



**T.C.
İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



[Yüksek Lisans Tezi]

**[DERİN ÖĞRENME YÖNTEMLERİ İLE CİLT LEZYON
BÖLÜTLEMESİ]**

[Sohaib Najat HASAN]

[Enformatik Anabilim Dalı]

[Enformatik Programı]

**DANIŞMAN
[Prof. Dr.] [Sevinç GÜLSEÇEN]**

**[II. DANIŞMAN
Dr. Murat GEZER]**

[Temmuz, 2019]

İSTANBUL

Bu çalışma, 2.07.2019 tarihinde aşağıdaki jüri tarafından Enformatik Anabilim Dalı,
Enformatik Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Prof. Dr. Sevinç GÜLSEÇEN(Danışman)
İstanbul Üniversitesi
Fakülte

Doç. Dr. Çiğdem EROL
İstanbul Üniversitesi
Fen Fakültesi

Dr. Öğr. Üyesi Ayşe ÇINAR
Marmara Üniversitesi
İşletme Fakültesi



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

ÖNSÖZ

Öncelikle danışmanlarım, Prof. Dr. Sevinç GÜLSEÇEN ve Dr. Murat GEZER'e çalışmalarım ve araştırmalarım esnasında verdikleri destekten ve gösterdikleri sabırdan ötürü teşekkür ederim. Ayrıca Yrd. Doç. Dr. Raghad Abdulaali Azeez'e de desteklerinden dolayı özellikle teşekkür ederim ve çalışmalarımda bana yardımcı olan, desteğini esirgemeyen İstanbul Üniversitesi'ndeki tüm arkadaşlarıma müteşekkir olduğumu belirtmek isterim.

İstanbul Üniversitesi'ndeki tüm profesörlerime, bütün modül ve laboratuvarlarda bana her zaman yardım ettikleri ve desteklerini benden esirgemedikleri için teşekkür ederim.

Son olarak, yıllarca süren çalışmalarım boyunca beni sürekli cesaretlendiren, ilgi ve sevgilerini eksik etmeyen aileme ve arkadaşlarıma teşekkür ederim. Bu başarı onların yardımı olmadan asla gerçekleşmezdi. Teşekkürler!

Temmuz 2019

Sohaib Najat HASAN

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	IV
İÇİNDEKİLER.....	V
ŞEKİL LİSTESİ	VII
TABLO LİSTESİ.....	X
SİMGE VE KISALTMA LİSTESİ	XI
ÖZET	XII
SUMMARY	XIV
1. GİRİŞ.....	1
1.1 TEZİN AMACI.....	5
1.2 TEZ TASLAĞI	5
2. GENEL KISIMLAR	6
2.1 LİTERATÜR İNCELEMESİ.....	6
2.1.1 Ön İşleme Yöntemleri	6
2.1.2 Lezyon kenarının tespitine ilişkin bölütleme.	9
2.1.2.1 Geleneksel görüntü işleme ve makine öğrenimi yöntemleri.	9
2.1.2.2 Derin öğrenme yöntemleri.	10
2.2 BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ.....	12
2.2.1 Dermoskopide Tıbbi teşhis Yöntemleri	12
2.2.1.1 Patern Analizi	13
2.2.1.2 ABCD-E Kuralı	14
2.2.1.3 7 Noktalı kontrol listesi	15
2.2.1.4 Menzies Yöntemi	18
2.3 YAPAY SİNİR AĞI (ANN)	19
2.3.1 Algılayıcı.....	20
2.3.2 Çok Katmanlı Algılayıcı Yapısı	20
2.3.3 Aktivasyon Fonksiyonları	21
2.3.3.1 Aktivasyon fonksiyonu türleri	22
2.3.3.2 Sigmoid veya Lojistik	22
2.3.3.3 Tanh—Hiperbolik tanjan	23
2.3.3.4 ReLU	24
2.3.3.5 Sızıntılı ReLU.....	24
2.3.4 Kayıp Fonksiyonu	25
2.3.5 Eğitim süreci	27
2.3.6 Normalleştirme Prosedürü.....	27
2.3.6.1 Girdileri Normalleştirme.	27
2.3.7 Optimizasyon algoritmaları.....	29
2.3.7.1 Geri Yayılım Algoritması	30
2.3.7.2 Adam Algoritması	31
2.3.8 Derin Öğrenme	32
2.3.8.1 Evrişimsel Sinir Ağı	33

2.3.9	U-Net Ağ Mimarisi	36
2.4	GÖRÜNTÜ ÖN İŞLEME TEKNİKLERİ.....	37
2.4.1	Görüntü ön işleme	37
2.4.1.1	Renk Modelleri.....	38
2.4.2	RGB renk modeli	38
2.4.3	Gri Renk Ölçeği	39
2.4.4	HSI Renk Ölçeği	39
2.4.5	Gauss Bulanıklığı	40
2.4.5.1	Morfolojik görüntü işleme	41
2.4.5.2	Görüntü İnterpolasyonu	43
2.4.5.3	Kenar bulma	45
2.5	GÖRÜNTÜ İÇ BOYAMA.....	48
2.6	PERFORMANS ÖLÇÜMLERİ.....	49
2.7	GRAFİK İŞLEME BİRİMİ (GPU)	51
2.8	KERAS KÜTÜPHANESİ.....	52
3.	MALZEME VE YÖNTEM	53
3.1	GİRİŞ	53
3.2	ISIC (ULUSLARARASI DERİ GÖRÜNTÜLEME İŞBİRLİĞİ) ÇALIŞMASI 2018 VERİ SETİ	53
3.3	ÖNERİLEN SİSTEM	54
3.3.1	Görüntü Ön İşleme	55
3.3.1.1	Renk dönüştürmeden gri ölçekli alana	56
3.3.1.2	Gauss Blörü/Fluluğu.....	57
3.3.1.3	Kenar tanıma	58
3.3.1.4	Maske Oluşturma	62
3.3.1.5	Görüntü Restorasyonu	63
3.3.1.6	Veri Seti Hazırlama	64
3.3.1.7	Deri lezyon bölümlere için Önerilen Değiştirilmiş Sisteme Genel Bakış.....	64
3.3.1.8	Veri Normalleştirme	65
3.3.1.9	U-Net tekniğinin geliştirilmesi	66
4.	BULGULAR	69
4.1	GİRİŞ	69
4.2	ÖNERİLEN SİSTEM ŞARTLARI VE SPESİFİKASYONLARI	69
4.3	ÖNERİLEN SİSTEMİN UYGULAMA SONUÇLARI	69
4.3.1	Ön işleme adım sonuçları	70
4.3.1.1	Görüntü Bölümlere Süreci.....	76
4.4	ÖNERİLEN U-NET YAPI SONUÇLARI	84
5.	TARTIŞMA VE SONUÇ.....	93
5.1	SONUÇLAR.....	93
5.2	GELECEK ÇALIŞMALAR İÇİN ÖNERİLER.....	94
	KAYNAKLAR.....	95
	ÖZGEÇMİŞ	100

ŞEKİL LİSTESİ

Sayfa No

ŞEKİL 1.1: BİYOPSİ YÖNTEMİ TİPLERİ	3
ŞEKİL 2.1: LOKAL ÖZELLİKLERE ÖRNEK	13
ŞEKİL 2.2: DERMATOSKOPİ GÖRÜNTÜLERİNDE GLOBAL ÖZELLİKLERE ÖRNEKLER: (A) RETİKÜLER, (B) GLOBÜLER, (C) KALDIRIM TAŞI, (D) HOMOJEN, (E) PARALLEL VE (F) PATLAYAN YILDIZ	14
ŞEKİL 2.3: ASİMETRİ, KENAR DÜZENSİZLİĞİ, RENK, ÇAP VE EVRİMLEŞME (ABCDE KURALI)	15
ŞEKİL 2.4: PUANLARIN TOPLAMI 7'DİR. BU YÜZDEN, BU LEZYON MELANOMDUR	17
ŞEKİL 2.5: PUANLARIN TOPLAMI 3'TÜR. BU YÜZDEN, BU LEZYON MELANOMDUR	17
ŞEKİL 2.6: PUANLARIN TOPLAMI 1'DİR. BU YÜZDEN, BU LEZYON CLARK NEVÜSTÜR	18
ŞEKİL 2.7: LEZYONDA POZİTİF İŞARET VARLIĞI ÖRNEĞİ	18
ŞEKİL 2.8: BİYOLOJİK SİNİR AĞI	20
ŞEKİL 2.9: BASİT BİR YAPAY SİNİR AĞI	20
ŞEKİL 2.10: TEK GİZLİ KATMANLA ÇOK KATMANLI ALGILAYICI.....	21
ŞEKİL 2.11: (A) SİGMOİD FONKSİYONU. (B) SİGMOİD FONKSİYONU GRADYANI	23
ŞEKİL 2.12: (A) TANH FONKSİYONU (B) TANH FONKSİYONU GRADYANI	23
ŞEKİL 2.13: (A) RELU FONKSİYONU. (B) RELU FONKSİYONU GRADYANI	24
ŞEKİL 2.14: (A) SIZINTILI RELU FONKSİYONU. (B) SIZINTILI RELU FONKSİYONU GRADYANI	25
ŞEKİL 2.15: MALİYET FONKSİYONUNUN ŞEKLİ	28
ŞEKİL 2.16: ORJİNAL VERİLER	28
ŞEKİL 2.17: İLK UYGULAMADAN SONRA NORMALLEŞTİRİLEN VERİ	28
ŞEKİL 2.18: VARYANS NORMALLEŞTİRME	29
ŞEKİL 2.19: TİPİK CNN YAPISI	33
ŞEKİL 2.20: 3D GÖRÜNTÜ GİRDİSİ (7,7,3) (3,3,2) MATRİS ELDE EDEREK EVRİŞEN 3D FİLTRE W_0 (3,3,3) ARTI YANLILIK B_0 (1,1,1) TEMSİL EDER	34
ŞEKİL 2.21: MAKS HAVUZ İŞLEMİ	35
ŞEKİL 2.22: ORJİNAL U-NET MİMARİSİ	37
ŞEKİL 2.23: GÜRÜLTÜYLE KAPLI OLAN DERMOSKOPİ GÖRÜNTÜLERİ. (A) KÜÇÜK HAVA KABARCIKLARI. (B) DALGALI SAÇ. (C) KÜÇÜK SAÇ. (D) CETVEL İŞARETİ	38

ŞEKİL 2.24: RENK PİKSELİ DERECE	39
ŞEKİL 2.25: GAUSS FONKSİYONU	40
ŞEKİL 2.26: 3X3 YAPISAL ELEMAN MATRİSİ KULLANILARAK ETKİLİ DİLATASYON İŞLEMİ	41
ŞEKİL 2.27: 3X3 YAPISAL ELEMAN MATRİSİ KULLANILARAK ETKİLİ BİR EROZYON İŞLEMİ	42
ŞEKİL 2.28: 3X3 YAPISAL ELEMAN MATRİSİ KULLANILARAK YAPILAN ETKİLİ BİR AÇMA İŞLEMİ	43
ŞEKİL 2.29: 3X3 YAPISAL ELEMAN MATRİSİ KULLANILARAK YAPILAN ETKİLİ BİR KAPAMA İŞLEMİ	43
ŞEKİL 2.30: MAKSİMUM OLMAYAN BASKI SÜRECİ	47
ŞEKİL 2.31: KARIŞIKLIK MATRİSİ	49
ŞEKİL 3.1: GENEL BLOK DİYAGRAM.....	54
ŞEKİL 3.2: DERMOSKOPI GÖRÜNTÜLERİ YENİDEN İŞLEME ADIMLARI	55
ŞEKİL 3.3: RENK DÖNÜŞTÜRME.....	56
ŞEKİL 3.4: GAUSS İLE YUMUŞATILMIŞ GÖRÜNTÜ	57
ŞEKİL 3.5: CANNY İLE KENAR TANIMA.....	59
ŞEKİL 3.6: SOBEL İLE KENAR TANIMA	60
ŞEKİL 3.7: ÇIKARTILMIŞ İMAJ	60
ŞEKİL 3.8: PARLAKLIK VE KONTRAST AYARI	62
ŞEKİL 3.9: KİL TANIMA	62
ŞEKİL 3.10: MASKE OLUŞTURMA	63
ŞEKİL 3.11: İMAJ RESTORASYONU.....	63
ŞEKİL 3.12: DERİ LEZYON BÖLÜMLEMENİN DEĞİŞTİRİLMİŞ SİSTEMİNE KARŞILAŞTIRMALI BAKIŞ	65
ŞEKİL 3.13: U-NET MİMARİ	68
ŞEKİL 4.1: GÖRÜNTÜ HAZIRLAMA ADIMI	71
ŞEKİL 4.2: KENAR TANIMA	73
ŞEKİL 4.3: MASKE OLUŞTURMA	74
ŞEKİL 4.4: ÖN İŞLEME YÖNTEMİNİN, DERMOSKOPI GÖRÜNTÜLERİ ÜZERİNDEKİ ETKİSİ	75
ŞEKİL 4.5: MODEL 5 PERFORMANS ANALİZİ	79
ŞEKİL 4.6: MODEL 7 PERFORMANS ANALİZİ	80
ŞEKİL 4.7: MODEL 8 PERFORMANS ANALİZİ	81

ŞEKİL 4.8: MODEL 9 PERFORMANS ANALİZİ	82
ŞEKİL 4.9: MODEL 10 PERFORMANS ANALİZİ	83
ŞEKİL 4.10: BAŞARILI BÖLÜTLEME SONUÇLARI ÖRNEKLERİ.....	90
ŞEKİL 4.11: BAŞARISIZ BÖLÜTLEME SONUÇLARI ÖRNEKLERİ.....	91



TABLO LİSTESİ

Sayfa No

TABLO 4.1: GÖRÜNTÜ RENK UZAYLARINA GÖRE KARŞILAŞTIRILMASI.....	70
TABLO 4.2: İLK DENEY GRUBU.....	76
TABLO 4.3: İKİNCİ DENEY GRUBU	77
TABLO 4.4: U-NET 32 MİMARİSİ	84
TABLO 4.5: U-NET 46 MİMARİSİ	86
TABLO 4.6: BAŞARILI SONUÇLARIN DEĞERLENDİRME TABLOSU	92
TABLO 4.7: BAŞARISIZ SONUÇLARIN DEĞERLENDİRME TABLOSU.....	92



SİMGE VE KISALTMA LİSTESİ

Kisaltmalar	Açıklama
Adam	: Adaptive Momentum
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
API	:Uygulama Programlama Arayüzü(Application Programming Interface)
CAD	: Bilgisayar Destekli Teşhis (Computer Aided automatic diagnoses)
CNN	: Evrişimli Sinir Ağları (Convolutional Neural Network)
CNMD	: Consensus Net Meeting on Dermoscopy
DA	: Teşhis Başarımı (Diagnostic Accuracy)
FCN	: Tam Evrişimli Ağ (Fully Convolution Network)
FCNN	: Tam Evrişimli Sinir Ağı (Fully Convolutional Neural Network)
GPU	: Grafik İşlem Ünitesi (Graphical Processor Unit)
ISIC	: Uluslararası Deri Görüntüleme İşbirliği (International Skin Imaging Collaboration)
MLP	: Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
MNN	: Çok Katmanlı Yapay Sinir Ağı (Multilayer Neural Networks)
NN	: Yapay Sinir Ağı (Neural Network)
PC	: Kişisel Bilgisayar (Personal Computer)
PCA	: Temel Bileşen Dönüşümü (Principle Component Analysis)
PDE	: Kısmi Difransiyel Denklem (Partial Differential Equation)
ReLU	: Doğrultulmuş Doğrusal Birim (Rectified linear unit)
RMSprop	: Root Mean Square Prop
ROI	: İlgi Alanı (Region Of Interest)
TQM	: Doku Kalite Ölçütü (Texture Quality Measure)
SEER	: Surveillance, Epidemiology, and End Results

1. ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ İLE CİLT LEZYYON BÖLÜTLEMESİ

Sohaib Najat HASAN

**İstanbul Üniversitesi
Fen Bilimleri Enstitüsü
Enformatik Anabilim Dalı**

Danışman : Prof. Dr. Sevinç GÜLSEÇEN

II. Danışman : Dr. Murat GEZER

Deri kanseri, orta yaşlı ve yaşlı beyaz tenli insanlar arasında yaygın olarak görülen bir hastalıktır. Tıbbi kriterlere göre birçok türe ayrılmıştır. En tehlikeli ve ölümcül kanser türlerinden biri malign melanomdur. Erken tanı konulursa tedavi edilebilir kanser türlerinden biridir. Erken tanı, tümör tiplerinin kötü huylu (malign) veya iyi huylu (benign) olup olmadığının sınıflandırılması için otomatik bir teşhis sistemi gerektirir. Doğru bir lezyon bölütlemesi otomatik bir teşhis sistemi oluşturmak için en gerekli adımdır. Dermoskopik görüntü bölütlemesi gerçekleştirilmesinde istenmeyen yapılar lezyon sınırını saptamayı olumsuz yönde etkilemektedir..

Bu tezin temel olarak odaklandığı konu deri kanserinin erken teşhisi sırasında lezyonun yüksek doğrulukla sınıflandırılmasını kolaylaştırmak amacıyla lezyonun sınırını bölütlenmesi için kesin, etkili, sağlam ve otomatik bir yol oluşturulmasıdır. Sürecimiz iki aşamalı olup: birinci aşamada kıl ve cetvel işaretleri gibi istenmeyen yapılardan arınmış görüntüleri elde etmek için görüntü işleme teknikleri kullanılmıştır. Tezin önemli olan ikinci aşamasında U-Net mimarisinin geliştirmesidir. Geliştirilen yöntemde, başarılı lezyon bölütlemesi oranı elde etmek için 46 katmanlı bir mimari oluşturulmuştur. Bu çalışmada farklı katman sayısına sahip beş değişik U-Net (U-Net 32, U-Net 30, U-Net 37, U-Net 48 ve U-Net 46) üzerinde deneyler gerçekleştirilmiştir. Önerilen sistem U-Net 46 katman mimarisini kullanmaktadır. Kullanılan U-Net mimarilerinin bölütleme sonuçlarını elde ettiğini görmek üzere sonuçları

değerlendirmek için Doğruluk, Dice ölçütü, Jaccard, Hassasiyet ve Özgüllük performans ölçekleri kullanılmıştır.

Bölütleme deneyleri için ISIC2018 Lezyon Sınır Bölütleme veri kümesi kullanılmıştır. Sırasıyla U-Net 32, U-Net 30, U-Net 37, U-Net 48 mimari leri için doğruluk değerleri % 89,% 87,% 85 ve % 86 şeklindedir. Tez kapsamında önerilen U-Net 46 mimarisiyle oluşturulan otomatik bölütleme sistemi, 1815 eğitim veri kümesi ve 779 doğrulama veri kümesi kullanarak , % 93 doğruluk, % 85 Dice ölçütü, % 93 Jaccard, % 91 duyarlılık ve % 97 özgüllük başarımları değerleri bulunmuştur.. Deneysel sonuçlar, önerilen 46 katmanlı U-Net mimarisinin deri lezyon bölütlemesi en başarılı mimari olduğunu göstermektedir.

Temmuz 2019, 115 sayfa.

Anahtar Kelimeler: Dermoskopi Görüntüleri, Derilezyonu, Derin Öğrenme, U-Net Konvolüsyonel Sinir Ağı, Dice ölçütü, Jaccard.

SUMMARY

M.Sc. THESIS

|SKIN LESION SEGMENTATION WITH DEEP LEARNING TECHNIQUES|

Sohaib Najat HASAN

İstanbul University

Institute of Graduate Studies in Sciences

Department of Informatics

Supervisor: Prof. Dr. Sevinç GÜLSEÇEN

Co-Supervisor: Dr. Murat GEZER

Skin cancer is a common disease among middle-aged and elderly white-skinned people. It is divided into many types in terms of medical criteria. One of the most dangerous and fatal cancers is malign melanoma. It is one of the types of cancer that can be treated if diagnosed early. Early diagnosis requires an automated diagnosis system to classify whether the tumor types are malignant or benign. Accurate lesion segmentation is the most necessary step to create an automated diagnosis system. When performing dermoscopy image segmentation, artifacts adversely affect the detection of the lesion border.

The main focus of this thesis is to provide a precise, effective, robust and automated way to segment the lesion in order to facilitate the classification of the lesion with high accuracy during the early diagnosis of skin cancer. The process consists of two stages, and in the first stage, image processing techniques are used to obtain images free of artifacts such as hair and ruler marks. The second stage which is the important part of the thesis is to develop a U-Net architecture. In the developed method, a 46-layered architecture was created to obtain a successful lesion segmentation rate. In this study, experiments were performed on five different U-Net (U-Net 32, U-Net 30, U-Net 37, U-Net 48 and U-Net 46) with different layer numbers. The proposed system uses the U-Net 46-layer architecture. Accuracy, Dice-coefficient, Jaccard, Sensitivity and Specificity performance measures were used to evaluate the results in order to see that the U-Net architectures used obtained the segmentation results.

ISIC2018 Lesion Border Segmentation dataset was used for segmentation experiments. For U-Net 32, U-Net 30, U-Net 37, U-Net 48 architectures, the accuracy scores are 89%, 85% and 86% respectively. By using the automated segmentation system which is created by the U-Net 46 architecture suggested within the scope of this thesis, 93% accuracy, 85% Dice-coefficient, 93% Jaccard, 91% sensitivity and 97% specificity performance scores were found with 1815 training datasets and 779 validation datasets. Experimental results show that the proposed 46-layer U-Net architecture is the most successful architecture for skin lesion segmentation.

July 2019, 115 pages.

Keywords: Dermoscopy Images, Skin lesion, Deep Learning, U-Net Convolutional Neural Network, Dice-coefficient, Jaccard.



1. GİRİŞ

İnsan vücudundaki en büyük organ deridir. Deri(cilt), vücut ağırlığının yaklaşık %16'sını oluşturmaktadır ve yüzeyi, üç katmandan oluşur: üst deri (epidermis), orta deri (dermis) ve deri altı (subkutanöz) doku (hipodermis). Bu üç katmanın kalınlığı ortalama 2 mm'ye ulaşmaktadır [1]. Derinin üst katmanında su geçirmez bir bariyer işlevi gören Epidermis katmanı bulunmaktadır. Deri renginin oluşumundan (Melanin) sorumlu doku, epidermisin alt bölümünde yer alır ve pigment hücreleri (Melanositler) bu katmanda bulunmaktadır. Bu katman, güneşe maruz kalan derinin melanin üretimini artırarak ultraviyole radyasyona karşı cildi korur. Melanositler, bağışıklık sisteminde de rol oynamaktadır [2] [3]. Derinin en önemli işlevi, iç organların zarar görmemesini sağlamaktır ve vücudu, zararlı dış ortamdan koruyan bir bariyer işlevi görmektedir [4], yani deri; insan vücudunu, istenmeyen güneş radyasyonuna maruz kalmaktan kurtarır, vücut sıcaklığını kontrol eder ve çeşitli enfeksiyonların ortaya çıkmasını önlemektedir [5].

Kanser (veya malign tümör), hücrelerin anormal boyutta büyümesi anlamına gelmektedir ve söz konusu hücreler, kontrol edilemeyen biçimde çoğalıp diğer dokulara da sıçrayabilmektedir [6]. Kanserli dokuların büyümesi, normal hücre büyümesinden çok daha farklıdır. Normal hücre büyümesi ile anormal hücre büyümesini ayıran faktör, anormal hücrelerin kaybolmak yerine sürekli olarak artmasıdır [5]. 100'den fazla kanser türü mevcuttur [7]. Tüm kanser türleri arasında hem erkeklerde hem de kadınlarda en yaygın olarak görülen malign kanser türü, deri (cilt) kanseridir. Bu, melanom ve melanom olmayan cilt kanseri olarak kategorize edilebilmektedir. Başlıca cilt kanseri türleri; bazal hücreli karsinom, skuamöz hücreli karsinom ve melanomdur. Bazal hücreli karsinom ve skuamöz hücreli karsinom; melanom olmayan cilt kanserleri grubuna girmektedir [8].


Diğer kanser türleri ile karşılaştırıldığında malign melanom, özellikle uzun süre güneş ışığına maruz kalan orta yaşlı ve yaşlı, beyaz tenli kişilerde diğer ırk gruplarına yaygın olan ve ölümcül cilt kanseri türüdür. Melanom, deriye renk veren melanosit hücrelerinin anormal çoğalmasından kaynaklanmaktadır. Son birkaç on yıldır melanom kaynaklı ölüm oranı diğer kanser türlerine oranla daha hızlı artış göstermiştir. Amerikan ulusal kanser enstitüsü , nihai

sonuç ve gözetim epideyoloji programı (Surveillance Epidemiology and End Results / SEER) 2018 tahminlerine göre 91,270 yeni melanom vakası ortaya çıkması öngörülmekte ve 9320 kişinin de malign melanom nedeniyle hayatını kaybedeceği tahmin edilmektedir [9].


Görüntü, bilgi aktarmak amacıyla kullanılan iki boyutlu piksel dizisidir. Görüntü içerisinde yoğun şekilde faydalı bilgiler bulunmaktadır. Sayısal görüntü işlemenin önemli bir uygulama alanı, sayısal görüntüyü anlamak ve ondan bilgi elde etmektir. Görüntüyü anlamamanın ilk adımı, görüntü bölütlemesidir. Bölütleme uygulamada görüntü bilgisini kaybetmeden faydalı kısımlara indirgemek amacıyla kullanılan bir yöntem olarak açıklanmaktadır. Görüntü bölütlemesi, bilgisayarlı görü ve görüntü işlemede kullanılan en etkili yöntemlerden biridir ve aynı zamanda görüntü tanımanın önemli temellerindendir. Deri görüntü bölütlemesi, sınıflandırıcıya girdi olacak şekilde kullanılacak lezyon bölgesinin belli satandartlara bağlı olarak ön plan olan lezyonun arka plandan çıkarılması işlemidir. Bu işlemin amacı, analiz için görüntü gösterimini basitleştirmek, tıbbi görüntü özelliklerini anlamayı kolaylaştırmak ve tıbbi görüntü özelliklerini tanımadır. Görüntü bölütlemesinin çıktısı, tüm görüntü bilgisini kapsayan piksel grubudur [10, 12].

Dermoskopi, deri lezyonlarındaki özellikleri incelemek ve teşhis etmek için kullanılan ve invaziv olmayan bir tekniktir. Deri yüzey mikroskobu ve epilüminesans gibi farklı adlarla da isimlendirilmektedir. Pigmente cilt kanserinin, özellikle melanomun teşhisinde destekleyici bir işlev görmektedir. Bu nedenle, melanom deri kanserinin erken teşhisi önemli olduğundan dolayı dermatologlar tarafından yaygın olarak kullanılmaktadır. Deri yüzeyinin, çıplak gözle görülemeyen detaylarının derinlemesine görüntülenmesini sağlamaktadır. Bu cihaz, benign lezyonların, malign (kanseri) lezyonlardan ayırt edilmesinde büyük kolaylık sağlamaktadır. Dermoskopi işlemi, dermatoskop adı verilen ve elle kullanılan bir araçla gerçekleştirilmektedir. Bu teknik, epidermisteki dermoepidermal bileşkedeki ve üst dermişteki yüzey altı deri yapılarının görüntülenmesine olanak tanımaktadır. Bu yapılar genellikle çıplak gözle görülmemektedir. Bu genellikle 10 kat büyüten bir büyüteçi, saydam bir plakayı ve cihazla deri arasındaki sıvı besiyerini ve polarize olmayan ışık kaynağını kapsamaktadır böylelikle deri yüzey yansımalarına maruz kalmadan deri lezyonlarının incelenmesine olanak tanımaktadır. Modern dermatoskoplarda, sıvı besiyeri kullanılmamakta ve onun yerine, deri yüzeyinin yansımalarını ortadan kaldırmak için polarize ışık kullanılmaktadır. Yüzey yansıması ortadan kaldırarak, derinin daha derin katmanları görüntülenebilmektedir [13, 15].

Geçmişte kutanöz melanoma karşı savaşmak için çıplak göz ve klinik deneyimler erken tanıda en yaygın olarak kullanılan yöntemleri oluşturmaktadır. Derinin şüphelenilen bölgesi, Punch biyopsi adı verilen iğneye benzer bir aletle veya Eksizyonel biyopsi adı verilen cerrahi prosedür yoluyla alınmaktaydı. Biyopsi adı verilen bu yöntem, %100 güvenilirliğe sahip en güvenli tanı prosedürü olarak kabul edilmektedir. Bu prosedürde, lezyonun şüpheli bölgesinin tamamı veya bir bölümü alınıp ve söz konusu numune patoloji uzmanı tarafından analiz edilmektedir. Biyopsi, Şekil 1.1’de gösterildiği gibi birçok farklı biçimde gerçekleştirilmektedir [16].



(a) Eksizyonel biyopsi



(b) Punch biyopsi

Şekil 1.1: Biyopsi Yöntemi tipleri [16]

Buradaki sorun, yöntemin insani veya fiziksel açıdan çok fazla kaynak gerektiren invaziv bir yöntem olmasıdır. Bu nedenle, invaziv olmayan yöntemlerin geliştirilmesi ve yüksek oranda bir doğrulukla faydalı hale getirilmesi gerekliliği açıktır. Böylece Dermoskopi adı verilen invaziv olmayan teknik, geleneksel tekniklerin yerini almaktadır. Bu araç, klinisyenlerin, lezyonun bölgesel incelemesini gerçekleştirmesine yardımcı olmaktadır. Dermatologların, lezyonun daha fazla özelliğini ortaya çıkarmasına yardımcı olabilen ve onlara en iyi lezyon görüntü çözünürlüğünü sunarak en doğru sonuçları almasına olanak tanıyan epilüminesans mikroskopisinden faydalanmaktadır [17].

SEER’in raporuna göre malign melanom en tehlikeli kanser türüdür [9]. Erken tanının gerçekleşmesi durumunda tedavi edilebilir kanser türleri arasındadır. Erken tanı için hastanın

kişisel kontrolü büyük önem taşımaktadır. Kolay şekilde elde edilebilecek bir cihaz (kamera) ve görüntünün sınıflandırılabilmesi için otomatik teşhis destek yazılımı erken tanı için gerekmektedir. Bu amaçla geleneksel makine öğrenimi ve görüntü işleme teknikleri bir arada kullanılmaktadır ancak karmaşık görüntüler için yetersiz kalmaktadır. Tümör sınıflandırması öncelikle enfeksiyonlu bölgenin, sağlıklı deri dokularından ne kadar doğrulukla izole edilebildiğine bağlıdır. Farklı deri dokularının yanı sıra lezyon yapıları, boyutları ve renkleri gibi faktörler de bölümlene sürecini bir ölçüye kadar zorlaştırmaktadır. Derin Öğrenme, bilgisayar görmesi kavramını kesin olarak değiştirmiştir. Bilgisayar destekli teşhis ve görüntü bölümlene gibi tıbbi görüntü analizinde büyük rol oynamıştır. Uzmanlar, derin öğrenmenin en etkili yaklaşım olduğunu ve 2021'e kadar tıbbi görüntülemenin pazarlamasından yaklaşık 300 milyon dolar elde edileceğini tahmin etmektedir [18].

1.1 TEZİN AMACI

Genel olarak bu çalışmanın amacı, cilt kanserinin erken teşhisi sırasında lezyon kenarlarını bölümlere ayırmanın kesin, etkili, sağlam ve otomatikleştirilmiş bir yolunu sunmak, lezyonu yüksek kesinlikle sınıflandırmaya olanak sağlamaktır.

Bu amaca ulaşmak için çalışma iki bölüme ayrılmıştır:

- Teşhis sırasında saç piksellerini, hava kabarcıklarını, ışık yansıma etkilerini jelden kaldırmak için yeni bir teknik ve görüntü bilgisine zarar vermeden lezyonun boyutunu tanımlamak için kullanılan bir cetvel işareti geliştirmek, kirlilik bulundurmeyen bir görüntü üretmek.
- Dermoskopik görüntülerden cilt lezyonu bölütlemesinin otomatikleştirilmiş tahminine yönelik derin öğrenme algoritması uygulamak.

1.2 TEZ TASLAĞI

Bu çalışma, sonuç bölümü de dahil olmak üzere beş bölümden oluşmaktadır. Birinci bölüm, cilt kanserine giriş, melanom teşhisinin geleneksel yolunu gösterir, derin öğrenme tekniğini kullanarak dermoskopi görüntülerini ve bölütlemesini sunmaktadır. Bu bölümün ikinci kısmında, tezin amaçları açıklığa kavuşturulduktan sonra son bir kısım olarak tezin taslağı gösterilmektedir.

Bölüm 2: "**Genel Kısım**"da, ilgili çalışma ve literatür taraması sunulduktan sonra cilt sorunlarına ilişkin temellerin arka planı ve derin öğrenme ve bölütleme yöntemi türleri gösterilmektedir.

Bölüm 3: Önerilen sistem ve pratik deneyler sunulmaktadır.

Bölüm 4: Önerilen sistemin gerçekleştirilme şekli ve sonuçlar sunulmaktadır.

Bölüm 5: Sonuçlar ve gelecekteki çalışmalara yönelik öneriler sunulmaktadır.

2. GENEL KISIMLAR

Bu bölüm, literatür taramasını ve ön işleme adımından sonra ilk CAD (Bilgisayar Destekli Teşhis) adımı olan dermoskopik görüntü bölütlemesinde uygulanan farklı yöntem ve araçlarla ilgili açıklayıcı bilgileri kapsamaktadır. Literatür taraması üç kısma ayrılmıştır; ön işleme yöntemleri, geleneksel bölütleme yöntemleri ve derin öğrenme yöntemleri. Dermoskopide tıbbi teşhis yöntemlerine genel bir bakış, Evrişimli Sinir Ağları (CNN), Derin Öğrenme, Yapay Sinir Ağları (ANN), veri kümesi ve son olarak performans metriklerinin kapsamlı bir açıklaması. Görüntü işleme teknikleri ve performans ölçümleri bu bölümün geri kalan kısımlarını oluşturmaktadır.

2.1 LİTERATÜR İNCELEMESİ

2.1.1 Ön İşleme Yöntemleri

Görüntü ön işleme adımı, analiz sürecinin önemli bir kısmını kapsayan zor, ancak Dermoskopik görüntülerin tanımlanması için etkili bir yoldur. Dermoskopik görüntülerde sıklıkla saç, yansıma, hava kabarcıkları, cetveller, mürekkep izleri, kan damarları ve muhtemelen lezyon kenarlarının tespitini etkileyen cilt çizgileri gibi yapılar bulunmaktadır. Bu yapılar lezyonların kenar bulunması sürecinde hasasiyetin azalmasının ve hesaplama süresinde artışa sebep olmaktadır. Kenar bulmayı basitleştirmek için pek çok yöntem kullanılmıştır, bu yöntemlerden bazıları aşağıda incelenmiştir:

Wighton ve ark. [19], düzeltici yöntem olan ve geleneksel DullRazor Yazılımı ile iç boyama [20] yöntemi arasında bir karşılaştırma yaparak disoklüzyon yönteminin ikinci kısmına odaklanmıştır. İç boyama yönteminin DullRazor'ın DullRazor yazılımında kullanılan lineer interpolasyonundan yaklaşık %32,7 daha iyi başarılı olduğunu gözlemlemişlerdir.

Abbas ve ark. [21], oklüzyon uygulanmış saçların onarım bilgilerine ilişkin dört adım önermiştir. Birinci adım, girilen görüntüyü, saç piksellerinin kesin tespitini yapmak için gri ölçeğe dönüştürmektir. İkinci adımda ise saç tespit edilmektedir. Bu adımda, sert saçlar Gauss Yönteminin 1. Derece Türevi ile Eşleştirilmiş Filtreleme kullanarak tespit edilip daha sonra eşit yönteminde oluşturulan maskede saç dışı piksellerinin hassasiyeti giderilmektedir. Üçüncü adımda da bu tespit edilen tutamları düzeltmek için morfolojik kenar tabanlı bir yöntem

kullanılmakta ve son olarak dördüncü adımda, saçtaki dokuları onarmak için Bornemann ve ark. [22] tarafından geliştirilen Hızlı Yürütme Algoritması (Fast Marching Algorithm) kullanılmıştır. Önerilen yöntemin doku ve renk gibi lezyon özelliklerini koruma kabiliyeti mevcuttur ve hem açık renk hem de koyu renk saçları eş zamanlı olarak bölütlemelere ayırabilmektedir. Önerilen yöntemin performansını diğer üç yöntemle karşılaştırmak için **DA** (Teşhis Başarımı) ve **TQM** (Doku Kalite Ölçütü) metrikleri kullanılmıştır. Önerilen yöntem, DA ve TQM'in en yüksek başarımlar oranlarını elde etmiştir ve bu oranlar sırasıyla %90,3, %90,0'dır.

Nasonova ve ark [23], Abbas ve arkadaşlarının [21] yöntemine dayalı algoritmayı sunmuştur. Ancak, tespit yöntemini iyileştirmek için saç bölgelerini tespit etmek amacıyla Gauss Yönteminin 1. Derece Türevi ile Eşleştirilmiş Filtreleme (MF-FDOG) yerine Gabor filtresi kullanılmıştır. Morfolojik kapama yöntemi, kopuk çizgileri bağlamak için kullanılmıştır. Daha sonra, elde edilen maskeden lezyon konturunu çıkararak tespit edilen maskeyi iyileştirmek için erozyon ve dilatasyon yöntemi seçilmiştir. Kaldırılan pikselleri yeniden doldurmak için Kısmi Diferansiyel Denklem (**PDE**) tabanlı yöntem kullanılmıştır. Bu yöntemde boşluk doldurulana kadar saç kenarı sınırını interpolate etmek için tekrarlanarak uygulanmaktadır. Yeniden yapılandırma filtrelerini kullandıktan sonra ortaya çıkan bulanık görüntü kalitesini düzeltmek için kenar keskinleştirme yöntemlerinden Warp filtreleri kullanılmıştır.

Toossi ve ark. [24], görüntü kontrastını geliştirmek için Temel Bileşenler Dönüşümü (**PCA**) kullanmış; daha sonra RGB renk uzayında maksimum kontrast ile gri ölçeğe dönüştürmüştür. Gri ölçek görüntüden gürültüyü yok etmek için Wiener filtresi [25] kullanılmıştır. Rosenfeld ve dig [26] tarafından önerilen ikili eşiğin seçilmesiyle Saç kenarlarını tespit etmek için iyileştirilmiş canny algoritması kullanılmıştır [27]. Pürüzsüz saç çizgileri elde etmek için saç tutamları maskesine morfolojik dilatasyon ve dolgu operatörü uyguladıktan sonra saçlar arkaplandan ayrılmıştır. Ayrılan saçlar, çok çözünürlüklü uyum taşıma iç boyama yöntemi kullanılarak kaldırılmıştır [28]. Algoritma, cetvel izini ve farklı kalınlıklardaki hem açık hem de koyu renk saçları %88,3 başarımlar oranı ile görüntüden ayırabilmektedir.

Mahmood ve ark. [29], Toossi'nin yaklaşımına [24] dayalı bir yöntem ortaya atmıştır ancak algoritma, görüntüyü iyileştirmek için sadece kırmızı görüntü kanalını ve Çokgen iç boyama yöntemini kullanmaktadır. Önerilen algoritma, Toosi'nin yaklaşımı ile karşılaştırıldığında olguları tespit etme ve onarma yaklaşımında tek kırmızı görüntü kanalının kullanılmasından dolayı hız bakımından verimini kanıtlamıştır. Algoritma, olguları (cetvel izleri, farklı kalınlıklardaki açık ve koyu renkte saçları) kolayca tespit edip onarabilmektedir.

Kiani and Sharafat [30], saç tutamlarının baskın yönünü tespit etmek için radon dönüşümünü kullanmıştır. Marr-Hildreth Algoritması (Laplacian of Gaussian) , Laplace işleci, Sobel ve Prewitt kenar bulma filtreleri için sinyal-gürültü oranı kriterini kullanarak test etmişlerdir ve çeşitli deneylerden sonra Prewitt filtresinin maksimum başarımlı oranı verdiğini görmüşlerdir. Gürültü ve saçsız yapılar gibi istenmeyen etkiler eşikleme-ortalama alma-eşikleme ve ardından pürüzsüzleştirme adımlarıyla görüntüden kaldırılmıştır. Daha sonra, işlem süresini azaltan bilinear interpolasyon yerine Ortalama Alma kullanılarak Geliştirilmiş Dull Razor yöntemi oluşturulmuştur. Önerilen yöntem, koyu ve açık renkteki saçları Dull Razor yönteminden yaklaşık 7 kat daha hızlı olarak etkili bir şekilde yok edebilmektedir.

Berata ve ark. [31], görüntü ön işlemeyi dermoskopi jelinin ve saçların neden olduğu yansımaları tespit etmek ortadan kaldırmaya ilişkin iki işlemde gerçekleştirmiştir. Önerdikleri yöntem dört adımdan oluşmaktadır: i) RGB görüntüsünü gri ölçek görüntüsüne dönüştürmek. ii) Yansıma tespiti için basit eşikleme algoritması kullanmak. Yoğunluğu komşusunun ortalama yoğunluğundan daha yüksek olan gri ölçek piksellerini seçmek. iii) Saç tespiti için deneyle tercih edilen parametreleri seçerek Gabor filtresine dayalı 64 bank yön filtresinden 41×41 maske [14] kullanmak. iv) Değeri 0,06 eşikini aşan saçlar olarak pikselleri sınıflandırmak. Her iki olguyu belirledikten sonra beliren boşlukları doldurmak için PDE tabanlı interpolasyon yöntemi kullanılmıştır.

Pathan ve ark. [33], Barata'nın [31] algoritmasına paralel saç tespiti algoritmasını önermiştir. Ancak, Dermoskopik saç tutamlarının özelliklerine göre saç tespiti maskelerinde sezgisel Gauss yerine Gabor filtresinin parametreleri seçilmiştir. Ayrıca, eşik değeri deneyle seçilenin aksine [31] otomatik olarak belirlenmiştir. Bölütlenmiş 24 görüntü çakışma hata denklemi kullanılarak değerlendirilmiş, sonucun, ön işleme aşaması olan ve olmayan,

bölütlenmiş görüntüler arasındaki farklılaşmayı belirgin bir şekilde gösterdiği ortaya çıkarmıştır

2.1.2 Lezyon kenarının tespitine ilişkin bölütleme.

Günümüzde, tıbbi görüntüleme sistemleri alanındaki ilerlemeyle beraber dermoskopi, dermatolojik hastalıkların analizinde ve teşhisinde önemli bir yöntem haline gelmiştir. Dolayısıyla, lezyon alanının otomatikleştirilmiş bölütlenmesi, kanser türünü ve kanserin iyi huylu olup olmadığını tespit etmeye yönelik önemli bir etkiye sahiptir. Lezyonun kenarının bölütlenmesi veya tespiti geleneksel görüntü işleme ve makine öğrenmesi yöntemleri ve Derin Öğrenme yöntemleri şeklinde iki gruba ayrılmaktadır.

2.1.2.1 Geleneksel görüntü işleme ve makine öğrenimi yöntemleri.

Son zamanlarda, cilt lezyon alanının geleneksel bilgisayar görü ve makine öğrenimi yöntemleriyle bölümlere ayırmak için çeşitli bölütleme teknikleri kullanılmaktadır. Aşağıdaki kısımlarda, bu tekniklerden bazıları açıklanmaktadır:

Abbas ve ark. [34], dermoskopi görüntülerinin kontrastını ve bölütlemesini geliştirmeye yönelik algı odaklı yöntemi birleştirerek yeni bir yöntem ileri sürmüştür. Söz konusu yöntem, dört ana adımdan oluşmaktadır. Birinci adımda, RGB görüntüleri CIE $L^*a^*b^*$ renk alanına dönüştürülüp daha sonra birinci adımın sonucunu iyileştirmek için belirli bir alandaki yoğunluk değerlerini ayarlayarak üç CIE $L^*a^*b^*$ kanalı kullanılmıştır. Ardından **ROI** haritasını tespit etmek için tepe tırmanan yöntem kullanılmıştır. Son olarak, lezyonun kesin kenarını belirlemek için Otsu eşik tekniği uygulanmıştır.

Abbas ve ark. [35], 2013 yılında çalışmalarını üç adıma bölerek otomatik tespiti ilişkin önceki yaklaşımlarını işleme, bölütleme ve işleme sonrası olacak şekilde geliştirmiştir. Birinci adımda, görüntü kontrastını iyileştirmek için girdi olarak verilen görüntünün gürültüleri (saç olgusu gibi) azaltılmış ve normalleştirilmiş pürüzsüz filtre uygulanmıştır. İlk lezyon alanı karışım modeller yöntemi ile bölütlemelere ayrılmaktadır. Zorlu bölütleme adımı, aday lezyon alanını tespit etmek için küresel ve yerel eşikleme ve morfolojik yeniden yapılandırma teknikleri birleştirilmektedir. İşlem sonrası adımda ise tespit edilen lezyon alanını pürüzsüzleştirmek için morfolojik yöntemler kullanılmıştır. Yazarlar, yaklaşımlarının test

etmek için EDRA İnteraktif Dermoskopi Atlası Veri Setinden alınan 100 dermoskopi görüntüsünü kullanmıştır.

aworek-Korjakowska ve Tadeusiewicz [36] çalışmasının ana amacı lezyonun kenar düzensizliğini tespit edip sınıflandırmaktır. Çalışmalarını, (Ön işleme, bölütleme, kenar düzensizliği tespiti ve sınıflandırılması) şeklinde sınıflara ayırmışlardır. Ön işleme adımı, (siyah çerçeve, cilt çizgileri, saçlar ve hava kabarcıkları) olguları kaldırılmıştır. Bölütleme süreci için, cilt lezyonunu çıkarmak amacıyla tohumlanan bölgede büyüyen algoritma uygulanmıştır ve daha sonra düzensizlik kenarı tespit edilip sınıflandırılmıştır.

Celebi ve ark. [37], Melgani [38] tarafından önerilen otomatik lezyon kenarı tespitini elde etmeye yönelik dört eşikleme yönteminin birleşimini kullanmıştır. (Görüntü mavi kanalına şu algoritmaları uygulamışlardır: (1) Huang and Wang [39] algoritması; (2) Kapur ve ark. [40] algoritması. (3) Kittler and Illingworth [41] algoritması. (5) Otsu's [42] algoritması).

Abadi ve Miry [43], histogram eşikleme tekniğine dayalı yeni bir bölütleme yöntemi sunmuştur. Bu yöntemin ön işleme adımı, dermoskopi görüntüleri, ilk görüntü gri ölçekli görüntü alanına dönüştürülerek izolasyon işlemine hazırlanmıştır. Daha sonra, bölütleme süreci üç ana adımda gerçekleşmiştir: (i) bozuk sinyalden gürültüleri filtrelemek için Wiener filtresi kullanılmış, (ii) histogram segmentasyon yöntemi, başlangıçtaki eşik değeri seçip gri ölçekli görüntüyü ikililer için seçilen başka bir eşik değeri belirleyerek ve lezyon noktasının ön plan ve arka plan alanlarını alarak gri seviye pikselleri iki sınıfa sınıflandırmak için gerçekleştirilmiştir, (iii) İlgili haritanın sonuç bölgesini iyileştirmek için morfolojik yöntem kullanılmıştır.

2.1.2.2 Derin öğrenme yöntemleri.

Görüntü bölütleme sürecinde, geleneksel görüntü işleme ve makine öğrenimi yöntemleriyle karşılaştırıldığında, derin öğrenme yöntemleri en iyi sonuçları elde etmiştir. Tıbbi dijital görüntülerin görüntü tanımadaki belirgin potansiyelleri nedeniyle tıbbi tanı alanında birçok derin öğrenme yöntemi uygulanmıştır. Bu yöntemlerden bazıları aşağıda sunulmuştur:

Lezyon bölgesinin yüksek kesinlikli çıkarımını elde etmek için Jafari ve ark. [44], derin öğrenme yaklaşımlarına dayalı bir yöntem ileri sürmüştür. Girdi ham dijital klinik görüntüsündeki gürültüyü azaltmak için ön işleme adımında gerekli bir işlem olarak kenar koruyucu düzleştirme kılavuzlu filtre kullanılmıştır. Küresel ve yerel lekeler özütlendikten sonra sağlıklı cilde ait olan pikseller için 0, lezyon pikselleri için 1 olmak üzere iki etiketten oluşan bölütleme haritası almak amacıyla bir sonuç olarak bu yamalar bir CNN'e beslenmiştir. Son adım olarak işleme sonrası yöntemler kullanılarak çıktı maskesi geliştirilmiştir.

Tam Evrişimsel Sinir Ağı (FCNN), dermatoskopik görüntüler için bölütleme sürecini yapmak üzere Qi's ve ark. [45] tarafından ortaya atılmıştır. Yazarlar bu yöntemde , uçtan uca öğrenme, transfer öğrenme ve piksel piksel tahmin amacıyla FCNN'ye odaklanmıştır.

Yuan ve ark. [46], 19 katmanlı derin Tam Evrişimsel Ağdan (FCN) oluşan Evrişimsel ve Ters Evrişimsel mimarisini kullanarak otomatik bir cilt lezyonu segmentasyonu yöntemi sunmuştur. Yazarlar, sınırlı veri sorununu çözmek için görüntü bölütlemenini piksel bazında bir sınıflandırma problemine dönüştürmek üzere FCN uygulama eğilimindedir. Daha sonra, çeşitli eğitim stratejileri (Adem optimizasyonu, Yığın normalleştirme, Düşme ve görüntü çoğaltma gibi) kullanarak aşırı uyum göstermeyi azaltmak ve eğitim ağının verimliliğini iyileştirmek için ağ hiper parametrelerini ayarlamışlardır. Son olarak, tıbbi görüntü bölütlemenin ön ve arka planından pikselleri yeniden dengeleme ihtiyacını azaltmak için jaccard mesafe tekniğine dayanan yeni bir kayıp fonksiyonu yöntemi tasarlanmıştır.

Tam Evrişimsel Ağlar kullanarak cilt lezyon bölgesinin çevre bölgelerinin sağlıklı cilt bölgesinden otomatik olarak bölütlenmesi amacıyla birçok araştırma makalesi yayınlanmıştır. Bu yöntemlerden bazıları şunlardır.

Otokodlayıcı yöntem, Salimi ve ark. [47] tarafından DermoNet adı altında sıraladıkları bir bölütleme çerçevesi olarak önerilmiştir. Bu çerçevenin iki görev kodlayıcı ve kod çözücüye bölünmesi, ardından her ikisinin arasında bağlantıyı atlamaktır. Kodlayıcı görevinde, özellikler yoğun bloğun ana bileşenleriyle çıkarılırken, kod çözücü görevinde özellikler çıktı örneklemede orijinal görüntünün çözünürlüğünü geri getirmek için yukarı örneklenir ve eğitilir.

Xu ve Hwang [48], otomatik cilt lezyonu bölütleme için U-Net [49] modelinden esinlenilen bir yöntem sunmuştur. Yöntemleri, üç ana bloktan oluşmaktadır: 3×3 dolgulu evrişim, yığın normalleştirme ve **ReLU** aktivasyonu fonksiyonunu içeren evrişim bloğu. Aşağı örnekleme iki Evrişim bloğu ve 2×2 maksimum havuz katmanı içermiştir. Yukarı örnekleme ise 2×2 yukarı evrişim katmanı ve üç evrişim bloğundan oluşmuştur.

Cui ve ark. [50], lezyon bölütleme problemini çözmek için değiştirilmiş U-Net'e dayalı çok ölçekli bir grup çerçeve kullanmıştır. Ön işleme adımından sonra ilk U-Net versiyonu ağı, daha fazla özellik elde etmek için ağı daha derin hale getirmek amacıyla 4 yerine 5 defa aşağı örnekleyerek değiştirilmiştir. Daha sonra, model eğitimi sırasında önceden eğitilmiş ağ kullanılmıştır. İyileştirme süreci, çok ölçekli özellik çıkarma uyguladıktan sonra bunları softmax katmanından önce bitleştirilerek Chen ve ark. [51] "atrous uzamsal piramit havuzu" yönteminden esinlenilmiştir.

2.2 BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ

CAD, doğru klinik tanı konmasında dermatologlara yardımcı olmakta önemli bir rol oynamıştır. Uygulamada, CAD sistemi dört ana adımdan oluşmaktadır: (i) Tıbbi görüntü olgularının azaltılması için ön işleme, (ii) Lezyon kenarının tespitine yönelik bölütleme, (iii) Özellik Çıkarımı ve seçimi, (iii) Cilt kanseri sınıflandırması. Yukarıda belirtilen tüm adımlar arasında, melanoma kenar bulma, lezyon kenarının kesin çıkarımını elde etmeye yönelik zor bir görevdir. Bu çalışma ise ön işleme ve bölütleme görevlerine odaklanmıştır.


2.2.1 Dermoskopide Tıbbi Teşhis Yöntemleri

Dünyanın dört bir yanından gelen uzman dermatologlar, lezyonun melanom veya iyi huylu melanositik lezyon olup olmadığını ayırt etmek için bir standart oluşturmuş ve iki aşamadan oluşan 2000 Dermoskopik Uzlaşma Toplantısı (Consensus Net Meeting on Dermoscopy - **CNMD**) sırasında değerlendirilmiştir. Birinci aşama, melanositik lezyonları melanositik olmayan lezyonlardan ayırmaya odaklanmıştır. İkinci aşama ise dört farklı teşhis algoritması kullanarak melanositik lezyonun şüpheli, iyi huylu ya da kötü huylu olduğunun tespitine odaklanmıştır. Bu dört farklı teşhis algoritması ise Doku Analizi, ABCD Kuralı, 7 Noktalı kontrol listesi ve Menzies Yöntemidir [52].

2.2.1.1 Desen Analizi

Desen analizi, dermatologlar tarafından en yaygın kullanılan yöntemdir. Lezyonlarda mevcut olan desenleri (lokal veya global) arar ve lezyonun melanositik olup olmadığını tespit eder. Desen analizi, 1987'de Pehamberger ve arkadaşları tarafından ortaya konan 2000 CNMD'si tarafından güncellenmiştir. Lokal özellikler, lezyonun etrafındaki özelliklerin bireysel koleksiyonları olarak elde edilebilmektedir. Ancak, tipik olarak cilt lezyon bölgesinin çoğunu saran pürüzlü desen bloğu olarak global özellikler görülmüştür [53].


Lokal özellikler ile ilgili olarak, lezyonda malignite veya malignite olmadığını gösteren atipik / tipik veya düzensiz / normal bir yapı olarak sunulmaktadır. Türlerin lezyonda bulunması (atipik pigment ağları, düzensiz çizgiler, regresyon yapıları, düzensiz noktalar/globüller, beyazımsı mavi örtü ve düzensiz lekeler) lezyonun kötü huylu olduğunu göstermektedir. Öte yandan, (tipik pigment ağları, düzenli çizgiler, düzenli noktalar/globüller ve düzenli lekeler) yaygın olarak lezyonun iyi huylu olduğu şeklinde yorumlanır. **Şekil 2.1**, lokal kötü huyluluk özelliklerine bazı örnekler göstermektedir [53, 54].



Şekil 2.1: Lokal özelliklere örnek [53]

Global özellikler, çoğunlukla teşhisine olanak sağlayan dermoskopik özelliklerle tespit edilmektedir. Melanositik ve melanositik olmayan global dermoskopik özellikler, şu terimler kullanılarak etiketlenmiştir: Retiküler (birbirine bağlı çizgiler), Globüller (kahverengi renk

tonlarında globüller), Homojen renkte, Patlayan Yıldız (tekdüze periferik radyal çizgiler, globüller veya noktalar), Paralel (sadece oluklar, avuç içleri ve tabanlar boyunca), Çok bileşenli, Karmaşık özellik, Atipik pigment ağı yapıları (kalınlaşmış, asimetrik), Noktalar ve globüller, Asimetrik lekeler, Mavi beyaz örtü, Beyaz yara izine benzer depigmentasyon. Mavi bibere benzer granüller [54]. **Şekil 2.2** dermatoskopi görüntülerinde global özelliklerin bazı örneklerini göstermektedir.



Şekil 2.2: Dermatoskopi görüntülerinde global özelliklere örnekler: (a) retiküler, (b) globüler, (c) kaldırım taşı, (d) homojen, (e) paralel ve (f) patlayan yıldız [55]

2.2.1.2 ABCD-E Kuralı

ABCD kuralı, melanomun erken saptanması prosedürünü basitleştirme sürecindeki ilk zorluktur ve patern analizi yönteminden sonra oluşturulan ikinci yöntem olarak kabul

edilmektedir. ABCD yönteminin standartları 1985 yılında Friedman ve ark. [56] tarafından sunulmuştur. Lezyonda şu parametreleri kontrol etmeye dayanır: Asimetri (A), Kenar düzensizliği (B), Renk değişikliği (C), ve Çap (D). ABCD standardına zaman içinde Lezyonun Evrimleşmesi (E) eklenerek ABCDE Kuralı olacak şekilde 2004 yılında Abbasi ve ark. [57] tarafından genişletilmiştir. ABCDE kuralının kısa açıklaması aşağıda verilmiş ve 'te gösterilmiştir.


Asimetri (A): mol, yarı yarıya katlanacak olsaydı kenarlar eşleşmezdi.

Kenar düzensizliği (B): kenarlar düz değil, düzensiz, oymalı veya girintilidir.

Renk değişikliği (D): mavi, kırmızı ve kahverengi gibi renk çeşitliliği vardır.

Çap (C): mol, 6mm'den geniş, yaklaşık bir kalem silgisi ucu boyutundadır.

Evrimleşme (D): Lezyona ait şekil, yükseklik, renk veya boyutta herhangi bir değişiklik.



Şekil 2.3: Asimetri, Kenar Düzensizliği, Renk, Çap ve Evrimleşme (ABCDE kuralı) [58]


2.2.1.3 7 Noktalı kontrol listesi


Bu yöntemde yedi özellik vardır ve bunların her biri 1 puan alır ve eğer teşhis cilt lezyonunda 3 puan alırsa, lezyonun daha fazla melanom olması beklenir ve deri doktoruna başvurması gerekir. Tüm bu 7 özellik, majör ve minör standartlar olarak iki gruba ayrılmıştır. [59], majör standartların 2 puan, minör standartların ise 1 puan ağırlığında olduğunu belirtmektedir. Bu iki grup, Tablo 2.1'de gösterilmiştir.

Tablo 2.1: 7 noktalı Kontrol Listesi yöntemi örneği


Özellik türleri	Standartlar	Ağırlıklar
Majör özellikler	Lezyonun boyutunda değişiklik	2 puan
	Düzensiz pigmentasyon	
	Düzensiz kenar	
Minör özellikler	İnflamasyon	1 puan
	Kaşıntı veya değişen his	
	Diğer lezyonlardan geniş (çap >7mm)	
	Lezyonda sızıntı/ kabuklanma	

7 noktalı kontrol listesi kullanarak melanom teşhis yöntemi, pigmente olmuş lezyonun içinde sunulan her bir standarda skor eklemektir. Daha açıklayıcı olması için (, ve) ‘de örnekler sunulmaktadır.

**Şekil 2.4:** Puanların toplamı 7’dir. Bu yüzden, bu lezyon Melanomdur [60]



Şekil 2.5: Puanların toplamı 3'tür. Bu yüzden, bu lezyon Melanomdur [60]




Şekil 2.6: Puanların toplamı 1'dir. Bu yüzden, bu lezyon Clark nevüstür [60]

2.2.1.4 Menzies Yöntemi

Bu yöntem, analiz için negatif ve pozitif olmak üzere iki sınıfın özelliklerini kullanmaktadır.. İyi huylu tümörlerin (negatif sınıf) tespiti için lezyonların tek renk veya simetrisine bakılmaktadır. Kötü huylu tümörler (pozitif sınıf) için ise lezyonların, Genişletilmiş ağ, Çoklu mavi/gri noktalar, Çoklu (5-6) renk, Periferik siyah noktalar/globüller, Yara izine benzer depigmentasyon, Radyal akış, Psödopod, Çoklu kahverengi noktalar, Mavi beyaz örtü, gibi niteliklere sahip olup olmadığına bakılmaktadır.

Dermatologların, teşhis prosedürüne yönelik negatif ve pozitif özellikleri toplaması gerekmektedir. Örneğin, diğer tüm negatif özelliklerin bulunmadığı (Radyal akarsu) gibi pozitif bir özelliğin varlığı, lezyonun melanom olduğuna karar vermek için yeterlidir [61]. **Şekil 2.7**'de bu durum için örnek gösterilmiştir..




Şekil 2.7: Lezyonda pozitif işaret varlığı örneği [61]

2.3 YAPAY SİNİR AĞI (ANN)

Yapay Sinir Ağları, insan beyninin sinir yapısını bilgisayar ortamına benzetimi olarak tasarlanmış Yapay Zekanın bir kısmıdır. Yapay Sinir Ağları, ses, metin ve görüntü verilerini tanımak için oluşturulmuş insan beynini taklit eden bir grup algoritma olarak tasarlanmıştır [62]. İnsan beyni, Biyolojik Sinir Ağı iken bilgisayar beyni Yapay Sinir Ağıdır [63]. Yapay Sinir Ağı ile Biyolojik Sinir Ağı arasında birtakım benzerlikler mevcuttur. Örneğin, yapay sinir ağlarının matematiksel kavramları, biyolojik sinir ağlarından esinlenilmiştir. Ayrıca sinir ağları, girdi çıktı ürettiğinde eşzamanlı olarak çalışmaktadır. Oysa insan beyni, istediği zaman girdi ve çıktı üretmek için tepki vermektedir.[64].


Yapay sinir ağları biyolojik organizmaların öğrenme tekniklerini taklit eden yaygın kullanılan makine öğrenme tekniklerindendir. 'de biyolojik organizmalarda bulunan bir nöron ve bileşenleri gösterilmektedir. İnsan sinir sistemi, nöronlar olarak anılan hücrelerden oluşur. Aksonlar ve dendritler, çoklu nöronları birbirine bağlayan bağlayıcıdır. Sinapslar, aksonun sonunda yer alır ve nöronlar arasındaki bağlantının kurulmasından sorumludur [65].



Şekil 2.8: Biyolojik Sinir Ağı [65]

2.3.1 Algılayıcı

İlk ANN yapısı 1958 yılında Rosenblatt tarafından geliştirilmiştir. Bu, algılayıcı (perceptron) adı verilen çok basit bir ağıdır. Ağ, çoklu ikili girdilerden oluşuyordu ve tekli ikili çıktı ürettiyordu. Rosenblatt, ikili sınıflandırıcı için basit bir model önermiştir. Bu, çıktının daha yüksek olasılığına güvenmektedir. Rosenblatt'ın ilk modelinin basit yapısı, lineer olmayan görevler için Çok Katmanlı Algılayıcılara ilham vermiştir [66][67]. Algılayıcı ağındaki bir nöron, ağırlıklara göre girdi ve çıktıyla ilişkili hesaplama yöntemi içermektedir ve bu, biyolojik organizmalardaki sinaptik bağlantılarla aynı rolü görmektedir. Nörona giren her bir girdi birimini ölçmek için ağırlıklar kullanılmaktadır ve . 'da basit bir yapay sinir ağı görülmektedir.



Şekil 2.9: Basit bir Yapay Sinir Ağı [68]

2.3.2 Çok Katmanlı Algılayıcı


Çok Katmanlı Algılayıcı (Multi-Layer Perceptron - **MLP**), birbirine bağlı çoklu nöron katmanları içeren ileri beslemeli bir yapay sinir ağı mimarisidir. MLP , girdi katmanı, bir veya daha fazla gizli katman ve çıktı katmanından oluşmaktadır (). Bir katmanda bulunan her bir nöron, bir sonraki katmandaki başka bir nöronla ilişkilidir. Dolayısıyla, gizli katmandaki her bir nöron tek bir algılayıcıyı temsil etmektedir. ANN mimarisi için **MLP** tasarlanmanın ardındaki asıl motivasyon, ağın, lineer olmayan görevleri çözebilmesini sağlamaktır [66, 67].

Temel bir hesaplama elemanına genellikle birim ve düğüm adı verilir ve diğer düğümlerden girdi almaktadır. Her bir girdinin kendi ağırlığı (w) olup sinaptik öğrenmeye

yönelik bir model olacak şekilde ayarlanabilmektedir. Düğümlerde girdilerin ağırlıklı toplamı için f fonksiyonunu hesaplanmaktadır:

$$y_i = f\left(\sum_j w_{ij}x_j + b\right) \quad (2.1)$$

Böylece, çıktı, diğer düğümler için girdi görevi görmektedir.



Şekil 2.10: Tek gizli katmanla Çok Katmanlı Algılayıcı

$\sum_j w_{ij}x_j$ i düğümünün net girdisi iken w_{ij} i, j düğümlerinin ağırlığı, f ise düğümün aktivasyon fonksiyonudur.

2.3.3 Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu, aynı zamanda Transfer Fonksiyonu olarak da bilinmektedir. Bu, ağda bulunan her bir katmanın çıktısına eklenen bir düğümdür. Aslında, nöronun aktivasyonu, aktivasyon fonksiyonunun, aktiveştirilip aktiveştirilmemesine karar vermesine bağlıdır.

$$A = \sum (\text{ağırlık} * \text{girdi}) + \text{yanlılık} \quad (2.2)$$

$$X = \text{Aktivasyon (A)} \quad (2.3)$$

Ağda aktivasyon fonksiyonunun olmaması durumunda, ağırlık ve yanlılık, Denklem 2.2 deki gibi lineer bir denkleme geçmektedir. Lineer denklemler, karmaşık sorunları çözme kabiliyetinde sınırlıdır. Lineer olmayan denkleme sahip bir aktivasyon fonksiyonu, görüntü bölütleme ve görüntü sınıflandırması gibi daha karmaşık görevleri öğrenip gerçekleştirebilmesini sağlamaktadır. Lineer olmayan aktivasyon fonksiyonları diferansiyel denklemler vasıtası ile çözülmektedir. Bu, öğrenme optimizasyonu sırasında geriye yayılım sürecini daha verimli hale getirmektedir [69] [70].

2.3.3.1 Aktivasyon fonksiyonu türleri


Yapay Sinir Ağlarında her biri farklı özelliklere sahip pek çok aktivasyon fonksiyonu türü vardır. Aktivasyon fonksiyonunun kullanımı, çalıştıkları ağ türü ve katman türüne bağlıdır. En yaygın fonksiyonlar aşağıda incelenmiştir:

2.3.3.2 Sigmoid veya Lojistik


Sigmoid fonksiyonlar, en yaygın kullanılan lineer olmayan ve monotonik olarak artan fonksiyonlardan biridir. Çıktısı her zaman (0-1) aralığında olacağı için özellikle sınıflandırma modellerinde kullanılmaktadır (bkz. **Şekil 2.11-a**). (2.4) denklemi ile tanımlanmaktadır:

$$f(a) = \frac{1}{1 + e^{-a}} \quad (2.4)$$

Sigmoid fonksiyonunda yaşanan en olası problemlerden biri, gradyanın her iki tarafta da başlangıca çok yatay olabilmesi ve bu nedenle öğrenme sürecinin yavaşlamasıdır. Bu duruma gradyan kaçış noktası adı verilmektedir ve **Şekil 2.11-b** bu problem görülmektedir.. Gradyan kaçış noktası probleminden uzak durmak için ağırlıkları çok küçük değerlerle başlatmaktan kaçınmak gerekmektedir [71].



(a)




(b)

Şekil 2.11: (a) Sigmoid fonksiyonu. (b) Sigmoid fonksiyonu gradyanı [69]


2.3.3.3 Tanh—Hiperbolik tanjan

Tanh da çok yaygın kullanılan bir aktivasyon fonksiyonudur. Sigmoide alternatif bir fonksiyon olan Tanh'ın çıktısı sıfır merkezlidir (bkz. Şekil 2.12-a). Bu nedenle, gizli birimlerde her zaman sigmoid yerine tercih edilmektedir. Ancak, yine de gradyan kaçış noktası problemini bu fonksiyonda da mevcuttur (bkz. Şekil 2.12-b). (-1, 1) aralığında kalmak durumundadır ve (2.5) formülüyle tanımlanır:

$$f(a) = \tanh(a) = \frac{2}{1 + e^{-2a}} - 1 \quad (2.5)$$



(a)



(b)


Şekil 2.12: (a) tanh fonksiyonu (b) tanh fonksiyonu gradyanı [69]

2.3.3.4 ReLU

ReLU, lineer olmayan bir fonksiyondur. Son beş yıl içinde oldukça popüler hale gelmiştir. Şu şekilde tanımlanmaktadır:

$$f(a) = \max(0, a) \quad (2.6)$$

Şekil 2.13'te gösterilen formül, x sıfırdan az olduğunda değerin sıfır olduğu, sıfırdan daha büyük olduğunda ise 1 eğimiyle lineer olduğu anlamına gelmektedir. Krizhevsky ve ark. [72] Derin Evrişimsel Sinir Ağları yazısında imagenet sınıflandırmasında tanh üzerinden yakınsamada altı kat iyileşme gösterdiğini belirtmiştir.




Şekil 2.13: (a) Relu fonksiyonu. (b) Relu fonksiyonu gradyanı [69]


ReLU, sigmoid ve tanh fonksiyonlarının karşılaştığı gradyan kaçış noktası probleminin çözülmesine yönelik bir fonksiyondur. Ancak yine de, **ReLU** nöron ölümü problemini yaşamaktadır. Bu problem, çeşitli nöronların ölmesine ve hata veya girdiden değişikliklere yanıt vermeyi durdurmasına ve dolayısıyla öğrenmenin engellenmesine neden olmaktadır. **ReLU** nöron ölümü problemi, Sızıntılı **ReLU** kullanılarak çözülebilmektedir.

2.3.3.5 Sızıntılı ReLU

ReLU fonksiyonunun geliştirilmiş bir versiyonudur. x sıfırdan büyük olduğunda **ReLU** gradyanı 0'dır (bkz. **Şekil 2.14**). Bu da o bölgedeki birimin ölmesini sağlar.



(a)



(b)

Şekil 2.14: (a) Sızıntılı Relu fonksiyonu. (b) Sızıntılı Relu fonksiyonu gradyanı [69]

Yatay çizgi alışverişinin ardında yatan asıl sebep sıfır gradyanını yok etmektir. Sızıntılı **ReLU** işleviyle ağ, belirli bölgedeki ölü birimle karşılaşmayacaktır.

2.3.4 Kayıp Fonksiyonu

Kayıp fonksiyonları, makine öğrenimi hattının önemli bir parçasıdır. Öğrenme sürecinde eğitim verileri, tahmin fonksiyonu üretmek için kullanılmaktadır. Söz konusu fonksiyon, X girdilerini alıp Y etiketleriyle eşleştirmeye çalışmaktadır. Model, eğitim verilerinde daha önce görmemiş olsa bile sonucu tahmin etmek için çalışmaktadır. Model, mümkün olduğunca genelleştirilmiş olmalıdır. İşlemlerin sıralaması, tahmini çıktıyı hesaplayıp üretecek şekilde oluşturmaktadır. Tahmini çıktı ile gerçek çıktının karşılaştırma sürecine hata değeri adı verilmektedir. Hata değeri, öğrenme sürecinde Adam, gradyan inişi gibi optimizasyon stratejileri kullanılarak en aza indirgenmelidir. Söz konusu hata değerini hesaplamak için kullanılma şekli kayıp fonksiyonunu hesaplayarak gerçekleşmektedir.

IoU (aynı zamanda Jaccard İndeksi olarak da bilinir), tahmini bölge ile kesin referans bölgesi arasındaki benzerliği bulmak için kullanılan standart bir ölçüdür ve aşağıdaki Denklem (2.7) ile tanımlanmaktadır:

$$\frac{TP}{FP + TP + FN} \quad (2.7)$$

TP, FP ve FN, sırasıyla Doğru Pozitif, Yanlış Pozitif ve Yanlış Negatif sayıları ifade etmektedir.

Rahman ve ark. [73], sayıma dayalı ölçüm yerine muhtemel değerleri kullanarak IoU puanını yaklaşık olarak elde etmeyi önermiştir. Aşağıdaki Denklemden (2.8) bu öneri açıklanmıştır.

$$IoU = \frac{I(A)}{U(A)} \quad (2.8)$$

Burada, $I(A)$:

$$I(A) = \sum_{z \in Z} A_z * B_z \quad (2.9)$$

Ve $U(A)$:

$$U(A) = \sum_{z \in Z} (A_z + B_z - A_z * B_z) \quad (2.10)$$

Z, tüm eğitim setindeki her bir görüntünün tüm piksellerini ifade ederken A, ağırlık çıktı piksellerinin olasılığını, B ise Z seti için kesin referansı belirtmektedir.

Kayıp fonksiyonu, sınır ağında eğitim sürecinin kılavuzu niteliğindedir. Bölütleme sorunu için genellikle kayıp fonksiyonu olarak Jaccard mesafesi kullanılmaktadır. Tahmini bölge ile eğitim setinin karşılaştırmalı değerlendirme bölgesi arasındaki benzersizliğin hesaplanması için Jaccard mesafesi kullanılır ve aşağıdaki şekilde tanımlanabilir:

$$L_{IoU} = 1 - IoU = 1 - \frac{I(A)}{U(A)} \quad (2.11)$$

2.3.5 Eğitim süreci

Sinir ağı, gerçek çıktı değerleri ile istenilen çıktı değerleri arasındaki hatalara yanıt olarak nöronların parametre değerlerini (ağırlıklarını ve yanlılıklarını) ayarlayarak öğrenme sürecini gerçekleştirmektedir. Yapay sinir ağındaki eğitim veri seti, örnek (girdi) verilere sahiptir ve etiketlerle (çıktı) sınıflandırılmaktadır.

Sinir ağını eğitmek, aslında ileri yayılım ve geri yayılım şeklindeki iki temel adımı tekrarlayarak tüm ağırlıkları standardize etmek anlamına gelmektedir. İleri yayılım, girdi verileriyle ağı besleme ve ilk ileri adım için rastgele ağırlıkları seçerek çıktı etiketlerinin olasılığını hesaplama sürecidir. Geri yayılımda, çıktı hatası ölçülür ve hata düşüşüne göre ağırlıklar ayarlanır. Epok adlı ağ yoluyla ağırlıkların güncellenmesiyle eğitim seti işlem adımı geçilir. Ağırlıklar tüm eğitim örnekleri üzerinden ortalama toplamının karesi alınmış hatayı en aza indirgeyene kadar tüm eğitim örnekleri tekrarlı olarak ağa girmektedir.


Eğitim aşamasının sonunda, eğitim verilerinin hedef çıktı değerleri en az hatayla çoğaltılmalıdır. Toplamının karesi alınmış hata minimizasyonuna gradyan inişi (gradient descent) adı verilen hata azaltma yöntemi denmektedir. [74].

2.3.6 Normalleştirme Prosedürü

Sinir ağında eğitimi hızlandırmak için pek çok teknik kullanılmaktadır.:

2.3.6.1 Girdileri Normalleştirme.

Girdileri Normalleştirme, sinir ağındaki bayası minimuma indirmek için verileri aynı değer aralıklarında dengelemek üzere girdi verilerini yeniden ölçeklendirme sürecidir. Ham girdilere yönelik normalleştirme prosedürünün verilerin eğitime uygun şekilde ayarlanmasında önemli bir etkisi vardır. Veriler normalleştirilmediği takdirde maliyet fonksiyonunun şekli tutarsız olacaktır (**Şekil 2.15-a**) ve dolayısıyla, sinir ağlarının eğitimi çok yavaş olacaktır çünkü gradyan inişinin öğrenme oranı, minimum maliyete ulaşana kadar küçük adımlar atacaktır. Öte yandan, normalleştirilmiş verilerle maliyet fonksiyonunun şekli tutarlı bir hale gelir (**Şekil 2.15-b**) ve gradyan inişi, minimum maliyeti birleştirmek için öğrenme oranında büyük adımlar atar [75]. Girdilerin normalleştirilmesi iki adımdan oluşur [76]:




Şekil 2.15: Maliyet fonksiyonunun şekli [76]

İlk olarak, her bir eğitim girdisinden ortalama çıkarılır (Denklemler (2.12)). Bu, eğitim girdilerinin (bakınız Şekil 2.16)'de gösterilen şekilde sıfıra ortalananmasını sağlar.


$$\mu = \frac{1}{m} \sum_{i=1}^m x^{(i)} \quad (2.12)$$

$$x = x - \mu \quad (2.13)$$

x eğitim setindeki girdi verileri ifade ederken m , eğitim setindeki örnek sayısıdır. Eğitim setindeki girdilerin ortalaması (Denklemler (2.12) ve (2.13))'te μ ile ifade edilmektedir.



Şekil 2.16: Orijinal veriler [76]




Şekil 2.17: İlk uygulamadan sonra normalleştirilen veri [76]

İkinci sürece varyans normalleştirilmesi adı verilmektedir. Ortalama varyans çıktıların her birine (denklem (2.11)) bölünür. **Şekil 2.16**'ya bakıldığında x_1 ve x_2 arasındaki verilerde büyük farklılıklar gözlemlenmektedir. Denklem (2.15) uygulanarak x_1 ve x_2 normalleştirilip verilerin varyansı **Şekil 2.18**'de gösterilen şekilde bir olmuştur.

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m x^{(i)2} \quad (2.14)$$

$$x/\sigma^2 \quad (2.15)$$

σ^2 , Denklem (2.14)'den elde edilen özelliklerin karesi alınmış vektörünün bir ortalamasıdır ve Denklem (2.15), normalleştirilmiş girdilerin nihai sonucunun bir vektörüdür.



Şekil 2.18: Varyans normalleştirme [76]

2.3.7 Optimizasyon algoritmaları

Optimizasyon, maliyet fonksiyonunu ayırt ederek negatif eğimi izleyip model parametrelerini değiştirerek eğitim hatasını azaltmak için tasarlanmış tekrarlayan bir işlemdir. Maliyet fonksiyonu gradyanı, toplam hatada ağırların her bir biriminin katkılarını tahmin etmek için çalışır [77].

Geri yayılım, en iyi çözümü elde etme amacıyla hazırlanan gradyan arama tekniklerinden biridir.

2.3.7.1 Geri Yayılım Algoritması

Geri yayılım, ANN’de ağırlıkların hesaplamak için gerekli olan gradyanı hesaplamak için en çok kullanılan yöntemdir. 1970’lerde ortaya çıkmıştır. Rumelhart ve ark. [78] tarafından geliştirilip 1986 yılında ünlü olmuştur [79].

Eğitim örnekleri, hedefe ulaşılan kadar pek çok adımdan geçmektedir. Bir demet görüntü, bir ileri veya geri geçiş yöntemiyle Sinir Ağına girer ve bu yöntem mini-yığın adı verilir. Geri yayılım algoritması, çoklu eğitim dönemleriyle tek bir yığın için tahmin edilen Yapay Sinir ağıнын hatasını en aza indirmek için maliyet fonksiyonu olarak gradyan inişi tekniğini kullanmaktadır [79].

Geri yayılım algoritması aşağıdaki adımları izler:

1. **İleri besleme:** İleri besleme adımında, ağıdaki her bir katman iki hesaplama adımına karşılık gelmektedir:

- a) z değeri hesaplanır:

$$z^l = w^l a^{l-1} + b \quad (2.16)$$

- b) z çıktısı için aktivasyon değeri hesaplanır.

$$a^l = \sigma(z^l) \quad (2.17)$$

$l, 2$ ’den L ’ye kadar katman sayılar sıralamasıdır. w^l , l katmanının ağırlığıdır. a^{l-1} , önceki katmanın çıktısı; a^l , mevcut katmanın aktivasyon fonksiyonudur. b , bayastır.

2. **Çıktı hatası δ^L :** İleri besleme işlem hatasıdır ve şu şekilde hesaplanır:

$$\delta^L = \nabla_a C \odot \sigma'(z^L) \quad (2.18)$$

L son nöral yapı katmanıdır ve $\nabla_a C$, a bakımından maliyet fonksiyonunun gradyanı ve $\odot$ Hadamard ürününü ifade etmektedir (elementle ilgili matris ürünü).

3. **Geri yayılım hatası:** δ^L çıktı hatasından başlar ve girdiye doğru geri döner. Şu şekilde tanımlanmaktadır:

$$\delta^l = \left((w^{l+1})^T \delta^{l+1} \right) \odot \sigma'(z^l) \quad (2.19)$$

$(w^{l+1})^T$ sonraki katmanın ağırlık vektörü ve l , mevcut katmanın sayısıdır.

4. Δw_{ij}^l ve Δb_{ij}^l eğitilebilir parametreleri aşağıdaki (2.20) ve (2.21) Denklemleriyle güncellenir:

$$w^l = w^l - \eta \frac{\partial C}{\partial w^l} \quad (2.20)$$

$$b^l = b^l - \eta \frac{\partial C}{\partial b^l} \quad (2.21)$$

η , eğitilebilir parametrelerin ne kadar hızlı güncellendiğini kontrol eden öğrenme oranı ve $\frac{\partial C}{\partial w^l}$, w parametresi bakımından hatanın türevi ve $\frac{\partial C}{\partial b^l}$, b [80] parametresi bakımından hatanın türevidir.

Öğrenme sürecini iyileştirmenin ve hatta belki de ivme, RMSprop ve Adam ile gradyan inişi gibi maliyet fonksiyonundan daha iyi sonuç elde etmenin pek çok yolu vardır.

2.3.7.2 Adam Algoritması

Sinir ağlarında oldukça yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Adam algoritması, ivme ve RMSprop algoritmalarının bir birleşimidir. Klasik Gradyan inişinden daha hızlı bir yakınsama gerçekleştirmektedir.

Asgari yakınsama hızından dolayı NN alanında en çok kullanılan optimizasyon algoritmasıdır.

$$v_{dW} = \beta_1 v_{dW} + (1 - \beta_1) \frac{\partial L_{IoU}}{\partial W} \quad (2.22)$$

$$s_{dW} = \beta_2 s_{dW} + (1 - \beta_2) \left(\frac{\partial L_{IoU}}{\partial W} \right)^2 \quad (2.23)$$

$$v_{dW}^{corrected} = \frac{v_{dW}}{1 - (\beta_1)^t} \quad (2.24)$$

$$s_{dW}^{corrected} = \frac{s_{dW}}{1 - (\beta_2)^t} \quad (2.25)$$

$$W = W - \alpha \frac{v_{dW}^{corrected}}{\sqrt{s_{dW}^{corrected} + \epsilon}} \quad (2.26)$$

v_{dW} ve s_{dW} , sırasıyla geçmiş gradyanların ve gradyanlar karesi geçmişinin üssel ağırlıklı ortalamasıdır. β_1 , β_2 , ayar yapılacak hiperparametrelerdir. $\frac{\partial L_{IoU}}{\partial W}$, mevcut katman bakımından kayıp gradyandır. α , öğrenme oranıdır ve ϵ , sıfıra bölünerek çevrilen çok ılımlı bir değerdir.


2.3.8 Derin Öğrenme

Derin öğrenme, (ANN) kavramını oluşturan ve nöron adı verilen insan beyni hücrelerinin işlevselliğinden ilham alan algoritmalarla ilgilenen makine öğreniminin özel bir alt alanıdır. Derin Öğrenmenin asıl avantajı, kenarlar veya köşeler gibi temel özellik setlerini yapıştırarak basit ham madde verilerinden karmaşık kavramlar oluşturmaktır. Günümüzde, derin öğrenme teknikleri, nesne tespiti, görüntü sınıflandırma ve bölütleme gibi pek çok alana uygulanmaktadır [81].

2.3.8.1 Evrişimsel Sinir Ağı

Aynı zamanda CNN olarak da bilinen evrişimsel sinir ağı, bu zamana kadar çoğunlukla görüntüleri analiz etme, desenleri tespit etme, görüntü sınıflandırma ve bölütleme sorunlarında yaygın olarak kullanılmış olan yapay bir sinir ağıdır.

CNN'ler, özel bir çok katmanlı sinir ağı (Multilayer Neural Networks - MNN) türüdür. CNN'in önemli avantajı, paylaşılan ağırlık kullanımı ve lokal bağlanabilirliktir. Dermoskopi görüntülerini tanımak ve piksel piksel etiketlemek için kullanılan lokal özellikleri öğrenmek için girdi verileri kullanılabilir. CNN'in örnek mimarisi, üç farklı tip katmandan oluşmaktadır ve bunlar **Şekil 2.19**'da gösterildiği gibi evrişim (convolution) , örnekleme (pooling) ve tam bağlantı katmanıdır. Her bir CNN katmanı için ileri ve hata geri sinyal yayılımının hesaplanmasının farklı bir kuralı bulunmaktadır [82].




Şekil 2.19: Tipik Evrişimsel Sinir Ağı (CNN) yapısı [79]

Tipik CNN katmanı türleri: Hem birinci hem de ikinci katman, özellik haritası adı verilen ögeden oluşmaktadır.

1. Evrişim Katmanı:

Girdi görüntüsünde özellik tanıma, evrişimsel katmanın temel amacıdır. Genellikle, pek çok özellik haritasından oluşur, her bir harita girdi görüntüsünde belirli bir özelliği tanır. Her bir tek özellik haritası, orijinal görüntünün belirli bir bölgesiyle örtüşür. Evrişimsel

katman, genellikle, paylaşılan ağırlıkları (filtre veya çekirdek) ve yanlılığı kullanarak görüntüyü evriştiren birinci CNN katmanıdır. Filtre, kayan pencere yoluyla görüntü verisi boyunca uygulanan küçük bir birimdir. Filtrenin derinliği, girdi kanalları ile aynıdır. RGB görüntüleri için 3 derinliğinde bir filtre uygulanmaktadır. Evrişim işlemi, görüntüdeki filtre elemanına göre filtre ürününü aldıktan sonra bu değerleri her bir kayma işlemi için toplar. Renkli görüntülü 3D filtreli evrişim çıktısı 2D matristir [83]. Paylaşılan ağırlıkları ve yanlılıkları kullanmanın ardında yatan asıl maksat, Convnet'te yer alan parametre sayısını büyük ölçüde azaltmasıdır [79]. **Şekil 2.20** yukarıdaki açıklamayı örneklemektedir.




Şekil 2.20: 3D görüntü girdisi (7,7,3) (3,3,2) matris elde ederek evrişen 3D filtre w_0 (3,3,3) artı yanlılık b_0 (1,1,1) temsil eder [84]

2. Alt örnekleme / Örnekleme katmanı:

Daima evrişimsel katmanı takip etmektedir. Alt örnekleme katmanının özellik haritalarının sayısı, evrişim katmanının her haritasının bir sonraki “alt örnekleme katmanı” ndaki eşleşen özellik haritasına bir girdi olarak kullanıldığı evrişimsel katman haritaları ile eşdeğerdir.

Şekil 2.21 örnekleme işlemini göstermektedir. Ağın derinliğine dayanan evrişimli ve alt örnekleme katmanları, ağdaki son katmana ulaşana kadar birbirlerini alternatif olarak takip eder [83].



Şekil 2.21: Maks Örnekleme işlemi [84]

3. Tam Olarak Bağlı Katman:

Tam olarak bağlı bir katmandaki Nöronlar, önceki katmandaki tüm nöronlara, normal ANN'lerden olduğu gibi bağlanmaktadır. Evrişimsel katmanlarla tam olarak bağlı katmanların arasındaki temel fark, tam olarak bağlı katman özellik haritalarını alır ve bir boyutlu vektör olarak çıktısını alır. Evrişimsel katmanlar girdinin lokal alanına katılır [81].


4. CNN Mimarileri

CNN, en az ön işlemeyle doğrudan piksel görüntülerinden görsel kalıpları tanıma alanındaki başarılarından dolayı, derin öğrenme alanında büyük bir yere sahiptir. Bu başarılar, bugünlerde piramidin en üstüne ulaşana kadar pek çok aşamadan geçmektedir. 1998 yılında, LeCun ve onun ortakları olan araştırmacılar elle yazılan haneler için 7 seviyeli evrişimsel bir ağ geliştirmesiyle başlamıştır ve buna LeNet adını vermişlerdir. 2012 yılında, Alex Krizhevsky'nin geliştirdiği LeNet mimarisi 7 gizli katman içermektedir ve kayıp oranını yaklaşık %15,3'e indirmiştir. 2014 yılında, Google, %6,67 ile insan seviyesindeki performansa çok yakın olan en iyi 5 hata oranına ulaşmıştır. Tasarımları, 22 CNN katmandan oluşmaktaydı ancak, parametre sayısı 60 milyondan (AlexNet) 4 milyona indirilmiştir. Aynı yıl, Simonyan ve Zisserman tarafından VGG Net geliştirilmiştir. VGG

Net, 16 ve 19 evrişimsel katman olmak üzere iki tür mimariye sahiptir. Aslında, görüntü özelliklerinin özütlenmesi alanında en çok tercih edilen seçenek olarak kabul edilmektedir. Son olarak 2015 yılında, diğer CNN yapılarıyla kayıp azaltımı bağlamında rekabet etmek üzere ResNet ortaya çıkmıştır. ImageNet veri setinde %3,57 ile insan seviyesindeki performansı geçen en iyi 5 hata oranına ulaşmıştır [85].

2.3.9 U-Net Ağ Mimarisi

[86] çalışmasında sunulan U-Net, temel amacı her bir piksel sınıfını tahmin ederek tıbbi görüntüleri bölütlemek amacıyla kullanılan Tam Olarak Evrişimsel Sinir Ağıdır. Mimari, adı itibarıyla ‘U’ şeklindedir. U-net mimarisi kodlama veya aşağı örnekleme yolu, darboğaz ve kod çözme ve yukarı örnekleme yolu olmak üzere üç bölüme ayrılmıştır. Kodlama kısmı, birçok kodlama bloğundan oluşmaktadır. Her bir bloktan sonra, özellik haritası sayısı, modelin karmaşık yapıları verimli bir şekilde öğrenebileceği şekilde çarpılır. Darboğaz kısmı, aşağı örnekleme ile yukarı örnekleme arasındadır. İki evrişimsel katmandan oluşmaktadır. U-net mimarisinin özü, kod çözme kısmında yatmaktadır. Kodlama kısmı gibi çeşitli kod çözme bloklarından oluşmaktadır. U-Net modeli girdiyi kodlayarak ve onun derin özelliklerini bularak aşamalı bir şekilde çalışmaktadır. Daha sonra bu özellikleri Ters evrişim ile deşifre eder ve bu kod çözme sonuçlarını aynı boyutlara sahip özelliklerle kanal olarak birleştirir. U-Net mimarisinin bir örneği **Şekil 2.22**’de gösterilmektedir.




2.4 GÖRÜNTÜ ÖN İŞLEME TEKNİKLERİ

Mevcut bölüm, kılları ve ışık dermoskopi görüntülerinin çoğunu kapsayan ışık yansımalarını tespit etmek ve kaldırmak için önerilen ön işleme tekniklerini açıklamaktadır. Ayrıca, lezyon sınır bölütleme işlemi için hazırlanacak girdi görüntüsünü geliştirmektedir.

2.4.1 Görüntü ön işleme

Çoğu dermoskopi görüntüleri, saç, cetvel işaretleri ve ışık yansımaları gibi öğelerle kaplıdır. Sonuç olarak bu görüntüler, bölütleme işlemi sırasında lezyonun kenarını gizleyip onu görünmez hale getirebilmekte ve lezyon kenarının tespit edilmesini zorlaştırabilmektedir. Buna ek olarak lezyon kenarının uygunsuz tespiti, daha sonra yanlış sınıflandırmaya neden olabilmektedir. Bu nedenle, etkili bölütleme sonuçları almak için saç tespiti ve yok etme işlemi gerekli görülmektedir. **Şekil 2.23**, ISIC veri seti görüntülerinin örneğini göstermektedir.




Şekil 2.23: Gürültüyle kaplı olan dermoskopi görüntüleri. (a) Küçük hava kabarcıkları. (b) Dalgali saç. (c) Küçük saç. (d) Cetvel işareti [87]

2.4.1.1 Renk Uzayları

Renk, beynin nesnelerden yansıyan ışığın niteliklerine verdiği tepkidir. Işık, nesnenin renginin tayfını görmek için gereklidir. Nesnenin üzerinde ışık düştüğünde renklerin bazıları emilirken diğerleri nesneden yansımaktadır. İnsan retinası sadece yansıyan görüntülere tepki vermektedir. Sonuç olarak renk uzayları, nesneden insan retinasına yansıma sürecini açıklamayı kolaylaştırmak için ortaya çıkmıştır. İnsanlar bir rengi tonuna ve parlaklığına göre tanımlayabildiği gibi bilgisayar da renge denk gelen kırmızı, yeşil ve mavi fosfor emisyonu miktarını kullanarak açıklamaktadır. Görüntü işlemede pek çok çeşit renk uzayı modelleri kullanılmaktadır. Bu modellerden en yaygın kullanılanları şu şekildedir [88]:

2.4.2 RGB renk uzayı

Ek bir renk sistemidir ve farklı renklerden oluşan geniş bir alanı çoğaltmak amacıyla her bir piksel verisi için 3 bayt veri kullanır. Görüntüdeki her bir piksel 3 kısma ayrılmıştır. Birinci bayt kırmızı miktarı için, ikinci bayt yeşil miktarı için ve üçüncü bayt mavi miktarı için. Her bir bayt **Şekil 2.24**'de gösterilen şekilde 256 farklı tona sahiptir.



Şekil 2.24: Renkli Piksel derecesi

2.4.3 Gri Renk uzayı

Gri ölçek, karanlıktan aydınlığa doğru monokromatik bir alandır. Böylelikle, renkli görüntülerde olduğu gibi sadece gri ölçek görüntüsü üç değil, tek bir kanaldan oluşur. Renkli görüntülerin gri ölçek görüntülerine dönüşümü Denklem (2.27)'de görüldüğü üzere RGB kanallarının ortalama ağırlıklı değerleri olan “**Parlaklık Yöntemi**” adı verilen yöntemle yapılmaktadır. Bu işlem ile tüm renk verileri ortadan kaldırılarak sadece her pikselin parlaklığını bırakılır. Parlaklık Yöntemi aşağıdaki denklemde gösterilmiştir:

$$\text{Gri}(x, y) = (0.3 * R) + (0.59 * G) + (0.11 * B) \quad (2.27)$$

(x, y), görüntü pikselinin konumudur. RGB, sırasıyla kırmızı, yeşil ve mavi rengin değeridir.

2.4.4 HSI Renk Ölçeği

HSI renk sistemi, her rengi üç bileşenle temsil eder: ton (H), doygunluk (S), yoğunluk (I). Renkleri, insan gözünün algıladığıyla benzer şekilde temsil etmektedir. RGB görüntüsünden HIS alan renginin elde edilmesi için aşağıdaki algoritma izlenmiştir:

$$H = \begin{cases} \theta & \text{Otherwise} \\ 360 - \theta & \text{if } B > G \end{cases} \quad (2.28)$$

$$S = 1 - \frac{3}{(R + G + B)} [\min(R, G, B)] \quad (2.29)$$

$$I = \frac{1}{3}(R + G + B) \quad (2.30)$$

iken


$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{1/2}} \right\} \quad (2.31)$$

2.4.5 Gauss Bulanıklığı

Kenar bulma sürecinde daha fazla kenar elde etmek için hazırlanacak olan tıbbi görüntülerden bazı ayrıntıları ve gürültüleri kaldırma işlemidir. Şekil 2.25’de [89] [90] Gauss “çan eğrisi” olarak gösterilen şekli temsil eden bir fonksiyonu kullanılmaktadır. Gauss Bulanıklığı aşağıdaki şekilde tanımlanmıştır:

$$G(x, y) = A \cdot e^{-\left(\frac{(x-x_0)^2}{2\sigma_x^2} + \frac{(y-y_0)^2}{2\sigma_y^2}\right)} \quad (2.32)$$

A, genlik (x_0, y_0) , Gauss fonksiyonunun merkezi, σ_x , σ_y , x ve y yönlerindeki standart sapmalardır.



Şekil 2.25: Gauss fonksiyonu [90]

2.4.5.1 Morfolojik görüntü işleme


Bir görüntüdeki nesnelerin şekliyle ilişkili ikili işlemler setidir. Girdi görüntüsünün basit bir eşik yöntemi kullanılarak ikiliye evirtimi sırasında gürültülerin neden olduğu aksaklıkları yok etmeyi amaçlamaktadır [91]. Genel olarak, “**yapısal öge**” adı verilen küçük tek boyutlu ikili matris (3x3, 5x5 veya 7x7) kullanır. Eşleşen komşu görüntü piksellerini karşılaştırmak için görüntüdeki her bir pikselle değiştirilmektedir. Aynı boyutta çıktı görüntüsü üretir. En temel morfolojik işlem türü aşağıda açıklanmıştır:

1. **Dilatasyon:** Nesnenin kenarlarını aşamalı olarak genişletme işlemidir. **Şekil 2.26**'da görülen şekilde görüntüdeki nesne boyutu artacak ve bu objelerin arasındaki delikler küçülecektir. İkili görüntünün dilatasyonu aşağıdaki şekilde tanımlanmıştır:

$$A \oplus B = \{a + b | \text{for } a \in A \text{ and } b \in B\} \quad (2.33)$$

$$A \oplus B = \bigcup_{b \in B} A_b \quad (2.34)$$

A, ikili görüntü, B ise çıkarma elemanı matrisidir. $A \oplus B$, B çıkarma elemanı bakımından A girdi görüntüsünün birleşmesine eş değerdir [92].




Şekil 2.26: 3x3 yapısal eleman matrisi kullanılarak etkili dilatasyon işlemi [93]

2. **Erozyon:** Nesnenin kenarlarını aşamalı olarak küçültme işlemidir. Böylece, **Şekil 2.27**'de görülen şekilde görüntüdeki nesne boyutu azalacak ve bu objelerin arasındaki delikler artacaktır. İkili görüntünün erozyonu aşağıdaki şekilde tanımlanmıştır:

$$A \ominus B = \{ p \mid p + b \in A \forall b \in B \} \quad (2.35)$$

$$A \ominus B = \bigcap_{b \in B} A_{-b} \quad (2.36)$$

A, ikili görüntü, B çıkarma elemanı matrisidir. $A \ominus B$ negatif çevirmelerin kesişmesine eşdeğerdir. $-b$, -1 ile çarpılan b vektörüdür [92].




Şekil 2.27: 3x3 yapısal eleman matrisi kullanılarak etkili bir erozyon işlemi [93]

3. **Açma:** Şekil 2.28’de görüldüğü gibi görüntüde nesne konturunu pürüzsüzleştirme ve nesnenin keskin uçlarını ve küçük adalarını ortadan kaldırma işlemidir. Temel olarak dilatasyon ve erozyon işlemlerinden türemiştir. Aşağıda ayrıntıları verilen şekilde her iki işlem için aynı yapısal eleman kullanılarak dilatasyondan önce yapılan bir erozyon işlemi olarak tanımlanmaktadır [92] [93]:

$$A \circ B = (A \ominus B) \oplus B \quad (2.37)$$

A, ikili görüntü, B, 3×3 yapısal eleman matrisidir.




Şekil 2.28: 3x3 yapısal eleman matrisi kullanılarak yapılan etkili bir açma işlemi [93]

4. **Kapama:** açma işleminin tam tersi işleve sahiptir. Şekil 2.29’da üzere nesne konturunu pürüzsüzleştirmek ve konturun üzerinde bulunan boşlukları doldurmak için kullanılır. Aşağıda ayrıntıları verilen şekilde her iki işlem için aynı yapısal eleman kullanılarak erozyondan önce yapılan bir dilatasyon işlemi olarak tanımlanmaktadır [92, 93]:

$$A \bullet B = (A \oplus B) \ominus B \quad (2.38)$$

A, ikili görüntü ve B, 3×3 yapısal eleman matrisidir.



Şekil 2.29: 3x3 yapısal eleman matrisi kullanılarak yapılan etkili bir kapama işlemi [93]

2.4.5.2 Görüntü İnterpolasyonu

İnterpolasyon, yakınlaştırma/uzaklaştırma, küçültme, döndürme ve geometrik düzeltme gibi fonksiyonlarda geniş ölçüde kullanılan bir araçtır. Temel olarak örnek adı verilen birtakım bilinen veriler arasında yatan pozisyonda yeni verileri tahmin etme işlemidir. Çoğaltma kalitesi ile işlemsel karmaşıklık arasındaki farklı değişimlerden çeşitli görüntü interpolasyon teknikleri

geliştirilmiştir. En sık kullanılan teknikler en yakın komşu, bilineer ve bikübik yöntemlerdir. Bu iki yöntemin kısa bir şekilde sonraki iki kısımda açıklanmıştır.

2.4.5.2.1 En Yakın Komşu Yöntemi

Bu yöntem, görüntü yeniden ölçeklendirme tekniklerinin en basit interpolasyon yöntemidir. Hesaplama karmaşıklığı bakımından en verimli yöntemdir ancak, çözünürlük kalitesi bakımından en zayıf olanıdır. Bu interpolasyonu yöntemi türü genellikle resimleri hem yakınlaştırma/uzaklaştırma hem de küçültmeye yönelik yetersiz kalabilmektedir. En yakın komşu fonksiyonu [94]:

$$v(i) = \begin{cases} 0 & |i| > 0.5 \\ 1 & |i| < 0.5 \end{cases} \quad (2.39)$$

i , interpolate olan nokta ile nokta ızgarası arasındaki mesafedir.

2.4.5.2.2 Bilineer İnterpolasyon Yöntemi

Bu yöntem önceki yönteme benzerdir, ancak iki değeri yerine dört komşu pikselin ağırlıklı ortalamasını kullanan son değeri hesaplamak için kullanılan piksel sayısında küçük bir fark bulunmaktadır. Bu yöntem, en yakın komşu yönteminden daha iyi sonuçlar vermektedir çünkü hem yatay hem de dikey olmak üzere her iki yöne uygulanmaktadır. En yakın komşu yönteminin fonksiyonu [94]:

$$v(i) = \begin{cases} 0 & |i| > 1 \\ 1 - |i| & |i| < 0.5 \end{cases} \quad (2.40)$$

i , interpolate olan nokta ile ızgara noktasının arasındaki alandır.

2.4.5.2.3 Bikübik İnterpolasyon Yöntemi

Kübik evrişim yöntemi bilineer yöntemle neredeyse benzerdir ancak daha büyük bir alan ağırlığına sahiptir. Bu nedenle, en yakın 16 hücre merkezine bakar ve gri seviye değerini, çıkış koordinatlarıyla ortaya çıkan 16 pikselin ağırlıklı ortalamasından belirler. Önceki iki yöntemden biraz daha keskin bir etkiye sahip olma eğilimindedir ve çözünürlük kalitesi bakımından en verimli yöntemdir. Ancak, hesaplamalar açısından nispeten pahalıdır. Kübik evrişim fonksiyonu [94]:

$$v(i) = \begin{cases} \frac{3}{2}|i|^3 - \frac{5}{2}|i|^2 + 1 & 0 \leq |i| < 1 \\ -\frac{1}{2}|i|^3 - \frac{5}{2}|i|^2 - 4|i| + 2 & 1 \leq |i| < 2 \\ 0 & 2 < |i| \end{cases} \quad (2.41)$$

i , interpolate olan nokta ile ızgara noktası arasındaki mesafedir.

2.4.5.3 Kenar bulma

Kenar, bir görüntüde iki farklı alan arasındaki sınırda gerçekleşmiş olan ani yoğunluk değişiklikleridir. Eğriler, köşeler ve çizgiler gibi tanımlayıcı özelliklerden oluşmaktadır ve görüntü işleme açısından önemli bilgiler içermektedir. Kenar bulma işlemi görüntü analizinde önemli bir nitelik olarak kullanılmak üzere görüntü üzerindeki kenarlarının tespiti ve özelliklerinin anlaşılması işlemidir. Görüntü üzerinde kenarların düzgün elde edilebilmesi için dört işlemin yapılması gerekmektedir:

Gürültü Azaltma; gürültüler, kenarların gerçek bilgilerini kaybetmeden mümkün olduğunca filtrelendir.

Keskinleştirme; iyileştirme filtresi uygulanır.

Tespit; hangi kenar piksellerinin kalması ve hangilerinin gürültü olarak silinmesi gerektiğini tespit etmek amacıyla eşikleme filtresi kullanılır.

Lokalizasyon; bir kenarın kesin bölgesi tespit edilir.

Görüntü bölütleme’de kullanılan bir çok kenar bulma filtresi (süzgeç) bulunmaktadır. Bunlardan, Sobel filtresi, Prewitt filtresi ve Canny filtresi en yaygın kullanılan yöntemler arasındadır.

2.4.5.3.1 Sobel Filtresi

Sobel kenar bulma yöntemi, 1970 yılında Sobel tarafından geliştirilmiştir. Bir görüntünün türevine yönelik bir yaklaşımdır [95]. Görüntü üzerinde türevlerin hesaplanması İki eksen olan x ve y için ayrı 3×3 lük çekirdek matrislerinin (kernel matrix) evrişimi(konvolüsyon) ile olmaktadır . x ekseninde görüntünün gradyanı evrişimi için çekirdek matrisi denklem 2.42’te

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (2.42)$$

y ekseninde gradyanı bulmak için çekirdek matrisi denklem 2.43'te verilmiştir.

$$G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (2.43)$$

2.4.5.3.2 Canny Filtresi

Canny Kenar Bulma algoritması 1986 yılında John Canny tarafından sunulmuştur. Bilgisayarla görme alanında en yaygın kullanılan kenar bulma filtresidir [95].

Algoritma, dört ana adımdan oluşmaktadır:

1. Gürültüsüz bir görüntü elde etmek için görüntüyü hem yatay hem de dikey olacak şekilde her iki yön için Gauss filtresine tabi tutulur.

$$f_x = \frac{\partial}{\partial x} (f * G) = f * \frac{\partial}{\partial x} G = f * G_x \quad (2.44)$$

$$f_y = \frac{\partial}{\partial y} (f * G) = f * \frac{\partial}{\partial y} G = f * G_y \quad (2.45)$$

$G(x,y)$, Gauss fonksiyonu, f_x ve f_y yatay ve dikey kenar maskesinden sonuçlar, $G_x(x,y)$, $G(x,y)$ türevi; x : $G_x(x,y) = \frac{-x}{\sigma^2} G(x,y)$, ve $G_y(x,y)$, $G(x,y)$ türevi ve y : $G_y(x,y) = \frac{-y}{\sigma^2} G(x,y)$.

2. Görüntünün eğim yoğunlu için büyüklük ve kenar yönü matrislerinin hesaplanması:

$$\text{büyüklük } (i,j) = \sqrt{f_x^2 + f_y^2} \quad (2.46)$$

$$\text{KENAR YÖNÜ} = \tan^{-1} \left[\frac{f_x}{f_y} \right] \quad (2.47)$$

3. Doğru kenar noktalarını bulmak için maksimum bastırma (en büyük olmayanı bastırma) uygulanır. Bu, örneğin filtre olarak 3 x 3 için küçük bir matris tasarlanarak yapılmaktadır ve o filtrenin gradyan yönündeki komşusunun merkez değeri ile karşılaştırılarak büyüklük değeri görüntü matrisine uygulanır. Merkez değer gradyan yönüyle birlikte bitişik piksel değerlerinden düşükse merkez değeri baskılanır. Aksi takdirde sonuç, **Şekil 2.30**'da gösterildiği üzere değişiklik olmaksızın aynı değer olacaktır. Maksimum olmayan baskı algoritması Algoritma 2.1 de verilmiştir:

Algoritma (2. 1): Maksimum Bastırma

Girdi: KENAR YÖNÜ dizisi

Çıktı: Maksimum Bastırma matrisi, M_{NMS}


Başla

1.Adım: Her bir piksel için (x,y) :

İf $\text{büyüklük}(i, j) < \text{büyüklük}(i_1, j_1)$ veya $\text{büyüklük}(i, j) < \text{büyüklük}(i_2, j_2)$
 then $I_N(i, j) = 0$
 else $I_N(i, j) = \text{büyüklük}(i, j)$

2.Adım: Return M_{NMS}

Bitir



Şekil 2.30: Maksimum olmayan baskı süreci

4. Gürültü maksimumunu konturları bozmadan yok etmek için T_{high} ve T_{low} şeklinde iki eşik kullanan GecikmeEşiklemesi (hysteresis thresholding) uygulanır.

$$\text{Piksel } (x, y) \begin{cases} \text{güçlü} & M_{NMS}(x, y) > T_{high} \text{ ise} \\ \text{zayıf} & M_{NMS}(x, y) \leq T_{low} \text{ ise} \\ \text{aday piksel} & \text{tüm diğer pikseller için} \end{cases} \quad (2.48)$$

Algoritma (2.2): Gecikme Eşığı

Girdi: Maksimum olmayan baskı matrisi, M_{NMS}

Çıktı: Hysterezis Eşığı Matrisi, M_{HT}

Başla

Her bir (x, y) pozisyonu için:

Adım1: Piksel (x, y) güçlüyse mevcut pikseli çıktı olarak alın; değilse mevcut piksel zayıftır ve onu atın.

Adım2: Piksel (x, y) adaysa

$M_{NMS} > T_{low}$ olduğu sürece kenar boyunca her iki yönde bağlı lokal maksimum serisini izleyin.

Adım3: Başlangıç aday pikseli (x, y) güçlü bir pikselle ilişkiliyse bu aday pikselini çıktı olarak alın; değilse aday pikseli atın.

Bitir

2.5 GÖRÜNTÜ İÇ BOYAMA

Görüntü iç boyama (impainting) eksik bölgelerin çevreleyen görüntü piksellerini kullanarak doldurma işlemidir. Tıbbi görüntü restorasyonu gibi görüntünün yeniden yapılandırmasının gerektiği her alanda kullanılmaktadır. Deri görüntülerinde bulunan saç veya diğer gürültüleri içeren bölgelerin orjinaline en yakın şekilde doldurmak amacıyla kullanılmaktadır. Görüntü iç boyamada en yaygın kullanılan algoritma olan Hızlı Yürüme Yöntemine dayalı (fast marching) görüntü iç boyama tekniğidir. Bu algoritmada içboyma kenardan başlayarak maske görüntüsünün seçtiği boşlukları adım adım doldurarak bölgenin içine gitmektedir. [96].

2.6 PERFORMANS ÖLÇÜTLERİ

Dermoskopik görüntü bölütleme yöntemlerinin değerlendirme performansı, görüntünün kesin referansının (ground truth) kullanılması kavramına bağlıdır. Kesin referans, uzmanlar tarafından elde edilen orijinal görüntü için bir maske olarak tanımlanmaktadır. Performans ölçütleri kesin referans görüntüsü ile bölütlenen görüntü çıktısı arasındaki ilişkidir. Doğruluk, Hassasiyet, Hassasiyet ve Özgülük gibi karışıklık matrisinin kullanımına dayanarak elde edilen bölütleme görüntüsünü ve kesin referans görüntüsünü karşılaştırmak için standart ölçüm kullanımlarına bağlı çeşitli ölçüm türleri mevcuttur. Jaccard İndeksi ve Dice Ölçütü benzerlik ölçümleri altında kategorize edilmektedir [97].

Karışıklık matrisi, “kesin referans” kriterini ve bölütleme modelinin çıktısını göstererek sınıflandırma modelinin performansını etiketlemek için tasarlanmış bir tablodur. Karışıklık matrisi, ikili sınıflandırma için aşağıdaki gibidir **Şekil 2.31**:

		Bölütleme çıktısı	
		Positive Pozitif	Negative Negatif
gerçek referans değer	Positive Pozitif	TP	FN
	Negative Negatif	FP	TN

Şekil 2.31: Karışıklık Matrisi [97]

Karışıklık matrisi faktörleri:

- **Doğru Pozitifler (TP):** pozitif sınıfa ait olan ve pozitif sınıfa doğru bir şekilde dahil edilen piksellerdir.
- **Doğru Negatifler (TN):** negatif sınıfa ait olan ve negatif sınıfa doğru bir şekilde dahil edilen piksellerdir.

- **Yanlış Pozitifler (FP):** negatif sınıfa ait olan ve pozitif sınıfa yanlış bir şekilde dahil edilen piksellerdir.
- **Yanlış Negatifler (FN):** pozitif sınıfa ait olan ve negatif sınıfa yanlış bir şekilde dahil edilen piksellerdir.

Aşağıda, bölütleme alanında daha yaygın olan yukarıda belirtilen altı ölçü türünün kısa bir açıklaması verilmiştir:

1. **Doğruluk (Accuracy)**, aşağıdaki formülle hesaplanabilir:

$$\text{Doğruluk} = \frac{\text{Doğru Sınıflandırılmış Puanlar}}{\text{Toplam Puan Sayısı}} \quad (2.49)$$

$$\text{Doğruluk} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (2.50)$$

2. **Hassasiyet (Precision)**, modelin, aşağıdaki formülle hesaplanabilen pozitif oranıdır:

$$\text{Hassasiyet} = \frac{TP}{\text{toplam pozitif çıktı sayısı}} \quad (2.51)$$

$$\text{Hassasiyet} = \frac{TP}{(TP + FN)} \quad (2.52)$$

3. **Özgünlük**, modelin, aşağıdaki formülle hesaplanabilen negatif oranıdır:

$$\text{Özgünlük} = \frac{TN}{\text{Toplam negatif öge sayısı}} \quad (2.53)$$

$$\text{Özgünlük} = \frac{TN}{(TN + FP)} \quad (2.54)$$

4. **Kesinlik (Recall)**, tahmin evet ise tahmin edilen sonucun ne kadar sıklıkla doğru olduğunu öğrenmek için kullanılır. Aşağıdaki formülle hesaplanabilir:

$$\text{Kesinlik} = \frac{TP}{\text{Tahminen evet}} \quad (2.55)$$

$$\text{Tahmin} = \frac{TP}{(TP + FP)} \quad (2.56)$$

5. **Jaccard İndeksi**, tahmin edilen görüntü ve kesin referans görüntüsü olarak iki görüntü seti arasındaki benzerliği ve farklılığı hesaplamak için kullanılır. Aşağıdaki formül kullanılarak hesaplanır:

$$\text{Jaccard indeksi } (A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2.57)$$

6. **Dice Ölçütü**, jaccard indeksi ölçümüne benzerdir. Ayrıca, bölütleme model performansını değerlendirmek için kullanılır. Aşağıdaki formül kullanılarak hesaplanır:

$$\text{Dice ölçütü } (A, B) = \frac{2 * |A \cap B|}{|A| + |B|} \quad (2.58)$$

2.7 GRAFİK İŞLEME BİRİMİ (GPU)

GPU bir grafik işlemci birimidir. GPU ayrıca görsel işlemci birimi VPU olarak da adlandırılır. İşleme süresini hızlandırmak ve ekranda çıktı için planlanan görüntü formasyonuna hız vermek için hafızayı değiştirmek üzere oluşturulmuş elektronik bir devredir.

GPU, paralel işlemeye yönelik olarak tasarlanmış binlerce çekirdeğe sahiptir. Böylece, paralel mimari, **GPU**'yu derin öğrenme eğitimi son derece uygun hale getirmiştir [98, 99].

2.8 KERAS KÜTÜPHANESİ

Keras, üst düzey bir sinir ağı Uygulama Programlama Arabirimidir (**API**). İlk sürümü 2015 yılında piyasaya sürülmüş daha sonra 2018’de sabit bir yayınlanma tarihi olacak şekilde güncellenmiştir ve araştırma ve geliştirme için mümkün olduğunca hızlı ve kolay bir şekilde derin öğrenim modelleri gerçekleştirmek üzere oluşturulmuştur. CPU’ları ve **GPU**’ları sorunsuz bir şekilde uygulayabilmektedir. Python programlama dilinde yazılmış bir kütüphane olduğu için tüm başlıca işletim sistemlerine çalışabilir. Programcıların, TENSORFLOW, CNTK ve THEANO da dahil olmak üzere makine öğrenimesi fonksiyon kütüphanelerine erişim sağlayabilmelerine ve bunları kişiselleştirebilmelerine olanak sağlar [100, 101].



3. MALZEME VE YÖNTEM

3.1 GİRİŞ

Otomatik Teşhis Sistemi, en önemli sistemlerden biridir ve tıp alanındaki teşhislerde, özellikle lezyon teşhisinde yaygın olarak kullanılmaktadır. Cilt kanserinde erken teşhis yöntemleri, hasta tarafından teşhis sisteminde yetersiz kalmaktaydı çünkü özel bir cihaz ve kendi kendine teşhis uygulaması mevcut değildi. Bu nedenle bu bölümde, lezyonun sınırlarını doğru bir biçimde seçerek hastanın kendi kendine teşhis koyabileceği bir sistemin uygulamasını geliştirmek amacıyla bir sistem önerisi sunulmaktadır.

Sonuçları önemli ölçüde etkilediği için dermoskopi görüntülerinde lezyon bölgesinin doğru bölütlenmesi, özellikleri özütleme ve lezyonun sınıflandırılması gibi sonraki aşamaların performansını artırmak için önemlidir. Sonuç olarak melanom hastalığının erken teşhisinde hayati rol oynamaktadır. Bölümleme aşaması iki temel nedenden ötürü zorlu bir iştir: İlk olarak görüntü üzerinde bulunan cetvel işaretleri, ışık yansıması, hava kabarcıkları ve kıllar gibi istenmeyen yapıların varlığıdır. İkinci olarak ise farklı cilt tipleri ve lezyonun rengi, dokusu ve şekli gibi faktörlerdir. Yukarıda belirtilen her iki neden de sistemin doğruluğunu olumsuz yönde etkilemektedir.

Bu tezde, yapay olguları ortadan kaldırmak ve tanı performansını arttırmak için yöntem sunulmaktadır. Ayrıca lezyon bölümleme süreci için otomatik sistem geliştirme girişiminde de bulunulmuştur. Önerilen sistem, takip eden bölümlerde açıklanmaktadır.

3.2 ISIC (ULUSLARARASI DERİ GÖRÜNTÜLEME İŞ BİRLİĞİ)

ÇALIŞMASI 2018 VERİ KÜMESİ


Uluslararası Deri Görüntüleme İş Birliği (ISIC) dermoskopi görüntü veri kümesi [102], 2016 yılındaki deri lezyonu analizi hakkındaki ilk değerlendirme çalışmasının temelini oluşturmaktadır.

ISIC çalışması 2018 veri kümesi, önceki çalışmalarda standart olarak kullanılan bu çalışmanın veri kümesi olarak seçilmiştir. Bu veri kümesi, bölütleme çalışması için kullanılabilen 2594 eşdeğer kesin referans yanıt maskeleri ile 2594 eğitim görüntüsünden, ilk

çevrim içi (online) öz değerlendirme için 100 validasyon (doğrulama) görüntünden ve çeşitli araştırma setlerinin nihai performans derecesi için kullanılan 1000 test görüntünden meydana gelmektedir [87]. ISIC görüntü verisi, en iyi uluslararası klinik merkezlerinden toplanmıştır ve her bir merkezdeki aletlerin tasnifinden elde edilmiştir. Elde edilen görüntüler, JPEG formatında 100x100 ila 1000x1000 piksel arasında değişen farklı boyutlu çözünürlüklere sahiptir [103].

3.3 ÖNERİLEN SİSTEM


Önerilen sistem iki ana aşamaya ayrılmıştır: dermoskopi görüntüsünü ön işleme ve bölütleme. Ön işleme; cetvel işaretleri, ışık yansıması, hava kabarcıkları ve kılların tespit edilip yok edilmesinden meydana gelmektedir. Bölütleme aşaması ise otomatik bölütleme süreci oluşturabilmek amacıyla U-Net derin öğrenme yaklaşımının uygulanmasından meydana gelmektedir. Önerilen CAD sistemi, aşağıdaki **Şekil 3.1**'de açık bir biçimde açıklanmaktadır.



Şekil 3.1: Genel Blok Diyagram

3.3.1 Görüntü Ön İşleme

Ön işleme, dermoskopi görüntülerindeki istenmeyen yapılar ve gürültü sayısını azaltmak amacıyla tıbbi görüntü analizinde kullanılan önemli bir adımdır. Ön işleme aşaması; Kenar tanıma, Yapay Olgular Maskesinin Oluşturulması, Renk İmaj Restorasyonu ve Veri setinin hazırlanması adımlarından meydana gelmektedir. Bu aşamanın amacı, renkli dermoskopik görüntüleri sisteme girmek ve belirli özelliklerin etkili biçimde ayırt edilebildiği bir görüntü ortaya çıkarmaktır. Ön işleme aşaması, **Şekil 3.2**'de görülebildiği üzere yedi adıma ayrılmaktadır.



Şekil 3.2: Dermoskopi görüntüleri yeniden işleme adımları

3.1.1.1 Gri renk modeline renk dönüşüm

Gri renk modelinde pikseller, siyahtan beyaza 256 olası farklı gri ton veren 8-bit tamsayı dizisi biçiminde saklanır. Renkli görüntünün gri ölçeğe dönüştürülmesi, sonraki aşamalarda hesaplama gereksinimlerinin azalmasını sağlamak amacıyla yapılmaktadır. Dönüştürme amacıyla Algoritma (3.1) kullanılır. **Şekil 3.3**'te bu işlemin sonucuna ait bir görüntü verilmiştir.

Algoritma (3.1): Renk Dönüştürme.

Girdi: Orijinal Görüntü (originalImage)

Çıktı: Gri Ölçekli Dermoskopi İmajı (grayImage)

Başlangıç

Adım1: Orijinal görüntüdeki her bir piksel için:

Mevcut pikselin R, G ve B kanallarının değerini getir.


Denklemleri uygula (2.27).

Adım2: Return gri ölçekli görüntü

Bitir



(a) Orijinal görüntü



(b) Gri Ölçekli görüntü

Şekil 3.3: Renk Dönüştürme

3.1.1.2 Gauss Bulanıklaştırma Filtresinin Uygulanması (Yumuşatma)

Dermoskopi görüntüsündeki gürültüyü azaltmak için Algoritma (3.2) kullanılmıştır. Şekil 3.4 Gauss bulanıklaştırmasına ait bir örnek görülmektedir.

Algoritma (3.2): Gauss Bulanıklaştırması ile görüntün yumuşatılması

Girdi: Gri Ölçekli Dermoskopi İmajı (grayImage), 5×5 çekirdek

Çıktı: Gauss blörlü görüntü (gaussBlurImage)


Başlangıç

İmaj Sıradaki her bir piksel için


İmaj Sütundaki her bir piksel için

Step1: (Gauss Blörlü görüntüyü) oluşturmak için Algoritmanın çıktısı ile (3.1) (gri görüntü) 5×5 Gauss çekirdeğini evriştir

Bitiş



(a) Gri ölçekli görüntü



(b) Gauss ile yumuşatılmış görüntü

Şekil 3.4: Gauss ile yumuşatılmış görüntü

3.1.1.3 Kenar tanıma İşlemi

Kenar tanıma, görüntü analizinde temel öge olarak kullanılacak görüntüdeki kenarları belirleme ve özelliklerini anlama sürecidir. Kılırları saptamak için dermoskopi görüntüsünde kenar algılama yöntemi olarak iki teknik kullanılmıştır ve bunlar Canny ve Sobel'dir. Kanton, ince tüylerin kenarlarını tespit etmeyi sağlarken (bkz. Şekil 3.5), sobel filtresi, farklı yönelimlerdeki saçların daha ince ve uzun yapısını tespit etmek için kullanılır (bkz. Şekil 3.6). Canny filtreleme yönteminin sonucu, sobel filtrelemenin **Şekil 3.7**'de gösterilen sonucundan elde edilmektedir. Sonuçta ortaya çıkan maskeli görüntüdeki kenarların parlaklığını ve kontrastını arttırmak için algoritma (3.5) kullanılmaktadır. **Şekil 3.8**'de yapılmış olan kenar tanıma işlemine ait sonuçlar görülmektedir.

Algoritma (3.3): Canny Algoritması ile Kenar Tanımanın Elde Edilmesi

Girdi: Yumuşatılmış Dermoskopi İmajı (Yumuşak İmaj)

Çıktı: Canny Sonucu Matrisi (M_{canny})

Başlangıç

Canny algoritmasının uygulanması dört adımdan oluşmaktadır:

Yumuşak İmajdaki her bir piksel için:


Adım1: Yumuşak görüntü elde etmek için Denklem (2.43) ve (2.44) uygulanır.

Adım2: Büyüklük ve kenar yönelim matrisleri, Denklem (2.45) ve (2.46) uygulanarak hesaplanır.

Adım3: Kenar noktalarını bulmak için **Algoritma (2. 1)** uygulanır.

Adım4: Konturları bozmadan maksimum gürültü ortadan kaldırmak için **Algoritma (2.2)** uygulanır.

Bitiş



Şekil 3.5: Canny ile Kenar Tanıma

Algoritma (3.4): Sobel Algoritması ile Kenar Tanımanın Özütlenmesi

Girdi: Yumuşatılmış Dermoskopi İmajı (Yumuşak İmaj)

Çıktı: Sobel Sonucu Matrisi ($M_{x \text{ and } y}$)


Başlangıç

Adım1: Girdi görüntü (Yumuşak İmaj) ile görüntünün gradyanı x yönünde, Denklemden (2.41) gösterilen şekilde evriştirilir.

Adım2: Girdi görüntü (Yumuşak İmaj) ile görüntünün gradyanı y yönünde, Denklemden (2.42) gösterilen şekilde evriştirilir.


Adım3: Her iki yön için kenar tanıma sonucunu elde etmek için Adım1, Adım 2'ye eklenir.

Bitir



Şekil 3.6: Sobel ile Kenar Tanıma

Algoritma (3.3), Algoritmadan (3.4) çıkartılarak Şekil 3'te gösterildiği gibi daha doğru kenarlar elde edilmektedir.



Şekil 3.7: Çıkartılmış İmaj

Algoritma (3.5): Parlaklık ve Kontrast Ayarlama

Girdi: Çıkartılan görüntünün sonucu (Çıkartılan İmaj), parlaklık değeri = 64, kontrast = 64

Çıktı: Çıkartılan görüntünün Parlaklığının ve Kontrastının artırılması (Parlaklık ve Kontrast Ayarı)

Başlangıç

Adım1: if parlaklık $\neq 0$ then

parlaklık > 0 daha then

gölge = parlaklık

vurgulama = 255

else gölge = 0, ve vurgulama = 255 + parlaklık

alfa = (vurgulama - gölge)/255

gama = gölge

Parlaklık ve Kontrast Ayarı = girdi görüntünün ağırlıklı toplamı alfa ile, girdi görüntüsü gama ile hesaplanır

İf parlaklık = 0

girdi görüntüsü değiştirmez

Adım2: if kontrast $\neq 0$


alfa = $131 * (\text{kontrast} + 127) / (127 * (131 - \text{kontrast}))$

gama = $127 * (1 - \text{alfa})$

Parlaklık ve Kontrast Ayarı = girdi görüntünün ağırlıklı toplamı alfa ile, girdi görüntüsü gama ile hesaplanır

Adım3: Return Parlaklık ve Kontrast Ayarı

Bitiş




(a) Çıkartılan İmaj

(b) Parlaklık ve Kontrast Ayarı

Şekil 3.8: Parlaklık ve Kontrast Ayarı

3.1.1.4 Maske Oluşturma


Yoğunluklu görüntüyü ikili görüntüye dönüştürmek için küresel görüntü eşikleme yöntemi kullanılmaktadır. Bu yöntem, görüntü yoğunluğunu $[0, 1]$ aralığında normalleştirmektedir. İkili görüntü (bkz. Şekil 3.9-b) saçların ana hatlarını içermektedir. Ana hatları doldurmak ve en üst seviye maske sonucunu elde etmek için genişletme (dilasyon) işlemi 11×11 kernel ile kullanılmaktadır. Oluşturulmuş maskenin nihai sonucu Şekil 3.10'da gösterilmektedir.



(a) Parlaklık ayarı

(b) İkili İmaj (Eşikleme)


Şekil 3.9: Kıl Tanıma



Şekil 3.10: Maske Oluşturma

3.1.1.5 Görüntü Onarımı

Çoğu iç boyama tekniği aşağıda gösterilen biçimde işlemektedir. Öncelikle görüntünün iç boyama yapılacak bölümü seçilir. Daha sonra çevresel bilinen görüntü verileri kullanılarak eksik bölgeler doldurulur. Hızlı İlerleme Yönteminin sonucu Şekil 3.11’de gösterilmektedir.



Şekil 3.11: Görüntü Onarımı

3.1.1.6 Veri Kümesinin Hazırlanması

Bölütleme tekniklerini kullanmak için dermoskopi görüntülerinin üzerinde son bir ön işlem yapmak önemlidir. Bu son işlemlerde iki aşamalı olacak şekilde veri indirgemesi teknikleri uygulanmaktadır. Bunlar bir önceki aşamada onarılmış olan renk uzayındaki görüntü gri renk uzayına dönüştürülür ve tüm görüntüler standart bir boyuta getirilir.

1. Renkli görüntülerin gri renk uzayına dönüştürülmesi

Renkli görüntüden gri renk uzayına dönüştürme, daha sonraki aşamalarda daha az hesaplama yapılmasını ve modelin hızlanmasını sağlamaktadır. Dönüştürme amacıyla Algoritma (3.1) kullanılır.


2. Görüntülerin yeniden boyutlandırılması

ISIC 2018 veri kümesi makine öğrenmesinde X veri kümesi olarak adlandırılan dermoskopik görüntüler ve etiket yada yer referansı olarak adlandırılan Y veri kümesinden oluşmaktadır. Bu görüntülerin standart çözünürlüğe sahip olmamasından dolayı boyutlandırma yapma gereksinimi bulunmaktadır. Boyutlandırma için mümkün olan yüksek çözünürlük alınması tavsiye edilmekle birlikte çözünürlüğün artışı hesaplama işlemine yük getirmesinden dolayı optimum değer seçilir. Bu çalışmada bu iki veri kümesi 448x448 piksellik bir çözünürlüğe getirilmiştir. X veri kümesi için denklem (2.39) da tanımlanan bilinmeyen interpolasyon kullanırken sadece ikili değerlerden Y için denklem (2.40)'da tanımlanan en yakın komşu ara değerlendirme kullanılmıştır.

3.1.1.7 Deri Lezyon Bölütleme Sistemine Genel Bakış

Şekil 3.12, ön işleme verilerinin çıktısını kapsayan deri lezyon bölütlemesi için önerilen sistemin genel bir görünümünü göstermektedir: Veri Kümesinde varyansı azaltmak ve önerilen modelin genele uyması ve daha az aşırı uyum problemine karşılaşmasını amacıyla öncelikle veri karıştırılarak parçalara ayrılmaktadır. Daha iyi bir genelleme sağlayabilmek ve aşırı uyumdan kaçınmak amacıyla veri kümesi %70 Eğitim ve %30 değerlendirme kümesi olmak üzere iki alt kümeye bölünmüştür. Veri normalize edikten sonra, tahmini maske oluşturmak

için öğrenme algoritmasına girdi olarak kullanılmakta ve daha sonra, önerilen modeli değerlendirmek için temel ölçüt verisiyle karşılaştırılmaktadır.



Şekil 3.12: Deri lezyon bölütleme sistemi

3.1.1.8 Veri Normalleştirme

Normalleştirme, yapay sinir ağındaki taraflılığı en aza indirmek için aynı değer aralığındaki veriyi dengelemek amacıyla girdi verisini yeniden ölçeklendirmeyi amaçlayan ve yaygın olarak kullanılan bir ön işleme adıdır. Önerilen ön işleme adımı, aşağıda gösterilen biçimde iki tip normalleştirme algoritması kullanılmıştır. Görüntüleri normalleştirmek için Algoritma (3.6) ve maskeli görüntüler için Algoritma (3.7) kullanılmıştır.

Algoritma (3.6): Normalleştirilmiş X Verisi**Girdi:** X Girdi Verisi**Çıktı:** Normalleştirilmiş X Girdi Verisi**Başlangıç****Step1:** Veri tipi dönüştürülür (uint8'den float 32'ye)


1.1 Denklem uygulanarak tüm X verisi için ortalama hesaplanır (2.12)

Step2: Denklem kullanılarak belirlenmiş eksen boyunca standart sapma hesaplanır (2.14)**Step3:** Normalleştirilmiş X Girdi Verisi $\leftarrow$ Denklem Uygulanır (2.13)**Step4:** Normalleştirilmiş X Girdi Verisi $\leftarrow$ Denklem Uygulanır (2.15)**Bitiş****Algoritma (3.7): Normalleştirilmiş Y Verisi****Girdi:** Y Girdi Verisi**Çıktı:** Normalleştirilmiş Y Girdi Verisi**Başlangıç****Step1:** Y veri tipi dönüştürülür (uint8'den float 32'ye)**Step2:** Normalleştirilmiş Y Girdi Verisi $\leftarrow$ (Y Girdi Verisi / 255,0)**Bitiş****3.1.1.9 U-Net tekniğinin geliştirilmesi**

Derin U-Net mimarisi, görüntü bölümlendirme çalışmalarında kullanılan yapılardan biridir.. Bu çalışmada lezyon bölümlendirme için U-Net mimarinin geliştirilmesi önerilmektedir. Önerilen teknikte, modelin yapısını oluşturmak amacıyla CNN notasyonları kullanılmaktadır. Önerilen ve **Şekil 3.13**'te sunulan mimari, iki adıma ayrılmış olan 45 katmandan meydana gelmektedir

bunlar Daralma – Kodlama yönü (Contraction path) ve Genişleme - kod çözme (Expansion path); tekrarlı konvolüsyonlar, aktivasyon işlevleri, aşağıya örnekleme ve yukarıya örnekleme işlemcisi şeklindedir. Kodlama yönü 6 bloktan meydana gelmektedir: her blok 3 katman içermektedir, iki desteksiz 3x3 konvolüsyon katmanı, her birini elu aktivasyon işlevi takip etmektedir ve daha sonra 2x2 maks birleştirme katmanı, aşağı örneklendirme için kullanılır. Her bir Kod çözme yönü 6 bloktan meydana gelip her bir blok 4 katman içerirken, 2x2 yukarı örneklendirme katmanı eklenir, özellik kanallarının sayısı ikiye indirilir ve daha sonra, zincirleme katman adı verilen uygun kodlama katmanı ile birleştirilir. Son iki katmanda desteklenmeyen 3x3 konvolüsyon katmanı eklenir. Her bir konvolüsyon katmanını, “elu” aktivasyon işlevi takip eder. Sonunda belirlenmiş pikselin deri lezyonuna ait olduğu değeri tahmin etmek için 1x1 konvolüsyon katmanı kullanılır.

Tahmini ve kesin referans arasında dice_coef_loss (ufak parçalara ayırma, katsayı, kayıp) kullanılır. İletişim ağı eğitimi için öğrenme oranı 0,045; rho=0,9 (derece-sıra korelasyonu) ve epsilon 1,0 ile RMSprop iyileştirici kullanılmaktadır.



Şekil 3.13: U-net Mimarisi

4. BULGULAR

4.1 GİRİŞ

Bu bölümde, dermoskopi görüntülerinin otomatik bölütlemesi için önerilen sistemin sonuçları sunulmaktadır. Önerilen sistemde, iki numune grubunun karışımı kullanılmaktadır. İlk grupta, ön işlemenin, detayları bölüm 4.3.1’de verilen dermoskopi görüntüsü üzerindeki etkileri gösterilmektedir. İkinci örnek grubu, önerilen modelin uygulanışını göstermek amacıyla 5 başarılı görüntüye ve 5 başarısız görüntüye ayrılmıştır ve bölüm 4.4’te gösterilmektedir.

4.2 ÖNERİLEN SİSTEMİN TEKNİK ÖZELLİKLERİ

Yüksek miktarda görüntü verisi, derin öğrenme mimarisinin uygulanışının uzun sürmesine neden olmaktadır. Bu nedenle donanım ve yazılımların seçimi , model eğitimi olabildiğince hızlandırmada önemli rol oynamaktadır. Bu seçimler GPU kapasitesi ve (Tensorflow veya Keras) gibi kütüphaneler veya çerçevelerle sınırlandırılabilir.

Bu tez kapsamında önerilen sistem, Windows 10’da yüklü olan jupyter dizüstü bilgisayar ortamında, Python 3.6.7 programlama dili üzerinden keras 2.2.4 çerçevesi kullanılarak uygulanmıştır. Kullanılan sistem olarak bir dizüstü bilgisayar olan MSI GE72MVR Apache Pro seçilmiştir ve aşağıdaki özelliklere sahiptir:

1. **CPU:** INTEL 7th Gen CORE i7-7700HQ 2.80 GHz.
2. **Grafik Kart (GPU):** NVIDIA GEFORCE GTX 1070.
3. **Video Hafızası:** 8GB GDDR5.
4. **Sistem Hafızası:** 16GB DDR4-2400MHz.
5. **Depolama:** 128GB M.2 PCIe SSD + 1TB HDD.
6. **İşletim Sistemi:** WIN10, 64-bit.

4.3 ÖNERİLEN SİSTEMİN UYGULAMA SONUÇLARI

Bu çalışmadaki tüm deneylerde, 2594 eğitim renkli dermoskopi görüntüsü bulunduran ISIC2018 veri kümesi [102] kullanılmıştır. Eğitim ve doğrulama için %70 eğitim veri kümesine ve %30 validasyon (doğrulama) kümesine ayrılmıştır. Bu veri kümesinde tüm veriler dermatologlar tarafından bölütlenmiş ve alanda temel ölçüt olarak kullanılmaktadır.

4.3.1 Ön işleme adım sonuçları

Bu çalışmada, deri lezyon belirleme için üç renk alanı karşılaştırılmıştır (HSI, RGB ve Gri ölçekli) ve sonuçlar, gri ölçekli renkli alanın, önerilen yöntem için daha uygun olduğunu göstermektedir. Aşağıdaki **Tablo 4.1**, önerilen bölütleme yöntemi uygulandıktan sonraki karşılaştırmanın sonuçlarını göstermektedir.

Tablo 4.1: Görüntü renk uzaylarına göre karşılaştırılması














Renk uzayı	Doğruluk	Dice	Jaccard	Duyarlılık	Özgüllük
HSI	0.7234	0.5123	0.7234	0.7639	0.8385
RGB	0.8936	0.8117	0.8936	0.9091	0.9783
Gri ölçek	0.9336	0.8571	0.9336	0.9158	0.9780

Dermoskopi görüntülerinde bulunan yapay olguların ve gürültülerin azaltılması için önerilen ön işleme yöntemi aşağıdaki adımlardan oluşmaktadır:

1. Görüntülerin Hazırlanması

Kıllar ve cetvel izleri maskesini oluşturmak için renkli görüntüler, Algoritma (3.1) uygulanarak gri ölçekli görüntüye dönüştürülmüştür. Sonuçlar **Şekil 4.1** ikinci sütunda gösterilmektedir.










İmaj iyileştirme süreci, minimum bilgi kaybıyla gürültüyü olabildiğince ortadan kaldırmaktan oluşur. **Şekil 4.1** üçüncü sütundaki sonuçları elde etmek için Yumuşatmak için Gauss Filtresi kullanılmıştır..


Görüntü No.	Orjinal Görüntü	Gri Görüntü	Gauss Filtresi
ISIC_0000218			
ISIC_0000219			
ISIC_0000264			
ISIC_0000355			
ISIC_0000439			
ISIC_0000498			
ISIC_0009935			
ISIC_0013086			
ISIC_0014393			
ISIC_0014457			

Şekil 4.1: Görüntü hazırlama adımı

2. Kenar tanıma

Önerilen ön işleme adımında kenar tanıma için Canny ve Sobel filtreleri kullanılmıştır. Kıllar ve cetvel izleri için en doğru kenarları tespit etmek amacıyla Canny kenar tanıma yöntemi kullanılmıştır. **Şekil 4.2**'deki ikinci sütun, kılların ve cetvel izlerinin kenarlarının gürültüsüz ancak aralıklı olduğunu göstermektedir. Tüm saç ve kıl yapılarını elde etmek Sobel filtre kullanılmıştır (**Şekil 4.2**'deki üçüncü sütuna bakınız). Dördüncü sütun, Sobel filtresinin, Canny filtresinden çıkarılmasıyla elde edilmektedir. Gürültünü bir kısmını saklamak ve kenarların parlaklığını vurgulamak için kontrast ve parlaklık Algoritma (3.5) kullanılmıştır. Sonuçlar beşinci sütunda gösterilmektedir.


Görüntü No.	Görüntü yapılarının iyileştirilmesi	Canny	Sobel	Sobel - Canny	Kenar Parlaklığı & Kontrast
ISIC_000218					
ISIC_000219					
ISIC_000264					
ISIC_000355					
ISIC_000439					




Şekil 4.2: Kenar tanıma

3. Yapıların Maskesinin Oluşturulması

İkili görüntü oluşturmak için küresel görüntü eşikleme yöntemi kullanılmıştır ve daha sonra kenarların ana hatlarını doldurmak için morfolojik genişletme uygulanmıştır. Şekil 4.3 ikinci ve üçüncü sütun, her iki süreci de sırasıyla göstermektedir.
















Şekil 4.3: Maske Oluşturma

4. İmaj Restorasyonu için İmaj iç boyama tekniğinin uygulanması

ISIC2018 veri setinden seçilmiş olan 10 farklı örnek için oluşturulmuş maske kullanılarak görüntü restorasyonu çıktı görüntüleri Şekil 4.4 üçüncü sütunda gösterilmiştir.,.

Görüntü No.	Orijinal Görüntü	Oluşturulmuş Maske	Görüntü Restorasyonu
ISIC_0000218			
ISIC_0000219			
ISIC_0000264			
ISIC_0000355			
ISIC_0000439			
ISIC_0000498			
ISIC_0009935			
ISIC_0013086			
ISIC_0014393			
ISIC_0014457			

Şekil 4.4: Ön işleme yönteminin, dermoskopi görüntüleri üzerindeki etkisi

4.1.1.1 Görüntü Bölütleme Süreci

Bu çalışmanın ikinci bölümünde çeşitli parametrelerle beş farklı U-Net katman yapısı tasarlanmıştır. Farklı U-Net yapısı kullanmanın amacı, dermoskopik görüntülerden doğru sınırı elde eden iyi yapıların tespit edilmesidir. Bu çalışmada kullanılan beş U-Net katman yapısı 32, 30, 37, 48 ve 46 katmandan meydana gelmektedir. Her bir U-Net mimarisinde katmanlar, kodlama ve deşifre etme yollarının her iki yanında eşit biçimde bölünmektedir.

İlk deney grubu için eğitim seti görüntüleri, eğitim veri seti için %70'e ve validasyon (doğrulama) veri seti için %30'a ayrılmıştır. U-Net 32 katman yapısına 224×224 görüntü boyutu uygulanmıştır. Bu; girdi katmanını dışında 4 blok kodlama yolundan, iki darboğaz büklüm katmanından ve bir tamamen büklümlü katmanla deşifre yolu için diğer dört bloktan meydana gelmektedir. Her bir blok, darboğaz katmanlarında 32 filtreden 512 filtreye kadar 8'in katlarıyla artan farklı filtrelere sahip iki adet büklümlü katman ve her bir bloğun sonunda bir birleştirme katmanı içermektedir. İlk gruptaki deneylerin özeti **Tablo 4.2**'de sunulmaktadır. İlk üç deney; aynı öğrenme oranı, seri boyutu, iyileştirici, Büklümlü katmanlarda Aktivasyon İşlevi ve Tamamen Büklümlü katmanlarda Aktivasyon İşlevi kullanılarak gerçekleştirilmiştir ve sırasıyla aşağıdaki gibidir (0.00001, 8, Adam, elu ve sigmoid). İkinci modelde dönemler arttırıldığında, validasyon Metrislerinde fark edilir artışlar gerçekleşmiştir. Renk alanı HSI'dan RGB'ye değiştirilerek, üçüncü model deneyinde önemli değişiklikler fark edilmiştir.

Tablo 4.2: İlk Deney Grubu

Model Numarası	Kullanılan Model Mimarisi	Dönem	Doğruluk	Dice	Jaccard	Duyarlılık	Özgüllük
1	U-Net 32	200	0.6963	0.5047	0.6963	0.7954	0.8366
2	U-Net 32	500	0.7234	0.5123	0.7234	0.7639	0.8385
3	U-Net 32	200	0.8352	0.7091	0.8352	0.9631	0.9680
4	U-Net 30	16	0.8729	0.7588	0.8729	0.7491	0.9951
5	U-Net 32	1000	0.8893	0.7938	0.8893	0.9210	0.9748
6	U-Net 32	1000	0.8936	0.8117	0.8936	0.9091	0.9783

Dördüncü model deneyinde ön işleme adımı renk alanı ve (seri boyutu ve eniyileyici) gibi diğer hiper parametreler korunmuştur. 30 katmanlı farklı bir U-Net yapısı (Darboğaz katmanlarında 64 filtreden 1024 filtreye kadar 8'in katlarıyla artan farklı filtrelere sahip aşağı örneklendirme ve yukarı örneklendirme arasında değişen 18 bükümlü katman ve kodlama ve deşifre yollarından katmanları birleştirmek ve katmanı sigmoid aktivasyon işleviyle tamamen bağlamak için **ReLU** Aktivasyon işlevi, 5 birleştirme katmanı, 2 adet 0,5 çıkarma katmanı e 4 zincirleme katmanı) kullanılmıştır. Ayrıca öğrenme hızı 0,00001'den 0,000001'e azaltılarak ve dönemlerin sayısı 200'den 16 iterasyona azaltılarak, işlem süresi hızlandırılmış ve Duyarlılık metrisindeki aşağıya düşüş dışında daha iyi performans sergilemiştir.

Model 3'ün performansına ilişkin olarak Veri Normalleştirmenin etkisi incelenmiştir. Veri Normalleştirmesi yapılan model hem eğitimde hem de validasyonda daha yüksek metris ortalaması göstermiş ve Veri Normalleştirmesi olmayan modellerden daha düşük kayıp göstermiştir. **Tablo 4.2** model 5 ve **Şekil 4.5**'te gösterildiği gibi model 6'da validasyon veri setinin %6'dan 33'e artması ile Doğruluk, Küçük Parçalara Ayırma, Jaccard, Duyarlılık, Özgüllük ortalamasını olumlu biçimde etkilerken, Duyarlılık Ortalamasını olumsuz yönde etkilediği ortaya çıkmıştır.

Tablo 4.3: İkinci Deney Grubu

Model Numarası	Model Mimarisi	Dönemler	Doğruluk	Dice	Jaccard	Duyarlılık	Özgüllük
7	U-Net 37	15	0.8562	0.7377	0.8562	0.8977	0.9708
8	U-Net 48	41	0.8698	0.6853	0.8698	0.8677	0.9759
9	U-Net 46	188	0.9209	0.8131	0.9209	0.8896	0.9720
10	U-Net 46	1000	0.9336	0.8571	0.9336	0.9158	0.9780

İkinci deney grubu için farklı parametrelerle ve ön işleme yöntemi yukarıdaki 4.3.1 numaralı bölümde tanımlananlarla değiştirilerek üç farklı U-Net katman yapısı

kullanılmıştır. Jaccard Endeksi yerine Küçük Parçalara Ayırma katsayı kayıp işlevi kullanılmıştır. Sonuçlar **Tablo 4.3**'te özetlenmektedir.


Bu deneyler grubunun ilk modelinde görüntü boyutu 224×224 'te tutulmuş ve 5 Çıkartma (0,1) katman kullanılarak U-Net 37 katman mimarisine beslenmiştir. **Tablo 4.3** model 7'deki sonuçlar, U-Net 37 kullanımının, eğitim ve validasyon veri setinin doğruluğunu önemli ölçüde etkilemediğini göstermiştir. Bu nedenle eğitim süreci, **Şekil 4.6**'da gösterilen biçimde erken aşamalarda durdurulmuştur. Ancak eğitim adımlarında ilerledikçe ortalama kayıp azalmıştır.

Bu deney grubunun ikinci modelinde görüntü boyutu 448×448 'e arttırılmış ve 2 Çıkartma (0,5) katman kullanılarak U-Net 48 katman mimarisine beslenmiştir. Bu iletişim ağı **Tablo 4.3** model 8'den elde edilen sonuçlara göre performans, egzersiz ve validasyon veri setinin doğruluğu üzerinde hala önemli bir etkiye sahip değildir. Bu nedenle egzersiz süreci **Şekil 4.7**'de gösterilen biçimde erken aşamalarda durdurulmuştur. Ancak bir önceki modelde olduğu gibi eğitim adımlarında ilerledikçe ortalama kayıp azalmıştır.


Bu deneyler grubunun bir sonraki modelinde eğitim adımlarının sayısı arttırılmıştır ve katman sayısı 46 katmana indirilmiştir. Bu, katman sayısının daha düşük kayba ve daha yüksek doğruluğa katkıda bulunduğunu göstermektedir (bkz. **Şekil 4.8**).

Bu deneyler grubunun son modelinin sonuçları **Şekil 4.9**'da sunulmuştur. Egzersiz dönemleri 1000 adıma arttırılmıştır; 0,045 öğrenme hızı, $\rho=0,9$ ve $\epsilon=1$ ile RMSprop kullanılmıştır. Toplam kayıp önemli ölçüde düşmüş ve eğitim ve validasyon doğrulukları derece derece artmıştır.


Her modelin sonucu karşılaştırılarak modellerin Jaccard Endeksi yerine Küçük Parçalara Ayırma katsayı kayıp işlevi ile daha iyi performans sergilediği ve RMSprop iyileştirici olan modellerin performansının, Adam iyileştiriciye oranla daha iyi çalıştığı sonucuna varılmıştır. Mimari olarak U-Net 46 katman kullanımı, modeli diğer mimarilerden daha etkin hale getirmektedir.




Şekil 4.5: Model 5 performans analizi




Şekil 4.6: Model 7 performans analizi



Şekil 4.7: Model 8 performans analizi



Şekil 4.8: Model 9 performans analizi



Şekil 4.9: Model 10 performans analizi

4.4 ÖNERİLEN U-NET YAPI SONUÇLARI

Önceki bölümlerde gösterildiği ve **Tablo 4.4**'te kapsamlı bir biçimde açıklandığı gibi orijinal U-Net 32 katman mimarisi kısa egzersiz süresine sahiptir ancak derinlik yeterince derin değildir.

Tablo 4.4: U-Net 32 mimarisi

sıra	Katman Adı	Çıktı Şekli (Filtre numarası, Harita boyutları)	Bağlantılı olduğu birim	Aktivasyon işlevi
01	Girdi Katmanı	(224, 224, 3)	-	
02	Bükümlü Katman #01	(224, 224, 32)	Girdi Katmanı	elu
03	Bükümlü Katman #02	(224, 224, 32)	Bükümlü Katman #01	elu
04	Maksimum Birleştirme Katmanı #01	(112, 112, 32)	Bükümlü Katman #02	
05	Bükümlü Katman #03	(112, 112, 64)	Maksimum Birleştirme Katmanı #01	elu
06	Bükümlü Katman #04	(112, 112, 64)	Bükümlü Katman #03	elu
07	Maksimum Birleştirme Katmanı #02	(56, 56, 64)	Bükümlü Katman #04	
08	Bükümlü Katman #05	(56, 56, 128)	Maksimum Birleştirme Katmanı #02	elu
09	Bükümlü Katman #06	(56, 56, 128)	Bükümlü Katman #05	elu
10	Maksimum Birleştirme Katmanı #03	(28, 28, 128)	Bükümlü Katman #06	
11	Bükümlü Katman #07	(28, 28, 256)	Maksimum Birleştirme Katmanı #03	elu
12	Bükümlü Katman #08	(28, 28, 256)	Bükümlü Katman #07	elu
13	Maksimum Birleştirme Katmanı #04	(14, 14, 256)	Bükümlü Katman #08	
14	Bükümlü Katman #09	(14, 14, 512)	Maksimum Birleştirme Katmanı #04	elu
15	Bükümlü Katman #10	(14, 14, 512)	Bükümlü Katman #09	elu

Tablo 4.4 (Devam): U-Net 32 mimarisi

sıra	Katman Adı	Çıktı Şekli (Filtre numarası, Harita boyutları)	Bağlantılı olduğu birim	Aktivasyon işlevi
16	Yukarı örneklemeye katmanı #01	(28, 28, 512)	Bükümlü Katman #10	
17	Zincirleme katmanı #01	(28, 28, 768)	Yukarı örneklemeye katmanı #01 ve Bükümlü Katman #08	
18	Bükümlü Katman #11	(28, 28, 256)	Zincirleme katmanı #01	elu
19	Bükümlü Katman #12	(28, 28, 256)	Bükümlü Katman #11	elu
20	Yukarı örneklemeye katmanı #02	(56, 56, 256)	Bükümlü Katman #12	
21	Zincirleme katmanı #02	(56, 56, 384)	Yukarı örneklemeye katmanı #02 ve Bükümlü Katman #06	
22	Bükümlü Katman #13	(56, 56, 128)	Zincirleme katmanı #02	elu
23	Bükümlü Katman #14	(56, 56, 128)	Bükümlü Katman #13	elu
24	Yukarı örneklemeye katmanı #03	(112,112,128)	Bükümlü Katman #14	
25	Zincirleme katmanı #03	(112,112,192)	Yukarı örneklemeye katmanı #03 ve Bükümlü Katman #08	
26	Bükümlü Katman #15	(112, 112, 64)	Zincirleme katmanı #03	elu
27	Bükümlü Katman #16	(112, 112, 64)	Bükümlü Katman #15	elu
28	Yukarı örneklemeye katmanı #04	(224, 224, 64)	Zincirleme katmanı #16	
29	Zincirleme katmanı #04	(224, 224, 96)	Yukarı örneklemeye katmanı #04 ve Bükümlü Katman #02	
30	Bükümlü Katman #17	(224, 224, 32)	Zincirleme katmanı #04	elu
31	Bükümlü Katman #18	(224, 224, 32)	Bükümlü Katman #17	elu
32	Bükümlü Katman #19	(224, 224, 1)	Bükümlü Katman #18	sigmoid

Geliştirme modeli U-Net 46 katmanları; daha derin katmanlara, daha uzun parametrelere sahiptir ve bölütleme etkisinde olağanüstü iyileşme sağlamaktadır. **Tablo 4.5**'te gösterilmiştir.

Tablo 4.5: U-Net 46 mimarisi

sıra	Katman Adı	Çıktı Şekli (Filtre numarası, Harita boyutlar)	Bağlantılı olduğu birim	Aktivasyon işlevi
01	Girdi Katmanı	(1, 448, 448)	-	
02	Bükümlü Katman #01	(16, 448, 448)	Girdi Katmanı	elu
03	Bükümlü Katman #02	(16, 448, 448)	Bükümlü Katman #01	elu
04	Maksimum Birleştirme Katmanı #01	(16, 224, 224)	Bükümlü Katman #02	
05	Bükümlü Katman #03	(32, 224, 224)	Maksimum Birleştirme Katmanı #01	elu
06	Bükümlü Katman #04	(32, 224, 224)	Bükümlü Katman #03	elu
07	Maksimum Birleştirme Katmanı #02	(32, 112, 112)	Bükümlü Katman #04	
08	Bükümlü Katman #05	(64, 112, 112)	Maksimum Birleştirme Katmanı #02	elu
09	Bükümlü Katman #06	(64, 112, 112)	Bükümlü Katman #05	elu
10	Maksimum Birleştirme Katmanı #03	(64, 56, 56)	Bükümlü Katman #06	
11	Bükümlü Katman #07	(128, 56, 56)	Maksimum Birleştirme Katmanı #03	elu
12	Bükümlü Katman #08	(128, 56, 56)	Bükümlü Katman #07	elu
13	Maksimum Birleştirme Katmanı #04	(128, 28, 28)	Bükümlü Katman #08	
14	Bükümlü Katman #09	(256, 28, 28)	Maksimum Birleştirme Katmanı #04	elu
15	Bükümlü Katman #10	(256, 28, 28)	Bükümlü Katman #09	elu

Tablo 4.5 (Devam): U-Net 46 mimarisi

sıra	Katman Adı	Çıktı Şekli (Filtre numarası, Harita boyutlar)	Bağlantılı olduğu birim	Aktivasyon işlevi
16	Maksimum Birleştirme Katmanı #05	(256, 14, 14)	Bükümlü Katman #10	
17	Bükümlü Katman #11	(512, 14, 14)	Maksimum Birleştirme Katmanı #05	elu
18	Bükümlü Katman #12	(512, 14, 14)	Bükümlü Katman #11	elu
19	Maksimum Birleştirme Katmanı #06	(512, 7, 7)	Bükümlü Katman #12	
20	Bükümlü Katman #13	(1024, 7, 7)	Maksimum Birleştirme Katmanı #06	elu
21	Bükümlü Katman #14	(1024, 7, 7)	Bükümlü Katman #13	elu
22	Yukarı örnekleme katmanı #01	(1024, 14, 14)	Bükümlü Katman #14	
23	Zincirleme katmanı #01	(1536, 14, 14)	Yukarı örnekleme katmanı #01 ve Bükümlü Katman #12	
24	Bükümlü Katman #15	(512, 14, 14)	Zincirleme katmanı #01	elu
25	Bükümlü Katman #16	(512, 14, 14)	Bükümlü Katman #15	elu
26	Yukarı örnekleme katmanı #02	(512, 28, 28)	Bükümlü Katman #16	
27	Zincirleme katmanı #02	(768, 28, 28)	Yukarı örnekleme katmanı #02 ve Bükümlü Katman #10	
28	Bükümlü Katman #17	(256, 28, 28)	Zincirleme katmanı #02	elu
29	Bükümlü Katman #18	(256, 28, 28)	Bükümlü Katman #17	elu

Tablo 4.5 (Devam): U-Net 46 mimarisi


















sıra	Katman Adı	Çıktı Şekli (Filtre numarası, Harita boyutlar)	Bağlantılı olduğu birim	Aktivasyon işlevi
30	Yukarı örnekleme katmanı #03	(256, 56, 56)	Bükümlü Katman #18	
31	Zincirleme katmanı #03	(384, 56, 56)	Yukarı örnekleme katmanı #03 ve Bükümlü Katman #08	
32	Bükümlü Katman #19	(128, 56, 56)	Zincirleme katmanı #03	elu
33	Bükümlü Katman #20	(128, 56, 56)	Bükümlü Katman #19	elu
34	Yukarı örnekleme katmanı #04	(128, 112, 112)	Zincirleme katmanı #20	
35	Zincirleme katmanı #04	(192, 112, 112)	Yukarı örnekleme katmanı #04 ve Bükümlü Katman #06	
36	Bükümlü Katman #21	(64, 112, 112)	Zincirleme katmanı #04	elu
37	Bükümlü Katman #22	(64, 112, 112)	Bükümlü Katman #21	elu
38	Yukarı örnekleme katmanı #05	(64, 224, 224)	Bükümlü Katman #22	
39	Zincirleme katmanı #05	(96, 224, 224)	Yukarı örnekleme katmanı #05 ve Bükümlü Katman #04	
40	Bükümlü Katman #23	(32, 224, 224)	Zincirleme katmanı #05	elu
41	Bükümlü Katman #24	(32, 224, 224)	Bükümlü Katman #23	elu
42	Yukarı örnekleme katmanı #06	(32, 448, 448)	Bükümlü Katman #24	
43	Zincirleme katmanı #06	(48, 448, 448)	Yukarı örnekleme katmanı #06 ve Bükümlü Katman #02	

Tablo 4.5 (Devam): U-Net 46 mimarisi

















sıra	Katman Adı	Çıktı Şekli (Filtre numarası, Harita boyutlar)	Bağlantılı olduğu birim	Aktivasyon işlevi
44	Bükümlü Katman #25	(16, 448, 448)	Zincirleme katmanı #06	elu
45	Bükümlü Katman #26	(16, 448, 448)	Bükümlü Katman #25	elu
46	Bükümlü Katman #27	(1, 448, 448)	Bükümlü Katman #26	sigmoid

Geliştirilmiş U-Net yapısı, en düşük oranda kayıp sunmakta (eğitim seti için -1 ve validasyon seti için -0,9) ve test edilen diğer U-Net yapılarına kıyasla daha yüksek doğruluk (%93) göstermektedir. Önerilen modelin hem Küçük parçalara ayırma katsayısını hem de Jaccard Endeksini kullanarak Duyarlılık, Özgüllük ve bölütleme doğruluğu sırasıyla şu şekildedir: %91, %97, %85 ve %93.

Başarılı sonuçlara karşın başarılı olmayan sonuç olarak değerlendirilen on örnek **Şekil 4.10** ve **Şekil 4.11**'de görülmektedir. Her örnek için orijinal dermoskopi görüntü maskesi (ikinci sütun), bölütleme önerilen yaklaşımıyla (üçüncü sütun) kıyaslanmaktadır. İlk durumda, önerilen modelin ne kadar doğru olduğu görülebilmektedir çünkü lezyon alanının yüksek kontrastı net bir biçimde görülebilmektedir. Başarılı ve başarısız sonuçların değerlendirmesi sırasıyla **Tablo 4.6** ve **Tablo 4.7**'de gösterilmiştir. İkinci durumda ise düşük kontrastın, bölütleme sürecini nasıl olumsuz yönde etkilediği görülmektedir.

Görüntü No.	Orijinal görüntü	Orijinal maske	Tahmini maske	Bitsel
98				
4				
70				
445				
507				

Şekil 4.10: Başarılı bölütleme sonuçları örnekleri

Görüntü No.	Orijinal görüntü	Orijinal maske	Tahmini maske	Bitsel
354				
428				
534				
606				
643				

Şekil 4.11: Başarısız bölütleme sonuçları örnekleri

Tablo 4.6: Başarılı sonuçların değerlendirme tablosu

Image No.	Doğruluk	Dice	Jaccard	Duyarlılık	Özgüllük
98	0.9824	0.9630	0.9824	0.9991	0.9991
4	0.9889	0.9453	0.9889	0.9992	0.9994
70	0.9843	0.9561	0.9843	0.9931	0.9995
445	0.9891	0.9471	0.9891	0.9906	0.9999
507	0.9783	0.9635	0.9783	0.9923	0.9985

Tablo 4.7: Başarısız sonuçların değerlendirme tablosu

Image No.	Doğruluk	Dice	Jaccard	Duyarlılık	Özgüllük
354	0.4625	0.1589	0.4625	0.0630	0.9675
428	0.5404	0.1923	0.5404	0.0716	1.0000
534	0.4919	0.1181	0.4919	0.0496	1.0000
606	0.9431	0.1144	0.9431	0.0028	1.0000
643	0.5827	0.5623	0.5827	0.3412	1.0000

5. TARTIŞMA VE SONUÇ

5.1 SONUÇLAR

Bu tezde, deri lezyon alanının dermoskopik görüntülerinin bölütleme çalışması için derin öğrenme yaklaşımı önerilmektedir. Bir başka deyişle, farklı U-Net mimarilerinin, deri lezyon alanı için bölütleme çalışmasının performansını nasıl geliştirdiği incelenmiştir.

Geliştirme süreci iki temel adımda gerçekleştirilmiştir: ön işleme adımı ve **görüntü** bölütleme adımı. İlk adımda, 6 farklı **görüntü** işleme yaklaşımı bir araya getirilerek farklı yapay olguları tespit etmek ve ortadan kaldırmak amacıyla dermoskopik görüntülere ön işleme teknikleri uygulanmıştır. Tezin önemli bir parçası olan ikinci adımda (U-Net 32, U-Net 30, U-Net 37, U-Net 48 ve U-Net 46) gibi 5 farklı U-Net mimarisi sunulmuştur.

Deneylerin eğitimi için ISIC2018 veri seti kullanılmıştır. Değerlendirme aşamasında, deneylerin sonuçlarını karşılaştırmak amacıyla dermatologlar tarafından geliştirilmiş ISIC2018 kesin referans – ikili görüntüler kullanılmıştır.

Otomatik olarak bölütlenmiş görüntülerde, 1815 eğitim görüntüsünden oluşan ISIC2018 veri setinde %93 doğruluk, %91 duyarlılık ve %97 özgüllük elde edilmiştir ve bunlar 779 validasyon (doğrulama) veri setinde değerlendirilmiştir. U-Net 46 katmanları kullanılarak mükemmel şekilde bölütlenmiş görüntüde, ortalama 1815 eğitim görüntüsünde %93 Doğruluk elde edilmiştir. Sırasıyla U-Net 48 ve U-Net 37 kullanıldığında doğruluk sırasıyla (%86,9 ve %85,6'ya) düşmüştür ve model eğitimi U-Net 32 katmanlarıyla yapıldığında ve önerilen ön işleme yöntemi kullanılmadığında doğruluk %89,3'e düşmüştür. U-Net 30 katmanları kullanıldığında doğruluk daha da aşağıya düşmüştür.

Beş U-Net mimarisinin karşılaştırmasına göre hiper parametreler ve küçük parçalara ayırma katsayı kaybı işlevine dayalı (öğrenme oranı = 0,045, RMSprop eniyileyici) U-Net mimarisinin 46 katmanının kullanıldığı, önerilen ön işleme yönteminin, en iyi dermoskopik görüntü bölütleme sonuçlarını verdiği sonucuna varılmıştır.

5.2 GELECEK ÇALIŞMALAR İÇİN ÖNERİLER

Bu tez kapsamında yapılan işlemlerin dışında gelecekte yapılacak olan çalışmalarda daha iyi sonuçlar için Ssç ve kıl tanıma için yeni bir kesin referans veri kümesinin oluşturulması ve bu yapıları tespit etmek için bir derin modelinin eğitiminin gerçekleştirilmesi düşünülebilir.

Öznitellikleri belirlemek için Residual U-Net, Recurrent U-Net veya R2U-Net gibi başka bir U-Net yapısının kullanılması ve karşılaştırılması yapılabilir.

RGB, CMYK vb. gibi renkli görüntüler için model oluşturulması ve onlarda var olan bölütlerin birleştirilerek tek bir bölütlemeye olarak de bir araya getirilmesi sağlanabilir.

Bölütlemeye sonuçlarındaki her bir lezyon için sınıflandırmalar yapılması sağlanabilir.

KAYNAKLAR

- [1] W. Sterry, *Thieme Clinical Companions Dermatology*, 1 edition. Stuttgart ; New York: Thieme, 2006.
- [2] "Melanocyte," *Wikipedia*. 22-Oct-2018.
- [3] "The layers of your skin | American Academy of Dermatology." [Online]. Available: <https://www.aad.org/public/kids/skin/the-layers-of-your-skin>. [Accessed: 23-Nov-2018].
- [4] D. Gawkrödger and M. R. Ardern-Jones, *Dermatology: An Illustrated Colour Text*. Elsevier Health Sciences, 2016.
- [5] A. Bhardwaj and D. J. Bhatia, "An image segmentation method for early detection and analysis of melanoma," *IOSR J. Dent. Med. Sci.*, vol. 13, no. 10, pp. 18–22, 2014.
- [6] "What is cancer?," *Cancer Research UK*, 16-Dec-2014. [Online]. Available: <https://www.cancerresearchuk.org/about-cancer/what-is-cancer>. [Accessed: 03-Nov-2018].
- [7] "Cancer," *Wikipedia*. 19-Nov-2018.
- [8] "An Overview of Skin Cancer," *WebMD*. [Online]. Available: <https://www.webmd.com/melanoma-skin-cancer/guide/skin-cancer>. [Accessed: 03-Nov-2018].
- [9] "Melanoma of the Skin - Cancer Stat Facts," *SEER*. [Online]. Available: <https://seer.cancer.gov/statfacts/html/melan.html>. [Accessed: 23-Nov-2018].
- [10] R. Deklerck, J. Cornelis, and M. Bister, "Segmentation of medical images," *Image Vis. Comput.*, vol. 11, no. 8, pp. 486–503, Oct. 1993.
- [11] G. S. Vennila, L. P. Suresh, and K. L. Shunmuganathan, "Dermoscopic image segmentation and classification using machine learning algorithms," in *2012 International Conference on Computing, Electronics and Electrical Technologies (ICCEET)*, Nagercoil, Tamil Nadu, India, 2012, pp. 1122–1127.
- [12] S. Yuheng and Y. Hao, "Image Segmentation Algorithms Overview," p. 6.
- [13] M. E. Vestergaard, P. Macaskill, P. E. Holt, and S. W. Menzies, "Dermoscopy compared with naked eye examination for the diagnosis of primary melanoma: a meta-analysis of studies performed in a clinical setting," *Br. J. Dermatol.*, vol. 159, no. 3, pp. 669–676, Sep. 2008.
- [14] "What is dermoscopy?," *Dr Jonathan Bowling*. [Online]. Available: <http://mydermatologist.co.uk/worried-about-a-mole/what-is-dermoscopy/>. [Accessed: 20-Nov-2018].
- [15] "Dermoscopy: Overview, Technical Procedures and Equipment, Color," Mar. 2018.
- [16] "Melanoma - Diagnosis and treatment - Mayo Clinic." [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/melanoma/diagnosis-treatment/drc-20374888>. [Accessed: 31-Dec-2018].
- [17] J. L. G. Arroyo and B. G. Zapirain, "Automated Detection of Melanoma in Dermoscopic Images," in *Computer Vision Techniques for the Diagnosis of Skin Cancer*, J. Scharcanski and M. E. Celebi, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, pp. 139–192.
- [18] K. Lawand, "Segmentation of Dermoscopic Images," *IOSR J. Eng.*, vol. 4, no. 4, pp. 16–20, Apr. 2014.
- [19] P. Wighton, T. Lee, and M. Atkins, "Dermoscopic hair disocclusion using inpainting," *Proc Soc Proc Inst Eng*, vol. 6914, Apr. 2008.
- [20] M. Bertalmio, G. Sapiro, V. Caselles, and C. Ballester, "Image inpainting," *ACM Press.-Wesley*, Jul. 2000.
- [21] Q. Abbas, I. F. Garcia, M. E. Celebi, and W. Ahmad, "A Feature-Preserving Hair Removal Algorithm for Dermoscopy Images," *Skin Res. Technol.*, vol. 19, no. 1, pp. e27–e36, Feb. 2013.
- [22] "Bornemann and März - 2007 - Fast Image Inpainting Based on Coherence Transport.pdf." .
- [23] A. Nasonova, A. Nasonov, A. Krylov, I. Pechenko, A. Umnov, and N. Makhneva, "Image Warping in Dermatological Image Hair Removal," in *Image Analysis and Recognition*, 2014, pp. 159–166.
- [24] M. T. B. Toossi, H. R. Pourreza, H. Zare, M.-H. Sigari, P. Layegh, and A. Azimi, "An effective hair removal algorithm for dermoscopy images," *Skin Res. Technol.*, vol. 19, no. 3, pp. 230–235, Aug. 2013.

- [25] W. K. Pratt, "Generalized Wiener Filtering Computation Techniques," *IEEE Trans. Comput.*, vol. C-21, no. 7, pp. 636–641, Jul. 1972.
- [26] A. Rosenfeld and P. D. L. Torre, "Histogram concavity analysis as an aid in threshold selection," *IEEE Trans. Syst. Man Cybern.*, vol. SMC-13, no. 2, pp. 231–235, Mar. 1983.
- [27] W. Rong, Z. Li, W. Zhang, and L. Sun, "An improved Canny edge detection algorithm," in *2014 IEEE International Conference on Mechatronics and Automation*, 2014, pp. 577–582.
- [28] F. Bornemann and T. März, "Fast Image Inpainting Based on Coherence Transport," *J. Math. Imaging Vis.*, vol. 28, no. 3, pp. 259–278, Jul. 2007.
- [29] A. F. Mahmood and H. Mahmood, "Artifact Removal from Skin Dermoscopy Image to Support Automated Melanoma Diagnosis," *AL Rafdain Eng. J.*, vol. 23, no. 5, pp. 22–30, 2015.
- [30] K. Kiani and A. R. Sharafat, "E-shaver: An improved DullRazor® for digitally removing dark and light-colored hairs in dermoscopic images," *Comput. Biol. Med.*, vol. 41, no. 3, pp. 139–145, Mar. 2011.
- [31] C. Barata, J. S. Marques, and J. Rozeira, "A System for the Detection of Pigment Network in Dermoscopy Images Using Directional Filters," *IEEE Trans. Biomed. Eng.*, vol. 59, no. 10, pp. 2744–2754, Oct. 2012.
- [32] H. Aboelsoud, "Edge Detection Using Directional Filtering | IJERA (www.ijera.com) - Academia.edu," *International journal of engineering research and applications*, Apr-2014. [Online]. Available: https://www.academia.edu/7548212/Edge_Detection_Using_Directional_Filtering. [Accessed: 01-Nov-2018].
- [33] S. Pathan, K. G. Prabhu, and P. C. Siddalingaswamy, "Hair detection and lesion segmentation in dermoscopic images using domain knowledge," *Med. Biol. Eng. Comput.*, vol. 56, no. 11, pp. 2051–2065, Nov. 2018.
- [34] Q. Abbas, I. F. Garcia, M. E. Celebi, W. Ahmad, and Q. Mushtaq, "A perceptually oriented method for contrast enhancement and segmentation of dermoscopy images," *Skin Res. Technol.*, vol. 19, no. 1, pp. e490–e497, Feb. 2013.
- [35] Q. Abbas, I. F. Garcia, M. E. Celebi, W. Ahmad, and Q. Mushtaq, "Unified approach for lesion border detection based on mixture modeling and local entropy thresholding," *Skin Res. Technol.*, vol. 19, no. 3, pp. 314–319, Aug. 2013.
- [36] J. Jaworek-Korjakowska and R. Tadeusiewicz, "Determination of border irregularity in dermoscopic color images of pigmented skin lesions," in *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2014, pp. 6459–6462.
- [37] M. E. Celebi, S. Hwang, H. Iyatomi, and G. Schaefer, "Robust border detection in dermoscopy images using threshold fusion," in *2010 IEEE International Conference on Image Processing*, 2010, pp. 2541–2544.
- [38] F. Melgani, "Robust image binarization with ensembles of thresholding algorithms," *J. Electron. Imaging*, vol. 15, no. 2, p. 023010, Apr. 2006.
- [39] L.-K. Huang and M.-J. J. Wang, "Image thresholding by minimizing the measures of fuzziness," *Pattern Recognit.*, vol. 28, no. 1, pp. 41–51, Jan. 1995.
- [40] J. N. Kapur, P. K. Sahoo, and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Comput. Vis. Graph. Image Process.*, vol. 29, no. 3, pp. 273–285, Mar. 1985.
- [41] J. Kittler and J. Illingworth, "Minimum error thresholding," *Pattern Recognit.*, vol. 19, no. 1, pp. 41–47, Jan. 1986.
- [42] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Trans. Syst. Man Cybern.*, vol. 9, no. 1, pp. 62–66, 1979.
- [43] N. K. E. Abbadi and A. H. Miry, *Automatic Segmentation of Skin Lesions Using Histogram Thresholding*. .
- [44] M. H. Jafari *et al.*, "Skin lesion segmentation in clinical images using deep learning," in *2016 23rd International Conference on Pattern Recognition (ICPR)*, 2016, pp. 337–342.
- [45] J. Qi, M. Le, C. Li, and P. Zhou, "Global and Local Information Based Deep Network for Skin Lesion Segmentation," *ArXiv170305467 Cs*, Mar. 2017.

- [46] Y. Yuan, M. Chao, and Y. Lo, "Automatic Skin Lesion Segmentation Using Deep Fully Convolutional Networks With Jaccard Distance," *IEEE Trans. Med. Imaging*, vol. 36, no. 9, pp. 1876–1886, Sep. 2017.
- [47] S. B. Salimi, B. Bozorgtabar, M. S. Rad, P. Schmid-Saugeon, H. K. Ekenel, and J.-P. Thiran, "DermoNet system for Skin Lesion Segmentation," p. 4.
- [48] H. Xu and T. H. Hwang, "Automatic Skin Lesion Segmentation Using Deep Fully Convolutional Networks," *ArXiv180706466 Cs*, Jul. 2018.
- [49] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," May 2015.
- [50] Z. Cui *et al.*, "Automatic Skin Lesion Segmentation Based on Ensemble of Fully Convolutional Neural Networks," p. 4.
- [51] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation," *ArXiv180202611 Cs*, Feb. 2018.
- [52] "Dermoscopy of pigmented skin lesions: Results of a consensus meeting via the Internet - ScienceDirect." [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0190962203003530>. [Accessed: 01-Jan-2019].
- [53] A. Sáez, B. Acha, and C. Serrano, "Pattern Analysis in Dermoscopic Images," in *Computer Vision Techniques for the Diagnosis of Skin Cancer*, J. Scharcanski and M. E. Celebi, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, pp. 23–48.
- [54] "Pattern analysis | DermNet NZ." [Online]. Available: <https://www.dermnetnz.org/cme/dermoscopy-course/pattern-analysis/>. [Accessed: 02-Jan-2019].
- [55] R. Oliveira, J. Papa, A. S. Pereira, and J. Tavares, "Computational Methods for Pigmented Skin Lesion Classification in Images: Review and Future Trends," *Neural Comput. Appl.*, Jul. 2016.
- [56] 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. Cancer J. Clin.*, vol. 35, no. 3, pp. 130–151, May 1985.
- [57] N. R. Abbasi *et al.*, "Early Diagnosis of Cutaneous Melanoma: Revisiting the ABCD Criteria," *JAMA*, vol. 292, no. 22, pp. 2771–2776, Dec. 2004.
- [58] "The Skin Cancer Detector That Could Save Your Life," *TipHero*, 12-Dec-2014. [Online]. Available: <https://tiphero.com/the-skin-cancer-detector-that-could-save-your-life/>. [Accessed: 03-Jan-2019].
- [59] F. M. Walter *et al.*, "Using the 7-point checklist as a diagnostic aid for pigmented skin lesions in general practice: a diagnostic validation study," *Br J Gen Pr.*, vol. 63, no. 610, pp. e345–e353, May 2013.
- [60] "Dermoscopy_tutorial - 7point check list." [Online]. Available: <http://www.dermoscopy.org/consensus/2d.asp>. [Accessed: 03-Jan-2019].
- [61] "Dermoscopy_tutorial - Menzies' scoring method." [Online]. Available: <http://www.dermoscopy.org/consensus/2c.asp>. [Accessed: 03-Jan-2019].
- [62] "A Beginner's Guide to Neural Networks and Deep Learning," *SkyMind*. [Online]. Available: <http://skymind.ai/wiki/neural-network>. [Accessed: 15-Jan-2019].
- [63] D. Anderson and G. McNeill, "Artificial neural networks technology," *Kaman Sci. Corp.*, vol. 258, no. 6, pp. 1–83, 1992.
- [64] "Amazon.com: Artificial Intelligence for Humans, Volume 3: Deep Learning and Neural Networks eBook: Jeff Heaton: Kindle Store." [Online]. Available: https://www.amazon.com/Artificial-Intelligence-Humans-Learning-Networks-ebook/dp/B0184WRDEQ?keywords=Artificial+Intelligence+for+Humans%2C+Volume+3%3A+Deep+Learning+and+Neural+Networks&qid=1547539255&sr=8-1-fkmrnull&ref=sr_1_fkmrnull_1. [Accessed: 15-Jan-2019].
- [65] B. Holländer, "Natural vs Artificial Neural Networks," *Becoming Human: Artificial Intelligence Magazine*, 20-Aug-2018. [Online]. Available: <https://becominghuman.ai/natural-vs-artificial-neural-networks-9f3be2d45fdb>. [Accessed: 17-Jan-2019].

- [66] M. Alradad, "Robust classification with convolutional neural networks," Thesis, University of Missouri--Columbia, 2015.
- [67] J. Vojt, "Deep neural networks and their implementation," Jun. 2016.
- [68] "Fig. 2. Mathematical model of artificial neuron.," *ResearchGate*. [Online]. Available: https://www.researchgate.net/figure/Mathematical-model-of-artificial-neuron_fig1_320270458. [Accessed: 30-Jan-2019].
- [69] "Fundamentals of Deep Learning - Activation Functions and their use," *Analytics Vidhya*, 23-Oct-2017. .
- [70] A. S. Walia, "Activation functions and it's types-Which is better?," *Towards Data Science*, 29-May-2017. [Online]. Available: <https://towardsdatascience.com/activation-functions-and-its-types-which-is-better-a9a5310cc8f>. [Accessed: 31-Jan-2019].
- [71] Y. A. LeCun, L. Bottou, G. B. Orr, and K.-R. Müller, "Efficient BackProp," in *Neural Networks: Tricks of the Trade: Second Edition*, G. Montavon, G. B. Orr, and K.-R. Müller, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 9–48.
- [72] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Advances in Neural Information Processing Systems 25*, F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, Eds. Curran Associates, Inc., 2012, pp. 1097–1105.
- [73] F. van Beers and D. M. A. Wiering, "Using Intersection over Union loss to improve Binary Image Segmentation," p. 10.
- [74] R. C. Eberhart, *Neural Network PC Tools: A Practical Guide*. Academic Press, 2014.
- [75] T. Jayalakshmi and A. Santhakumaran, "Statistical Normalization and Back Propagation for Classification," *Int. J. Comput. Theory Eng.*, pp. 89–93, 2011.
- [76] M. Cavaioni, "DeepLearning series: Deep Neural Networks tuning and optimization," *Medium*, 23-Feb-2018. .
- [77] M. Niknafs, "Neural Network Optimization," p. 7.
- [78] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 6088, p. 533, Oct. 1986.
- [79] M. A. Nielsen, "Neural Networks and Deep Learning," 2015.
- [80] M. A. Nielsen, "Neural Networks and Deep Learning," 2015.
- [81] X. Serra, J. Castán, and S. Escalera, "Face recognition using Deep Learning," p. 96.
- [82] L. Dian and S. Dongmei, "Contactless palmprint recognition based on convolutional neural network," in *2016 IEEE 13th International Conference on Signal Processing (ICSP)*, 2016, pp. 1363–1367.
- [83] J. Vojt, "Deep neural networks and their implementation," Jun. 2016.
- [84] "CS231n Convolutional Neural Networks for Visual Recognition." [Online]. Available: <http://cs231n.github.io/convolutional-networks/>. [Accessed: 08-May-2019].
- [85] S. Das, "CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more," *Medium*, 16-Nov-2017. .
- [86] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, vol. 9351, N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, Eds. Cham: Springer International Publishing, 2015, pp. 234–241.
- [87] "Task 1: Lesion Boundary Segmentation | ISIC 2018." .
- [88] A. Ford, A. Roberts, and A. Roberts, "and Alan Roberts (Alan.Roberts@rd.bbc.co.uk). August 11, 1998(a)," p. 31.
- [89] E. Gedraite and M. Hadad, "Investigation on the effect of a Gaussian Blur in image filtering and segmentation," 2011, pp. 393–396.
- [90] "Spatial Filters - Gaussian Smoothing." [Online]. Available: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/gsmooth.htm>. [Accessed: 06-May-2019].
- [91] "Morphological Image Processing." [Online]. Available: <https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic4.htm>. [Accessed: 10-Mar-2019].

- [92] A. R. Kofi, "Revised Mathematical Morphological Concepts: Dilation, Erosion, Opening and Closing.," p. 85.
- [93] "Morphology." [Online]. Available: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/morops.htm>. [Accessed: 10-Mar-2019].
- [94] Prof. P. S. Parsania and Dr. P. V. Virparia, "A Review: Image Interpolation Techniques for Image Scaling," *Int. J. Innov. Res. Comput. Commun. Eng.*, vol. 02, no. 12, pp. 7409–7414, Jan. 2015.
- [95] S. E. Umbaugh, *Digital Image Processing and Analysis: Human and Computer Vision Applications with CVIPtools, Second Edition*. CRC Press, 2010.
- [96] A. Telea, "An Image Inpainting Technique Based on the Fast Marching Method," *J Graph. GPU Game Tools*, vol. 9, pp. 23–34, 2004.
- [97] D. Surya Prabha and J. Satheesh Kumar, "Performance Evaluation of Image Segmentation using Objective Methods," *Indian J. Sci. Technol.*, vol. 9, no. 8, Feb. 2016.
- [98] M. Heller, "What is CUDA? Parallel programming for GPUs," *InfoWorld*, 30-Aug-2018. [Online]. Available: <https://www.infoworld.com/article/3299703/deep-learning/what-is-cuda-parallel-programming-for-gpus.html>. [Accessed: 05-Dec-2018].
- [99] "Graphics processing unit," *Wikipedia*. 01-Dec-2018.
- [100] "Keras," *Wikipedia*. 14-Nov-2018.
- [101] "Home - Keras Documentation." [Online]. Available: <https://keras.io/>. [Accessed: 04-Dec-2018].
- [102] "ISIC 2018 | ISIC 2018: Skin Lesion Analysis Towards Melanoma Detection." .
- [103] N. C. F. 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)," *ArXiv171005006 Cs*, Oct. 2017.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Sohaib HASAN
Doğum Yeri	Irak – Kerkük
Doğum Tarihi	01-01-1986
Uyruğu	☐ T.C. ☒ Diğer: Iraklı
Telefon	05316603306
E-Posta Adresi	sohaibnajathasan@ogr.iu.edu.tr
Web Adresi	



Eğitim Bilgileri	
Lisans	
Üniversite	Kerkük Üniversitesi
Fakülte	Fen Bilimler
Bölümü	Bilgisayar Bilimi
Mezuniyet Yılı	2018-2019 BAHAR

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Enformatik Anabilim Dalı
Programı	Enformatik

Makale ve Bildiriler	