir başarı yüzdesine sahip olmasıdır. Biraz deha detaylı açıklayacak olursak evrimsel ağlarda derinlik yani katman sayısı önemli bir parametredir. Teorik olarak derinliğin artması ağın temsil kapasitesini arttıracığı düşünülmektedir. Bunun sonucunda daha başarılı ağ mimarilerinin ortaya çıkması beklenirken ortaya iki önemli sorun çıkmaktadır. Bu sorunlardan ilki (vanishing / exploding gradients) eğimin sıfır olması sonucu eğitim esnasında bazı nöronların ölmesidir. Biraz daha açarsak geri yayılım esnasında güçlü aktivasyonları olmayan nöronların uzun katman zincirleri arasında kaybolması ve ağın eğitime katkı verememesidir. Diğer bir sorunda derinlik arttıkça parametrelerin optimizasyonun zorlaşmasıdır. ResNet'in getirdiği yenilik ise ağın derinliğini arttırmasına rağmen yukarda bahsedilen sorunları (residual connections) artık bağlantılar ismini verdiği bir yöntem ile çözmüş olmasıdır.




Şekil 2.35 ResNet'in artık bağlantıları [60]

Şekil 2.35'te gösterilen yöntem incelendiğinde normal şartlarda girişten çıkışa kadar olan kısmı doğrusal olmayan $H(x)$ fonksiyonu ile haritalandırabilmektedir. ResNet mimarisinde bu yol, $H(x)$ yerine $F(x) := H(x) - x$ olarak tanımlanan başka bir doğrusal olmayan fonksiyon kullanılarak haritalandırılmaktadır. Buna ek olarak da girişten çıkışa bir kısa yol bağlantısı yapılarak, x (giriş) değeri $F(x)$ fonksiyonuna aritmetik olarak ekleniyor. Daha sonra $F(x)+x$ fonksiyonu birlikte ReLU'dan geçiriliyor. Dolayısıyla ikinci katmanın sonuna girişte eklenerek, geçmiş katmanlardaki değerlerin ileriki katmanlara daha güçlü bir şekilde iletilmesi sağlanmış olmaktadır. ResNet'in Şekil 2.36'da gösterildiği gibi farklı katmanlara sahip mimarileri bulunmaktadır.

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


Şekil 2.36 Farklı ResNet mimarileri [60]

Xception: 2017 yılında François Chollet tarafından Inception V3 mimarisinden ilham alınarak tasarlanmıştır [61]. Xception modelin özgün yanı normal evrişim işlemi yapmak yerine derinlemesine ayrılabilir evrişim (SeparableConv) işlemini modifiye ederek kullanmasıdır. Bu yöntemde özellik haritalarına önce 1x1 filtre uygulanarak özellik haritaları daraltılmakta, daraltılan haritaların her birine ayrı 3x3 filtre uygulanarak sonuçlar birleştirilmektedir. Şekil 2.37’de bu durumu anlatan bir görsel yer verilmiştir.




Şekil 2.37 Xception mimarisinde kullanılan derinlemesine ayrılabilir evrişim yaklaşımı [61]

Xception modelinin özellik çıkarmak için 36 evrişimsel katmanı ve tam bağlı katmanlar, çıkışta mantıksal sınıflandırma katmanı bulunmaktadır. Toplamda 14 modülden oluşan evrişimsel katmanların her biri doğrusal artık bağlantılara sahiptir.



Şekil 2.38 Xception mimarisi [61]

MobileNet: Andrew G. Howard ve arkadaşları tarafından 2017 yılında tasarlanan MobileNet'in esas tasarlanma amacı mobil veya gömülü sistemlerde kullanılabilecek hafif ama etkili bir model ortaya çıkarmaktır [62]. MobileNet mimarisi derinlemesine ayrılabilir evrişim işleminden faydalanarak parametre sayısını, işlem hacmini ve model karmaşıklığını düşürmüştür, bu sayede donanımsal olarak kısıtları olan mobil ve gömülü cihazlarda kullanılabilecek hale getirilmiştir (Şekil 2.39). Detaylı MobileNet mimarisi Şekil 2.40'ta verilmiştir.




Şekil 2.39 Derinlemesine ayrılabilir evrişim [62]

Tür/ Adım	Filtre Boyutu	Girdi Boyutu
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5×	Conv dw / s1	$3 \times 3 \times 512$ dw
	Conv / s1	$1 \times 1 \times 512 \times 512$
	Conv dw / s2	$3 \times 3 \times 512$ dw
	Conv / s1	$1 \times 1 \times 512 \times 1024$
	Conv dw / s2	$3 \times 3 \times 1024$ dw
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Sınıflandırıcı	$1 \times 1 \times 1000$

Şekil 2.40 MobileNet mimarisi [62]

2.6.2 ESA'ların Segmentasyonda Kullanımı


Derin ağların görüntü sınıflandırma problemlerinin yanı sıra diğer bir kullanım alanı da görüntü segmentasyonudur. Segmentasyonun sınıflandırmadan farkı ise; sınıflandırmada, sınıflandırılmak istenilen sınıflara dair bir aidiyet değeri elde edilirken segmentasyonda ise girdi görüntüsüne karşılık istenilen nesnenin görüntü içerisinde arka plandan ayrılmış halinin elde edilmesidir. Bu durumun sağlanabilmesi için eğitim esnasında giriş görüntüsünün yanında onun segmente edilmiş görüntüsü de kullanılmaktadır. Şekil 2.41'de bir lezyon ve onun ikili halde segmente edilmiş hali etiketi (ground truth) ve segmentasyon sonucu gösterilmiştir.



Şekil 2.41 Segmentasyon işlemi (a) orijinal görüntü (b) lezyonun arka plandan ayrılmış ikili görüntüsü(etiketi), (c) orijinal görüntü ile iki görüntünün birleştirilmesi sonucu elde edilen segmentasyon görüntüsü


Sınıflandırmaya nazaran segmentasyon çok daha zor bir problemdir. Bu amaçla farklı derin ağlar geliştirilmiştir. Aşağıda bunlardan bazılarının mimari detaylarına değinilecektir.

FCN (Fully Convolutional Network): Tam Evrişimli Ağ 2015 yılında Jonathan Long ve arkadaşları tarafından anlamsal segmentasyon için önerilmiştir [63]. Ana fikir sahne hakkında fikir sahibi olmak yani görüntüde neler var ve kabaca görüntünün neresinde yar aldıklarıdır. Esasında bir ESA olan FCN'nin farkı tam bağlı katmanların evrişimsel katmanlar ile değiştirilmesi ve yukarı örnekleme katmanları kullanılarak kategori bilgisi yerine bir sıcaklık haritası elde etmesidir. Şekil 2.42'de tam bağlı katmanların evrişimsel katmanlara dönüştürülmesini konu alan bir görsel paylaşılmıştır. FCN-8, FCN-16, FCN-32 gibi farklı mimariler bulunmaktadır [63].



Şekil 2.42 FCN model mimarisi [63]


U-Net: Olaf Ronneberger ve arkadaşları tarafından 2015 yılında geliştirilen U-Net mimarisi özellikle medikal görüntülerin sınıflandırılmasında kullanılmak üzere tasarlanmıştır [64]. İsmi U şeklindeki yapısından alan mimari Şekil 2.43'te gösterilmektedir.



Şekil 2.43 U-Net mimarisi [64]

U-Net mimarisi incelediğinde üç farklı bölümden oluştuğu görülmektedir. Bunlar daralma, darboğaz ve genişlemedir. Daralma bölümü, daralma bloklarından oluşmaktadır. Her bir blok girdiye, 3x3 filtre kullanarak evrişim işlemi uygulamakta ve bunu 2x2 maksimum havuzlama takip etmektedir. Filtre sayısı her blokta iki kat arttırılmıştır. Bu sayede daha karmaşık yapılar öğrenilebilmektedir. Darboğaz katmanı ise daralma ile genişleme arasında aracılık etmektedir. U-Net mimarisinin getirdiği ana yenilik genişleme kısmındadır. Daralma katmanı gibi genişleme katmanı da bloklardan oluşmaktadır. Her blokta 3x3 filtreler ile evrişim yapılmasının ardından 2x2 üst örnekleme yapılmaktadır. Her blokta daralma katmanı ile olan simetriyi korumak adına bir önceki katmandaki özellik haritalarının yarısı alınır. Daralma bloklarından gelen özellik haritaları genişleme bloğunda karşılık gelen özellik haritalarına eklenmektedir. Bu sayede, görüntüyü daraltırken öğrenilen özellikleri onu yeniden yapılandırmak için kullanılacaktır. Genişleme bloğu sayısı, daralma bloğu sayısı ile aynıdır. Genişleme katmanının sonlarına doğru 3x3'lük filtreler kullanılarak yapılan evrişim işlemleri ile özellik haritaları segmentasyon sonucunu elde etmek için daraltılmaktadır.

SegNet: 2016 yılında Vijay Badrinarayanan ve arkadaşları tarafından önerilen model kodlayıcı ve çözücü olmak üzere iki bölümden oluşmaktadır [65]. Şekil 2.44'te önerilen mimarinin detaylarına ait bir görsel paylaşılmıştır.




Şekil 2.44 SegNet mimarisi [65]

SegNet'in kodlayıcı kısmında birbirini takip eden evrişimler ve havuzlama işlemleri yer almaktadır. Vgg-16'dan baz alınarak kodlayıcı bölümünde 13 evrişim katmanı bulunmaktadır. Mimarinin çözücü kısmında ise yukarı örnekleme ve evrişim işlemleri birbirini takip eden sıra ile uygulanmıştır. En sonda ise bir softmax sınıflandırıcısı kullanılarak pikseller kategorilere ayrılmıştır. Kodlayıcı katmandaki özellik haritaları çözücü katmandaki karşılık gelen özellik haritalarına eklenmektedir. SegNet, U-Net ile benzer bir mimariye sahiptir. SegNet'de havuzlama indisleri yerine tüm özellik haritaları kodlayıcıdan çözücüye aktarılmıştır.

Yolo: Sınıflandırma algoritmaları görüntü içerisinde önceden belirlenen bir nesnenin varlığını bulmaya çalışırken, tespit algoritmaları sınıflandırmanın yanında söz konusu objenin etrafında bir dikdörtgen çizerek görüntüdeki yerini de tespit etmektedir. Bu amaç için geliştirilmiş derin öğrenme tabanlı farklı algoritmalar bulunmaktadır. Bu algoritmalar iki gruba ayrılmaktadır. İlk grup algoritmalar iki aşamadan oluşmaktadır. İlk aşamada görüntü üzerinde belirli sayıda sınırlayıcı kutu oluşturulur. İkinci aşamada bu sınırlayıcı kutular ESA sınıflandırıcıları kullanılarak içinde nesne olup olmadığı tespit edilmeye çalışılır. Sınıflandırıcıdan gelen sonuçlar bazı son işleme adımları ile (yinelenen tespitlerin ortadan kaldırılması, sınırlayıcı kutuların resimdeki nesnelere göre yeniden sıralanması vb.) geliştirilerek nihai sonuç elde edilir. Bu süreç oldukça yavaş, optimize edilmesi zor ve karmaşıktır. En bilinen örnekleri alan tabanlı evrişimsel sinir ağlarıdır RCNN, Fast-RCNN, Faster-RCNN. İkinci grup algoritmalar ise sınırlayıcı kutuları daha önceden belirlemek yerine tek seferde hem sınırlayıcı kutuyu hem de sınıfları tespit etmeyi amaçlamaktadır.

Yolo derin öğrenme yöntemleri kullanan ikinci grup algoritmalarının en başarılısı ve nesne tespit hızı en iyi olan örneklerinden bir tanesidir. Yolo'nun ilk versiyonu Redmon ve arkadaşları tarafından 2016 yılında tanıtıldı [66]. Yolo saniyede 45 kare görüntü içerisinde gerçek zamanlı olarak nesne tespiti yapabilmektedir. Bunu tek bir ESA ağını kullanarak yapmaktadır. Yolo'nun çalışma prensibi oldukça basittir. Bir ESA ağı birden çok sınırlayıcı kutuyu ve onlara ait sınıf olasılıklarını tahmin etmektedir. Bunu yaparken tam görüntüyü tek seferde kullandığı için nesneler arası ilişkileri öğrenme kapasitesi rakiplerine nazaran yüksektir. Yolo nesne tespit problemini regresyon problemine dönüştürmüştür. Ağı tahminleri $(SXS)*B*(5+C)$ 'lik tensorlar ile temsil edilmektedir. Yolo'nun nesne tespitindeki

gücünü anlamak için ilk olarak tahmin tensor'unu anlamak gerekmektedir. Yolo ilk olarak ele aldığı görüntüyü birbirini kesmeyen (SXS) sayıda ızgaraya bölmektedir. Eğer bir nesnenin orta noktası bir ızgara hücresinin ortasına denk gelirse, bu ızgara hücresi bu nesneyi tespit etmekte sorumludur. Bu amaçla her ızgara hücresi B adet sınırlayıcı kutu ve bu kutulara ait güven puanlarını hesaplamaktadır. Güven puanı kavramı, sınırlayıcı kutu içerisinde bir nesne olup olmadığının göstergesidir. Yolo'nun tespit aşamaları Şekil 2.45'te gösterilmiştir.



Şekil 2.45 Yolo lezyon yerini tespit aşamaları [67]

Güven puanı, mevcut nesnenin görüntüde olma olasılığının ve kesişme yüzdesinin (IOU) çarpımı ile elde edilmektedir.

$$\text{Güvenpuanı} = \text{Pr}(\text{Nesne}) * \text{IOU}_{\text{arzu edilen tahmin edilen}} \quad (2.24)$$




$$IOU = \frac{\text{Kesişim bölgesi}}{\text{Birleşim bölgesi}}$$

Şekil 2.46 Kesişme yüzdesi hesaplama formülü

Eğer ilgili hücrede herhangi bir nesne yok ise güven puanı sıfır olmalıdır. Aksi takdirde güven puanı IOU değerine eşittir. Her sınırlayıcı kutu x , y , w , h ve güven puanı olmak üzere beş parametreye sahiptir. Bu parametrelerden x ve y sınırlayıcı kutunun merkezini temsil ederken w ve h değerleri sınırlayıcı kutunun genişlik ve uzunluğudur. Ayrıca sınıf puanlarını temsil eden ekstra bir C parametresi bulunmaktadır (Şekil 2.47). Her ızgara hücresi C adet sınıf olasılığını tahmin etmektedir $\Pr(\text{Sınıf}_i | \text{Nesne})$. Yolo sınıf olasılık tahminlerini aşağıdaki formüle göre hesaplamaktadır. Bu puanlar, o sınıfın kutuda ortaya çıkma olasılığını ve öngörülen kutunun nesneye ne kadar uygun olduğunu göstermektedir.

$$\Pr(\text{Sınıf}_i | \text{Nesne}) * \Pr(\text{Nesne}) * IOU_{\text{tahmin edilen}}^{\text{arzu edilen}} = \Pr(\text{Sınıf}_i) * IOU_{\text{tahmin edilen}}^{\text{arzu edilen}} \quad (2.25)$$



Şekil 2.47 Sınırlayıcı kutuların içerdikleri parametreler [67]

Yolo'nun mimarisi GoogLeNet'ten [58] esinlenmiştir. Özellik çıkarımı için 24 evrişimli katman ve olasılıkların ve koordinatların çıktısını öngörmek için tam bağlı iki katmandan oluşur. Yolo, son katman için doğrusal bir aktivasyon işlevi kullanırken, sızdıran rektifiye doğrusal aktivasyon (LReLU) işlevi, aşağıdaki formülde görüldüğü gibi diğer katmanlar için kullanılır.

$$\beta(x) = \begin{cases} x, & \text{eğer } x > 0 \\ 0.1 * x, & \text{aksi takdirde} \end{cases} \quad (2.26)$$

Yolo hata fonksiyonu olarak MSE kullanmaktadır. Hata fonksiyonun detayları formül 2.27'de verilmiştir.

$$\begin{aligned}
hata = & \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right] \\
& + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[\left(\sqrt{w_i} - \sqrt{\hat{w}_i} \right)^2 + \left(\sqrt{h_i} - \sqrt{\hat{h}_i} \right)^2 \right] \\
& + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} (C_i - \hat{C}_i)^2 + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} (C_i - \hat{C}_i)^2 \\
& + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in classes} (p_i(c) - \hat{p}_i(c))^2
\end{aligned} \tag{2.27}$$

Yukarıda verilen hata formülünde x ve y sınırlayıcı kutunun orta noktasının koordinatlarını temsil ederken, w ve h genişlik ve yüksekliği temsil etmektedir. C_i güven puanını p_i ise sınıflandırma tahmini temsil etmektedir. Lambda sabitleri sınırlayıcı kutu tahminlerini arttırmak ve hiçbir nesne içermeyen sınırlayıcı kutulardan gelen güven tahminlerinin kaybını için kullanılmaktadır. Bu değerler lambda=5, ve 0.5 olmak üzere ayarlanır. Son olarak 1_{ij}^{obj} , i hücresinde görünen bir nesnenin varlığını belirtmekle birlikte ayrıca 1_{ij}^{obj} , i hücresindeki j. sınırlayıcı kutunun bu tahminden sorumlu olduğunu gösterir. Formülde ilk iki katman lokalizasyon kaybını hesaplar, üçüncü katman güven kaybını hatasını hesaplar ve son katman sınıflandırma hatasını belirler. Yolo, görüntüye bir kez baktığından ve karmaşık işlemler gerektirmediğinden diğer nesne algılama ve sınıflandırma algoritmalarına kıyasla oldukça hızlıdır. Ayrıca, tüm görüntüyü tararken daha doğru tahminler yapar.

Bu çalışmada, önceki Yolo ağlarının en son ve gelişmiş versiyonu olan Yolov3 modeli kullanılmıştır [68]. Nesne algılama algoritmalarındaki son gelişmelere paralel olarak, önceki Yolo versiyonlarındaki az ama etkili geliştirmeler sonucu Yolov3 ortaya çıkmıştır. Yolov3'teki ana değişiklikler aşağıda listelenmiştir:

- Yolov3, sınırlayıcı kutularının güven puanlarını tahmin ederken, kayıp fonksiyonu olarak lojistik regresyon kullanmaktadır.
- Yolov3, sınıf olasılıklarının tahmini için softmax fonksiyonu yerine çoklu bağımsız lojistik sınıflandırıcı kullanmaktadır. Görüntüde birden fazla nesne olduğunda bu gelişme büyük avantaj sağlamaktadır.
- Yolov3, 53 evrişim katmanı ve artık blokları olan DarkNet-53 adlı güçlü bir özellik çıkarıcı ağdan yararlanmaktadır. DarkNet-53'e ek olarak, algılama

görevi için 53 katman daha eklenerek 106 katmanlı tamamen evrişimli bir mimari yapılmıştır. Şekil 2.48, DarkNet-53 mimarisini göstermektedir.

Katman Türü	Filtre Boyutu	Çıktı
Convolutional	32 3×3	256×256
Convolutional	64 $3 \times 3 / 2$	128×128
1x	Convolutional	32 1×1
	Convolutional	64 3×3
	Residual	128×128
	Convolutional	128 $3 \times 3 / 2$
2x	Convolutional	64 1×1
	Convolutional	128 3×3
	Residual	64×64
	Convolutional	256 $3 \times 3 / 2$
8x	Convolutional	128 1×1
	Convolutional	256 3×3
	Residual	32×32
	Convolutional	512 $3 \times 3 / 2$
8x	Convolutional	256 1×1
	Convolutional	512 3×3
	Residual	16×16
	Convolutional	1024 $3 \times 3 / 2$
4x	Convolutional	512 1×1
	Convolutional	1024 3×3
	Residual	8×8
	Avgpool	Global
Connected		1000
Softmax		

Şekil 2.48 DarkNet 53 mimarisi [68]

- Yolov3, maksimum havuzlama yerine alt örnekleme için kademeli evrişim yöntemi kullanmaktadır.
- Yolov3, temel özellik çıkarıcı katmanlara ek olarak birçok evrişimsel katmandan oluşur ve bu sayede ağıın üç farklı boyutta tahmin yapabilme kabiliyetini artırır. Bu, sistemin görüntüdeki küçük nesneler üzerinde daha doğru tespitler yapmasını sağlar.
- Yolov3'teki son gelişme, tahmin katmanları arası bağlantılardır. Yukarı örnekleme işleminden elde edilen özellik haritaları, birleştirme işlemi kullanılarak önceki katmanların özellik haritaları ile birleştirilmiştir. Bu kombinasyon sayesinde küçük nesnelerde daha doğru algılama performansı sağlamıştır.

2.7 GrabCut

GrabCut, yinelemeli yarı otomatik bir görüntü segmentasyon tekniğidir [69]. Bu teknikte, segmente edilecek görüntü bir graf ile temsil edilir. Bu graf, görüntünün en iyi şekilde segmente edilmesini sağlamak için minimum bir maliyet azaltma

fonksiyonu kullanılarak oluşturulur. Oluşturulan grafta düğümler görüntüdeki piksellerden oluşur. Başka bir deyişle, görüntüdeki her piksel, graftaki bir düğüm ile sembolize edilir. Bu düğümlere ek olarak, grafa, ön plan ve arka plan denilen iki ekstra düğüm daha eklenir. Görüntüdeki her bir piksel, yani graftaki her bir düğüm bu iki düğümden birine bağlanır. Arka plan düğümü arka piksellerin bağlantı noktasını oluştururken ön plan düğümüne ise segmente edilecek alandaki pikseller bağlanmaktadır. Bu bağlanma işlemi görüntüdeki sınır bilgisine ve renk bilgisine göre belirlenen bir ağırlıklandırma bilgisine göre yapılmaktadır. GrabCut tekniği görüntüdeki renk bilgisini kullanarak bölge bilgisini elde eden Gauss Karışım Modellerini (GKM'ler) [70] kullanır. Daha sonra ağırlıklandırılan grafi segmente etmek için bir minimum kesme / maksimum akış tekniği kullanılır. Algoritmanın matematiksel ifadesi aşağıdaki gibidir. N sayıda pikselden oluşan bir görüntüye I diyelim ve pikselleri temsilen bir $p = (p_1, p_2, \dots, p_N)$ vektörümüz olsun. Vektör içindeki piksellerin renk dağılımlarını RGB uzayında $p_i = (R_i, G_i, B_i)$ ile temsil edelim, $i \in [1, \dots, N]$. Segmentasyon ise görüntüdeki her bir pikselin piksellerin arka plana veya ön plana ait olup olmadığının belirlenmesidir. Vektörel olarak ifade edersek $s = (s_1, s_2, \dots, s_N)$, $s_i \in \{0, 1\}$. GrabCut algoritması kullanıcı tarafından segmente edilmek istenilen objenin etrafına bir sınırlayıcı kutu (R) çizilmesi ile başlar. R tanımlanmasından sonra görüntü üç farklı bölgeye ayrılır bunlar R_B, R_F, R_U . Bu bölgeler sırası ile arka plan pikselleri, ön plan pikselleri ve bilinmeyen piksellerdir. R dışında kalan pikseller R_B olarak düşünülürken, içinde kalan pikseller R_U olarak ele alınır. GrabCut algoritması R_U piksellerinin R_B 'yemi yoksa R_F 'yemi ait olduğunu belirlemeye çalışır. Bunu yapabilmek için GKM'ler tarafından sağlanan renk bilgisini kullanır. GKM'ler görüntüyü komponentlere (C) ayırır, bu komponentler arka plan için ($s_i = 0$) ön plan için ($s_i = 1$)'dir.

$$\theta = \{\pi(s, c), \omega(s, c), \Sigma(s, c), s \in \{0, 1\}, c = 1, \dots, C\} \quad (2.28)$$

Formül 2.28'e göre π ağırlıkları, ω GKM'lerin ortamlarını, Σ modelin kovaryans matrislerini temsil eder. $c = (c_1, \dots, c_i, \dots, c_N)$, $c_i \in (1, \dots, C)$, $i \in [1, \dots, N]$ dizindeki bileşenlere göre p_i pikselin arka plana mı ön plana mı ait olduğu belirlenir. Enerji fonksiyonu ise:

$$E(s, c, \theta, p) = U(s, c, \theta, p) + V(s, p) \quad (2.29)$$


U olasılık potansiyelidir ve GKM'lerin olasılık dağılımı ise $p(\cdot)$ formül 2.30'a göre belirlenir.

$$U(s, c, \theta, p) = \Sigma_i - \log pr(p_i | s_i, c_i, \theta) - \log \pi(s_i, c_i) \quad (2.30)$$

V, her pikselin etrafındaki bir C bölgesini göz önünde bulundurarak bölümlere ayrılmış bölgelerin renk açısından tutarlı olması gerektiğini varsayarak düzenli bir önceliktir.

$$V(s, p) = \gamma \sum_{\{m, n\} \in C} [s_m \neq s_n] \exp(-\beta \|p_m - p_n\|^2) \quad (2.31)$$

Bu enerji azaltma şeması, verilen ilk dikdörtgenin bulunduğu görüntüye uygulanır. Minimum kesim yöntemi kullanılarak elde edilen son bölümlendirme Şekil 2.49'da verilmiştir.



Şekil 2.49 GrabCut yöntemi [71]

Algoritmanın işleyiş süreci:

- 1- İlk adım, kullanıcı tarafından elle çizilmiş olan ve ilgilenilen nesneyi çevreleyen bir dikdörtgenle başlar. Bu adım, ilgilenilen alanın arka planı ve ön planı hakkında bilgi verir. Dikdörtgenin içindeki pikseller bilinmeyen olarak kabul edilirken, dikdörtgenin dışındaki pikseller arka plan olarak kabul edilir. Bu bilgilere dayanarak, algoritma bilinmeyen piksellerin ön plana mı yoksa arka plana mı ait olduğunu belirlemek için bir model oluşturur.
- 2- Bilinmeyen piksellerin ön plan sınıfı olarak kabul edildiği ve bilinmeyen piksellerin dışındaki diğer tüm piksellerin arka plan olarak kabul edildiği bir başlangıç segmentasyon modeli oluşturulur.
- 3- Başlangıç arka plan ve ön plan sınıfları GKM'ler kullanılarak, iki bölge için C parça GKM bileşenleri oluşturularak yapılır.
- 4- Arka plan sınıfındaki her piksel, arka plan GKM'sindeki en olası Gauss bileşenine atanmıştır. Aynı işlem, en muhtemel ön plan Gaussian bileşenine atanan ön plan pikselleri için de gerçekleştirilir.
- 5- Önceki adımda oluşturulan piksel kümeleri kullanılarak yeni GKM'ler elde edilir.
- 6- N düğümlü bir graf oluşturulur ve bağlantılar arasındaki ağırlık değerleri belirlenir. Bundan sonra, ön plan ve arka plan piksellerini belirlemek için minimum kesim algoritması kullanılır.
- 7- Nihai segmentasyon sonucunu elde edene kadar 4-6 arasındaki adımlar tekrarlanır.


3. DERİ KANSERİ

Tezin bu bölümünde deri lezyonlarının biyolojik yapısı ve literatürde deri lezyonlarının sınıflandırılmasında kullanılan makine öğrenmesi yöntemlerine değinilecektir. Bölüm cilt lezyonlarının genel patolojisi hakkında verilen kısa bir bilgilendirme ile başlayıp deri kanserinin detaylarını, teşhis ve tedavi sürecini ele almaktadır. Daha sonra deri lezyonlarının tanı sürecine yardımcı olmak için geliştirilen derin öğrenme yöntemlerinden bahsedilecektir. Bölümün sonunda derin öğrenme yöntemlerinin literatürdeki yerleri değerlendirilecek gelecek çalışmalar ve araştırmalar hakkında bilgi verilecektir.

3.1 Deri Lezyonları ve Deri Kanseri

3.1.1 Derinin Yapısı


Deri insan vücudunun en büyük organı olmakla beraber yetişkin bir insanın toplam vücut ağırlığının %15'ini oluşturmaktadır. Vücudu dışardan gelebilecek kimyasal ve fiziksel etkilere karşı korumak, vücuttaki su dengesini ayarlamak, vücut ısını dengelemek gibi birçok hayati görevi yerine getirmektedir. Kötü huylu deri hastalıklarını anlamak için derinin biyolojik yapısını ve bu yapıda yer alan dokuların işlevlerini anlamak önemlidir. Şekil 3.1' de görüldüğü üzere deri üç ana katmandan meydana gelmektedir.



Şekil 3.1 Derinin katmanları [72]

En alt katman olan hipodermis, deri altı doku olarak bilinir; gevşek bağ dokularından ve yağ depolama özelliğine sahip temel yağ dokularından oluşmaktadır. Bu katmanda yoğun bir şekilde bulunan yağ lobları enerji rezervi, yalıtım ve koruma katmanı oluşturmak gibi görevleri üstlenmektedir, ayrıca bu katmanda sinirler büyük kan damarları ve lenfatik damarlar bulunmaktadır. Hipodermisin üzerinde kollajen ve elastik liflerden, yani bağ dokusundan oluşan bir tabaka olan dermis bulunmaktadır. Bu katman kan ve lenfatik damarları, duyuşal reseptörleri saç köklerini ve ter bezlerini içermektedir [73]. Üst deri tabakası olan epidermis keratinleşmiş olan çok katlı yassı epitel hücrelerinden meydana gelmektedir. Epidermis; stratum corneum, stratum lucidum, stratum granulosum, stratum spinosum ve stratum basale olmak üzere beş katmandan oluşmaktadır. Şekil 3.2’de epidermisin katmanlarını temsil eden bir görsel paylaşılmıştır. Bu katmanlardan epidermis ile dermis arasında uzanan ve en alt katman olan stratum basale canlı hücrelerden oluşmaktadır. Yukarı ki katmanlara doğru çıkıldıkça hücreler şekil değiştirip farklı özellikler kazanarak canlılığını yitirmektedir. Cildimizin en önemli katmanlarından bir tanesi olan stratum basale kübik şeklindeki keratinosit hücrelerinden meydana gelmektedir [73]. Bu katmanda yer alan keratinosit hücrelerinin mitoz bölünmesi ile ortaya çıkan yeni hücreler sayesinde deri kendisini yenilemektedir. Mitoz bölünme sonucunda oluşan keratinositler ortalama 21 ila 25 günlük bir süreç içerisinde üst katmanlara doğru şekil ve yapı değiştirerek yol almaktadırlar. Üst katmanlara çıkan hücreler eski hücreler ile yer değiştirerek

yenilenmeyi tamamlamaktadır. Bir keratinositin bütün tabakaları geçerek cansız bir kreatin tabakası haline gelmesi kadar geçen süreye derinin çevrimi denilmektedir [74].



Şekil 3.2 Epidermin katmanları [75]

Epidermis keratinositin hücrelerin yanı sıra bir dizi farklı hücreyi de bünyesinde bulundurmaktadır. Bu hücrelerden Langerhans hücreleri deri bağışıklık sistemine aitken [76], Merkel hücreleri mekanoreseptör görevi görmekte, mekanik basıncı algılayıp, nöronlar vasıtası ile beyne iletmektedir [77]. Son olarak bu hücrelerden en önemlisi olan Melanositler, sinir-kret türevli hücrelerdir ve derinin yanı sıra saçta iriste, iç kulakta, sinir sisteminde ve kalpte bulunurlar [78]. Başlıca işlevleri, melanozom olarak bilinen özel organeller için melanin üretimidir. Melanin farklı formları olan doğal bir pigmenttir; kahverengi/siyah eumelanin, kırmızı/sarı pheomelanin ve kahverengi / siyah neuromelanin. Derideki en belirgin tip olan eumelanin, bir ışın emici görevi görür ve güneşten gelen UV ışınlarının % 99.9'undan fazlasını emerek deriyi oluşabilecek zararlardan korur [79]. Melanozomlar, bu koruma görevini melaninleri stratejik bir şekilde biriktiği keratinositlere taşıyarak hücrelerin UV'ye maruz kalan tarafında kapak benzeri bir örtü oluşturarak yerine getirmektedir. (Şekil 3.3) [80].



Şekil 3.3 Bronzlaşma yoluyla UV radyasyonuna maruz kalma, melanin üretimini artırarak cildin pigmentasyonunda değişikliklere neden olur [81].

Deri pigmentasyonundaki farklılıklar, melanosit miktarındaki farklılıktan ziyade, melanogenez miktarı (melanin üretimi), melanozomların dağılımı, büyüklüğü ve içeriğindeki bir farka dayanmaktadır [80]. UV'ye maruz kalmaya yanıt olarak melanin üretiminin, keratinositlerin kendi kontrolü altında olduğu düşünülmektedir [82].

3.1.2 Deri Kanseri Patolojisi

Deri lezyonları, deri hücrelerinde meydana gelen anormal değişimlerin sonucu olarak ortaya çıkmaktadırlar. Kanserli, kanser öncesi ve kansersiz olmak üzere üç tür lezyon bulunmaktadır. Deri kanseri, deri hücrelerinin anormal düzeyde çoğalması ile ortaya çıkan bir hastalıktır. Güneş ışığından kaynaklanan ultraviyole radyasyonun (UVR) deri kanserinin en önemli nedeni olduğu iyi bilinmektedir [83]. Güneş yanığı, güneşe aşırı maruz kalmak, solaryum cihazları deri kanserinin patogenezinde rol oynayan immünosüpresyona neden olan kümülatif hasardan sorumludur. Ozon tabakasının incilmesi, UV ışığının seviyeleri, enlem, irtifa ve ayrıca hava koşulları, dünya yüzeyine ulaşan UV radyasyon emisyonunu etkilemektedir. Ayrıca, çevresel kirleticiler, kimyasal kanserojenler ve kanserojenlere mesleki maruziyetler de deri kanserini tetikleyen etmenler arasında gösterilmektedir. Son olarak, Çin tescilli bazı ilaçları kullanma, inorganik arsenik içeren içme suyu tüketimi, ten rengi ve sigara ekstra risk faktörleri arasındadır [83].

Deri kanserinin en önemli kaynağı olarak bilinen olan UVR içerdiği dalga boylarına göre üç ayrı kategoriye ayrılmıştır: (1) Ultraviyole A, UVA ışınları 315-400 nm aralığında dalga boyuna sahip olmakla birlikte UVR ışınlarının çoğunluğunu

oluşturmaktadır ve ozon tabakasını rahatlıkla geçebilmektedirler. (2) UVB ışınları 280-325 nm aralığında dalga boyuna sahiptir ve çoğunluğu ozon tabakası tarafından yakalanmaktadır. Sadece %1-10'luk kısmı dünya yüzeyine ulaşmaktadır ancak ozon tabakasının son yıllarda aldığı hasardan dolayı bu ışına maruz kalınma riski artmıştır. (3) En yüksek enerjili radyosuna sahip olan UVC ışınlarının dalga boyu 100-280 nm arasındadır. Bu ışınların tamamı ozon tabakası tarafından dünya yüzeyine varmadan filtrelenmektedir [84]. Söz konusu ışıklardan UVA deriye derinlemesine nüfus edebilmekle birlikte derinin dermis tabakasının alt kısımlarına kadar inebilmektedir. Bununla birlikte daha yüksek enerjili UVB ışınları derinin daha üst katmanlarına etki edebilmektedir [84].

UVR deri üzerinde çok çeşitli akut ve kronik etkilerden sorumludur. İnsan derisinin UVR'ye karşı akut tepkileri photodamage(çiller), erythema, mutasyon, immunosuppression, D vitamini sentezi ve bronzlaşmadır. Kronik UVR etkileri fotoyaşlanma ve fotokarsinogenez; mutasyon ve immünoşüpresyon ile uyarıldığı düşünülmektedir [85].


UVB radyasyonu DNA ve onarım sistemlerine verdiği hasar ile birlikte immünitenin kısmi baskılanmasıyla birlikte immün sistemdeki değişiklikler sonucu çoğu deri kanserinin birincil derecede sorumlusudur [86]. Öte yandan daha önceleri kanserojen etkisi olmadığı düşülen UVA radyasyonunun hayvanlara aşırı doz uygulanmasının deri kanserini ortaya çıkardığı kanıtlanmıştır [87]. Bununla birlikte bronzlaşma salonlarında kullanılan yapay UVA radyasyonun uzun dönem kullanımına bağlı olarak özellikle melanom olmayan deri kanseri (NMDK) riskini arttırdığı gözlemlenmiştir [88]. UVC radyasyonu güçlü bir kanserojendir fakat çoğunluğu ozon tabakası tarafından filtrelendiği için kanserojen etkisi azdır. Ancak ozon tabakasındaki incelleme artmaya devam ederse UVC radyasyonun kanser oluşturma potansiyelinde artış gerçekleşeceği öngörülmektedir. Ozon tabakasının %1'lik incilmesi ile birlikte deri kanseri riskinin %2 ila %4 oranında arttığı gözlemlenmiştir [89]. UVR'nin %90 oranında NMDK'ların sorumlusu olduğu tahmin edilmektedir.

3.1.3 Tehlikeli Olmayan Deri Kanseri

Melanom olmayan deri kanseri (NMDK), özellikle Avrupa popülasyonunda sık rastlanan bir deri kanseri türüdür. Temel olarak keratinocyte tümörlerinden oluşmakla

birlikte ve basal cell carcinoma (BCC) ve squamous cell carcinoma (SCC) olmak üzere iki türü bulunmaktadır [90]. Amerika Birleşik Devletlerindeki (ABD) Amerikan Kanseri Derneği'nin (AKD) verdiği istatistiklere göre 2012 yılında tahminen 5,4 milyon BCC ve SCC vakası teşhis edilmiştir [91].

BCC çok yaygın bir NMDK türü olmakla birlikte NMDK vakalarının %80'ni oluşturmaktadır [92]. Çoğunlukla boyun kafa gibi vücudun güneşe maruz kalan kısımlarında görülür, ancak yavaş gelişir ve vücudun diğer kısımlarına yayılma olasılığı oldukça düşüktür. SCC deri kanseri vakalarının %19'unu oluşturmakla birlikte eller, kulaklar, kollar, bacaklar gibi güneşe maruz kalan bölgelerde ve kimyasal yollarla zarar görmüş deride görülür. Vücudun diğer bölgelerine yayılma olasılığı yüksek olsa da bu yayılma olasılığı %2 ila 5 arasında kalmaktadır. NMDK vakalarının sadece %1 ini oluşturan merkel cell carcinoma, cutaneous lymphoma ve kaposi sarcoma gibi NMSK türleri bulunmaktadır [90-92]. Farklı seviyelerde deri kanseri türlerini gösteren bir görsel Şekil 3.4'te verilmiştir.



Şekil 3.4 Deri kanseri türleri [93]

NMDK'ların özellikle güneşe maruz kalan bölgelerde ortaya çıktığı düşünüldüğünde UV radyasyonunun hastalıktaki etkin rolü ortaya çıkmaktadır. DNA hasarının birikmesi genellikle mutasyonları ortaya çıkarır. Bu mutasyonlar hem tümör baskılayıcı genlerde hem de oncogenlerde görülmektedir. İnsanlarda görülen deri kanserinin %50'sinden fazlasında p53'ün üretilmesinden sorumlu tümör baskılayıcı gen olan TP53 genindeki mutasyonlar olduğu gözlemlenmiştir. TP53 geni hücrenin

dış strese karşı sağlıklı kalmasında anahtar rol alan bir gendir. Daha spesifik olarak, tüm BCC'lerin yaklaşık %50'si ve tüm SCC'lerin%90'ı TP53 mutasyonuna sahip oldukları tespit edilmiştir [94, 95]. Bu genlere ek olarak CDKN2A locus ve RAS oncogenleri de NMSK oluşumunda etkili oldukları gözlemlenmiştir [96].


3.1.4 Melanoma Deri Kanseri

Melanoma ölümcül bir deri kanseri türüdür. AKD'nin 2019 yılı başlarında yayınladığı rapora göre 96,480 yeni melanoma vakası olacağı ve bu vakalardan 7230'unun ölümle sonuçlanacağı öngörülmektedir [10]. Melanomanın diğer deri kanserleri arasında görülme olasılığı %1 olmasına karşın ölüm ile sonuçlanma oranı %75'dir. ABD'de yıllar içinde melanoma görülme sıklığı artış gösterirken ölüm oranı sabit kalmıştır [91]. Bu artış oranı yaşlanan popülasyon ile birlikte insan davranışlarındaki değişim ile (sık güneşlenme gibi) ilişkili olma ihtimali bulunmaktadır. Bununla birlikte tarama yöntemlerinin geliştirilmesi ve sıklığının arttırılması da bu oranın artmasına sebep olmuş olabilir.

Belçika'da yer alan bir rapora göre 2013 yılında 2635 yeni Melanoma vakası tanısı konulduğu belirtilmiştir. Bu yıl baz alındığında Belçika'da kadınlarda en sık görülen dördüncü erkekler de ise en sık görülen yedinci kanser türüdür [97]. Belçika'da 2014-2024 yılları arası olası melanoma görülme oranı tahminlere göre bir artışın olacağı öngörülmektedir. Bu artış miktarının yıllık %49 civarı olabileceği ve melanoma vakalarının yıllık 2925 ila 4356 arasında artacağı beklenmektedir [98].

Sağlık bakanlığının verilerine göre ülkemizde melanoma görülme sıklığı kadınlarda 1,3/ 100.000 iken erkeklerde 1,9/100.000 olarak saptanmıştır [99].

Hücre içi bozulan sinyalleşmenin bir sonucu olarak melanositler keratinositlerin sıkı kontrolünden kurtulur ve sonuç olarak kontrolsüz çoğalmaya ve dağılarak yayılmaya başlarlar. Bu süreci konu alan bir görsel Şekil 3.5'te paylaşılmıştır.



Şekil 3.5 Melanoma yayılma süreci [100]

İlk olarak epidermiste başlayan çoğalma, dermis tabakası boyunca devam ederek daha alt tabakalara kadar ilerlemektedir. Radyal büyüme evresi (RBE) genellikle kötü huylu kanserin başlangıcı olarak nitelendirilmektedir. Bu evrede dermis tabakasında küçük gruplar halinde istilalar başlamaktadır. Daha tehlikeli dikey büyüme evresine (DBE) ulaşıldığında, çoğalan hücrelerin kümeleri dermis tabakasında bulunur ve buradan diğer bölgelere kolayca yayılabilmektedir [100]. Bu yayılmacı tavırları melanomayı tehlikeli yapan başlıca unsurdur.

3.1.5 Deri Kanseri Risk Faktörleri ve Korunma

İki tip, melanom ve melanom dışı cilt kanseri şu anda Avrupa popülasyonunda en yaygın görülen malignite türüdür. Hastalığın görülme oranının yüksek olmasına karşın ölüm oranları düşüktür ancak hastalığın tedavi süreci ekonomiye ağır bir yük getirmektedir. ABD’de yıllık 650 milyon dolar bu hastalığın çeşitli tedavi süreçleri için harcanmaktadır [101]. Sonuç olarak deri kanserini erken teşhis etmek ya da önlemek güçlü bir ihtiyaçtır. Bu hedefe ulaşmak için iki aşamalı bir program üzerine odaklanılmalıdır. Bir yandan toplumun davranış biçimleri incelenirken diğer yandan erken teşhis için bir dizi önlemler uygulanmalıdır.


NMDK vakalarında güçlü kişisel ve çevresel risk faktörleri bulunmaktadır. Kişisel risk faktörleri arasında cinsiyet, genetik yatkınlık ve yaş bulunmaktadır. Günümüz yaşam şartları kalitesinde görülen artış ile birlikte uzayan yaşam süresi artan deri kanseri vakaları ile birlikte düşüşe geçmiştir. Güneş ışığına maruz kalmak çevresel faktörlerin başında gelmektedir. Bu nedenle korunma stratejisi birinci hedef olmalıdır. SCC vakalarında uzun süreli güneş ışığına maruz kalmanın risk faktörünü arttığı gözlemlenmiştir. Bununla birlikte çalışmalar BCC’larda daha karmaşık bir bağlantının

olduğunu, çocukluk döneminde güneşe maruz kalmak ve kapalı bronzlaşma risk faktörleri olarak gösterilmektedir [102]. Bu durumda kamuoyunu güneş ışığına doğrudan maruz kalma noktasında bilgilendirme eğitimi vermek bu hastalıkların önlemesi noktasında önemli bir önlemdir.

Deri kanserini ikinci önleme stratejisi ise, uzmanlar tarafından sık periyot aralıklarında yapılan muayenelerle hastalığın erken teşhis edilmesidir. Bu konuda toplum bilinçlendirilerek oluşan lezyonları kendileri değerlendirip riske girmeden bir uzman yardımı istemesi sağlanabilir [103]. Melanoma vakalarında derinliği 1mm'nin altında olan lezyonların cerrahi bir müdahale ile çıkarılmasından sonra hastanın iyileşme oranı %95'in üzerindedir. Daha öncede belirtildiği gibi bu oran daha ileriki safhalarda düşmektedir. Bu yüzden erken teşhis melanoma vakalarında çok önemlidir. Bu yüzden deri lezyonlarının iyi huylu veya kötü olmak üzere doğru bir şekilde sınıflandırılması uygun tedavi planının oluşturulması için bir gerekliliktir [37].

3.1.6 Melanomanın Diğer Lezyonlardan Ayrılması

Deri lezyonlarının teşhis süreci lezyon tipine göre risk faktörlerinin incelenmesi ile başlamaktadır. Yerleşim yeri, yaş, cinsiyet, lezyonların vücuttaki dağılımı gibi çeşitli risk faktörlerinin de göz önünde bulundurulması ile birlikte lezyonun görsel muayenesi ile çeşitli özellikleri incelenmektedir. Bir deri lezyonuna melanoma denilebilmesi için araştırmacılar bugüne kadar farklı yöntemler geliştirmişlerdir. Bu yöntemlerden en popüler olanı 1985 yılından Friedman ve arkadaşları tarafından önerilen ve melanomayı erken teşhis etmede kullanılan ABCDE yöntemidir [104]. Günümüzde halen pigmente olmuş deri lezyonlarının incelenmesinde bu yöntem kullanılmaya devam etmektedir. Şekil 3.6'da da görüleceği üzere bu yöntemde, lezyonun bazı spesifik karakteristik özelliklerine bakılmaktadır. Bu özellikler asimetri, kenar (border), renk (color) ve çap (diameter) ve son olarak gelişim (evaluation)'dir. Yöntem ismini bu karakteristik özelliklerin baş harflerinin birleşiminden almaktadır. İlk çıktığında ABCD yöntemi olarak anılan bu yöntemde melanomanın hızlı gelişimi göz önünde bulundurularak sonradan gelişim (evaluation) parametresi de eklenmiştir [105].



Şekil 3.6 ABCDE yöntemi [106]


Yöntem incelendiğinde Melanoma şüphesi olan bir lezyonun asimetrik olmaması, düzensiz sınırlara sahip olması, içerisinde birden fazla renk bulundurması, 6.35 mm'den daha geniş çapa sahip olması ve hızlı gelişimi, Melanoma kıstaslarını sağladığının göstergesidir [105].

Her ne kadar bu yöntem deri lezyonlarının değerlendirilmesinde yarı-sayısal (kantatif) ölçümler sunmuş olsa da doktorlar lezyonların sınıflandırılmasında kendi bilgi, deneyim ve öznel algılarına daha çok güvenmektedirler. ABCDE yönteminde deri lezyonunun derinliği hakkında herhangi bir bilgi bulunmamaktadır. Breslow kalınlığı veya derinliği, lezyonun epidermisin granüler tabakasında yaptığı istilanın derinliğini belirler ve teşhis sürecinde dikkate alınması gereken önemli bir ipucudur [107]. Fakat melanomanın tipik özelliklerini göstermeyen sapkın lezyonlar bu değerlendirme ile gözden kaçabilmektedir. Bu metotların yanı sıra 7 nokta kontrol listesi (seven point check list), Mezones ve CASH (Color, architecture, symmetry and homogeneity) yöntemleri de melanomanın teşhisi için önerilen bazı metotlardır [108, 109].

Melanoma teşhisini zorlaştıran diğer bir faktör, her ikisi de melanostik kökenlerini paylaşan pigmentte cilt lezyonlarına olan benzerliğidir (nevus, doğum lekeleri, moles). Nevus melanosit birikimin neden olduğu iyi huylu lezyonlara verilen isimdir. En yaygın tipleri common nevus, blue nevus, dysplastic nevus ve congenital nevus (doğum lekesi). Bununla birlikte bir nevus melanomanın öncüsü olabilmektedir. Bu yüzden bu tür lezyonların takip edilmesi önemlidir [104].

Deri lezyonlarını yakından incelemek için araştırmacılar geçmişten günümüze farklı yöntemler geliştirmişlerdir. Bu yöntemlerden bir tanesi olan ve epilüminesans mikroskobu olarak da bilinen dermoskopi, cilt yüzeyindeki yansımayı azaltarak uygun ışıklandırma ve yakınlaştırma ile deri lezyonlarının daha detaylı incelenmesini sağlayan cerrahi olmayan bir yöntemdir. Dermoskopide iki farklı yöntem ile kullanılır: (1) stratum korneumun ışık yansımalarını azaltmak için kullanılan polarize olmayan ışık mikroskobu; (2) derinin daha derinlerine inebilecek ve yansımayı azaltacak bir filtreye sahip polarize bir ışık mikroskobu [110, 111].

Dermoskopik görüntülerin muayenesinde, lezyonların öncelikle renginden, yapılarından ve desenlerinden bilgiler çıkarılır bu bilgiler daha sonra lezyonun sınıflandırılması için önemlidir [112]. Şekil 3.7’de normal bir kamera ile çekilmiş bir lezyon görüntüsünün, dermoskop cihazı ile alınmış görüntüsü bulunmaktadır. Şekilden de görüleceği üzere dermoskopik görüntüde daha detaylı bilgi elde edilebilmektedir. Bu yöntem sayesinde uzmanın deneyimine göre hastalığın teşhis oranında %50 artış olduğu gözlemlenmiştir [113].



Şekil 3.7 Dermoskopik görüntü örneği [114]

Bununla birlikte lezyon görünümünde hasta farkından dolayı ortaya çıkan değişiklikler, kanserli ve kansersiz lezyonlar arasındaki benzerlikler nedeni ile lezyonları görsel olarak sınıflandırmak oldukça zor ve öznelidir. Bu yüzden tanının kesin olarak doğrulanması için doktorlar histopatolojik incelemelere ihtiyaç duymaktadırlar. Dermoskopi sayesinde gereksiz biyopsilerde bir düşüş olduğu gözlemlenmiştir [115]. Ayrıca dermoskopinin lezyonların takibinde de kullanışlı olduğu kanıtlanmıştır. Sadece lezyonların gelişimlerini incelemeye değil, yeni ortaya

çıkan lezyonlarında değerlendirilmesinde güçlü bir araçtır. Şüpheli her lezyona cerrahi müdahalede bulunup biyopsi yapılması uygun değildir [108-110].

Her ne kadar dermoskop cihazı teşhis oranlarında bir iyileştirme sağlasa da dermoskopik bir görüntü üzerinde bir deneyimsiz doktorun doğru tanı yapması %75 ile %84 oranında değişmektedir [116]. Bu nedenle hastalığın teşhis sürecinde doktora yardımcı olabilecek gereksiz biyopsilerin önüne geçebilecek bilgisayarlı destek sistemlerine ihtiyaç duyulmaktadır.

3.2 Deri Kanserinin Teşhisinde Kullanılan Makine Öğrenmesi Yöntemleri

Daha önceki bölümlerde bahsedildiği gibi melanomanın erken teşhis edilmesi ölüm riskini ortadan kaldırmaktadır. Bununla birlikte melanom olan ve olmayan lezyon görüntüleri arasındaki benzerlik, lezyon görüntülerinde hastalar arası değişkenlik gibi nedenlerden ötürü tanı koymak karmaşık bir hal almaktadır. Doktorların tanı koymada deyimleri en büyük yardımcılarıdır. Bunun yanında tanısı konulan bir lezyonun kesin hasta olup olmadığını belirlemek için biyopsi yapılması bir gerekliliktir. Dermoskopi ile birlikte deri lezyonlarının yüksek çözünürlüklü, büyütülmüş görüntüleri elde edilmiştir. Bu sayede BDTS deri lezyonlarının teşhisinde yardımcı bir araç olarak ortaya çıkmıştır.

3.2.1 Veri Setleri


Dermoskopi yönteminin gelişmesi ile birlikte hekimler deri lezyonlarının açıkça aydınlatılarak yakınlştırılması ile daha fazla detaya sahip yüksek çözünürlüklü görüntülerini elde etmeye başlamışlardır. Dermoskopi yönteminin yaygınlaşması ile birlikte 2000'li yıllarda çeşitli veri setleri ortaya çıkmaya başlamıştır. Bunlardan bazıları kullanıma açık olarak araştırmacılara sunulurken bazılarına erişim kısıtlanmıştır. Bu veri setlerinden en büyüğü ve kapsamlısı Uluslararası Deri Görüntüleme İş birliği (ISIC) tarafından farklı kaynaklardan elde edilen klinik ve dermoskopik deri lezyonu görüntülerini bir araya getirerek araştırmacılara sunulan ISIC arşividir [117]. Birliğin sağladığı görüntü veri tabanı şu an ki verilere bakıldığında 23906 bin civarındadır. ISIC'in temel amacı, dijital görüntüler vasıtası ile melanoma teşhisini iyileştirmek, erken teşhisi arttırmak ve gereksiz biyopsileri azalmaktır. Ayrıca ISIC hali hazırda kliniklerde elde edilen görüntülerin gizlilik ve

farklı platformlar arasında paylaşılma olasılığına karşı çeşitli standartlar oluşturmak için çalışmalar sürdürmektedir. Birlik 2016 yılından bu yana temel veri setinden oluşturdukları kısmı veri setlerini araştırmacılara sunarak üç farklı dalda yarışmalar düzenlemektedir. Oluşturdukları veriyi eğitim, doğrulama ve test olarak ayıran birlik lezyon segmentasyonu, dermoskopik özellik çıkarma, lezyon sınıflandırma kategorilerinde yarışmacılara sunmaktadır [118]. Kullanıma açık diğer bir veri seti olan PH2 Porto üniversitesinden bir araştırma grubu tarafından Portekiz'deki bir hastanenin dermatoloji servisinden elde edilerek araştırmacılara sunulmuştur [119]. Toplamda 200 dermoskopik görüntüden oluşmaktadır. Diğer bir veri seti olan EDRA 1757 klinik görüntüden oluşmaktadır [120]. Klinik görüntüler normal görüntüleme cihazları ile elde edildikleri için dermoskopik görüntüler kadar detaylı bilgiye sahip değildir. Bu yüzden teşhis sürecinde sık tercih edilmemektedir.

3.2.2 Klasik Makine Öğrenmesi Yöntemleri

Araştırmacılar klasik makine öğrenmesi yöntemlerini deri lezyonlarının sınıflandırılmasında bir hayli kullanmışlardır. Bu teşhis sistemleri bir lezyonun türünü belirlemede genellikle aynı metodolojiyi takip etmektedir. Bir deri lezyonun bilgisayarlı sistemler tarafından sınıflandırılması genellikle 4 temel adımdan oluşmaktadır. Bunlar ön işleme, segmentasyon, özellik çıkarma ve sınıflandırmadır. Konu ile ilgili klasik yöntemler oldukça fazla olduğu için detaylı bilgi için Arasi ve arkadaşları tarafından yapılan çalışma incelenebilir [121].

Görüntü Ön İşleme (Image Preprocessing): Dermoskop cihazı ile alınan lezyon görüntüleri üzerinde, kıllar, mürekkep izleri, cetvel izleri, işaretleyici, siyah köşeler, jel baloncukları gibi bazı gürültülerle birlikte görüntünün alındığı koşullara göre değişiklik gösteren, kontrast, yoğunluk, açı, perspektif gibi sınıflandırmayı etkileyecek önemli engeller bulunmaktadır. Bu engellerin olduğu bir görsel Şekil 3.7'de verilmiştir. Bu nedenle görüntüler üzerinde ön işleme aşamaları uygulanmaktadır. Bu ön işleme aşamaları genellikle görüntü iyileştirme, gürültü silme, bulanıklık giderme, kılları temizleme gibi işlemlerden oluşmaktadır [122]. Başlı başına bir çalışma alanı olan bu konuda araştırmacılar halen çalışmalarını sürdürmektedir.




Şekil 3.8 Dermoskopik görüntüler üzerinde bulunan; bulunan kıllar, mürekkep, siyah daire, cetvel, jel baloncukları ve aşırı aydınlatma gibi gürültüler [67].

Segmentasyon: Görüntü içerisindeki ilgi duyulan bölgeyi arka plandan çıkarmak için yapılan işleme segmentasyon denilmektedir. Bu bağlamda lezyonun kendisini çevreleyen sağlıklı dokudan ayırt edilmesi gerekmektedir (Şekil 3.8). Lezyonu çevreleyen sağlam dokudan ayırmak, lezyonlu bölgeden daha fazla özellik çıkarılmasını sağlayarak daha iyi sınıflandırma sonuçları vermektedir [123, 124]. Şimdiye kadar araştırmacılar otomatik ya da yarı otomatik olmak üzere birçok deri lezyon segmentasyon yöntemi geliştirmişlerdir [12, 124-126]. Bu yöntemler beş ana gruba ayrılmaktadır. Histogram eşikleme yöntemleri, lezyonun çevresindeki dokudan segmentasyonu için bir eşik değeri belirlemeye çalışmaktadır [127-129]. Denetimsiz kümeleme yaklaşımları, homojen bölgeler elde etmek için RGB dermoskopik görüntülerin renk uzayı özelliklerini kullanırlar [130-133] Kenar tabanlı ve bölge tabanlı yöntemler, kenar operatöründen ve bölge bölme veya birleştirme gibi farklı algoritmalarından yararlanır [134-136]. Aktif kontur yöntemleri lezyonun segmentasyonu için sezgisel algoritmaları kullanırlar, (genetik algoritmalar ve yılan algoritmaları vb.) [131, 137, 138].

Son grup denetimli segmentasyon yöntemleridir. Bu yöntemler lezyon segmentasyonunda eğitilmiş tanımlayıcıları kullanırlar bunlara örnek olarak; destek vektör makineleri, karar ağaçları, yapay sinir ağları vb. [131, 139]. Bu yöntemler hakkında daha kapsamlı ve detaylı bilgi verilen çalışmalarda bulunabilir [12, 140,

141]. Son yıllarda derin öğrenmenin popüleritesinin artması ile birlikte derin ağlar bu problemin çözümü için kullanılmaya başlanmıştır.



Şekil 3.9 Lezyon segmentasyonu

Özellik Çıkarma (Feature Extraction): Sınıflandırmanın hesaplama maliyetini düşürmek için, makine öğrenmesi yöntemlerine veri içerisinden belirli sayıda girdi görevi görebilecek özellikler çıkarılmalıdır. Bu özelliklerin kalitesi deri lezyonlarının sınıflandırılması ile doğrudan ilişkilidir. Bu yüzden çıkarılan özelliklerin kalitesi sınıflandırıcının başarısını arttıracaktır. Genellikle bu özelliklerin belirlenmesinde deri lezyonlarının teşhisinde kullanılan yöntemler taklit edilmektedir. (ABCDE, 7 noktalı kontrol, Mezine) [142]. Sınıflandırıcı belirlenen özellikler çeşitli görüntü işleme yöntemleri ile elde edilerek sınıflandırıcıya girdi olarak verilmekte ve sınıflandırıcıdan lezyonun türü ile ilgili bir çıktı alınmaktadır. Derin öğrenme ile birlikte bu aşama ortadan kalkmıştır.

Sınıflandırma (Classification): Çıkarılan özelliklere, destek vektör makineleri (DVM), en yakın k komşuluk algoritması (K-NN) ve karar ağaçları gibi farklı bir makine öğrenmesi yöntemi uygulanmaktadır. Bir dizi farklı tekniğin karşılaştırmalı bir değerlendirmesi daha önce yapılmış çalışmalar arasındadır [143]. El yordamı ile belirlenen özelliklere dayalı teşhis sistemleri bu tarz makine öğrenmesi yöntemlerinde bir darboğaz oluşturmaktadır. Daha çok dermatologlar tarafından kullanılan bu yöntemlerin öznel ve güvenilmez olduğu kanıtlanmıştır. Ayrıca elle çıkarılan özelliklerde, özellikleri belirleyen kişinin deneyimi ve özelliklerin çıkarılmasında kullanılan yöntemlerin performansı büyük ölçüde etkilemektedir. Bu durum kişi bağımlı bir sınıflandırmayı beraberinde getirmektedir. Bunun yanında seçilen özelliklerin ve özellik çıkarma yöntemlerinin belirli bir veri seti için tasarlanmış

olması, başka veri setleri üzerinde doğru sonuçlar vermemesine yol açabilmektedir. Bu nedenle son zamanlarda ortaya çıkan ve kendi özelliklerini kendisi öğrenen derin ağlara olan merak bu alanda da olumlu sonuçlar ortaya çıkarmıştır.


3.2.3 Literatür: Derin Öğrenme Tabanlı Metotlar

Derin öğrenme yöntemlerinden olan ESA'lar son yıllarda özellikle sınıflandırma, nesne takibi, segmentasyon gibi bilgisayarlı görüde önemli problemlerde başarılı sonuçlar elde etmişlerdir. Bu durumun altında yatan ana etmen ESA'ların ham görüntü verisindeki hiyerarşik özellikleri çıkarması ve anlamlandırmasıdır. Doğal görüntülerin sınıflandırılmasının yanı sıra ESA'lar birçok medikal problemin çözümünde kullanılmıştır. Örneğin beyin MR görüntülerinden tümör segmentasyonu [144], mamografi görüntülerinden meme kanseri tespiti [145], fundus görüntüleri üzerinden retinopati hastalığı tespiti [146] gibi örneklerini çoğaltmak mümkündür. Derin ağlar ile medikal görüntüler üzerinde yapılan farklı çalışmaların buluşu bir derleme Litjens ve arkadaşları tarafından yapılmıştır [147]. Diğer medikal problemlerde elde edilen başarılı sonuçlar araştırmacıları deri lezyonlarının sınıflandırılmasında derin ağların özellikle ESA'ların kullanılabilirliğini sorgulamaya ve bu alanda çalışmalar yapmaya itmiştir. Denetimli öğrenme türlerinden bir tanesi olan ESA kendisine verilen görevi yerine getirebilmesi için büyük miktarlarda eğitim verisine ihtiyaç duymaktadır. Medikal alanda verilerin toplanması, etiketlenmesi ve etik kaygılar gibi olumsuz etkenler medikal veriye olan ulaşımı oldukça güçleştirmektedir. Ancak ISIC arşivinin oluşturulması araştırmacıların bu alanda yapacakları çalışmalara bir nebze olsun kolaylık sağlamıştır.

Deri lezyonlarının teşhisinde derin ağlar sentetik veri üretiminden segmentasyona, özellik çıkarmadan sınıflandırmaya kadar çeşitli görevlerde kullanılmaktadır. Bazı çalışmalarda söz konusu adımların hepsi bir arada kullanılırken bazılarında farklı kombinasyonlarından faydalanılmaktadır.

Christoph Baur ve arkadaşları 2018 yılında yayınladıkları çalışmalarında [148] üretici çekişmeli ağları (Generative Adversarial Networks (GANs)) kullanarak uzmanların bile gerçeğinden ayırt etmekte zorlanacağı yüksek çözünürlükte sentetik deri lezyon görüntüleri üretmeyi başarmışlardır. Kullandıkları yöntem olan ilerici büyüyen üretici ters ağlar (Progressive Growing GAN (PGGAN)) [149] diğer derin öğrenme

modellerinden (DCGAN [150], LAPGAN [151]) daha başarılı sonuçlar elde etmiştir. Şekil 3.10'da üretilen görüntülere ait bir görsel paylaşımıdır.



Şekil 3.10 (a) gerçek görüntüleri temsil ederken (b) DCGAN, (c) LAPGAN, (d) PGGAN tarafından oluşturulmuş yapay görüntüleri göstermektedir [148].

Sentetik veri üretmenin yanı sıra çeşitli görüntü işleme yöntemleri kullanılarak da deri lezyon görüntülerinde arttırma yapılmaktadır. Bu yöntemlerin geneline verilen isim veri çoğaltmadır. Bu yöntemin sentetik veri üretmekten farkı ise derin ağlar kullanılmadan mevcut görüntüler üzerinde çeşitli görüntü işleme yöntemleri (çevirme, belirli açı ile döndürme, kırpma, yakınlaştırma, aydınlatma, karartma vb.) ile yeni görüntülerin elde edilmesidir. 2018 yılında Fabio Prez ve arkadaşlarının yayınlamış oldukları bir çalışmada 13 farklı veri çoğaltma yöntemini (saturasyon, kontrast, aydınlatma, affine, flips, random crops, random earising, elastic, lesion mix) farklı kombinasyonlarda kullanarak elde ettikleri veri ile Incepiton-V4, ResNet-152 ve DenseNet-161 deri ağlarını eğitmişlerdir. Elde ettikleri sonuca göre en iyi veri çoğaltma senaryosu lezyonların geometrik ve renk değişimlerini birlikte kullandıkları olmuştur (random crop-affine-flips-saturation-contrast, brightness, and hue) [152].

Yine Ayan ve arkadaşları tarafından yapılan bir çalışmada kullanılan çeşitli görüntü işleme yöntemleri (döndürme, çevirme, yakınlaştırma) ile çoğaltılan görüntülerle

eđitilen bir ESA modelinin çođaltılmamıř veri setiyle eđitilen modelden % 4 oranında daha başarılı sonuçlar elde ettiđini bulmuřlardır [153].

Lezyon görüntülerine ait bazı belirleyici özellikler BDTS tarafından melanomanın sınıflandırılmasında kritik bir rol oynamaktadır. Söz konusu özellikler ancak lezyonun etrafını çevreleyen sağlam dokudan ayırt edilmesi ile elde edilebilmektedir. Bu ayırt etme işlemine deri lezyonun segmentasyonu denilmektedir. Deri lezyonlarının segmentasyonunda derin ađlar oldukça başarılı sonuçlar elde ettiđini ortaya koymuřlardır.

2017 yılında Yu ve arkadaşları tarafından geliştirilen bir FCRN (Fully Convolutional Residual Network) modeli deri lezyonlarını segmente etmek için kullanılmıř ve ISIC tarafından düzenlenen (IEEE International Symposium on Biomedical Imaging) ISBI 2016 yarışmasının lezyon segmentasyon kategorisinde %94,9 doğruluk oranı elde ederek ikinci olmuřtur [154]. Aynı ekip tarafından geliştirilen DRN (Deep Residual Network) modeli FCRN tarafından segmente edilmiř görüntüler üzerinde aynı yarışmanın sınıflandırma kategorisinde elde ettiđi %85 doğruluk oranı ile birinci olmuřtur [154].

Yuan ve arkadaşları tarafından 2017 yılında yapılan başka bir çalışmada, herkes tarafından bilinen FCN (Fully Convolutional Network) modeli için Jaccard distance formülünü maliyet fonksiyonu olarak kullanılmıřtır [155]. Kullandıkları bu maliyet fonksiyonu sayesinde normal deri dokusuna ait piksel sayısı ile lezyona ait piksel sayısı arasındaki dengesizliđin yol açtıđı problemleri çözdüler. Geliřtirdikleri FCN modeli ISBI 2016 ve PH2 veri setleri üzerinde test etmiřler ve test sonucu sırası ile %95,5 ve %93,8 doğruluk oranlarını bulmuřlardır [155].

2017 yılında, Bi ve arkadaşları tarafından geliştirilen çok kademeli bir FCN modeli ve modelin devamında kullanılan (parallel integration) PI yöntemi dermoskop görüntülerinin segmentasyonunda kullanılmıřtır [156]. FCN ile birlikte kullanılan PI metodu segmente edilmiř lezyonların sınırlarının iyileřtirilmesinde kullanılmıřtır. Geliřtirilen yöntem ISBI 2016 ve PH2 veri setleri üzerinde test edilmiř ve sırası ile %95,51 ile %94,24 doğruluk oranları elde edilmiřtir [156].

2017 yılında Goyal ve arkadaşları geliřtirdikleri bir FCN ađını birden fazla lezyon tipini segmente etmekle birlikte aynı zaman sınıflandırmak için eđitmiřlerdir [157].

Önerdikleri model üç farklı lezyon türünü; Melanoma, benign, seborrheic keratoses olmak üzere segmente etmeyi başarmıştır. ISBI 2017 veri seti ile değerlendirdikleri model üç farklı lezyon türünde %57, %65 ve %78,5 Dic değerlerini elde etmiştir [157].

Lin ve arkadaşları yapmış oldukları bir çalışmada klasik C-means kümeleme yöntemi ile derin öğrenme tabanlı model U-Net'i deri lezyonlarını segmente etmedeki başarılarını karşılaştırmışlardır. Bu karşılaştırmayı ISBI 2017 veri seti üzerinde test etmişlerdir. Derin öğrenme tabanlı U-Net %77 Dic değeri elde ederken klasik kümeleme yöntem %61'de kalmıştır [158].

2018 yılında Hang Li ve arkadaşlarının geliştirdiği yeni bir DNN (Dense Deconvolutional Network) deri lezyonlarının segmentasyonunda kullanılmıştır [159]. Geliştirilen bu model DDL (Dense Convolutional Layers), CRP (Chained Residual Pooling) ve HS (Hierarchical Supervision) gibi alt fonksiyonlardan oluşmaktadır. Kullanılan DDL sayesinde girdi görüntüsü ile çıktı arasında çözünürlük farkı olmamasını sağlamıştır [159]. CRP kullanılarak lokal ve global özelliklerin harmanlanıp birlikte kullanılmasına olanak sağlanmıştır. Tahmin maskesini düzeltmek için ise HS yönteminden faydalanmışlardır. Modelin kodlayıcı kısmında ResNet mimarisi kullanılmıştır. Geliştirdikleri modeli ISBI 2017 veri seti üzerinde değerlendirmişler ve 0,86 Dic, 0,76 Jac ve 0,93 doğruluk değerlerini elde etmişlerdir [159].

2018 yılında Al-Masni ve arkadaşları tarafından FrCN (Full resolution Convolutional Network) isminde yeni bir lezyon segmentasyon yöntemi önerilmiştir [160]. Bu modelin sunduğu avantajlardan biride alt örnekleme katmanlarının olmamasıdır. Bu sayede girdi görüntüsünün çözünürlüğü azalmaz ve lezyona ait daha belirgin özellikler kaybolmaz ve daha yüksek çözünürlükte segmentasyon sonuçları elde edilir. Geliştirilen model ISBI 2017 ve PH2 veri setleri üzerinde denemiş ve sırası ile %85,40, %96,69, %94,03 ve %93,72, %95,65, %95,08, duyarlılık, özgüllük, doğruluk değerleri elde edilmiştir [160].

2018 yılında yapılan başka bir çalışmada Peng Yanjun ve arkadaşları çekişmeli ağlardan faydalanarak bir segmentasyon mimarisi önermişlerdir [161]. Önerdikleri model iki aşamadan oluşmaktadır. İlk aşamada U-Net tabanlı bir ağ ile lezyonu segmente etmişler daha sonra çekişmeli (adversarial) bir ağı ayırıcı olarak

tasarlamışlar, segmente edilen bölgenin ne kadar doğru segmente edildiğine dair bu ağdan gelen geri beslemeyi sonucu geliştirmekte kullanmışlardır. Sistem ISBI 2016 ve PH2 veri setleri ile test edilmiş ve ISBI 2016 veri setinde 0,97 doğruluk ve 0,94 Dic değerleri elde etmişlerdir [161].

Yine 2018 yılında yapılan bir çalışmada, Jeremy Kawahara ve arkadaşları, dermoskop görüntülerinden elde edilen ve tanı için kullanılan belirli klinik özellikleri tespit edebilmek için süper piksel yöntemini segmentasyon problemi olarak ele almışlar ve bu amaçla bir FCN ağını eğitmişlerdir [162]. 2017 yılında düzenlenen ISBI 2017 yarışmasının dermoskopik özellik sınıflandırma kategorisinde 0,895 AUC (eğri altında kalan alan) değeri ile birinci olmuşlardır [162].

Yading Yuan ve arkadaşların 2019 yılında yayınladıkları çalışmalarında farklı renk kanallarını kullanarak çoğalttıkları veri ile CDNN (Convolutional-Deconvolutional Neural Network) modelini eğitmişlerdir. Geliştirdikleri modeli ISBI 2017 veri seti üzerinde test etmişler ve 0,756 Jac değerini elde etmişlerdir [163].

2019 yılında Ünver ve arkadaşları tarafından dermoskopik görüntüler kullanılarak deri lezyonlarının segmentasyonu için Yolo ve GrabCut yöntemlerini birleştiren bir boru hattı önermişlerdir. Önerilen yöntem görüntü içerisinde Yolo tarafından lezyonun yeri tespit edilmekte, bu yer bilgisi daha sonra GrabCut algoritması tarafından lezyonun segmentasyonu için kullanılmaktadır. Bu melez sistem ISBI 2017 ve PH2 veri setlerinde test edilmiş ve %91 duyarlılık oranı elde etmiştir [67].

2017 yılında Estava ve arkadaşları tarafından yayınlanan çalışma deri lezyonlarının sınıflandırılmasında önemli bir dönüm noktası olmuştur [164]. Yapılan çalışmada 3374'ü dermoskopik olmak üzere toplamda 129450 klinik görüntü kullanılmıştır. Herhangi bir ön işleme, özellik çıkarma, ya da segmentasyon işlemi uygulanmamıştır. Aktarım öğrenme yöntemi ile birlikte Incetion-V3 modeli söz konusu veri seti üzerinde eğitilmiştir. Inception-V3 ağının çıkış katmanı 757 farklı deri hastalığını sınıflandıracak şekilde düzenlenmiştir. Yapılan testlerde eğitilen modelin %72,1 doğruluk oranı ile uzman dermatologlardan daha iyi sonuçlar elde ettiği gözlemlenmiştir. Ayrıca önerilen modelin Melanoma sınıflandırmada %94 AUC değeri elde ettiği belirtilmiştir [164].

2017 yılında Codella ve arkadaşları deri lezyonlarını sınıflandırmak için iki aşamadan oluşan bir sınıflandırma metodu öne sürdüler [142]. Yaptıkları çalışmada U-Net tabanlı bir derin ağ ile segmente edilen lezyon, el ile çıkarılan özellik çıkarıcıları, seyrek kodlama yöntemlerini, SVM ve derin ağları birlikte kullanarak sınıflandırma işlemi yapmışlardır. Önerdikleri yöntemi ISBI 2016 veri seti üzerinde test etmişler ve 0,83 AUC değeri elde etmişlerdir [142].

2017 yılında Lopez ve arkadaşları, melanomanın erken teşhisi için image-net üzerinde eğitilmiş Vgg-16 derin ağını aktarım öğrenme yönteminden de faydalanarak dermoskopik görüntüler üzerinde eğitmişlerdir [165]. Eğittikleri derin ağı ISBI 2016 veri seti üzerinde test etmişler %81 doğruluk, %78,66 duyarlılık, %79,74 özgüllük değerlerini elde etmişlerdir [165].

2018 yılında, Harangi Balanz deri lezyonlarını melanoma, nevus, and seborrheic keratosis olmak üzere üç sınıfa ayırmak için; GoogLeNet, AlexNet, ResNet ve VggNet ağlarını eğiterek test aşamasında ağların verdiği sonuçları birleştirmiş daha yüksek bir doğruluk oranı elde etmeyi hedeflemişlerdir [166]. Ağlarının sonuçlarını birleştirirken ağırlıklı toplam yöntemi uygulamışlardır. Ağırlıklı toplama yönteminde her bir ağı veriyi yalnız başına sınıflandırma performansına göre bir ağırlık değeri atanır ve bu ağırlık değerleri toplamaları bire eşit olur. Böylelikle daha iyi sınıflandırma performansına sahip olan ağı toplam sonuçta daha çok etkisi olmaktadır. ISBI 2017 verisinde test edilen sistem 0,89 AUC değeri elde etmiştir [166].

2018 yılında Rezvantab, Amirreza ve arkadaşları sunmuş oldukları çalışmalarında sekiz farklı deri hastalığını (melanoma, melanocytic nevi, basal cell carcinoma, benign keratosis, actinic keratosis and intraepithelial carcinoma, dermatofibroma, vascular lesions, ve atypical nevi) sınıflandırmak için daha önce ImageNet verisi ile eğitilmiş derin ağları (DenseNet 201, ResNet 152, Inception v3, InceptionResNet v2) HAM1000 ve PH2 veri setleri ile yeniden eğitmişlerdir [167]. Çalışmanın amacı derin öğrenme ile deneyimli bir uzmanın deri hastalıklarını sınıflandırma başarısını karşılaştırmak. Yapılan testler sonucu deri hastalıklarının sınıflandırılmasında derin öğrenme yöntemlerinin deneyimli bir uzmandan %11'lik bir farkla daha başarılı sonuç elde ettiği görülmüştür. Ayrıca Melanoma ve basal cell carcinoma için en iyi ROC AUC değerlerini %94,40 (ResNet 152) ve %99,30 (DenseNet 201) elde etmiştir. Bununla birlikte deneyimli uzman %82,26 ve %88,82 de kalmıştır [167].

2018 yılında Yang, Jiawen ve arkadaşları, ESA tabanlı bir sistem ile melanoma teşhisi yapmışlardır [168]. Çalışmada lezyon bölgesini daha iyi tespit edebilmek için global ortalama havuzlama yerine bölgesel ortalama havuzlama kullanmışlardır. Önerdikleri ESA modelinde segmentasyon ve sınıflandırmayı birleştirerek daha iyi sınıflandırma sonuçları elde etmişlerdir. Ayrıca modelin sonunda kullandıkları RAPooling olarak adlandırdıkları sınıflandırma yöntemi ile direk ROC değeri üreten sınıflandırma sonuçları elde etmişlerdir. Önerdikleri ESA modelini ISBI 2017 veri seti üzerinde test etmişler ve 0,84 AUC ve 0,833 doğruluk değerlerini elde etmişlerdir [168].

2018 yılında Lee, Yeong Chan ve arkadaşları 7 farklı deri lezyonunu sınıflandırmak için WonDerM ismini verdikleri bir boru hattı tasarlamışlardır [169]. Önerdikleri boru hattı içinde lezyon görüntülerine sırası ile veri çoğaltma, kıl tespiti ve silinmesi, lezyonun segmentasyonu ve sınıflandırma adımları bulunmaktadır. Boru hattının ilk adımında eğittikleri bir yapay sinir ağı ile üzerinde kıl bulunan lezyon görüntüsü tespit edilerek DullRazor [170] algoritması ile kıllar temizlenmiştir. İkinci aşamada modifiye edilmiş U-Net modeli lezyonu çevreleyen sağlam dokundan ayırmak için kullanılmıştır. Sınıflandırma aşamasında ise dört adet CNN ağından gelen sonuç ağırlıklandırma toplam yöntemi ile birleştirilmiş ve sonuç elde edilmiştir. Yöntem ISBI 2018 veri seti üzerinde test edilmiş ve 0,83 oranında doğruluk oranı elde etmişlerdir [169].

2018 yılında Yap Jordan ve arkadaşları, beş farklı deri hastalığını (nevus, melanoma, basal cell carcinoma, squamous cell carcinoma, pigmented benign keratoses) sınıflandırmak için çok işlevli bir derin ağ modeli önermişlerdir [171]. ResNet-50 mimarisini özellik çıkarıcı olarak kullanan ekip, iki ResNet-50'yi dermoskopik, makroskopik görüntülerle ayrı ayrı eğitmiş, eğitilmiş ResNet-50'lerden gelen özelliklere ek olarak hastaya ait meta-data bilgisini (yaş, cinsiyet vb.) de dahil ederek sınıflandırıcıya sokmuşlardır. Yapıkları test sonuçlarına göre 0,72 doğruluk değeri ve 0,86 melanoma AUC değeri elde etmişlerdir [171].

2018 yılında Burdick ve arkadaşları Vgg-16 ve Inception-V3 ağlarını kullanarak segmente edilmiş deri lezyonlarında, lezyon çevresinde bulunan yakın dokunun sınıflandırmaya etkisini gösteren bir çalışma yapmışlardır [172]. Bu çalışmada lezyonu çevreleyen dokunun bir belirli bir kısmının sınıflandırmada faydalı olduğu mükemmel segmentasyona göre daha iyi sonuçlar elde edildiği gösterilmiştir.

Çalışmada ISBI 2016 veri seti üzerinde test edilmiş Inception-V3 derin ağı segmente deri edilmiş görüntülerine her yöne 75 piksel eklenmesi ile elde edilen sonuçlarda en iyi doğruluk 0,69, duyarlılık 0,76, özgüllük 0,72, AUC 0,73 değerlerini elde etmiştir [172].

2019 yılında Khalid M. Hosny ve arkadaşları tarafından yayınlanan bir çalışmada, Alex-Net mimarisi üzerinde farklı kombinasyonlarda aktarım öğrenme ve ince ayar yöntemleri kullanılarak deri lezyonlarının sınıflandırılmasında kullanılmıştır [173]. Çalışmada veri çoğaltma yöntemlerinden de faydalanılmıştır. Önerilen model Med-Node, Derm, ve ISIC veri setleri ile test edilmiş ve %96,86, sırası %97,70 ve %95,91 doğruluk oranları elde edilmiştir [173].

2019 yılında yapılan başka bir çalışmada Sara Hosseinzadeh Kassani bilinen ünlü derin ağların; ResNet50, Vgg-16, Vgg-19, AlexNet ve Xception'nın deri kanseri teşhisinde gösterdikleri performansları karşılaştırılmıştır [174]. Aktarım öğrenme ve veri çoğaltma yöntemlerinden faydalanılan kullanılan çalışmada tüm modeller ISBI 2018 veri seti üzerinde eğitilerek test edilmiş, en iyi sonucu ResNet-50 modeli, 0,93 hassasiyet, 0,92 duyarlılık, 0,92 f-skor, 0,92 doğruluk değerlerini elde ederek kazanmıştır [174].

3.2.4 Zorluklar

ISIC arşivinin varlığı ile birlikte, BDTS'nin deri lezyon teşhisinde kullanılması oldukça popüler bir araştırma alanı olmuştur. Her bir araştırma bireysel bileşenlere sahip olmakla birlikte, belirli özelliklere odaklanmaktadır, bununla birlikte daha global özelliklere odaklanan karşılaştırmalı bir bakış açısı elde etmek oldukça güçtür. Açık araştırma alanları genelde AUC (Eğri altında kalan alan) değerini yükseltmeye odaklıdır.

4. MELANOMA TESPİTİ İÇİN ÖNERİLEN MODEL

Bu bölümde deri kanserinin tespiti için yapılan çalışmalara ek olarak tez kapsamında yapılan çalışmalar ve katkılar yer almaktadır. Ayrıca sırası ile kullanılan veri seti, metotlara detaylıca değinilecektir.

4.1 Uygulama Ortamı

4.1.1 Programlama Dili ve Kütüphaneler

Çalışmada kullanılan bütün yöntemler python programlama dili kullanılarak kodlanmıştır. Kullanılan ESA mimarileri arka planında Tensorflow kütüphanesini kullanan Keras [52] derin öğrenme kütüphanesi ile modellenmiştir. Ayrıca OpenCV [175] görüntü işleme kütüphanesinden de faydalanılmıştır. Tüm işlemler Ubuntu 14.04 işletim sistemi bulunan bir bilgisayar üzerinde gerçekleştirilmiştir.

4.1.2 Donanımsal İhtiyaçlar

Derin ağların eğitilmesinde güçlü donanıma sahip bilgisayarlar hesaplama zamanı yönünden büyük avantaj sağlamaktadır. Özellikle derin öğrenme kütüphanelerini destekleyen bir ekran kartıyla, işlemci ile aylar sürecektir bir eğitim sürecini saatler içinde gerçekleştirebilmektedir. Bu nedenle önerilen boru hattı mimarisinin bütün süreçleri iki Xenon işlemcili, 32GB RAM, 512 GB SSD ve Nvidia GTX 1080 Ti ekran kartına sahip bir iş istasyonu kullanılarak gerçekleştirilmiştir.

4.2 Çalışmada Kullanılan Veri Setleri


Çalışmada iki farklı veri seti kullanılmıştır bu veri setlerinden ilki ISBI 2017 [176] olarak bilinen: “Melanom Teşhisine Yönelik Deri Lezyon Analizi” isimli yarışma için ISIC veri setinden oluşturulmuş bir alt veri setidir. Bu veri seti 2000’i eğitim verisi (374 melanoma, 254 seborrheic keratosis ve 1372 zararsız nevus) 150’si doğrulama verisi ve 600’ü test verisi olmak üzere toplamda 2750 dermoskopik görüntüden oluşmaktadır. Verinin detaylı dağılımı Çizelge 4.1’de verilmiştir. Veri setini 540×722 ile 4499×6748 arasında değişken çözünürlükteki 8 bit RGB görüntüler

oluşturmaktadır. Veri setinin segmentasyon için kullanılmak üzere uzmanlar tarafından oluşturulmuş ikili segmentasyon görüntüleri de bulunmaktadır.

Çalışmada kullanılan diğer bir veri seti ise PH2 olarak bilinen veri setidir [119]. PH2 veri seti Porto üniversitesindeki bir grup araştırmacı tarafından Pedro Hispano hastanesinin dermatoloji servisinde toplanmıştır. Aynı hastaneden aynı şartlar altında aynı cihaz ile çekilmiş görüntüler 768x560 çözünürlüğe sahip 200 adet 8 bit RGB dermoskopik görüntüden oluşmaktadır. Veri setinin sınıf bazından dağılımı Çizelge 4.1’de verilmiştir. Bu veri seti de uzman dermatologlar tarafından segmente edilmiş ikili segmentasyon verisine sahiptir. Veri setlerinden bazı örnek görüntüler Şekil 4.1’de verilmiştir.

Çizelge 4.1 ISBI 2017 ve PH2 veri setleri sınıf dağılımları


Veri seti	Eğitim				Doğrulama				Test					Top
Etiket	N	M	SK	Top	N	M	SK	Top	N	M	SK	AT	Top	
ISBI 2017	1372	374	254	2000	78	30	42	150	393	117	90	*	600	2750
PH2	*	*	*	*	*	*	*	*	80	40	*	80	200	200
Top				2000				150					800	2950
N-Normal, M-Melanoma, SK-Seborrheic keratosis, AT-Atypical nevus														



Şekil 4.1 (a) ISBI 2017 veri setinden orijinal görüntü ve ikili segmentasyonu (b) PH2 veri setinden orijinal görüntü ve ikili segmentasyonu

4.3 Deri Lezyonlarının Sınıflandırılması İçin Önerilen Boru Hattı Mimarisi


Bu çalışmada deri lezyonlarının sınıflandırılması için üç temel adımdan oluşan bir boru hattı mimarisi önerilmiştir. Bu mimarideki ilk adım lezyon üzerindeki kılların tespiti ve silinmesi, ikinci adım lezyonun sağlıklı dokudan ayrılması ve son adım ise lezyonun türünü belirlemek için sınıflandırılmasıdır. Her adım kendi içinde birçok alt yöntemi barındırmaktadır. Bu yöntemlerin uygulanması ve detayları, ilgili başlıklar altında detaylıca anlatılacaktır. Önerilen mimarinin adımlarını gösteren bir görsel Şekil 4.2’de verilmiştir.



Şekil 4.2 Önerilen boru hattı mimarisinin adımları

4.4 Kılların Tespiti ve Temizlenmesi


Mimarinin ilk adımı olan kılların tespiti ve temizlenmesi iyi bir sınıflandırma sonucu elde etmek için oldukça önemlidir. Özellikle lezyonun sağlıklı dokudan ayrımı esnasında lezyon üzerini kapatan kıllar büyük sorun teşkil etmektedir. İyi segmente edilmemiş görüntüler ise sınıflandırmada başarı oranını düşürmektedir [177]. Bu amaçla geliştirdiğimiz iki aşamadan oluşan bir yöntem ile dermoskopik lezyon görüntüleri üzerindeki kılların temizlenmesi sağlanmıştır. İlk aşama görüntü içinde kıl olup olmadığının tespit edilmesidir. Bu aşama için bir ESA’dan faydalanılmıştır. İkinci aşamada ise üzerinde kıl olduğu tespit edilen lezyonun üzerindeki kıllar bir dizi görüntü işleme yöntemi ile temizlenmiştir. Şekil 4.3’te önerilen yöntem ile temizlenmiş bazı görüntülere yer verilmiştir.



Şekil 4.3 Üzerinde kıl bulunan lezyonların temizlik işleminden sonraki durumları


4.4.1 Kılların Tespit Edilmesi

Görüntü üzerindeki kılların otomatik olarak temizlenebilmesi için ilk adım görüntüde kıl olup olmadığının tespit edilmesidir. Ancak bu aşamadan sonra temizleme işlemine geçilebilmektedir. Görüntü üzerinde kılların tespitini yapabilmek için Vgg-16 tabanlı ESA modeli kullanılmıştır. Bu ağ aktarım öğrenme yöntemi ve ince ayar yöntemleri kullanılarak kıl içeren ve içermeyen lezyon görüntüleri ile yeniden eğitilmiştir. Eğitim esnasında Vgg-16 ağının tüm evrişimsel katmanları dondurulmuş yani eğitime katılmamıştır. Sınıflandırmak için ise 256'lık bir tam bağımlı katman eklenmiştir. Evrişimsel katman ile tam bağımlı katman arasında global ortalama havuzlama yöntemi kullanılmıştır. Kullanılan ağın konfigürasyonu Şekil 4.4'te gösterilmiştir.



Şekil 4.4 Kılların tespit edilmesi için kullanılan aktarım öğrenme mimarisi


Düzenlenen ESA modelini eğitmek için ISIC veri setinden 4473 temiz 3525 kılı olmak üzere toplamda 7998 lezyon görüntüsü kullanılmıştır. Doğrulama için ise 1000'i temiz 1000'i kılı olmak üzere 2000 lezyon görüntüsü kullanılmıştır. Sistemin testinde ise 120'si kılı olmak üzere 600 adet görüntü kullanılmıştır. Ağ 25 epok boyunca eğitilmiş, ayrıca eğitim esnasında veri çoğaltma yöntemi, tam bağımlı katmandan önce ve sonra iletim sönümü ve normalizasyon yöntemleri kullanılmıştır. Çıkış katmanında softmax aktivasyon fonksiyonu kullanılmış, harici katmanlarda ReLU aktivasyon fonksiyonundan faydalanılmıştır. Hata fonksiyonu olarak kategorik çapraz düzensizlik (categorical_crossentropy), optimizasyon algoritması olarak ise Adam kullanılmıştır. Elde edilen sonuçlar tezin sonuçlar kısmında verilecektir. Şekil 4.5'te ağı eğitimi esnasında elde edilen hata ve doğruluk eğrileri paylaşılmıştır.



Şekil 4.5 Kıl tespiti için eğitilen ESA'nın doğruluk ve hata eğrileri

4.4.2 Kılların Temizlenmesi


Üzerinde kıl olan lezyon tespit edildikten sonraki aşama bu kılların lezyon üzerinden temizlenmesidir. Bu amaçla bir dizi görüntü işleme yöntemi kullanılmıştır. İlk olarak kırmızı (Red), yeşil (Green) ve mavi (Blue) (RGB) kanallardaki piksellerden oluşan görüntü $(0,3 \times R) + (0,59 \times G) + (0,11 \times B)$ formülü kullanılarak gri renk uzayına yani tek kanala çevrilmiştir. Gri görüntü üzerinde kenarları daha kolay tespit edebilmek için ortanca filtre (median) kullanılarak görüntü bulanıklaştırılmıştır. Bulanıklaştırılan gri görüntüye adaptif eşikleme yöntemi uygulanarak gri görüntü ikili görüntüye çevrilmiştir. İkili görüntü üzerinde Canny [178] kenar bulma algoritması kullanılarak kıllar tespit edilmiştir. Tespit edilen kılları belirginleştirmek için bir dizi morfolojik işlemler ikili görüntü üzerine uygulanmıştır. İlk morfolojik işlem olan açma yöntemi ile tespit edilen kıllar daha belirgin hale getirilmiştir. İkinci morfolojik işlem olan kapama ile görüntü üzerindeki küçük siyah noktalar temizlenmiştir [175]. Elde edilen ikili maske görüntüsü ile renkli görüntü birleştirilmiş kılları yer aldığı beyaz gölgeler dolgu (inpainting) yöntemiyle komşu pikseller ile doldurularak işlem sonlandırılmıştır [175]. Algoritma aşamalarını ve sonucu gösteren bir görsel Şekil 4.6'da gösterilmiştir.



Şekil 4.6 Görüntü üzerinde bulunan kılların temizlenme adımları ve her bir adım sonrası görüntünün işlenmiş hali

4.5 Deri Lezyon Görüntülerinin Segmentasyonu


Bilgisayar destekli sistemlerin iyi bir sınıflandırma yapması için segmentasyon önemli adımlardan bir tanesidir. Segmente edilmiş lezyon görüntülerinden sınıflandırmayı kolaylaştıracak belirgin özellikleri çıkarmak daha kolay olmakta, bu sayede sınıflandırma performansı artmaktadır [154, 155]. Çalışmanın bu bölümünde Yolov3 ve GrabCut algoritmalarının güçlü yanları birleştirilerek çözünürlük bağımsız bir segmentasyon yöntemi geliştirilmiştir. Önerdiğimiz boru hattı mimarisinin ikinci adımı olan segmentasyon üç alt adımdan oluşmaktadır. Adımlardan ilkinde Yolov3 yardımı ile görüntü içerisinde lezyon bölgesi tespit edilmekte, ikincisinde tespit edilen bölge GrabCut algoritması kullanılarak lezyonun arka plandan ayrılması sağlanmakta, son adımda ise bazı morfolojik işlemler ile küçük gürültüler temizlenmektedir. Segmentasyon adımlarını gösteren bir görsel Şekil 4.7’de paylaşılmıştır.



Şekil 4.7 Lezyonun görüntü içerisinde tespit edilmesi ve segmentasyonu


4.5.1 Lezyonlu Bölgenin Tespit Edilmesi

Yarı otomatik segmentasyon algoritmalarından biri olan GrabCut algoritmasında kullanıcı tarafından sınırlanan bölge bilgisi kullanılarak segmentasyon yapılmaktadır. Yaptığımız çalışma ile bu algoritmayı YOLOv3 ile birleştirerek otomatik segmentasyon yapar hale getirdik. Bu amaçla YOLOv3 görüntü içerisindeki lezyon bölgesini tespit etmesi kullanılmıştır. YOLOv3'ün eğitiminde ISBI 2017 veri seti kullanılmıştır. Eğitim için 2000, doğrulama için 150 ve test için 600 dermoskopik lezyon görüntüsü kullanılmıştır. YOLOv3'ü eğitmek için görüntüler YOLOv3'ün istediği çıktıya göre etiketlenmiştir. Bu amaçla python programlama dili kullanılarak bir etiketleme aracı geliştirilmiştir. Bu araca ait bir görsel Şekil 4.8'de paylaşılmıştır. Kullanılan bu araç sayesinde her bir lezyon görüntüsü için lezyonu çevreleyen kutunun orta noktasının x, y koordinatları ve sınırlayıcı kutuya ait w, h genişlik ve yükseklik değerleri bir txt dosyasında saklanmıştır. YOLOv3'ün verdiği çıktıya ait detaylara Bölüm 2'de değinilmiştir. Şekil 4.8'de bu çıktıların hesaplanmasına dair bir görsel paylaşılmıştır.




Şekil 4.8 Yolov3 veri etiketleme işlemi

Etiketleme işlemi bittikten sonra daha önce ImageNet verisi üzerinde 1000 farklı sınıfı tanımak üzere eğitilmiş olan Yolov3 ağına sadece lezyonları ve yerlerini tespit etmesi için bazı değişiklikler yapılmıştır. Bu değişikliklere ait detaylar Şekil 4.9’da kırmızı renkte verilmiştir. Bunun yanında Yolov3 eğitilirken aktarım öğrenme yöntemi kullanılarak ImageNet verisi ile eğitilmiş ağırlıklardan da faydalanılmıştır. Bütün bu ayarlamalar ile birlikte Yolov3 ağı 10000 iterasyon boyunca eğitilmiştir. Eğitim sonucu yapılan testlere ait bazı sonuçlar Şekil 4.10’da gösterilmektedir.




Şekil 4.9 Görüntü içerisinde lezyon bölgesini tespit etmek için modifiye edilmiş Yolov3.



Şekil 4.10 YOLOv3 tarafından yeri doğru tespit edilmiş örnekler

4.5.2 Lezyonlu Bölgenin Arka Plandan Ayrılması


YOLOv3 yardımı ile lezyonlu bölgenin yeri tespit edildikten sonraki aşama bu bilginin kullanılarak lezyonun arka plandan ayrılması yani segmentasyonudur. Bu amaçla Bölüm 2’de detaylı olarak değinilen GrabCut algoritması kullanılmıştır. Yarı otomatik olan bu algoritma bu sayede tam otomatik hale getirilmiştir. Bunun yanında çözünürlük bağımsız segmentasyon yapabilme yeteneğine sahip bir yöntem ortaya konulmuştur [67]. Segmentasyonu yapılan ikili görüntü üzerinde bazı morfolojik işlemler sırası ile (açma, kapama) uygulanarak küçük gürültüler ortadan kaldırılmıştır. Son adımda segmente edilmiş ikili görüntü ile orijinal RGB görüntü birleştirilerek işlem sonlandırılmıştır. Elde edilen sonuçlara dair bazı görseller Şekil 4.11’de verilmiştir.



Şekil 4.11 Segmentasyon sonuçları

4.6 Sınıflandırma


Önerilen sistemin son aşaması olan sınıflandırma safhasında segmente edilen görüntüler ile Xception, MobileNet ve ResNet-50 ESA modellerinin melanom teşhisi için yeniden yapılandırılmış mimarileri ayrı ayrı eğitilmiştir. Ağların eğitim sürecinde iki farklı aktarım öğrenme sürecinden faydalanılmıştır. İlk eğitim sürecinde her bir ağın evrişim katmanları ImageNet ağırlıkları kullanılarak eğitime başlatılmış sınıflandırıcı katmanların ağırlıkları sıfırdan atanmıştır. Hiçbir katmanda dondurma yapılmadan her bir ağ ISIC verisinden alınan 5000'i sağlam 4000'i melanoma olmak üzere toplamda 9000 görüntü belirli açılarla döndürme, rasgele kırpma, parlaklık, kontrast geliştirme, yakınlaştırma gibi yöntemlerle çoğaltılarak elde edilen 50.000 görüntü ile eğitilmiştir. Eğitim sonunda elde edilen ağırlıklar kaydedilmiştir. İkinci eğitim sürecinde ise modellerin segmente edilmiş görüntüler ile eğitimine bu ağırlıklar kullanılarak başlanmıştır. Fakat modeller tam eğitilmemiş modelin büyüklüğüne göre bazı evrişimsel katmanlar eğitime katılmamıştır. Ağların sınıflandırıcı kısımları ise sıfırdan eğitilmiştir. Her bir ağın segmente edilmiş lezyon görüntülerinden melanoma tespiti için düzenlenmiş son hali Şekil 4.12'de verilmiştir. Ayrıca Çizelge 4.3'te ağların toplam katman sayıları, toplam parametre sayıları, eğitilen katman sayısı ve parametre sayıları verilmiştir.



Şekil 4.12 Sınıflandırma için önerilen oylama modeli

Öte yandan aşırı uyumu engellemek için evrimsel ve tam bağımlı katmanlarda L2 düzenlileştirme, iletim sönümü, yığın normalizasyonu ve eğitim anında ve öncesinde veri çoğaltma yöntemleri kullanılmıştır. Modellerin eğitimi için kullanılan ISBI 2017 veri setinde dengesiz bir dağılım görülmektedir. Bu yüzden görüntüler sağa, sola, aşağı, yukarı ve çeşitli açılarda döndürülerek yeni örnekler ile sınıflar arası bir denge

elde edilmiştir. Her bir ağ toplamda 20000 görüntü ile eğitilmiş 1000 görüntü ile doğrulama yapılmıştır. Veri çoğaltma sonucu elde edilen yeni görüntülerden bazı örnekler Şekil 4.13'te verilmiştir.



Şekil 4.13 Çeşitli görüntü işleme yöntemleri ile orijinal görüntüden elde edilmiş yeni örnekler


Her bir ağ aynı parametreler ile eşit koşullarda 100 epok boyunca eğitilmiştir. Eğitim esnasında Xception ağına 299x299 çözünürlüğe sahip RGB görüntüler kullanılırken MobileNet ve ResNet-50 ağlarında 224x224 çözünürlüklü görüntüler kullanılmıştır. Yığın (Batch) büyüklüğü 32, öğrenme katsayısı $1e-4$, çıkış katmanı hariç bütün katmanlarda ReLU aktivasyon fonksiyonu kullanılmıştır. Çıkış katmanında softmax aktivasyon fonksiyonu tercih edilmiştir. Hata fonksiyonu olarak categorical_crossentropy, hatayı minimize etmek için ise Adam optimizasyon algoritması kullanılmıştır. Ayrıca her epok sonunda en iyi model saklanmış, aşırı uyumu engellemek için ise erken durma(early_stop) yönteminden faydalanılmıştır. Test esnasında her bir ağ test verisi üzerinde kendi yöntemlerini uygulayarak bir sonuç çıkarmakta, üretilen sonuçlar oylama yöntemi kullanılarak nihai sonuç ortaya çıkmıştır. Oylama işleminin formülü 4.1'de verilmiştir. Formüle göre nihai karar her bir modelin çıktı olasılıklarının toplamının model sayısına bölünmesi ile elde edilmektedir. Eğer karar değeri 0,5 'e eşit veya büyük ise 1 yani melanoma aksi takdirde 0 yani sağlıklı olmaktadır.

Çizelge 4.2 Modellere ait aktarım öğrenme detayları

	Toplam Parametre Sayısı	Eğitilen Parametre Sayısı	Eğitilmeyen Parametre Sayısı	Toplam Katman Sayısı	Eğitilmeyen Katman Sayısı
ResNet-50	24.910.722	23.271.170	1.639.552	183	80
Xception	22.184.490	17.252.138	4.932.352	140	60
MobileNet	4.023.490	3.460.610	562.880	90	45

$$karar = \begin{cases} 0, & \text{eğer } \frac{\sum_{i=1}^m O(\text{Model}_i)}{m} < 0,5 \\ 1, & \text{eğer } \frac{\sum_{i=1}^m O(\text{Model}_i)}{m} \geq 0,5 \end{cases} \quad (4.1)$$

Ağların eğitimi esnasında ortaya çıkan doğruluk ve hata grafikleri Şekil 4.14'te gösterilmiştir.



Şekil 4.14 ResNet-50, MobileNet, Xception modellerinin eğitim sırasındaki doğruluk ve hata eğrileri

5. ARAŞTIRMA SONUÇLARI

Tezin bu bölümünde önerilen boru hattı mimarisinin test verisi üzerinde gösterdiği performans sonuçları paylaşılacaktır. Ön işleme, segmentasyon ve sınıflandırma sonuçları ayrı ayrı değerlendirilmiştir. Değerlendirme kriterleri literatüre ve adımlara uygun olarak seçilmiştir.

5.1 Değerlendirme Kriterleri


Bu çalışmada önerdiğimiz boru hattı mimarisini üç adımı da ayrı ayrı değerlendirilmiştir. İlk adımda lezyon üzerindeki kılların doğru tespit edilmesini, ikinci adımda segmentasyon sonuçlarını ve en son adımda ise genel sınıflandırma sonuçlarının değerlendirilmesi yapılmıştır. Her bir adıma uygun değerlendirme kriterleri belirlenmiştir. Kullanılan değerlendirme kriterleri:

Doğruluk (Accuracy, Doğ): Doğruluk, sınıflandırma problemleri için yaygın olarak kullanılan bir değerlendirme ölçütüdür. Doğru tahmin sayısının toplam numune sayısına bölünmesi ile ortaya çıkan oran ile temsil edilmektedir. Verideki sınıflara ait örnek sayısı eşit ise daha kayda değer sonuçlar vermektedir.

Duyarlılık (Sensitivity, Duy): Hasta olan örnekler içinden doğru olarak tespit edilmiş örnek sayısını temsil etmektedir. Önerilen modelin gerçek hastaları ayırma yeteneğidir.

Özgüllük (Specificity, Özg): Sağlam olan örnekler içinden doğru olarak tespit edilmiş örnek sayısını temsil etmektedir. Önerilen modelin sağlamları tespit etme yeteneğidir.

Eğri Altındaki Alan (Area Under Curve, AUC) ve (Receiver Operating Characteristics, ROC) Eğrisi: ROC bir olasılık eğrisidir ve AUC ayrıla bilirliliğinin derecesini veya ölçüsünü temsil etmektedir. Modelin sınıflar arasında yaptığı ayırma kapasitesi hakkında bilgi vermektedir. ROC eğrisi altında kalan alana AUC denilmektedir. AUC değerinin yüksek olması sınıflandırma başarımının yüksek olduğu manasına gelmektedir. Grafiğin y ekseninde doğru pozitiflerin orantısı (DPO) veya duyarlılık, x ekseninde ise yanlış pozitiflerin orantısı (YPO) veya özgüllük ROC eğrisini oluşturmaktadır (Şekil 5.1).



Şekil 5.1 ROC eğrisi grafiği

Intersection over union (IOU): Nesne lokalizasyon problemlerinde kullanılan bu değerlendirme kriteri model tarafından bulunan arzu edilen nesneyi içine alan bir sınırlayıcı kutu ile asıl elde edilmesi istenilen sınırlayıcı kutunun kesişim oranını temsil etmektedir. Bu oran kutuların keşim değerinin birleşim değerine bölünmesi ile elde edilmektedir.

Jaccard İndeksi (Jacard index Jac): Deri lezyonlarında lezyon bölgesi sağlam dokuya göre daha fazla alan kapladığı için, doğruluk, duyarlılık ve özgüllük her zaman gerçekçi sonuçlar elde edememektedir. Özellikle segmentasyon problemlerinde segmentasyonun performansını ölçmek için kullanılan bu kriter elde edilen segmentasyon sonucu amaçlanan sonucun kesişim oranını temsil etmektedir.

Diece katsayısı (Diece coefficient, Dic): Segmentasyon problemlerinde yoğun olarak tercih edilen bu değerlendirme ölçütü elde edilen segmentasyon sonucu ile arzu segmentasyon sonucu arasındaki benzerlik oranını ölçmektedir.

Söz konusu ölçütleri hesaplamak için belirlenen bazı parametreler ve formüller kullanılmaktadır. Ölçütleri hesaplamak için kullanılan parametreler Doğru Pozitif, Yanlış Negatif, Yanlış Pozitif, Doğru Negatif dir. Şekil 5.2’de gösterilen karmaşıklık matrisinde kriterlerin durumları verilmiştir.

Doğru Pozitif (DP): Sistemin test sonucunda hasta dediği ve gerçekten hasta olan vakalar.

Yanlış Negatif (YN): Sistemin test sonucunda hasta değil dediği ama gerçekte hasta olan vakalar.

Yanlış Pozitif (YP): Sistemin test sonucunda hasta dediği fakat gerçekte hasta olmayan vakalar.

Doğru Negatif (DN): Sistemin test sonucunda hasta değil dediği ve gerçekten hasta olmayan vakalar.

	Hasta (+)	Hasta (-)
Test (+)	Doğru Pozitif DP	Yanlış Pozitif YP
Test (-)	Yanlış Negatif YN	Doğru Negatif DN

Şekil 5.2 Karmaşıklık matrisi

Yukarıda belirtilen ölçütler DP, YN, YP, DN parametrelerini kullanarak aşağıdaki formüllere göre hesaplanmaktadır.

$$IOU = \frac{\text{Kesişim Bölgesi}}{\text{Birleşim Bölgesi}} \quad (4.2)$$

$$Duy = \frac{DP}{DP + YN} \quad (4.3)$$

$$Özg = \frac{DN}{DN + YP} \quad (4.4)$$


$$Dic = \frac{2 * DP}{(2 * DP) + YP + YN} \quad (4.5)$$

$$Jac = \frac{DP}{DP + YN + YP} \quad (4.6)$$

$$Doğ = \frac{DP + DN}{DP + DN + YN + YP} \quad (4.7)$$

5.2 Kılların Doğru Tespit Edilme Sonuçları

İyi bir segmentasyon sonucu elde etmek için görüntü üzerinde bulunan kılların tespit edilip temizlenmesi büyük önem arz etmektedir. Önerilen mimarinin ilk adımı olan kılların temizlenmesi iki adımdan oluşmaktadır. İlk adım üzerinde kıl bulunan lezyonun tespiti, ikinci adım ise silinmesidir. Kılların silinmesi için literatür incelendiğinde bir değerlendirme ölçütü yer almamaktadır. Bu yüzden bu bölümde eğitilen evrimsel ağı, üzerinde kıl olan görüntüleri bulmadaki başarısına yer verilmiştir. ISBI 2017 test veri seti üzerinde denenen sistem %95 AUC oranı elde ederken PH2 veri setinde %96 AUC elde edilmiştir. Test için kullanılan ISBI 2017 veri setinde 466'sı kılsız 134'ü kıllı olmak üzere toplam 600 görüntü bulunmaktadır. Diğer bir test veri seti PH2'de ise 53'ü kıllı 147'si kılsız olmak üzere toplada 200 görüntü bulunmaktadır. Şekil 5.3'te her iki veri setinde yapılan testler sonucu elde edilen karmaşıklık matrisleri ve ROC eğrileri verilmiştir. Ayrıca Çizelge 5.1'de doğruluk, özgülük, duyarlılık gibi ölçütlere dair bilgiler sunulmaktadır.



Şekil 5.3 Eğitilen ESA ağının (a) ISBI 2017 ve (b) PH2 veri setlerinde kıl tespitinde elde ettiği karmaşıklık matrisleri ve ROC eğrileri

Çizelge 5.1 Vgg tabanlı ESA'nın ISBI 2017 ve PH2 veri setlerinde kılı lezyonları tespit yüzdeleri

Veri Seti	Doğ	Duy	Özg	AUC
ISBI 2017	%97	%98	%95	%95
PH2	%97	%97	%96	%96

5.3 Lezyon Segmentasyon Sonuçları


Önerilen boru hattı mimarisinin ikinci adımı olan lezyonların arka plandan ayrılması işleminin değerlendirilmesi iki aşamada gerçekleştirilmiştir. İlk aşamada önerilen sistemin lezyon yerini tespit etme başarısı, ikinci aşamada segmentasyon başarısı değerlendirilmiştir. Bu amaçla PH2 ve ISIC 2017 veri setleri kullanılmıştır.

5.3.1 Görüntü İçerisinde Lezyon Yeri Tespit Sonuçları

Önerilen sistemin lezyon yerini tespit etme performansı iki ölçüt ile değerlendirilmiştir. İlk ölçüt olan doğruluğa göre yöntem PH2 veri setinde %94 başarı elde etmiştir. 200 görüntü içerisinde yalnızca 6 görüntüde lezyon yerini tespit edememiştir. ISBI 2017 veri setinde ise %96,4 doğruluk değeri elde edilmiş, yöntem 600 görüntü içerisinde 22 görüntüde lezyon yerini tespit edememiştir. Değerlendirme ölçütlerinden bir diğeri olan IOU ölçütüne göre önerilen yöntem PH2 veri setinde %90 ISIC 2017 veri setinde ise %86 değerini elde etmiştir. Şekil 5.4'te her iki veri setinden başarılı ve başarısız tespit örneklerine verilmiştir. Ayrıca lezyon yeri tespit sonuçları Çizelge 5.2 'de gösterilmektedir.

Çizelge 5.2 Yolov3'ün lezyon yeri tespit başarı oranı (%)

Veri Seti	Doğ	IOU	Tespit edilemeyen
PH2	94,40	90	200 resimde 6
ISBI 2017	96	86	600 resimde 22




Şekil 5.4 Yolov3 tarafından lezyon yerinin doğru tespit edildiği (a), (c) ve tespit edilemediği durumlar (b), (d) [67].

5.3.2 Lezyon Segmentasyon Sonuçları

Lezyon yerini tespit etme başarımın değerlendirmesinden sonra, önerilen yöntemin segmentasyon başarısı değerlendirildi. Bu başarıyı tespit edebilmek için Doğ, Duy, Özg, Jac, Dic gibi literatürce kabul görmüş değerlendirme ölçütleri kullanıldı. PH2 ve ISIC 2017 veri seti üzerinde yapılan testler sonucu Çizelge 5.3'teki sonuçlar elde edilmiştir. Ayrıca Şekil 5.5'te her iki veri setinden başarılı segmente edilmiş görüntülere ait örnekler paylaşılmıştır.

Çizelge 5.3 Önerilen yöntemin yüzde üzerinden segmentasyon sonuçları

Veri Seti	Doğ	Duy	Özg	Jac	Dic
PH2	92,99	83,63	94,02	79,54	88,13
ISBI 2017	93,39	90,82	92,68	74,81	84,26




Şekil 5.5 Önerilen yöntemin segmentasyon sonuçları (a) orijinal resim, (b) Yolov3 tarafından yeri tespit edilen lezyon, (c) istenilen segmentasyon, (d) önerilen yöntem ile elde edilen segmentasyon, (e) sonucu [67]

5.4 Sınıflandırma Sonuçları


Çalışmanın sınıflandırma aşamasında üç farklı ESA modeli test veri setleri üzerinde değerlendirilmiş, belirlenen başarı kriterleri her bir ağ için hesaplanmıştır. Daha sonra her bir ESA'nın verdiği çıktılar oylama sistemi ile değerlendirilerek nihai sonuç elde edilmiştir. Sınıflandırmada 0 zararsız lezyon 1 ise melanoma olarak belirlenmiştir. Çizelge 5.4'te ISBI 2017 veri setinde edilen sonuçlar paylaşılmıştır. Ayrıca Şekil 5.6' ve Şekil 5.7'de her bir modele ait karmaşıklık matrisi ve ROC eğrisi paylaşılmıştır.

Çizelge 5.4 Modellerin ISBI 2017 veri seti değerlendirmesi

Modeller	Doğ	Duy	Özg	AUC
ResNet-50	0,89	0,81	0,91	0,86
Xception	0,92	0,87	0,93	0,90
MobileNet	0,88	0,87	0,89	0,88
Birleşim	0,95	0,91	0,96	0,94



Şekil 5.6 ResNet-50 ve Xception mimarilerinin ISBI 2017 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri




Şekil 5.7 MobileNet ve Birleşim Modelin ISBI 2017 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri

Çizelge 5.5’de ise modellerin PH2 veri setindeki değerlendirme sonuçlarına yer verilmiştir. Bununla birlikte PH2 veri seti ile yapılan testler sonucu elde edilen karmaşıklık matrisleri ve ROC eğrileri Şekil 5.8’ de ve Şekil 5.9’da gösterilmektedir.


Çizelge 5.5 Modellerin PH2 veri seti performans yüzdeleri

Modeller	Doğ	Duy	Özg	AUC
ResNet-50	0,85	0,81	0,97	0,66
Xception	0,92	0,70	0,98	0,84
MobileNet	0,89	0,72	0,94	0,83
Birleşim	0,93	0,70	0,99	0,84


ResNet-50




ROC Eğrisi




Xception



ROC Eğrisi




Şekil 5.8 ResNet-50 ve Xception mimarilerinin PH2 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri



Şekil 5.9 MobileNet ve Birleşim Modelin mimarilerinin PH2 veri setinde değerlendirilmesinden elde edilen karmaşıklık matrisleri ve ROC eğrileri

6. TARTIŞMA

Çalışma kapsamında önerilen sistem dermoskopik görüntülerden melanomanın tespiti için gerekli olan adımları içermektedir. Bu kapsamda literatürde yapılan çalışmalar arasında melanomanın teşhisinde bütün adımları içeren ve başarılı sonuçlar elde edilen çalışmalardan bir tanesidir. Çalışmanın ilk adımı olan ön işleme kısmında lezyon üzerindeki kılların tespiti ve bir dizi görüntü işleme yöntemi ile temizlenmesi sağlanmıştır. Bu sayede daha iyi segmentasyon sonuçları elde edilmiştir. Şekil 6.1’de bu durumu doğrular nitelikte örnekler verilmiştir. Görüldüğü üzere kıllardan temizlenmiş görüntülerde daha başarılı segmentasyon sonuçları elde edilmiştir.



Şekil 6.1 (a) ve (c) üzerinde kıl bulunan bir görüntünün orijinal ve segmente edilmiş halini temsil ederken, (b) ve (d) aynı görüntülerin kıllardan arındırılmış hallerinin ve segmentasyon sonuçlarını temsil etmektedir.

Literatüre bakıldığında kılların tespiti için kullanılmış bir ESA örneğine rastlanılmamıştır. Bu amaçla kullanılmak için bazı değişiklikler yapılmış Vgg tabanlı bir ESA ile ISBI 2017 ve PH2 veri setinde %97 doğruluk oranında üzerinde kıl olan lezyonlar doğru tespit edilmiştir. Tespit işleminden sonra ise bir dizi görüntü işleme algoritması ile lezyon üzerindeki kıllar temizlenmiştir. Lezyon üzerinden kılların temizlenmesi için bilinen algoritmalarından olan DullRazor’a alternatif bir yöntem geliştirilmiştir.

Segmentasyon aşamasında ise literatürde ilk kez Yolov3 ile GrabCut algoritması birleştirilerek deri lezyonu segmentasyonu için kullanılmıştır. Önerilen yöntemin

avantajı lezyon görüntülerini çözünürlük bağımsız olarak segmente edebilmesidir. Bu sayede sınıflandırma için kullanılabilecek daha detaylı özellikler korunmuş olacaktır. Dezavantajı ise literatürdeki derin öğrenme tabanlı yöntemler ile karşılaştırıldığında daha kaba bir segmentasyon sonucu vermesidir. Fakat yapılan bir çalışmaya göre lezyon çevresindeki dokunun sınıflandırmada faydalı olduğu bu sayede daha başarılı sonuçlar elde edildiği öne sürülmüştür [172]. Önerilen segmentasyon yöntemi U-Net tabanlı bir yöntem [158], ISBI 2017 de ilk sırayı almış yöntemler [179-181] ve FrCN [160] gibi literatürdeki başarılı çalışmalar ile karşılaştırılması Çizelge 6.1’de verilmiştir.


Çizelge 6.1 ISBI 2017 veri seti test edilmiş literatürdeki çalışmalar ile önerilen segmentasyon yönteminin karşılaştırılması

Referanslar	Doğ	Duy	Özg	Jac	Dic
Yuan ve ark. (CDNN) [179]	93,40	82,50	97,50	76,50	84,90
Li ve ark. [180]	93,20	82,00	97,80	76,20	84,70
Bi ve ark. (ResNets) [181]	93,40	80,20	98,50	76,00	84,40
Lin ve ark. (U-Net) [158]	-	-	-	62,00	77,00
Al-Masni ve ark. [160]	94,03	85,40	96,69	77,11	87,08
Önerilen yöntem	93,39	90,82	92,68	74,81	84,26

Çizelge 6.1 incelendiğinde önerilen yöntemin duyarlılık kriterinde %90,82 ile en yüksek sonucu elde etmiştir. Ayrıca Li ve arkadaşlarının önerdiği yöntemden %74,81 Jac ve %84,26 Dic oranları elde ederek daha başarılı olmuştur. Ayrıca diğer sonuçlara göre değerlendirilecek olursa, önerilen yöntemin rakiplerine çok yakın değerler elde ettiği görülmektedir. Önerilen yöntemin lezyon yerini tespit aşamasında düşük kontrastlı resimlerde sorunlar yaşandığı gözlemlenmiştir (Şekil 5.4). Bu sorun eğitim esnasında düşük kontrastlı verilerin sayısını arttırmakla veya kontrast iyileştirme yöntemi kullanılarak çözümü sağlanabilir.


Önerilen yöntemin sınıflandırma kısmında kullanılan farklı ESA modellerinin veri seti üzerinde gösterdiği başarı sıralaması Çizelge 5.4 ve Çizelge 5.5 incelendiğinde iyiden kötüye doğru Xception, MobileNet ve ResNet-50 sıralaması ile ortaya çıkmıştır. Bununla birlikte, bazı modeller iyi örneklerde yüksek başarı oranı elde ederken bazı modeller kötü huylu örneklerde daha iyi sonuçlar vermiştir. Şekil 6.2’de bu durumu

gösteren bir görsele yer verilmiştir. Karmaşıklık matrislerinden anlaşılacağı üzere ResNet-50 normal veriler üzerinde MobileNet modeline göre daha iyi performans gösterirken MobileNet’de kötü huylu örneklerde daha iyi sonuçlar elde etmiştir.



Şekil 6.2 (a) PH2 test verisinde ResNet-50 karmaşıklık matrisi (b) aynı veri setinde MobileNet karmaşıklık matrisi

Bu noktadan yola çıkılarak önerilen, modeller arasında oylamaya dayalı bir test sisteminin kullanımı sonucunda modellerin bireysel başarımlarının ortaklaşa başarımlarından daha düşük olduğu görülmüştür. Bu durum Çizelge 5.4’te görüleceği üzere oylama yönteminin başarı sonuçları ağların bireysel başarı sonuçlarından yüksek olması ile kanıtlanmıştır. Şekil 6.3’te oylama yöntemi sayesinde doğru tespit edilen bazı örneklerle yer verilmiştir. Örneğin gerçekte melanoma olan (a) görüntüsünü MobileNet ve Xception melanoma olarak yorumlarken ResNet-50 normal olarak değerlendirmiştir. Fakat yapılan oylamada ResNet-50 ikiye karşı birle kaybetmiş sonuç bu sayede doğru tahmin edilmiştir. Öte yandan gerçekte normal olan (g) görüntüsüne MobileNet ve ResNet-50 normal derken Xception bu görüntüyü melanoma olarak değerlendirmiştir. Sonuç olarak ikiye birle kaybetmiş doğru sonuç bu sayede elde edilmiştir.



Şekil 6.3 Oylama yöntemi sayesinde doğru tespit edilmiş melanoma (a), (b), (c) ve normal (e), (f), (g) lezyon örnekleri

Önerilen oylama yöntemi ile elde edilen sonuçların literatürdeki derin öğrenme temelli çalışmalar karşılaştırılması Çizelge 6.2’de verilmiştir.

Çizelge 6.2 Önerilen yöntemin ISBI 2017 veri setindeki başarımlar oranının literatürdeki çalışmalar ile karşılaştırılması

Referanslar	Doğ	Duy	Özg	AUC
Yang [168]	0,83	0,60	0,88	0,84
Harangi [166]	0,85	0,40	0,71	0,85
Sultana [182]	0,83	0,52	0,90	0,78
Li [180]	0,85	0,49	0,96	0,91
Önerilen Yöntem	0,95	0,91	0,96	0,94

Çizelge 6.2’ye göre önerdiğimiz aktarım öğrenme tabanlı ESA ağlarının oylamaya dayalı sınıflandırma sonuçları literatürdeki diğer yöntemlerden bütün ölçütlerde daha iyi sonuçlar elde etmiştir. Bu başarımın arkasında etkili aktarım öğrenme ve ince ayar

yöntemleri, veri çoğaltma yöntemi, kıl temizleme yöntemi ve segmentasyon yöntemi yatmaktadır. Çizelge 6.3'te segmente edilmemiş ve ince ayar yapılmamış görüntüler üzerinde aynı ağların elde ettiği sonuçlar paylaşılmıştır. Çizelge incelendiğinde sonuçların segmente edilmiş görüntüler kullanılarak yapılan sınıflandırma sonuçlarından oldukça düşük olduğu görülmektedir. Bu bağlamda kullanılan yöntemlerin sınıflandırmayı olumlu etkilediği görülmektedir.

Çizelge 6.3 ISBI 2017 veri setinde modellerin segmentasyon ve aktarım öğrenme yapılmadan elde ettikleri başarı oranları

Modeller	Doğ	Duy	Özg	AUC
ResNet-50	0,79	0,44	0,88	0,66
Xception	0,85	0,36	0,96	0,67
MobileNet	0,82	0,63	0,86	0,75
Birleşim	0,88	0,50	0,97	0,73

7. SONUÇ VE ÖNERİLER

Deri kanseri türlerinden biri olan melanoma çeşitli çevresel faktörlerin etkisiyle birlikte son yıllarda görülme oranı artan ölümcül bir hastalıktır. Erken teşhis edildiğinde tedavi edilebilen bir hastalık olan melanomanın kesin teşhis süreci demoskopik görüntüler kullanılarak yapılan muayene sonucuna göre şüpheli lezyona biyopsi yapılması ile elde edilmektedir. Melanom olmayan lezyonlarla melanom olan lezyonların gösterdiği benzerlikler, hekimin deneyimi, uzman hekim sayısı gibi faktörler göz önünde bulundurulduğunda hastalığın geç fark edilmesi ya da gereksiz biyopsiler gibi olumsuz durumlar ortaya çıkabilmektedir. Bu nedenle hekimlere teşhis sürecinde yol gösterecek BDTS sistemleri son yıllarda oldukça popüler bir konu haline gelmiştir. Özellikle derin öğrenme tabanlı yöntemlerin elde ettiği başarılar hastalığın erken teşhisinde hekimlere yardımcı olması açısından umut vericidir.

Bu çalışma kapsamında ölümcül kanser türlerinden bir olan deri kanseri melanomanın erken teşhisi için kullanılabilecek derin öğrenme temelli bir BDTS geliştirilmiştir. Önerilen sistem bir boru hattı mimarisi mantığı ile kurgulanmış olup ön işlem, segmentasyon ve sınıflandırma adımlarından oluşmaktadır. Mimari ISBI 2017 ve PH2 veri setlerinde test edilmiştir. Sistemin ilk adımı olan kılların tespiti ve temizlenmesinde %98 oranında duyarlılık elde edilmiştir. Boru hattı mimarisinin ikinci aşamasında lezyonun segmentasyonunda %90 duyarlılık oranı elde edilmiştir. Bu aşamada geliştirilen yöntem çözünürlük bağımsız segmentasyon yapabilmektedir. Yöntem uyarladığı taktirde farklı medikal görüntülerin segmentasyonunda kullanılma imkânı sağlamaktadır. Önerilen boru hattı mimarisinin en son adımı olan sınıflandırmada ise ISBI 2017’de %94 ve PH2’de %84 AUC değerleri elde edilmiştir. Sınıflandırmadaki bu başarıda etkili aktarım öğrenme teknikleri, veri çoğaltma yöntemleri, segmentasyon ve ön işleme işlem aşamalarının önemli derecede katkısı olmuştur.

Görüntü çözünürlüğüne göre değişen teşhis süreci ortalama 13 saniye sürmektedir. .Bu süre donanımda yapılacak iyileştirmeler ile düşürülebilir. Önerilen yönteme uygun ekipman (dermoskop) ve donanım eklendiği takdirde klinik muayenelerde uzmanın sistemi ikinci bir görüş almak için kullanması mümkündür. Buna ek olarak şüpheli lezyonların izlenmesi değişimlerinin gözlemlenmesi yapılabilir. Sistem sayesinde

dermatologların iş yükü azalacak, uzun zaman alan lezyon inceleme süreleri azalarak hastaya ayrılan vakit artacaktır. Ayrıca uzman dermatolog bulunmayan bölgelerde rutin ziyaretlere gelen hastalarda kullanılması ile hastalığın erken teşhisi sağlanabilir. İleriki süreçlerde yöntemin mobil cihazlar üzerinde çalışabilir hale getirilmesi ile hasta kendi muayenesini evinden gerçekleştirebilir. Bu sayede gereksiz klinik ziyaretler azaltılarak, erken teşhis oranları arttırılabilir.



KAYNAKLAR

- [1] E. P. Balogh, B. T. Miller, and J. R. Ball, "Committee on Diagnostic Error in Health Care, Board on Health Care Services, Institute of Medicine, & The National Academies of Sciences, Engineering, and Medicine," Technology and tools in the diagnostic process, 2015.
- [2] P. H. Meyers, C. M. Nice Jr, H. C. Becker, W. J. Nettleton Jr, J. W. Sweeney, and G. R. Meckstroth, "Automated computer analysis of radiographic images," *Radiology*, vol. 83, no. 6, pp. 1029-1034, 1964.
- [3] R. P. Kruger, J. R. Townes, D. L. Hall, S. J. Dwyer, and G. S. Lodwick, "Automated radiographic diagnosis via feature extraction and classification of cardiac size and shape descriptors," *IEEE Transactions on Biomedical Engineering*, no. 3, pp. 174-186, 1972.
- [4] J.-I. Toriwaki, Y. Suenaga, T. Negoro, and T. Fukumura, "Pattern recognition of chest X-ray images," *Computer Graphics and Image Processing*, vol. 2, no. 3-4, pp. 252-271, 1973.
- [5] K. Doi, "Computer-aided diagnosis in medical imaging: historical review, current status and future potential," *Computerized medical imaging and graphics*, vol. 31, no. 4-5, pp. 198-211, 2007.
- [6] A. M. Abdel-Zaher and A. M. Eldeib, "Breast cancer classification using deep belief networks," *Expert Systems with Applications*, vol. 46, pp. 139-144, 2016.
- [7] F. Ciompi et al., "Towards automatic pulmonary nodule management in lung cancer screening with deep learning," *Scientific reports*, vol. 7, p. 46479, 2017.
- [8] M. Havaei et al., "Brain tumor segmentation with deep neural networks," *Medical image analysis*, vol. 35, pp. 18-31, 2017.

- [9] R. Gargeya and T. Leng, "Automated identification of diabetic retinopathy using deep learning," *Ophthalmology*, vol. 124, no. 7, pp. 962-969, 2017.
- [10] R. L. Siegel, K. D. Miller, and A. Jemal, "Cancer statistics, 2019," *CA: a cancer journal for clinicians*, vol. 69, no. 1, pp. 7-34, 2019.
- [11] R. Siegel, J. Ma, Z. Zou, and A. Jemal, "Cancer statistics, 2014," *CA: a cancer journal for clinicians*, vol. 64, no. 1, pp. 9-29, 2014.
- [12] K. Korotkov and R. Garcia, "Computerized analysis of pigmented skin lesions: a review," *Artificial intelligence in medicine*, vol. 56, no. 2, pp. 69-90, 2012.
- [13] A. M. Turing, "Computing machinery and intelligence," in *Parsing the Turing Test*: Springer, 2009, pp. 23-65.
- [14] P. Kashyap, "Industrial applications of machine learning," in *Machine Learning for Decision Makers*: Springer, 2017, pp. 189-233.
- [15] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [16] T. Mitchell, "Machine Learning, McGraw-Hill Higher Education," New York, 1997.
- [17] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436-444, 2015.
- [18] S. J. Russell and P. Norvig, "Artificial intelligence: a modern approach. Malaysia," ed: Pearson Education Limited, 2016.
- [19] R. Raina, A. Battle, H. Lee, B. Packer, and A. Y. Ng, "Self-taught learning: transfer learning from unlabeled data," in *Proceedings of the 24th international conference on Machine learning*, 2007, pp. 759-766: ACM.

- [20] P. M. Domingos, "A few useful things to know about machine learning," Commun. acm, vol. 55, no. 10, pp. 78-87, 2012.
- [21] C. M. Bishop, Pattern recognition and machine learning. springer, 2006.
- [22] S. Wold, K. Esbensen, and P. Geladi, "Principal component analysis," Chemometrics and intelligent laboratory systems, vol. 2, no. 1-3, pp. 37-52, 1987.
- [23] Pixabay. (2019). Sinir hücresi. Available: <https://pixabay.com/tr/vectors/n%C3%B6ron-sinir-h%C3%BCresi-akson-dendrite-296581/>
- [24] D. Kriesel, "A brief introduction on neural networks," 2007.
- [25] S. Haykin, Neural networks: a comprehensive foundation. Prentice Hall PTR, 1994.
- [26] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," The bulletin of mathematical biophysics, vol. 5, no. 4, pp. 115-133, 1943.
- [27] D. O. Hebb, The organization of behavior: a neuropsychological theory. Science Editions, 1962.
- [28] M. Minsky and S. A. Papert, Perceptrons: An introduction to computational geometry. MIT press, 2017.
- [29] N. J. Smelser and P. B. Baltes, International encyclopedia of the social & behavioral sciences. Elsevier Amsterdam, 2001.
- [30] M. A. Nielsen, Neural networks and deep learning. Determination press San Francisco, CA, USA:, 2015.

- [31] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning internal representations by error propagation," California Univ San Diego La Jolla Inst for Cognitive Science 1985.
- [32] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, 2012, pp. 1097-1105.
- [33] F. Newcombe, "Missile wounds of the brain: A study of psychological deficits," 1969.
- [34] E. H. de Haan and A. Cowey, "On the usefulness of 'what' and 'where' pathways in vision," Trends in cognitive sciences, vol. 15, no. 10, pp. 460-466, 2011.
- [35] L. G. Ungerleider, "Two cortical visual systems," Analysis of visual behavior, pp. 549-586, 1982.
- [36] R. L. Mapou and J. Spector, Clinical neuropsychological assessment: A cognitive approach. Springer Science & Business Media, 1995.
- [37] R. Vanheule, "Deep Learning in Skin Lesion Classification Tasks," 2018.
- [38] N. K. Medathati, H. Neumann, G. S. Masson, and P. Kornprobst, "Bio-inspired computer vision: Towards a synergistic approach of artificial and biological vision," Computer Vision and Image Understanding, vol. 150, pp. 1-30, 2016.
- [39] M. A. Goodale and A. D. Milner, "Separate visual pathways for perception and action," Trends in neurosciences, vol. 15, no. 1, pp. 20-25, 1992.
- [40] D. J. Kravitz, K. S. Saleem, C. I. Baker, L. G. Ungerleider, and M. Mishkin, "The ventral visual pathway: an expanded neural framework for the processing of object quality," Trends in cognitive sciences, vol. 17, no. 1, pp. 26-49, 2013.

- [41] D. H. Hubel and T. N. Wiesel, "Receptive fields of single neurones in the cat's striate cortex," *The Journal of physiology*, vol. 148, no. 3, pp. 574-591, 1959.
- [42] D. H. Hubel and T. N. Wiesel, "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex," *The Journal of physiology*, vol. 160, no. 1, pp. 106-154, 1962.
- [43] R. H. Wurtz, "Recounting the impact of Hubel and Wiesel," *The Journal of physiology*, vol. 587, no. 12, pp. 2817-2823, 2009.
- [44] D. L. Ringach, "Mapping receptive fields in primary visual cortex," *The Journal of Physiology*, vol. 558, no. 3, pp. 717-728, 2004.
- [45] A. Afraz, D. L. Yamins, and J. J. DiCarlo, "Neural mechanisms underlying visual object recognition," in *Cold Spring Harbor symposia on quantitative biology*, 2014, vol. 79, pp. 99-107: Cold Spring Harbor Laboratory Press.
- [46] D. D. Cox and T. Dean, "Neural networks and neuroscience-inspired computer vision," *Current Biology*, vol. 24, no. 18, pp. R921-R929, 2014.
- [47] K. Fukushima and S. Miyake, "Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition," in *Competition and cooperation in neural nets*: Springer, 1982, pp. 267-285.
- [48] K. Fukushima, "Artificial vision by multi-layered neural networks: Neocognitron and its advances," *Neural networks*, vol. 37, pp. 103-119, 2013.
- [49] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
- [50] A. Deshpande. (2019). *A Beginner's Guide To Understanding Convolutional*

- Neural Networks. Available: <https://adeshpande3.github.io/A-Beginner%27s-GuideTo-Understanding-Convolutional-Neural-Networks/>
- [51] S. University. (2019). Convolutional Neural Networks for Visual Recognition. Available: <http://cs231n.github.io/understanding-cnn/>
 - [52] F. Chollet, "Keras," <https://github.com/keras-team/keras/tree/master/docs>, vol. 25, p. 2017, 2015.
 - [53] S. J. Pan and Q. Yang, "A survey on transfer learning," IEEE Transactions on knowledge and data engineering, vol. 22, no. 10, pp. 1345-1359, 2009.
 - [54] W. Rawat and Z. Wang, "Deep convolutional neural networks for image classification: A comprehensive review," Neural computation, vol. 29, no. 9, pp. 2352-2449, 2017.
 - [55] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in 2009 IEEE conference on computer vision and pattern recognition, 2009, pp. 248-255: Ieee.
 - [56] M. D. Zeiler and R. Fergus, "Visualizing and understanding convolutional networks," in European conference on computer vision, 2014, pp. 818-833: Springer.
 - [57] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.
 - [58] C. Szegedy et al., "Going deeper with convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9.
 - [59] A. Shustanov and P. Yakimov, "Modification of single-purpose CNN for creating multi-purpose CNN," in Journal of Physics: Conference Series, 2019, vol. 1368, no. 5, p. 052036: IOP Publishing.

- [60] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770-778.
- [61] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2017, pp. 1251-1258.
- [62] A. G. Howard et al., "Mobilenets: Efficient convolutional neural networks for mobile vision applications," arXiv preprint arXiv:1704.04861, 2017.
- [63] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 3431-3440.
- [64] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in International Conference on Medical image computing and computer-assisted intervention, 2015, pp. 234-241: Springer.
- [65] V. Badrinarayanan, A. Kendall, and R. Cipolla, "Segnet: A deep convolutional encoder-decoder architecture for image segmentation," IEEE transactions on pattern analysis and machine intelligence, vol. 39, no. 12, pp. 2481-2495, 2017.
- [66] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 779-788.
- [67] H. M. Ünver and E. Ayan, "Skin lesion segmentation in dermoscopic images with combination of YOLO and grabcut algorithm," Diagnostics, vol. 9, no. 3, p. 72, 2019.

- [68] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," arXiv preprint arXiv:1804.02767, 2018.
- [69] C. Rother, V. Kolmogorov, and A. Blake, "Grabcut: Interactive foreground extraction using iterated graph cuts," in ACM transactions on graphics (TOG), 2004, vol. 23, no. 3, pp. 309-314: ACM.
- [70] Z. Zivkovic, "Improved adaptive Gaussian mixture model for background subtraction," in Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004., 2004, vol. 2, pp. 28-31: IEEE.
- [71] D. Wang, "The Experimental Implementation of GrabCut for Hardcode Subtitle Extraction," in 2018 IEEE/ACIS 17th International Conference on Computer and Information Science (ICIS), 2018, pp. 1-4: IEEE.
- [72] K. Akar. (2019). Cildimizin yapısı. Available: <http://www.kadriyeakar.com/cildimizin-yapisi/>
- [73] R. K. Freinkel and D. T. Woodley, The biology of the skin. CRC Press, 2001.
- [74] C. Blanpain and E. Fuchs, "Epidermal homeostasis: a balancing act of stem cells in the skin," Nature reviews Molecular cell biology, vol. 10, no. 3, p. 207, 2009.
- [75] H. Buzoğlu. (2019). Deri ve derinin yapısı. Available: <https://www.hakanbuzoglu.com/deri-ve-derinin-yapisi>
- [76] S. Jaitley and T. Saraswathi, "Pathophysiology of Langerhans cells," Journal of oral and maxillofacial pathology: JOMFP, vol. 16, no. 2, p. 239, 2012.
- [77] N. Boulais and L. Misery, "Merkel cells," Journal of the American Academy of Dermatology, vol. 57, no. 1, pp. 147-165, 2007.

- [78] M. Cichorek, M. Wachulska, A. Stasiewicz, and A. Tymińska, "Skin melanocytes: biology and development," *Advances in Dermatology and Allergology/Postępy Dermatologii I Alergologii*, vol. 30, no. 1, p. 30, 2013.
- [79] P. Meredith and J. Riesz, "Radiative Relaxation Quantum Yields for Synthetic Eumelanin¶," *Photochemistry and photobiology*, vol. 79, no. 2, pp. 211-216, 2004.
- [80] J. Y. Lin and D. E. Fisher, "Melanocyte biology and skin pigmentation," *Nature*, vol. 445, no. 7130, p. 843, 2007.
- [81] S. Blog. (2019). Dark Skin Turns UV Rays To Heat, Rendering Them Harmless. Available: <https://scienceblog.com/74575/dark-skin-turns-uv-rays-heat-rendering-harmless/>
- [82] T. Hirobe, "Keratinocytes regulate the function of melanocytes," *Dermatologica Sinica*, vol. 32, no. 4, pp. 200-204, 2014.
- [83] G. Fabbrocini et al., "Epidemiology of skin cancer: role of some environmental factors," *Cancers*, vol. 2, no. 4, pp. 1980-1989, 2010.
- [84] D. L. Narayanan, R. N. Saladi, and J. L. Fox, "Ultraviolet radiation and skin cancer," *International journal of dermatology*, vol. 49, no. 9, pp. 978-986, 2010.
- [85] M. Brenner and V. J. Hearing, "The protective role of melanin against UV damage in human skin," *Photochemistry and photobiology*, vol. 84, no. 3, pp. 539-549, 2008.
- [86] L. Gafa, M. Filippazzo, R. Tumino, G. Dardanoni, F. Lanzarone, and L. Dardanoni, "Risk factors of nonmelanoma skin cancer in Ragusa, Sicily: a case-control study," *Cancer causes & control*, vol. 2, no. 6, pp. 395-399, 1991.

- [87] F. Urbach, Biological responses to ultraviolet A radiation. Valdenmar Pub. Co., 1992.
- [88] B. Diffey, "Analysis of the risk of skin cancer from sunlight and solaria in subjects living in northern Europe," *Photo-dermatology*, vol. 4, no. 3, pp. 118-126, 1987.
- [89] B. Diffey, "Stratospheric ozone depletion and the risk of non-melanoma skin cancer in a British population," *Physics in Medicine & Biology*, vol. 37, no. 12, p. 2267, 1992.
- [90] R. Gordon, "Skin cancer: an overview of epidemiology and risk factors," in *Seminars in oncology nursing*, 2013, vol. 29, no. 3, pp. 160-169: Elsevier.
- [91] R. Alteri, A. Barzi, and T. Bertaut, "American Cancer Society. Cancer Facts and Figures 2017," ed: American Cancer Society, Atlanta, Georgia, 2017.
- [92] M. R. Albert and M. A. Weinstock, "Keratinocyte carcinoma," *CA: a cancer journal for clinicians*, vol. 53, no. 5, pp. 292-302, 2003.
- [93] E. Health. (2018). Types of Skin Cancer: Do You Know How to Spot Them. Available: <https://www.everydayhealth.com/skin-cancer/types/>
- [94] V. Madan, J. T. Lear, and R.-M. Szeimies, "Non-melanoma skin cancer," *The lancet*, vol. 375, no. 9715, pp. 673-685, 2010.
- [95] G. Giglia-Mari and A. Sarasin, "TP53 mutations in human skin cancers," *Human mutation*, vol. 21, no. 3, pp. 217-228, 2003.
- [96] Y. Matsumura and H. N. Ananthaswamy, "Toxic effects of ultraviolet radiation on the skin," *Toxicology and applied pharmacology*, vol. 195, no. 3, pp. 298-308, 2004.

- [97] L. Van Eycken, "Cancer burden in Belgium 2004–2013," Belgian Cancer Registry: Brussels, pp. 71-80, 2015.
- [98] L. Van Eycken, "Cancer Incidence Projections in Belgium 2015 to 2025," Belgian Cancer Registry: Brussels, pp. 48-53, 2017.
- [99] M. Solak, "Hacettepe Üniversitesi Hastanelerin'de Takip Edilen Melanom Hastalarının Klinik Özellikleri, Uygulanan Tedavi Modaliteleri ve Sağ Kalımlarının İncelenmesi," 2014.
- [100] V. Gray-Schopfer, C. Wellbrock, and R. Marais, "Melanoma biology and new targeted therapy," *Nature*, vol. 445, no. 7130, p. 851, 2007.
- [101] T. Mudigonda, D. J. Pearce, B. A. Yentzer, P. Williford, and S. R. Feldman, "The economic impact of non-melanoma skin cancer: a review," *Journal of the National Comprehensive Cancer Network*, vol. 8, no. 8, pp. 888-896, 2010.
- [102] Z. Apalla, A. Lallas, E. Sotiriou, E. Lazaridou, and D. Ioannides, "Epidemiological trends in skin cancer," *Dermatology practical & conceptual*, vol. 7, no. 2, p. 1, 2017.
- [103] K. G. Linden, "Screening and early detection of skin cancer," *Current oncology reports*, vol. 6, no. 6, pp. 491-496, 2004.
- [104] R. J. Friedman, D. S. Rigel, and A. W. Kopf, "Early detection of malignant melanoma: the role of physician examination and self-examination of the skin," *CA: a cancer journal for clinicians*, vol. 35, no. 3, pp. 130-151, 1985.
- [105] H. Tsao et al., "Early detection of melanoma: reviewing the ABCDEs," *Journal of the American Academy of Dermatology*, vol. 72, no. 4, pp. 717-723, 2015.
- [106] A. Dermatology. (2019). Skin Cancer at Arta Dermatology, Newport Beach. Available: <http://www.artaderm.com/skin-cancer-newport-beach/>

- [107] J. Messina and V. Sondak, "Prognostic factors in localized cutaneous melanoma with particular reference to thin primary lesions," *Giornale Italiano Di Dermatologia E Venereologia*, vol. 142, no. 2, p. 123, 2007.
- [108] G. Argenziano and H. P. Soyer, "Dermoscopy of pigmented skin lesions—a valuable tool for early," *The lancet oncology*, vol. 2, no. 7, pp. 443-449, 2001.
- [109] J. S. Henning et al., "CASH algorithm for dermoscopy revisited," *Archives of dermatology*, vol. 144, no. 4, pp. 554-555, 2008.
- [110] L. Thomas and S. Puig, "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*, vol. 97, 2017.
- [111] B. Nirmal, "Dermatoscopy: Physics and principles," *Indian Journal of Dermatopathology and Diagnostic Dermatology*, vol. 4, no. 2, p. 27, 2017.
- [112] S. Bajaj, M. A. Marchetti, C. Navarrete-Dechent, S. W. Dusza, K. Kose, and A. A. Marghoob, "The role of color and morphologic characteristics in dermoscopic diagnosis," *JAMA dermatology*, vol. 152, no. 6, pp. 676-682, 2016.
- [113] R. P. Braun, H. S. Rabinovitz, M. Oliviero, A. W. Kopf, and J.-H. Saurat, "Dermoscopy of pigmented skin lesions," *Journal of the American Academy of Dermatology*, vol. 52, no. 1, pp. 109-121, 2005.
- [114] S. T. Hospitals. (2019). Clinical photograph for mole mapping including dermoscopy taken by medical illustration STHNHSFT. Available: <https://www.southtees.nhs.uk/services/medical-illustration-team/private-patientreferrals-information-healthcare-professionals/>

- [115] D. S. Rigel, J. Russak, and R. Friedman, "The evolution of melanoma diagnosis: 25 years beyond the ABCDs," *CA: a cancer journal for clinicians*, vol. 60, no. 5, pp. 301-316, 2010.
- [116] A.-R. A. Ali and T. M. Deserno, "A systematic review of automated melanoma detection in dermoscopic images and its ground truth data," in *Medical Imaging 2012: Image Perception, Observer Performance, and Technology Assessment*, 2012, vol. 8318, p. 83181I: International Society for Optics and Photonics.
- [117] ISIC. (2019). The International Skin Imaging Collaboration. Available: <https://isic-archive.com/>
- [118] D. Gutman et al., "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*, 2016.
- [119] T. Mendonça, P. M. Ferreira, J. S. Marques, A. R. Marcal, and J. Rozeira, "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)*, 2013, pp. 5437-5440: IEEE.
- [120] G. Argenziano, H. Soyer, V. De Giorgi, D. Piccolo, P. Carli, and M. Delfino, "Dermoscopy: a tutorial," *EDRA, Medical Publishing & New Media*, vol. 16, 2002.
- [121] M. A. Arasi, E.-S. A. El-Dahshan, E.-S. M. El-Horbaty, and A.-B. M. Salem, "Malignant Melanoma Detection Based on Machine Learning Techniques: A Survey," *Egyptian Computer Science Journal (ISSN: 1110-2586)*, vol. 40, no. 03, 2016.

- [122] A. N. Hoshyar, A. Al-Jumaily, and A. N. Hoshyar, "The beneficial techniques in preprocessing step of skin cancer detection system comparing," *Procedia Computer Science*, vol. 42, pp. 25-31, 2014.
- [123] G. Schaefer, B. Krawczyk, M. E. Celebi, and H. Iyatomi, "An ensemble classification approach for melanoma diagnosis," *Memetic Computing*, vol. 6, no. 4, pp. 233-240, 2014.
- [124] M. E. Celebi, H. Iyatomi, G. Schaefer, and W. V. Stoecker, "Lesion border detection in dermoscopy images," *Computerized medical imaging and graphics*, vol. 33, no. 2, pp. 148-153, 2009.
- [125] Z. Ma and J. M. R. Tavares, "A review of the quantification and classification of pigmented skin lesions: from dedicated to hand-held devices," *Journal of medical systems*, vol. 39, no. 11, p. 177, 2015.
- [126] R. B. Oliveira, E. Mercedes Filho, Z. Ma, J. P. Papa, A. S. Pereira, and J. M. R. Tavares, "Computational methods for the image segmentation of pigmented skin lesions: a review," *Computer methods and programs in biomedicine*, vol. 131, pp. 127-141, 2016.
- [127] M. Emre Celebi, Q. Wen, S. Hwang, H. Iyatomi, and G. Schaefer, "Lesion border detection in dermoscopy images using ensembles of thresholding methods," *Skin Research and Technology*, vol. 19, no. 1, pp. e252-e258, 2013.
- [128] M. E. Yüksel and M. Borlu, "Accurate segmentation of dermoscopic images by image thresholding based on type-2 fuzzy logic," *IEEE Transactions on Fuzzy Systems*, vol. 17, no. 4, pp. 976-982, 2009.
- [129] F. Peruch, F. Bogo, M. Bonazza, V.-M. Cappelleri, and E. Peserico, "Simpler, faster, more accurate melanocytic lesion segmentation through meds," *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 2, pp. 557-565, 2013.

- [130] K. Møllersen, H. M. Kirchesch, T. G. Schopf, and F. Godtliebsen, "Unsupervised segmentation for digital dermoscopic images," *Skin Research and Technology*, vol. 16, no. 4, pp. 401-407, 2010.
- [131] F. Xie and A. C. Bovik, "Automatic segmentation of dermoscopy images using self-generating neural networks seeded by genetic algorithm," *Pattern Recognition*, vol. 46, no. 3, pp. 1012-1019, 2013.
- [132] H. Zhou, G. Schaefer, A. Sadka, and M. E. Celebi, "Anisotropic mean shift based fuzzy c-means segmentation of skin lesions," in *Proceedings of the 5th international conference on Soft computing as transdisciplinary science and technology*, 2008, pp. 438-443: ACM.
- [133] A. S. Ashour, A. R. Hawas, Y. Guo, and M. A. Wahba, "A novel optimized neutrosophic k-means using genetic algorithm for skin lesion detection in dermoscopy images," *Signal, Image and Video Processing*, vol. 12, no. 7, pp. 1311-1318, 2018.
- [134] Q. Abbas, M. Celebi, and I. F. García, "Skin tumor area extraction using an improved dynamic programming approach," *Skin Research and Technology*, vol. 18, no. 2, pp. 133-142, 2012.
- [135] Q. Abbas, M. E. Celebi, I. Fondón García, and M. Rashid, "Lesion border detection in dermoscopy images using dynamic programming," *Skin Research and Technology*, vol. 17, no. 1, pp. 91-100, 2011.
- [136] M. Emre Celebi et al., "Border detection in dermoscopy images using statistical region merging," *Skin Research and Technology*, vol. 14, no. 3, pp. 347-353, 2008.
- [137] M. Mete and N. M. Sirakov, "Lesion detection in demoscopy images with novel density-based and active contour approaches," in *BMC bioinformatics*, 2010, vol. 11, no. 6, p. S23: BioMed Central.

- [138] B. Erkol, R. H. Moss, R. Joe Stanley, W. V. Stoecker, and E. Hvatum, "Automatic lesion boundary detection in dermoscopy images using gradient vector flow snakes," *Skin Research and Technology*, vol. 11, no. 1, pp. 17-26, 2005.
- [139] H. Wang et al., "Modified watershed technique and post-processing for segmentation of skin lesions in dermoscopy images," *Computerized Medical Imaging and Graphics*, vol. 35, no. 2, pp. 116-120, 2011.
- [140] M. E. Celebi, Q. Wen, H. Iyatomi, K. Shimizu, H. Zhou, and G. Schaefer, "A state-of-the-art survey on lesion border detection in dermoscopy images," *Dermoscopy image analysis*, vol. 10, pp. 97-129, 2015.
- [141] S. Pathan, K. G. Prabhu, and P. Siddalingaswamy, "Techniques and algorithms for computer aided diagnosis of pigmented skin lesions—A review," *Biomedical Signal Processing and Control*, vol. 39, pp. 237-262, 2018.
- [142] N. C. Codella et al., "Deep learning ensembles for melanoma recognition in dermoscopy images," *IBM Journal of Research and Development*, vol. 61, no. 4/5, pp. 5: 1-5: 15, 2017.
- [143] S. Dreiseitl, L. Ohno-Machado, H. Kittler, S. Vinterbo, H. Billhardt, and M. Binder, "A comparison of machine learning methods for the diagnosis of pigmented skin lesions," *Journal of biomedical informatics*, vol. 34, no. 1, pp. 28-36, 2001.
- [144] H. Chen, Q. Dou, L. Yu, J. Qin, and P.-A. Heng, "VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images," *NeuroImage*, vol. 170, pp. 446-455, 2018.

- [145] B. Q. Huynh, H. Li, and M. L. Giger, "Digital mammographic tumor classification using transfer learning from deep convolutional neural networks," *Journal of Medical Imaging*, vol. 3, no. 3, p. 034501, 2016.
- [146] N. Yalçın, S. Alver, and N. Uluhatun, "Classification of retinal images with deep learning for early detection of diabetic retinopathy disease," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 2018, pp. 1-4: IEEE.
- [147] G. Litjens et al., "A survey on deep learning in medical image analysis," *Medical image analysis*, vol. 42, pp. 60-88, 2017.
- [148] C. Baur, S. Albarqouni, and N. Navab, "Generating highly realistic images of skin lesions with GANs," in *OR 2.0 Context-Aware Operating Theaters, Computer Assisted Robotic Endoscopy, Clinical Image-Based Procedures, and Skin Image Analysis*: Springer, 2018, pp. 260-267.
- [149] T. Karras, T. Aila, S. Laine, and J. Lehtinen, "Progressive growing of gans for improved quality, stability, and variation," *arXiv preprint arXiv:1710.10196*, 2017.
- [150] A. Radford, L. Metz, and S. Chintala, "Unsupervised representation learning with deep convolutional generative adversarial networks," *arXiv preprint arXiv:1511.06434*, 2015.
- [151] E. L. Denton, S. Chintala, and R. Fergus, "Deep generative image models using a[00] laplacian pyramid of adversarial networks," in *Advances in neural information processing systems*, 2015, pp. 1486-1494.
- [152] F. Perez, C. Vasconcelos, S. Avila, and E. Valle, "Data augmentation for skin lesion analysis," in *OR 2.0 Context-Aware Operating Theaters, Computer Assisted Robotic Endoscopy, Clinical Image-Based Procedures, and Skin Image Analysis*: Springer, 2018, pp. 303-311.

- [153] E. Ayan and H. M. Ünver, "Data augmentation importance for classification of skin lesions via deep learning," in 2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT), 2018, pp. 1-4: IEEE.
- [154] L. Yu, H. Chen, Q. Dou, J. Qin, and P.-A. Heng, "Automated melanoma recognition in dermoscopy images via very deep residual networks," IEEE transactions on medical imaging, vol. 36, no. 4, pp. 994-1004, 2016.
- [155] Y. Yuan, M. Chao, and Y.-C. Lo, "Automatic skin lesion segmentation using deep fully convolutional networks with jaccard distance," IEEE transactions on medical imaging, vol. 36, no. 9, pp. 1876-1886, 2017.
- [156] L. Bi, J. Kim, E. Ahn, A. Kumar, M. Fulham, and D. Feng, "Dermoscopic image segmentation via multistage fully convolutional networks," IEEE Transactions on Biomedical Engineering, vol. 64, no. 9, pp. 2065-2074, 2017.
- [157] M. Goyal and M. H. Yap, "Multi-class semantic segmentation of skin lesions via fully convolutional networks," arXiv preprint arXiv:1711.10449, 2017.
- [158] B. S. Lin, K. Michael, S. Kalra, and H. R. Tizhoosh, "Skin lesion segmentation: U-nets versus clustering," in 2017 IEEE Symposium Series on Computational Intelligence (SSCI), 2017, pp. 1-7: IEEE.
- [159] H. Li et al., "Dense deconvolutional network for skin lesion segmentation," IEEE journal of biomedical and health informatics, vol. 23, no. 2, pp. 527-537, 2018.
- [160] M. A. Al-Masni, M. A. Al-antari, M.-T. Choi, S.-M. Han, and T.-S. Kim, "Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks," Computer methods and programs in biomedicine, vol. 162, pp. 221-231, 2018.

- [161] Y. Peng, N. Wang, Y. Wang, and M. Wang, "Segmentation of dermoscopy image using adversarial networks," *Multimedia Tools and Applications*, vol. 78, no. 8, pp. 10965-10981, 2019.
- [162] J. Kawahara and G. Hamarneh, "Fully convolutional neural networks to detect clinical dermoscopic features," *IEEE journal of biomedical and health informatics*, vol. 23, no. 2, pp. 578-585, 2018.
- [163] Y. Yuan and Y.-C. Lo, "Improving dermoscopic image segmentation with enhanced convolutional-deconvolutional networks," *IEEE journal of biomedical and health informatics*, vol. 23, no. 2, pp. 519-526, 2017.
- [164] A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, p. 115, 2017.
- [165] A. R. Lopez, X. Giro-i-Nieto, J. Burdick, and O. Marques, "Skin lesion classification from dermoscopic images using deep learning techniques," in *2017 13th IASTED International Conference on Biomedical Engineering (BioMed)*, 2017, pp. 49-54: IEEE.
- [166] B. Harangi, "Skin lesion classification with ensembles of deep convolutional neural networks," *Journal of biomedical informatics*, vol. 86, pp. 25-32, 2018.
- [167] A. Rezvantlab, H. Safigholi, and S. Karimijeshni, "Dermatologist level dermoscopy skin cancer classification using different deep learning convolutional neural networks algorithms," *arXiv preprint arXiv:1810.10348*, 2018.
- [168] J. Yang, F. Xie, H. Fan, Z. Jiang, and J. Liu, "Classification for dermoscopy images using convolutional neural networks based on region average pooling," *IEEE Access*, vol. 6, pp. 65130-65138, 2018.

- [169] Y. C. Lee, S.-H. Jung, and H.-H. Won, "WonDerM: Skin lesion classification with fine-tuned neural networks," arXiv preprint arXiv:1808.03426, 2018.
- [170] T. Lee, V. Ng, R. Gallagher, A. Coldman, and D. McLean, "Dullrazor®: A software approach to hair removal from images," *Computers in biology and medicine*, vol. 27, no. 6, pp. 533-543, 1997.
- [171] J. Yap, W. Yolland, and P. Tschandl, "Multimodal skin lesion classification using deep learning," *Experimental dermatology*, vol. 27, no. 11, pp. 1261-1267, 2018.
- [172] J. Burdick, O. Marques, J. Weinthal, and B. Furht, "Rethinking skin lesion segmentation in a convolutional classifier," *Journal of digital imaging*, vol. 31, no. 4, pp. 435-440, 2018.
- [173] K. M. Hosny, M. A. Kassem, and M. M. Foad, "Classification of skin lesions using transfer learning and augmentation with Alex-net," *PloS one*, vol. 14, no. 5, p. e0217293, 2019.
- [174] S. H. Kassani and P. H. Kassani, "A comparative study of deep learning architectures on melanoma detection," *Tissue and Cell*, vol. 58, pp. 76-83, 2019.
- [175] G. Bradski and A. Kaehler, "OpenCV," *Dr. Dobb's journal of software tools*, vol. 3, 2000.
- [176] N. C. Codella et al., "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)*, 2018, pp. 168-172: IEEE.
- [177] H. Mirzaalian, T. K. Lee, and G. Hamarneh, "Hair enhancement in dermoscopic images using dual-channel quaternion tubularness filters and

MRF-based multilabel optimization," IEEE Transactions on Image Processing, vol. 23, no. 12, pp. 5486-5496, 2014.

- [178] J. Canny, "A computational approach to edge detection," IEEE Transactions on pattern analysis and machine intelligence, no. 6, pp. 679-698, 1986.
- [179] Y. Yuan, "Automatic skin lesion segmentation with fully convolutional-deconvolutional networks," arXiv preprint arXiv:1703.05165, 2017.
- [180] Y. Li and L. Shen, "Skin lesion analysis towards melanoma detection using deep learning network," Sensors, vol. 18, no. 2, p. 556, 2018.
- [181] L. Bi, J. Kim, E. Ahn, and D. Feng, "Automatic skin lesion analysis using large-scale dermoscopy images and deep residual networks," arXiv preprint arXiv:1703.04197, 2017.
- [182] N. N. Sultana, B. Mandal, and N. B. Puhon, "Deep residual network with regularised fisher framework for detection of melanoma," IET Computer Vision, vol. 12, no. 8, pp. 1096-1104, 2018.

ÖZGEÇMİŞ

Adı Soyadı : Enes AYAN

Doğum Tarihi : 09/05/1988

Yabancı Dil : İngilizce

Eğitim Durumu :

Lisans : Süleyman Demirel Üniversitesi 2009-2013,

Bilgisayar Müh.

Yüksek Lisans : Kırıkkale Üniversitesi 2013-2015, Bilgisayar Müh.

Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar:

Kırıkkale Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

Araştırma Görevlisi 2014-Devam ediyor.

Yayınları (SCI) :

1- Ünver, H. M., & Ayan, E. (2019). Skin lesion segmentation in dermoscopic images with combination of YOLO and GrabCut algorithm. Diagnostics, 9(3), 72.

Yayınları (Diğer) :

1- Cihan, Ş., Ayan, E., Eren, T., Topal, T., & Yıldırım, E. K. Çok Ölçütlü Karar Verme Yöntemleri ile Ekokardiyografi Cihazı Seçiminin Yapılması Echocardiography Device Selection with Multicriteria Decision Making Methods. Cilt 4 Sayı 1 Yıl 2017, 41.

2- Ayan, E., & Yıldırım, E. K. (2016). Real Time Blood Type Determination by Gel Test Method on an Embedded System. International Journal of Applied Mathematics, Electronics and Computers, (Special Issue-1), 412-415.

Bildiriler :

1. Ayan, E., & Ünver, H. M. (2019, April). Diagnosis of Pneumonia from Chest X-Ray Images Using Deep Learning. In 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT) (pp. 1-5). IEEE.
2. Ayan E., Ünver H.M., Importance Of Transfer Learning When Classifying Skin Lesions Via Deep Learning, 3rd International Congress on Vocational and Technical Sciences, (UMTEB-3 2018), Gaziantep, Turkey, 2018.
3. Ayan E., Ünver H.M., Hair Removal From Skin Lesions With Image Processing Methods, 3rd International Congress on Vocational and Technical Sciences, (UMTEB-3 2018), Gaziantep, Turkey, 2018.
4. Ayan E., Ünver H.M, Data Augmentation Importance for Classification of Skin Lesions via Deep Learning, The Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT 2018), İstanbul, Turkey, 2018.
5. Ayan, E., & Yıldırım, E. K., Preparation of Development Environment for Deep Learning Applications”, I. International Scientific and Vocational Studies Congress, 05-08 October 2017, Nevşehir Turkey.
6. Ayan, E., & Yıldırım, E. K., Selecting the Suitable Graphic Display Card for Deep Learning Applications”, I. International Scientific and Vocational Studies Congress, 05-08 October 2017, Nevşehir Turkey
7. Ayan, E., Ünver, H. M., Image Augmentation Methods for Deep Learning”, International Conference on Engineering Technologies, 7 – 9 December 2017, Konya Turkey.
8. Ayan, E., Ünver, H. M., Web Based Online Examination System, International Conference on Quality in Higher Education 7-8 December 2017, Sakarya Turkey.

Araştırma Alanları : Derin Öğrenme, Evrimsel Sinir Ağları, Görüntü İşleme, Deri Kanseri