

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

**DERİN ÖĞRENME TABANLI YÖNTEMLER İLE CİLT LEZYONLARININ
BÖLÜTLENMESİ**

YÜKSEK LİSANS TEZİ

Nurullah ŞAHİN

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Davut HANBAY

Ağustos 2020

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

**DERİN ÖĞRENME TABANLI YÖNTEMLER İLE CİLT LEZYONLARININ
BÖLÜTLENMESİ**



YÜKSEK LİSANS TEZİ

**Nurullah ŞAHİN
(36173619011)**

Bilgisayar Mühendisliği Anabilim Dalı

**Tez Danışmanı: Prof. Dr. Davut HANBAY
Eş Danışman: Dr. Öğr. Üyesi Nuh ALPASLAN**

Ağustos 2020

TEŐEKKÜR VE ÖNSÖZ

Bu tez çalışmasının her aşamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgemeyen danışman hocam Sayın Prof. Dr. Davut HANBAY'a, çalışmam boyunca bir an olsun desteğini, emeğini esirgemeyen, takıldığım her noktada azimle yardımcı olan, yönlendiren eş danışmanım Sayın Dr. Öğr. Üyesi Nuh ALPASLAN'a,

Çalışmalarımda ayrıca tüm hayatım boyunca olduğu gibi bu çalışmalarım süresince en büyük destekçim olan Sevgili Eşim ve Aileme,

teşekkür ederim.



ONUR SÖZÜ

Yüksek lisans tezi olarak sunduđum “Geleneksel ve Derin Öğrenme Tabanlı Yöntemler ile Cilt Lezyonlarının Sınıflandırılması” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Nurullah ŞAHİN



İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ	i
ONUR SÖZÜ	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
SEMBOLLER VE KISALTMALAR	vii
ÖZET	viii
ABSTRACT	ix
1. GİRİŞ.....	1
1.1 Motivasyon	1
1.2 Amaç.....	2
1.3 Literatür İncelemesi	3
2. CİLT KANSERİ	8
2.1 Melanom	8
2.2 Dermoskopi	8
2.3 Lezyon Değerlendirmesinde Kullanılan Yöntemler	10
2.3.2 Yedi nokta kontrol listesi.....	11
2.3.3 Üç nokta kontrol listesi.....	11
2.3.4 Menzies yöntemi	12
2.3.5 CASH yöntemi	12
3. MATERYAL VE METOD	14
3.1 Materyal.....	14
3.2 Metod.....	14
3.2.1 Ön işleme	14
3.2.1.1 Görüntü boyutlandırma.....	14
DullRazor algoritması	14
3.2.1.2 DullRazor algoritması	15
3.2.1.3 Shades of gray	15
3.2.1.4 Ağırlık dağılımı ile adaptif gama doğrulama	16
3.2.2 Renk kanalı seçimi	17
3.2.3 Metasezgisel optimizasyon yöntemleri	17
3.2.3.1 Parçacık sürü optimizasyonu (PSO).....	18
3.2.3.2 Benzetimli tavlama algoritması	20
3.2.3.3 Harmoni arama algoritması	21
3.2.4 SegNet	23
3.2.5 Otsu eşikleme	25
3.2.6 Kapur yöntemi	26
3.2.7 Minimum hata eşikleme yöntemi	28
3.2.8 Bayes optimizasyon.....	29
4. DENEYSEL SONUÇLAR	32
4.1 Performans Ölçütleri.....	32
4.2 Tez Kapsamında Yapılan Deneysel Çalışmalar	33

4.2.1 Renk kanallarının eşikleme tabanları yöntemlerin performansı üzerine etkisi	33
4.2.2 Klasik otsu temelli metasezgisel yöntemlerin cilt lezyon bölütlemesine etkisi	35
4.2.3 Önışleme, kodlayıcı derinliđi ve renk kanallarının SegNet ađının performansına etkisi	37
4.2.4 Bayes yöntemi ile hiper-parametre optimizasyonunun SegNet ađının performansı üzerine etkisi	41
5. SONUÇ VE ÖNERİLER.....	45
KAYNAKÇA	47
ÖZGEÇMİŐ	54



ÇİZELGELER DİZİNİ

Çizelge 2.1 : ABCD kuralı.	11
Çizelge 2.2 : Yedi nokta kontrol listesi.	11
Çizelge 2.3 : Üç nokta kontrol listesi.	12
Çizelge 2.4 : CASH yönetimi.	13
Çizelge 4.1 : Karmaşıkık Matrisi.	32
Çizelge 4.2 : Bölütleme için kullanılan performans ölçütleri.	32
Çizelge 4.3 : Otsu, kapur ve minimum hata eşiklemesinin renk kanallarına göre başarımı.	34
Çizelge 4.4 : Her bir algoritma için dice skoru ve kosinüs benzerliği başarımları..	36
Çizelge 4.5 : SegNet ağının eğitiminde kullanılan hiperparametre değerleri.	39
Çizelge 4.6 : Önışleme adımları ve veri büyütmenin SegNet bölütleme performansına etkileri.	39
Çizelge 4.7 : SegNet ağında farklı derinlik değerlerinin bölütleme performansına etkisi..	40
Çizelge 4.8 : Farklı renk kanallarının ve çok kanallılığın bölütleme performansına etkisi.	40
Çizelge 4.9 : Optimizasyon parametreleri ve Seg-Net seçenekleri.	42
Çizelge 4.10 : S1 seçeneğinde elde edilen en iyi bölütleme için performans ölçütleri.	43
Çizelge 4.11 : S1 için en iyi başarımları veren ağın parametre değerleri.	43
Çizelge 4.12 : Literatürdeki çalışmlar ve önerilen çalışma.	44

ŞEKİLLER DİZİNİ

Şekil 2.1 : Soldan sağa sırası ile temaslı ve temassız dermoskopi yardımı ile cilt lezyon bölgesinin incelenmesi (Marghoob, Ashfaq A., Braun, Ralph P., Kopf, 2012).....	9
Şekil 2.2 : Soldan Sağa sırası ile dermoskopi kullanmadan, temaslı dermoskopi ve temassız dermoskopi kullanıldığında ışığın optik hareketleri (Marghoob, Ashfaq A., Braun, Ralph P., Kopf, 2012).....	9
Şekil 2.3 : (A), klinik cilt görüntüsü (B), temaslı dermoskopi (C), polarize ışık kullanarak temassız dermoskopi (D), polarize ışık kullanmadan temassız dermoskopi ile elde edilen malign melanom görüntüleri (Benvenuto-Andrade ve diğerleri, 2007).....	10
Şekil 3.1 : DullRazor algoritması uygulanmış görüntü.	15
Şekil 3.2 : Shades of gray algoritması uygulanmış görüntü.	16
Şekil 3.3 : Adaptif Gama Doğrulaması Uygulanmış Lezyon Görüntüsü	17
Şekil 3.4 : Parçacık sürüsü optimizasyonun esinlendiği davranış modelleri.	18
Şekil 3.5 : PSO akış diyagramı.	19
Şekil 3.6 : Isıl işlem aşamaları	20
Şekil 3.7 : Benzetimli tavlama algoritması akış diyagramı.	21
Şekil 3.8 : Harmoni arama yöntemi akış diyagramı.	23
Şekil 3.9 : SegNet ağının mimarisi.	24
Şekil 3.10 : Otsu eşikleme için (a) görüntü histogramı (b) eşik değeri (c) bölütlenmiş görüntü.	26
Şekil 3.11 : Kapur yöntemi için (a) görüntü histogramı (b) eşik değeri (c) bölütlenmiş görüntü.	27
Şekil 3.12 : Minimum hata eşikleme yöntemi için (a) görüntü histogramı (b) eşik değeri (c) bölütlenmiş görüntü.....	28
Şekil 3.13 : Bayes optimizasyon ile Segnet ağının optimizasyonu.	31
Şekil 4.1 : Her bir görüntü için bölütleme başarımları.	34
Şekil 4.2 : Yöntemin akış şeması.....	35
Şekil 4.3 : En iyi eşik değerinin bulunması süreci.....	36
Şekil 4.4 : Saniye cinsinden harcanan ortalama süre.....	36
Şekil 4.5 : Önerilen yöntem akış şeması.....	38
Şekil 4.6 : Ağın eğitim süreci.	38
Şekil 4.7 : SegNet ağı altyapısı	39
Şekil 4.8 : Sunulan yöntemle ilişkin akış diagramı.....	42
Şekil 4.9 : 6 farklı seçenek ile eğitilen SegNet ağında bayes optimizasyonun 30 iterasyon boyunca amaç fonksiyonundaki değişim.	43
Şekil 4.10 : SegNet ve Bayes optimizasyon bölütlemesi: a) doğru öğrenme b) aşırı öğrenme ve yetersiz öğrenme.....	44

SEMBOLLER VE KISALTMALAR

HA	: Harmoni Arama (HS : Harmony Search)
BT	: Benzetilmiş Tavlama (SA : Simulated Annealing)
PSO	: Parçacık Sürüsü Optimizasyonu (PSO : Particle Swarm Optimization)
RGB	: Red-Green-Blue Renk Uzayı
CIELAB	: CIELAB Renk Uzayı
ESA	: Evrimsel Sinir Ağları (CNN : Convolutional Neural Network)
ELM	: Epidermik Lüminesans
HSV	: Hue-Saturation-Value Renk Uzayı
HSI	: Hue-Saturation-Intensity Renk Uzayı
BDF	: Birikimli Dağılım Fonksiyonu (CDF : Cumulative Distribution Function)
OYF	: Olasılık Yoğunluk Fonksiyonu (PDF : Probability Density Function)
T	: Başlangıç Sıcaklığı
HBB	: Harmony Bellek Boyutu (HMS : Harmony Memory Size)
HBDAO	: Harmoni Belleğini Dikkate Alma Oranı (HMCR : Harmony Memory Consideration Rate)
TAO	: Ton Ayarlama Oranı (PAR : Pitch Adjustment Rate)
YN	: Yiğın Normalleştirme (BN : Batch Normalization)
DDB	: Doğrultulmuş Doğrusal Birim (RELU : Rectified Linear Unit)
e	: Euler Sayısı
BO	: Bayes Optimizasyon
ABİ	: Artı Beklenen İyileştirme (EIP : Expected Improvement Plus)
ASBİ	: Artı Saniyede Beklenen İyileştirme (EIPPS : Expected Improvement Plus Per Second)
UM	: Uyarlanabilir Moment (ADAM : Adaptive Momentum)
MSGİ	: Momentum ile Stokastik Gradyan İniş (SGDM : Stochastic Gradient Descent with Momentum)
UBGS	: Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI : International Symposium on Biomedical Imaging)
TDS	: Toplam Dermatoskopik Skor

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TABANLI YÖNTEMLER İLE CİLT LEZYONLARININ BÖLÜTLENMESİ

Nurullah ŞAHİN

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

54+IX sayfa

2020

Danışman: Prof. Dr. Davut HANBAY

Melanom, tüm kanser türleri içinde en yaygın görülen ve en ölümcül kanser türüdür. Melanomun erken teşhisi, tedavi başarımını ve hastanın hayatta kalma olanağını önemli ölçüde arttırmaktadır. Dermoskopi, dermatologlar tarafından melanom tespitinde yaygın olarak kullanılan, cilt bütünlüğünü bozmayan, düşük maliyetli ve etkili bir yöntemdir. Melanom teşhisi için dermoskopi görüntülerinin analizi temel olarak önişleme, bölütleme, özellik çıkarımı ve sınıflandırma adımlarından oluşur. Bölütleme adımı kendisinden sonraki adımlardaki başarı performansını doğrudan etkilediği için kritik öneme sahiptir. Fakat cilt üzerindeki kıl, hava kabarcıkları ve yağ kabarcıkları gibi kalıntılar; cilt lezyonlarının renk dağılımlarındaki farklılıklar, sınır düzensizlikleri ve düşük kontrast gibi olumsuz koşullar cilt lezyonlarının doğru tespit edilmesini zorlaştırmaktadır.

Bu tez çalışmasında, cilt lezyon bölütlemesinde kullanılan geleneksel ve güncel derin öğrenme tabanlı yöntemler, bölütleme doğruluğu ve sürelerine göre incelenerek kapsamlı analizleri gerçekleştirilmiştir. Böylece yöntemlerin birbirlerine göre güçlü ve zayıf yönleri ortaya konulmuştur. Bu kapsamda 4 farklı çalışma gerçekleştirilmiştir. İlk çalışmada eşikleme tabanlı yöntemlerin farklı renk kanalları ile cilt lezyon bölütleme başarımları incelenmiştir. İkinci çalışmada, harmoni arama (HA), benzetimli tavlama (BT) ve parçacık sürü optimizasyonu (PSO) yöntemlerinin Otsu eşikleme yönteminin bölütleme performansını üzerindeki etkileri incelenmiştir. Üçüncü çalışmada, kodlayıcı derinliği ve farklı renk kanallarının SegNet ağının cilt lezyon bölütleme performansı üzerindeki etkisi incelenmiştir. Son olarak, bayes optimizasyon yöntemi ile SegNet ağın eğitilmesinde kullanılan en iyi hiper-parametreler belirlenerek SegNet ağının bölütleme başarımının artırılması sağlanmıştır. Bunun yanında, yöntemlerin cilt lezyon bölütleme performansları, doğruluk, hassasiyet, özgüllük, dice ve jaccard katsayısı olmak üzere 5 farklı ölçüt kullanılarak elde edilmiştir. Deneysel sonuçlar, önerilen sistemin etkinliğini ve gerçek zamanlı klinik uygulamalardaki kullanılabilirliğini ortaya koymaktadır.

Anahtar Kelimeler: cilt kanseri, melanom, otsu, metasezgisel, segnet, bayes optimizasyon.

ABSTRACT

Master Thesis

CLASSIFICATION OF SKIN LESIONS WITH DEEP LEARNING BASED METHODS

Nurullah ŞAHİN

Inonu University
Graduate School of Nature and Applied Sciences
Department of Computer Engineering

54+IX sayfa

2020

Supervisor: Prof. Dr. Davut HANBAY

Melanoma is the most common and deadliest form of cancer among all cancer types. Early diagnosis of melanoma significantly improves treatment performance and survival rates. Dermoscopy is a non-invasive, low-cost and effective method that is widely used by dermatologists for melanoma detection. Analysis of dermoscopy images for melanoma detection mainly consists of preprocessing, segmentation, feature extraction and classification steps. The segmentation stage is critical as it directly affects the performance of the next stages. However, the low contrast, differences in color distributions of skin lesions, border irregularities, and the artifacts such as hair, air bubbles, oil bubbles in skin lesion images, complicate the segmentation process.

In this thesis, conventional and the state-of-the-art deep learning based methods were examined according to their segmentation and time performance for skin lesion segmentation and their comprehensive analyzes were carried out. Thus, the strengths and weaknesses of the methods relative to each other have been revealed. In this manner, four different experimental studies have been carried out. In the first study, different color channels and skin lesion segmentation performance of thresholding-based methods were examined. In the second study, the effects of harmoni search (HS), simulated annealing (SA) and particle swarm optimization (PSO) methods on the segmentation performance of the otsu thresholding method have been investigated. In the third study, the effect of encoder depths and different color channels on performance of Seg-Net has been investigated. Finally, the best hyper-parameters of trained SegNet were determined with the bayes optimization and the segmentation performance of the SegNet has been improved. Besides, the skin lesion segmentation performance of the methods have been obtained using five different metrics: accuracy, sensitivity, specificity, dice and jaccard coefficient. Experimental results indicate the efficiency of the proposed system and the viability of a real-time clinical application.

Keywords: skin cancer, melanoma, otsu, metaheuristic, segnet, bayesian optimization.

1. GİRİŞ

1.1 Motivasyon

Cilt kanseri tiplerini genel olarak melanom ve melanom olmayan diye iki sınıfa ayırabiliriz. Kötü huylu melanom, cilde rengini veren hücrelerin yapısal DNA hasarından kaynaklı olarak anormal şekilde büyümesinden kaynaklanan, diğer kanser türlerine kıyasla insan vücuduna kolayca yayılabilen en ölümcül cilt kanseri türüdür. Melanom vakalarındaki artış son yıllarda hız kazanmakta olup, sadece Amerika Birleşik Devletlerinde 2015 yılında görülen tahmini yeni vaka sayısı 73.870 ve bu vakalardan kaynaklı tahmini ölümlerin sayısı 9.940 iken bu sayılar 2016 yılı için 76.380 yeni vaka ve bu vakalardan kaynaklı ölümlerin sayısı 10.130 olarak tahmin edilmektedir (Siegel, Miller ve Jemal, 2015, 2016). Melanomun yayılma oranı yüksek olmasına rağmen, erken tespit edilmesi durumunda melanom en kolay tedavi edilebilen cilt kanseri türüdür. Melanom erken tespit ve teşhis edilebilirse yara bölgesi basit bir operasyon ile kesilip çıkartılabilmekte, tedavisindeki başarı oranı artmakta ve hastanın yaşam süresi uzamaktadır (Geller ve diğerleri, 2007). Melanomun kesin teşhisi yara bölgesinin patolojik olarak incelenmesiyle mümkün olmaktadır. Fakat bu işlem hastayı tedirgin eden, cilt bütünlüğünü bozan, zaman ve maddiyat bakımından maliyetli bir yöntem olduğu için dermatologlar tarafından çok tercih edilmemektedir. Bunun yerine dermatologlar tarafından melanom teşhisinde yaygın olarak kullanılan araç/yöntem olan dermoskopi tercih edilmektedir (Campos-do-carmo ve Ramos-e-silva, 2008; Venugopal, Peter Soyer ve Menzies, 2011). Dermatologlar tarafından dermoskopik görüntülerden melanomun erken evresinde tanı ve teşhisi yapılırken ABCDE kuralı (Cognetta, Vogt, Landthaler, Braun-Falco ve Plewig, 1994), yedi aşamalı kontrol listesi (Argenziano ve diğerleri, 1998), 3 aşamalı kontrol listesi (Zalaudek ve diğerleri, 2006), Menzies yöntemi (Menzies, Ingvar, Crotty ve McCarthy, 1996) ve CASH algoritması (Thiers, y.y.) gibi çeşitli prosedürleri uygulanmaktadır. Bu prosedürler genel olarak lezyon bölgesinin renk bilgisi, geometrisi, yapısal ve dokusal özelliklerine göre skorlama yaparak hekimin melanom teşhisi yapmasında kullanılmaktadır. Dermatologlar her ne kadar melanom teşhisi için yardımcı prosedürler kullansa da yaptıkları teşhisler öznel ve insan faktöründen kaynaklı kusurlar içerebilmektedir. Yapılan araştırmalar bilgisayar destekli tanı sistemleri olmadan ve çıplak göz ile yapılan cilt lezyon bölgesi değerlendirmelerinde, hekimin teşhis doğruluğunun %65

ile %80 arasında olduğunu göstermektedir (Argenziano ve Soyer, 2001). Bu işlem tecrübeli bir dermatolog tarafından dermoskopik görüntüler üzerinden çeşitli prosedürler yardımı ile yapılsa dahi teşhis doğruluğu 75%-84% aralığında olmaktadır (Corona, Sera, Binder ve Cerroni, 2003).

Son yıllarda, melanom tanı doğruluğundaki başarımı arttırmak ve melanom tespitinde hekime yardımcı olmak adına çok sayıda bilgisayar destekli tanı sistemleri geliştirilmiştir. Melanom tespitinde kullanılan bilgisayar destekli tanı sistemleri genel olarak önışleme, bölütleme, öznitelik çıkarımı ve sınıflandırma modüllerinden oluşmaktadır (Feldman, Fleischer ve Coldiron, 2015). Bölütleme adımı, öznitelik çıkarımı ve sınıflandırma adımlarının başarımına doğrudan etki ettiği için melanom teşhisinde kritik öneme sahiptir.

1.2 Amaç

Bu tez çalışmasının temel amacı literatürdeki geleneksel ve güncel derin öğrenme temelli bilgisayar destekli cilt lezyonu tanı sistemlerinin tasarlanması ve değerlendirilmesidir. Bu yöntemlerin basit ve karmaşık veri setlerinde performansları incelenmiştir. Özellikle lezyon bölgesinin kıl, yağ ve hava kabarcıkları nedeniyle sınır tespitinin zor olduğu, kitle görünümünün kısmen engellendiği, ortam ışık miktarının değiştiği, nesnenin kameraya yaklaştığı veya uzaklaştığı gibi problemlere sahip veri setleri üzerindeki güncel yöntemlerin performansları değerlendirilmiştir. Bunun sonucunda geliştirilen yöntemlerin klinik kullanımlardaki kararlılığı ve etkinliği ortaya konulacaktır.

İkinci önemli amaç ise, geleneksel öznitelik tabanlı yöntemler gibi yaygın olarak kullanılan yöntemlerin yanında son zamanlarda çıkan derin öğrenme tabanlı yöntemlerin ele alınıp tasarlanmasıdır. Bu yöntemlerin ortak veri setleri üzerinde güçlü ve zayıf yönleri ortaya konulup, bu değerlendirmelere ilişkin performans verileri sunulmuştur.

Üçüncü amaç ise klasik bölütleme yöntemleri ve derin öğrenme tabanlı yöntemler üzerinde, parçacık sürü optimizasyonu, harmoni arama, ve bayes optimizasyonu gibi metasezgisel yöntemlerin lezyon bölütleme performansı üzerindeki etkilerinin ortaya konulmasıdır.

Dermatologlar ciltte bulunan lezyonların teşhisini, görsel ve mikroskopik özelliklerin değerlendirilmesi ile gerçekleştirirler. Lezyonların şekilleri, renk dağılımları, kenarları, yapısal ve dokusal özellikleri karar vermede önemli parametrelerdir. Bu nedenle lezyon görüntüleri, görüntü işleme teknolojileri ile çeşitli önışleme adımlarına tabi tutularak, görüntülerin belirginliği arttırılmış ve lezyon bölgesindeki çeşitli kalıntılar ortadan

kaldırılmıştır. Böylece hekimlerin lezyonları incelemeleri ve karar vermeleri kolaylaştırılarak insan kaynaklı hata yapma olasılığı azaltılarak teşhis doğruluğu artırılmıştır. Son olarak tamamen işlevsel geleneksel ve derin öğrenme tabanlı otomatik bölütleme yöntemleri ile lezyon bölgesinin doğru bir şekilde elde edilmesi sağlanarak hekime yardımcı olacak karar destek sistemleri sunulmuştur.

1.3 Literatür İncelemesi

Lezyon bölütlemesinin amacı, lezyon bölgesine ait özelliklerin çıkartılarak, çıkarılan özellikler yardımı ile lezyon bölgesinin doğru biçimde sınıflandırılmasını sağlamaktır. Lezyon bölütlemesi ile görüntüdeki pikseller $L = \{"lezyon", "arka\ plan"\}$ olarak tanımlanabilir, böylece her pikselin lezyona veya arkaplana ait olma olasılığı kontrol edilebilir (Wighton, Lee, Lui, McLean ve Atkins, 2011). İyi bir bölütleme ve sınır çıkarımı, lezyon bölgesinin melanom olup olmadığının tespitinde önemli bir rol oynamaktadır. Bu nedenle, son klinik tanı için dermatologları destekleyebilen yeni bir yaklaşım üretmek amacıyla etkilenen lezyonların cilt görüntüleri üzerinde segmentasyonunu gerçekleştirmek için çok sayıda yarı otomatik ve otomatik yöntem önerilmiştir. Bu yöntemleri genel olarak histogram eşikleme tabanlı, kümeleme tabanlı, kenar tabanlı, bölge tabanlı, morfoloji tabanlı, aktif kontur tabanlı, yumuşak hesaplama tabanlı ve son yıllarda yaygınlaşan derin öğrenme tabanlı yöntemler olarak kategorize etmek mümkündür.

Celebi ve arkadaşları (Celebi ve diğerleri, 2008) cilt lezyon görüntülerini bölütlemek için bölge büyümesi ve birleştirme yaklaşımlarını esas alarak geliştirilmiş bir teknik olan istatistiksel bölge birleştirme yöntemi önermişlerdir. Yüksel ve arkadaşları (Yüksel ve Borlu, 2009) sağlıklı ciltten pigmente cilt lezyonunun sınırının çıkarılması için bir yöntem önermişlerdir. Yazarlar, görüntü piksellerini ön plan (lezyon alanı) ve arka plan (sağlıklı cilt) olarak sınıflandırmak için kullanılan otomatik bir eşik değeri belirlemek amacıyla tip-2 bulanık mantık tekniğini kullanmışlardır. Celebi ve arkadaşları (Emre-Celebi, Hwang, Iyatomi ve Schaefer, 2010), dermoskopik görüntülerde doğru lezyon sınırlarını bölütlere ayırmak için Otsu, Kapur, Kittler gibi eşikleme tabanlı yöntemlerin birleşmesine (fusion) dayanan bir yöntem sunmuşlardır. Humayun ve arkadaşları (Humayun, Malik ve Kamel, 2011), Otsu'nun yöntemini kullanarak yoğunluk seviyesine bağlı olarak her sınıf için eşik değerlerini seçerek görüntü histogramını yinelemeli olarak birden çok sınıfa bölen çok eşikli bir yöntem önermişlerdir. Cilt lezyonlarını bölütlemek için Wong ve arkadaşları (Wong, Scharcanski ve Fieguth, 2011) tekrarlamalı stokastik bölge birleştirmeye dayalı otomatik bir

yöntem önermişlerdir. Başlangıç olarak her bir piksel benzersiz bir bölgeye atanmıştır. Daha sonra bir bölge birleştirme benzerlik fonksiyonu yardımı ile bu bölgeler hassas bölütlenmiş görüntüyü elde etmek için bir durdurma kriteri sağlanana kadar birleştirme işlemine tabi tutulmuştur. Castillejos ve arkadaşları (Castillejos, Ponomaryov, Nino-De-Rivera ve Golikov, 2012) cilt lezyonunu bölütlemek ve sınırlarını tespit etmek için bir kümeleme tabanlı k-ortalama, bulanık c-ortalama ve küme ön seçim bulanık c-ortalama için dalgacık dönüşümüne dayanan yeni bir yaklaşım sunmuşlardır. Zornberg ve arkadaşları (Zornberg, Celebi ve Member, 2012), görüntü piksellerinin x, y koordinatları ve R, G, B renk kanalları yardımı ile elde ettikleri beş boyutlu vektörleri kullanarak k-ortalama yardımı ile bölütlendiği bir yöntem önermişlerdir. Abbas ve arkadaşları (Abbas, Garcia, Emre Celebi, Ahmad ve Mushtaq, 2013), bölge ve kenar bazlı bölütleme tekniklerini birleştirerek melanom sınır tespiti için yeni bir algısal yönelimli yaklaşım önermişlerdir. Yöntemlerinde, RGB görüntüler CIE L * a * b * renk uzayına dönüştürülerek, daha sonra lezyon kontrastı, CIE L * a * b'nin üç kanalı kullanılarak belirtilen aralıktaki lezyon piksellerinin yoğunluk değerlerinin ayarlanması ve haritalanması ile elde edilmiştir. Kruk ve arkadaşları (Kruk ve diğerleri, 2015), RGB renk uzayındaki R, G, B bileşenleri için histogram tabanlı eşikleme kullanan tam otomatik bir bölütleme yöntemi önermişlerdir. Agarwal ve arkadaşları (Agarwal, Issac, Dutta, Riha ve Uher, 2017), RGB lezyon görüntülerini öncelikle L*a*b formatına dönüştürüp, L*a*b görüntü yardımı ile $Gri = a+b-L$ kombinasyonu kullanarak farklı gri tonlamalı görüntü elde etmişlerdir. Elde edilen görüntü bölütlemesi için k-ortalama yöntemini kullanmışlardır. Dalila ve arkadaşları (Dalila, Zohra, Reda ve Hocine, 2017) cilt lezyon bölütlemesi ve sınıflandırma üzerine yaptıkları çalışmada, RGB uzayından G kanalı ve HSV uzayından S kanalını kullanarak, karınca kolonisi kullanarak bir bölütleme yöntemi önermişlerdir. Kasmi ve arkadaşları (Kasmi ve Mokrani, 2016), nesne şeklinin topolojik değişikliklerine uyarlanabilirliği nedeniyle biyomedikal görüntüde yaygın olarak kullanılan ve görüntü bölütleme için etkili bir çerçeve sağlayan geodesic aktif kontur yöntemi ile bir bölütleme yöntemi sunmuşlardır. Chunming ve arkadaşları (Li, Xu, Gui ve Fox, 2010), cilt lezyon bölütlemesi için, mesafe profillerinin muhafaza edilmesini sağlayan mesafe belirleme fonksiyonu yardımı ile seviye belirleme yöntemi önermişlerdir. Burada seviye belirleme yöntemi gradyan vektörlerden esinlenerek fonksiyonun değerlerinin eşit olduğu noktalar kümesini elde etmekte kullanılmıştır. Bi ve arkadaşları (Bi ve diğerleri, 2016a), lezyon görüntülerinin farklı rotasyonlarından ve ölçeklerinden türetilmiş yakından ilişkili çok sayıda histogramını kullanarak cilt lezyonlarını temsil etmeye çalışan çok ölçekli bir bölütleme yöntemi önermişlerdir. Silveira ve arkadaşları, bir otomatik uyarlanabilir/adaptif

eşik kullanmışlardır (Silveira ve diğerleri, 2009). Bölütleme aşamasına gelindiğinde, yoğunluk değeri eşik değerinden daha büyük olan pikseller ilgilenilen bölge (lezyon) olarak sınıflandırılırken, diğer pikseller arka plan (sağlıklı cilt) olarak sınıflandırılmıştır. Barata ve arkadaşları (Barata, Ruela, Francisco, Mendonca ve Marques, 2014), dermoskopi görüntülerinde melanom tespiti için iki farklı sistem önermişlerdir. Nowak ve arkadaşları (Nowak, Ogorzałek ve Pawłowski, 2012), pigment ağı yapılarını tespit etmek amacıyla, sürü zekası optimizasyon algoritmalarından esinlenerek uyarlanabilir bir filtre geliştirmişlerdir. Filtre işleminin başlangıcında, filtreler görüntünün bölümlerine rastgele uygulanmıştır. Bu, dermatoskopik yapı tespiti problemine yeni bir yaklaşım olup yazarlarca, önceki ön işleme adımına gerek kalmadan görüntülere uygulanabileceğinden ötürü oldukça esnek olduğu iddia edilmiştir. Ahn ve arkadaşları (Ahn ve diğerleri, 2017), dermoskopik görüntülerde cilt lezyonlarının tanımlanması ve karakterizasyonu için görsel belirginliğe (saliency) dayalı bir segmentasyon çerçevesi kullanmışlardır. Bi ve arkadaşları (Bi ve diğerleri, 2016b), görüntü bazlı denetimli öğrenme ve çok ölçekli süper piksel tabanlı hücresel otomata ile yeni bir otomatik cilt lezyonu bölütleme yöntemi önermişlerdir. Mustafa ve arkadaşları (Mustafa, Dauda ve Dauda, 2017), lezyon sınıflandırma için karar destek makineleri kullandıkları çalışmalarında, görüntü bölütlemesi için graf teorisinde bir ağacın belirli dallarının kesilmesine dayalı GrabCut tekniğini önermişlerdir. GrabCut algoritmasının temeli, ağacın tek kesimde iki parçaya ayrılması ve kesimin boyunun kestiği kenarların ağırlıkları toplamı kadar olması temeline dayandırılmıştır.

Grafik işlemci birimlerinde meydana gelen gelişmeler ile birlikte derin öğrenme tabanlı yöntemlerin popüleritesi yakın zamanda gittikçe yaygınlaşmış ve cilt lezyon bölütlemesinde çok sayıda derin öğrenme temelli yöntem geliştirilmiştir; Yuan ve arkadaşları (Yuan, Chao ve Lo, 2017), cilt lezyon bölütlemesinde, bölütleme performansının adam optimizasyonu, parti normalizasyonu ve Jakard indeksi tabanlı kayıp fonksiyonu gibi teknikler kullanılarak geliştirildiği derin evrimsel sinir ağlarına dayanan bir yöntem önermişlerdir. Cilt ve lezyonları belirlemek için asimetri, sınır, renk ve doku analizine dayanan görüntülerden cilt lezyonu özelliklerini çıkarmak için Oliveira ve arkadaşları (Oliveira, Papa, Pereira ve Tavares, 2018); yöne bağımlı bir yayılma filtresi, kenarları olmayan aktif bir kontur modeli ve görüntülerde sunulan gürültüyü azaltmak, lezyon sınırlarını segmentlere ayırmak ve lezyon sınıflandırma aşamasını gerçekleştirmek için bir destek vektör makinesine dayanan bir yöntem önermişlerdir.

Kawahara ve arkadaşları (Kawahara ve Hamarneh, 2016), çok çözünürlüklü bir CNN önermişlerdir. Donanım kısıtlamaları ile karşılaşılsa da, yazarlar, düşük çözünürlüklü girdilerin genel şekil gibi yüksek seviye özellikleri sağlayabileceği ve yüksek çözünürlüklü girdilerin lezyon içindeki desenler gibi ek düşük seviye özellikleri sağlayabileceği düşüncesinden yola çıkarak, cilt lezyonlarını sınıflandırmak için çoklu çözünürlük girişleri kullanmayı önermişlerdir. Ünver ve arkadaşları (Ünver ve Ayan, 2019), cilt lezyon bölütlemesinde çözünürlükten bağımsız bir çözüm sunmak için GRABCUT algoritması ve derin öğrenme tabanlı bir evrişimsel sinir ağı modeli olan YOLO mimarisinin bir kombinasyonundan oluşan boru hatı modeli önermişlerdir. Lin ve arkadaşları (Lin, Michael, Kalra ve Tizhoosh, 2018), güncel derin öğrenme tabanlı yöntem olan U-Net mimarisi ve kümeleme yöntemlerinin, bölütleme performansını karşılaştırmalı olarak sunmuşlardır. Tang ve arkadaşları (Tang ve diğerleri, 2019), cilt lezyon bölütlemesi için olasılıksal ağırlıklı ortalama ve ayrıştırılabilir U-net mimarisine dayanan bir yöntem önermişlerdir. Önerilen yöntem ayrıştırılabilen bloklar ve U-net mimarisinin avantajlarına sahip olduğu bu sayede tamamen evrişimli ağların (FCN) piksel düzeyinde ayrımcı temsil yeteneğinin geliştirilebildiği yüksek anlamsal bilgileri yakalayabildiği iddia edilmiştir. Olasılıksal ağırlıklı ortalama tekniği ile de sistemin aşırı uyuma yatkınlığı azaltılarak daha iyi genelleme yapmasının sağlanabileceği iddia edilmiştir. Brahmbhatt ve arkadaşları (Brahmbhatt ve Rajan, 2019), farklı hiper parametreler ile birlikte katmanları yeniden düzenlenmiş bir SegNet modeli ve ikili çapraz entropy yöntemine dayanan bir yöntem önermişlerdir. Al-masni ve arkadaşları (Al-masni, Al-antari, Choi, Han ve Kim, 2018), ciltteki kıl ve benzeri kalıntıların giderilmesi, düşük kontrast değerleri, sınırların geliştirilmesi gibi ön işleme ve son işleme adımlarına gerek duymadan giriş verilerinin her bir pikselinin tam çözünürlük özelliklerini doğrudan öğrenen bir tam çözünürlüklü evrişimsel ağ modeli önermişlerdir.

Bu tez çalışmasında, cilt lezyon bölütlemesinde kullanılan geleneksel ve güncel derin öğrenme tabanlı yöntemler, bölütleme doğruluğu ve sürelerine göre incelenerek kapsamlı analizleri gerçekleştirilmiştir. Böylece yöntemlerin birbirlerine göre güçlü ve zayıf yönleri ortaya konulmuştur. Bu kapsamda 4 farklı çalışma gerçekleştirilmiştir. İlk çalışmada klasik eşikleme tabanlı yöntemler farklı renk kanalları ile birlikte kullanılarak bölütleme performansları incelenmiştir. İkinci çalışmada, harmoni arama (HA), benzetimli tavlama (BT) ve parçacık sürü optimizasyonu (PSO) yöntemlerinin Otsu eşikleme yönteminin bölütleme performansı üzerindeki etkileri incelenmiştir. Üçüncü çalışmada, kodlayıcı derinliği ve farklı renk kanallarının SegNet ağının cilt lezyon bölütleme performansı

üzerindeki etkisi incelenmiştir. Son olarak, bayes optimizasyon yöntemi ile SegNet ağıın eğitilmesinde kullanılan en iyi hiper-parametreler belirlenerek SegNet ağıının bölütleme başarımının artırılması sağlanmıştır.

Tezin organizasyonu şu şekildedir; Bölüm 1’de tezin amacı belirtilerek, melanom ve dermoskopiden kısaca bahsedilmiştir. Bölüm 2’de cilt lezyonları, melanom dermoskopi yöntemleri hakkında bilgi verilmiştir. Dermoskopi görüntülerinin analizinde dermatologa yardımcı olması için kullanılan yöntemlerden bahsedilmiştir. Bölüm 3’te tez çalışmamızda otomatik cilt lezyon bölütlemesi için kullanılan materyal ve metodlar tanıtılmıştır. Bölüm 4’te tez çalışması kapsamında yapılan 4 farklı deneysel çalışmadan bahsedilmiştir. Literatüre katkıları ve elde ettikleri başarımlar değeri gösterilmiştir. Son olarak Bölüm 5’te sonuçların tartışılması ve gelecekte yapılması planlanan çalışmalardan bahsedilmiştir.

2. CİLT KANSERİ

Bu bölümde cilt lezyonlarının biyolojik yapısı ve literatürde cilt lezyonlarının sınıflandırılmasında kullanılan yöntemler kısaca anlatılacaktır. Bu bölümde öncelikle cilt lezyonlarının genel patolojisi hakkında kısaca bilgilendirme yapılacak, sonrasında cilt kanseri ile ilgili detaylı bilgiler verilerek, teşhis ve tedavi süreci ele alınacaktır.

2.1 Melanom

Cilt üç tabakadan meydana gelmektedir. Bunlardan en üst tabaka cildimizi dış etkilerden, ısı ve su kaybından koruyan epidermis tabakasıdır. Bu tabakada, bazal hücreler dizisi, dikensi hücreler , daha yüzeyde ise granüllü hücrelerin arasında yer alan ve cilde rengini veren, cildi ultraviyole ışınların zararlı etkilerinden koruyan melanin pigmentinin salgılandığı melanosit olarak bilinen hücreler bulunur. İkinci tabaka kıl folikülleri, ter ve yağ bezleri, damarlar, sinirlerin bulunduğu dermis tabakası ve üçüncü tabaka subcutis olarak adlandırılan deri altı yağ dokusu tabakasıdır (Cancer, 2013).

Melanom cilt kanseri, epidermis tabakasında bulunan melanin pigmenti üreten melanosit hücrelerinin yapısal DNA'larında meydana gelen hasardan ötürü anormal şekilde çoğalmalarından kaynaklanır. Melanom oluşumunda çevresel faktörler,genetik özellikler ve fenotip özellikler gibi çok sayıda faktör bulunmaktadır.


2.2 Dermoskopi

Günümüzde dermoskopi yöntemi düşük maliyetli, erken teşhisi kolaylaştıran bir yöntem olarak karşımıza çıkmaktadır. Dermoskopi (derinin yüzeysel mikroskopik incelenmesi) diğer bir adı ile epidermik lüminesans (ELM), cilt saydamlığını sağlayacak bir ışık kaynağı ve standart büyütme sağlayacak merceklerden oluşan dermatoskop adı verilen bir alet yardımı ile melanomun ve pigmentli cilt lezyonlarının erken tanısında çıplak gözle görülmeyen deri yüzey ve yüzey altı yapılarının fark edilmesine olanak sağlayan bir tekniktir. Dermoskopi temaslı ve temassız olarak uygulanabilmektedir. Temassız

dermoskopi, çarpraz polarize ışık filtreleri kullanılarak uygulanabilirken temaslı dermoskopide dermoskopide dermatoskop cihazı, cilt yüzeyine sürülen jel veya yağ arayüzü yardımı ile uygulanır. Şekil 2.1 ise temaslı ve temassız dermoskoplar yardımı ile cilt lezyonlarının tespitini göstermektedir. Şekil 2.2 dermoskopi kullanmadan, temassız ve temaslı dermoskopi kullanıldığında, ışığın sergilediği optik davranışları göstermektedir.



Şekil 2.1 : Soldan sağa sırası ile temaslı ve temassız dermoskopi yardımı ile cilt lezyon bölgesinin incelenmesi (Marghoob, Ashfaq A., Braun, Ralph P., Kopf, 2012).



Şekil 2.2 : Soldan Sağa sırası ile dermoskopi kullanmadan, temaslı dermoskopi ve temassız dermoskopi kullanıldığında ışığın optik hareketleri (Marghoob, Ashfaq A., Braun, Ralph P., Kopf, 2012).


Şekil 2.2’de dermoskopi olmadan büyüteçli veya büyüteçsiz olarak yapılan klinik incelemede sadece cilt yüzeyinden yansıyan ışınlar görünebilir bu sebeple cilt altı dokularının bir çoğu görünmeden gizli kalmış olur. Polarize olmayan dermoskop ile yapılan incelemede, ışığın çoğu minimal saçılma olaylarından (kalın kırmızı çizgi) geçtikten sonra epidermisin yüzeyel tabakalarından emilir ve yansıtılır. Yansıyan veya daha derine (siyah çizgi) inen ışığın katkısı azdır ve retina daha çok minimal dağılmış ışıktan (kırmızı çizgiden) gelir. Polarize dermoskopide ise ışık kaynağında kullanılan bir polarize filtresi ve ışık dedektöründen önce kullanılan bir çarpaz polarizasyon filtresi sayesinde saçılan ışıkların elenmesi ve cildin daha derinlerine işleyip yansıyan ışıkların görünmesi böylece daha derindeki cilt bölgelerinin görselleştirilmesi sağlanır. Şekil 2.3’te ilk satır sırasıyla dermoskopi kullanılmadan elde edilen klinik fotoğraf görüntüsünü, polarize olmayan temaslı

dermoskopi görüntüsü ve ikinci satır sırası ile polarize temaslı dermoskopi ve polarize temaslı olmayan dermoskopi görüntüleri yer almaktadır.

2.3 Lezyon Değerlendirmesinde Kullanılan Yöntemler

2.3.1 ABCD kuralı

ABCD kuralı Stolz ve arkadaşları tarafından 1994 yılında ortaya atılmış olup A parametresi asimetriyi (Asymmetry), B parametresi kenarı (Border), C parametresi rengi (Color) ve D parametresi ayırt edici yapıları (Differential structures) sembolize etmek üzere toplam dört parametreden oluşmaktadır. Lezyonun dermoskopik görüntüsü bu dört parametreye göre belirlenerek risk katsayısı oluşturulur. Oluşturulan risk katsayısına toplam dermatoskopik skor (TDS) adı verilmektedir (Stolz, Reimann ve Cagnetta, 1994). ABCD kuralında A parametresi [0,2] aralığında, B parametresi [0,8] aralığında, C parametresi [1,6] aralığında, D parametresi [1,5] aralığında skorlanmakta olup, $TDS=(A*1.3)+(B*0.1)+(C*0.5)+(D*0.5)$ olarak hesaplanır. Lezyon bölgesi için hesaplanan TDS skoruna göre; $TDS<4.75$ ise melanom olma ihtimali düşük, $4.75<TDS<5.45$ ise şüpheli $TDS>5.45$ ise yüksek olasılıkla melanom tanısı konur. Çizelge 2.1 ABCD kuralını göstermektedir. Yöntemin eksisi, melanomayı düşündürecek regresyon yapıları, damarlı yapılar, sütlü kırmızı alanlar dikkate alınmamaktadır.



Şekil 2.3 : (A), klinik cilt görüntüsü (B), temaslı dermoskopi (C), polarize ışık kullanarak temassız dermoskopi (D), polarize ışık kullanmadan temassız dermoskopi ile elde edilen malign melanom görüntüleri (Benvenuto-Andrade ve diğerleri, 2007).

Çizelge 2.1 : ABCD kuralı.

Parametre	Ölçütler	Skor	Katsayı
A	Yatay ve dikey eksenlerde renk, yapı, kenar asimetrisi	[0,2]	*1.3
B	8 kenarda ani kesilen pigment yapısı	[0,8]	*0.1
C	Beyaz, kırmızı, mavi-gri, koyu kahverengi, açık kahverengi, siyah renklerin varlığı	[1,6]	*0.5
D	Homojen olmayan bölgeler, pigment ağ yapısı, noktalar, globüller, ışımsal uzantılar	[1,5]	*0.5

2.3.2 Yedi nokta kontrol listesi

Argenziano ve arkadaşları tarafından (Argenziano ve diğerleri, 2011) 1998 yılında geliştirilen bu yöntemde melanom ile ilişkili yedi (7) adet dermatoskopik özellik göz önünde bulundurularak bu özelliklere göre yeni bir puanlama sistemi ortaya konuldu. Yöntemde ele alınan yedi özelliğin üç (3) tanesi major ölçüt kalan dört (4) tanesi minör ölçüt olarak ele alınmıştır. Yöntemde, majör ölçütler skorlamada iki (2) minör ölçütler ise bir (1) puana karşılık gelmekte olup toplam skor üç (3)'ün üstünde olduğu durumlar için melanom riski yüksek olarak kabul edilir. Çizelge 2.2, yedi nokta kontrol listesini göstermektedir.

Çizelge 2.2 : Yedi nokta kontrol listesi.

Majör Ölçütler	Skor	Minör Ölçütler	Skor
Tipik olmayan pigment ağı	2	Düzensiz uzantılar	1
Tipik olmayan damar örüntüleri	2	Düzensiz pigmentasyon	1
Mavi beyaz bölgeler	2	Düzensiz globüller	1
-	-	Regresyon alanları	1

2.3.3 Üç nokta kontrol listesi

Argenziano ve Arkadaşları tarafından 2001 yılında online olarak gerçekleştirilen dermatoskopi toplantısında asimetri, tipik olmayan pigment ağı ve mavi-beyaz bölgeler olmak üzere toplam üç özelliğin melanomu diğer cilt lezyonlarından ayırmada çok önemli olduğu sonucuna varıldı. Bu özelliklerden özellikle birden fazlasının bir arada görülmesi bizi lezyon bölgesinin yüksek ihtimalle melanom olduğu kanısına götürmektedir. Çizelge 2.3, üç

nokta kontrol listesini ifade etmektedir. Buna göre toplam skor>1 ise lezyon bölgesi kuvvetle muhtemel melanomdur.

Çizelge 2.3 : Üç nokta kontrol listesi.

Ölçütler	Skor
Asimetri	1
Tipik olmayan pigment ağı	1
Mavi-Beyaz bölgeler	1

2.3.4 Menzies yöntemi

Menzies ve arkadaşları tarafından 1996 yılında, klinisyenlere yardımcı olmak adına bulunan bu yöntem dokuz (9) adet pozitif iki (2) adet negatif olmak üzere toplam onbir (11) özellik kullanarak lezyon bölgesinin melanom olup olmadığı ile ilgili çıkarım yapmayı sağlamaktadır. Pozitif özellikler; mavi-beyaz bölgeler, birden fazla kahverengi nokta, yalancı ayaklar (pseudopod), merkezden yayılan biçimdeki akışlar, yara izi benzeri depigmentasyon (renk kaybı), çevresel siyah noktalar, birden çok rengin varlığı (>5), birden çok mavi-gri nokta, genişleyen ağ ve negatif özellikler örüntünün simetrikliği ve tek renk varlığıdır. Lezyon bölgesine melanom teşhisi konulabilmesi için negatif özelliklerin hiçbirini taşıması ve en az bir tane pozitif özelliği taşıması gerekir. P ve N'yi pozitif ve negatif kümede tanımlı birer eleman olarak alırsak melanom teşhisini Denklem 2.1'de ifade edildiği gibi yapmamız mümkündür;

$$\exists P = \& \forall N = 0 \Rightarrow \text{Melanom Riski Yüksek} \quad (2.1)$$

2.3.5 CASH yöntemi

Henning ve arkadaşları tarafından 2007 yılında bulunan bu yöntem diğer yöntemlerden farklı olarak lezyon bölgesindeki yapıların tek biçimliliğine bakarak skorlama yapmaktadır. Tek biçimlilik var ise sıfır (0) puan, yer yer bozulan tek biçimlilikler için bir (1) puan ve tekbiçimlilik belirgin şekilde yok ise her bir özellik için iki (2) puan verilir. CASH yöntemine göre tabloda verilen özelliklere atanan skorların toplamı TDS>8 ise melanom riski yüksek, TDS<8 ise melanom riski düşük olarak kabul edilir.

Çizelge 2.4 : CASH yönetimi.

Parametre	Ölçütler	Skor
Mimari Düzensizlik	Yok	0
	Orta	1
	Belirgin	2
Simetri (yapı ve renk)	Çift eksenli simetri,	0
	Tek eksenli simetri	1
	Simetri yok	2
Homojenlik	Pigment ağı, globül, mavi-beyaz bölgeler, regresyon yapıları, lezyon bölgesinin %10'undan büyük lekeler, çok biçimli damarlar, uzantılar/psödopodlar	Her biri 1 puan
Renk	Mavi,beyaz, siyah, kırmızı, açık kahverengi, Koyu kahverengi	[1,5]

Sonuç olarak, dermoskopi tekniğinin ve ABCD, yedi (7) nokta kontrol listesi, üç (3) nokta kontrol listesi, Menzies yöntemi, CASH algoritması gibi çeşitli prosedürlerin kullanılması melanom erken tanı ve teşhisinde birçok fayda sağlamakla beraber bu yöntemlerin eksik yanları ve dezavantajları da vardır. İlk olarak kullanılan prosedürlerin herbir lezyon için tek tek uygulanması zaman bakımından maliyetlidir ve görüntüler çoğaldıkça bu maliyet katlanarak artmaktadır. Ayrıca lezyon görüntülerinde yapısal ve dokusal çeşitlilikten dolayı mevcut prosedürleri geniş bir yelpazede kullanmak yeterli değildir. Örneğin damarlı bölgelerin yoğun olduğu bir bölge için ABCD kuralı yetersiz kalacaktır. Bir diğer dezavantaj tüm lezyon tipleri için başarılı sonuçlar verebilen, genelleştirilebilir olduğu kabul gören bir prosedür yoktur. Farklı uzmanlar farklı prosedürleri diğerlerinde daha başarılı kabul edebilmektedir. Bunların dışında dermoskopi görüntülerini incelemek için yine bir uzman dermatoloğa ihtiyaç vardır. Dermoskopi görüntüleri her ne kadar çıplak gözle görülebilenlerden daha detaylı veriler sunabilse de uzman dermatoloğun dikkati ve tecrübesi erken teşhiste önemli bir problem olarak karşımıza çıkmaya devam etmektedir. Tüm bu eksiklikler ve dezavantajlar melanom teşhisi için otomatik tanı sistemlerine duyulan gereksinimi beraberinde getirmektedir.

3. MATERYAL VE METOD

3.1 Materyal

Yapılan çalışmada cilt lezyon veri kümeleri olarak yaygın olarak kullanılan PH2 ve ISBI 2016 veri kümeleri kullanılmıştır. PH2 veri kümesi, Portekiz’de yer alan PedroHispano Hastanesi tarafından derlenmiş 80 adet yaygın nevüs 80 adet displazitik nevüs ve 40 adet habis melanom görüntüsünden olmak üzere toplamda 200 adet dermoskopi görüntüsünden ve bu 200 görüntü için uzman dermatologlar tarafından çıkartılan gerçek referans görüntülerinden oluşan cilt lezyon veri setidir. ISBI 2016 veri kümesi Uluslararası Cilt Görüntüleme İşbirliği(The International Skin Imaging Collaboration-ISIC) tarafından derlenmiş 173’ü kötü huylu 727’si iyi huylu olmak üzere toplamda 900 adet cilt lezyonu dermoskopi görüntüsü ve bu 900 görüntü için uzman dermatologlar tarafından çıkartılan gerçek referans görüntülerinden oluşan cilt lezyon veri setidir. Çalışmalar, Intel(R) Core(TM) i5-8300 CPU @ 2.3GHZ, 8GB RAM donanımlı bilgisayarda gerçekleştirilmiştir.

3.2 Metod

3.2.1 Ön işleme


Otomatik tanı sisteminde bölütleme adımının başarımı için temiz, yumuşak, mümkün olduğunca düşük kontrast değerlerinden kurtulmuş ve sabit ışık kaynağından elde edilmiş görüntüler istenir. Görüntü üzerinde yapılan ilk işlemler yeniden boyutlandırma yapmak, görüntü üzerindeki kalıntıları silmek, görüntüye filtreler uygulamak renk sabitliğini sağlamak, görüntü keskinliğini arttırmak olarak sayılabilir.

3.2.1.1 Görüntü boyutlandırma

Çalışmada boyutları 720x538’den 2814x2110’a değişen dermoskopi görüntüleri kullanıldı. Görüntüler klasik yöntemler için 720x538’e derin öğrenme tabanlı yöntemler için 256x192 boyutlarına göre yeniden boyutlandırma yapılarak kullanıldı. Bu sayede kullanılan segmentasyon algoritmalarının çalışma sürelerinin kısaltılması hedeflendi.

3.2.1.2 DullRazor algoritması

DullRazor Algoritması kalın kılların temizlenmesinde basit ve etkili bir yöntem olup türkçeye K r Ustura olarak gemiŐ bir algoritmadır (Lee, Ng, Gallagher, Coldman ve McLean, 1997). Bu algoritmaya g re  ncelikle kıl b lgelerinin tespiti iin R,G ve B kanalları  zerinde farklı yapı maskeleri ile kapama iŐlemine tabi tutulduktan sonra elde edilen ıktılar birleŐtirilerek kıllar konumsal olarak belirlenir. Ardından kıl olan b lgelerdeki pixseller komŐuluklarında kıl olmayan pikseller ile deĐiŐtirilir. Son adımda ise deĐiŐtirilen b lge yumuŐatma(smoothing) iŐlemine tabi tutulur. Kıl silme aŐamasında yaygın olarak kullanılan ve  zellikle kalın kılların silinmesinde olduka baŐarılı bir y ntem olan (K r Ustura)DullRazor kullanılır. Dull Razor Algoritması genel olarak; kılların konumlarını belirleme, kıl piksellerinin yakınındaki bir alandan sa olmayan piksellerle deĐiŐtirilmesi, ve deĐiŐtirilen b lgenin d zeltilmesi (smooth edilmesi) aŐamalarından oluŐur. Kılların tespiti iin  ncelikle bir kıl maskesi oluŐturulur.Bu kıl maskesi, farklı renk kanalı  zerine,   farklı aıdaki yapı elemanı (0, 45 ve doksan derecelik yapısal elamanlar yeterlidir) ile kapama iŐlemi uygulanması,   renk kanalının birleŐtirilmesi ve nihai olarak bu birleŐimin orijinal g r nt  ile eŐiklenmesi sonucunda oluŐturulur. Bu kıl maskesi g r nt y  kıl ve kıl olmayan b lgeler olarak ayırır. Kıl maskesi oluŐturulduktan sonra g r lt  giderme iŐlemi ve kıl olan b lgelelerin, kıl olmayan b lgelerle deĐiŐtirilmesi ve son olarak d zeltme (smoothing) iŐlemleri yapılır. Őekil 2.1’de cilt lezyon g r nt s ne uygulanmıŐ DullRazor algoritma ıktısı g sterilmiŐtir.



Őekil 3.1 : DullRazor algoritması uygulanmıŐ g r nt .


3.2.1.3 Shades of gray

Cilt lezyon b l tlemesinde kullanılan dermoskopi g r nt leri farklı ıŐık kaynakları altında ekilmiŐ olabilirler. D zg n bir cilt lezyon b l tleme iŐlemi iin ise sabit bir ıŐık kaynaĐı altında ekilmiŐ g r nt ler  nem arz etmektedir. Farklı ıŐık kaynakları altında ekilmiŐ g r nt ler arasında renk sabitliĐi saĐlayabilmek iin gray world, max-RGB ve shades of gray algoritmaları yaygın olarak kullanılmaktadır (Barata, Celebi ve Marques, 2015). Ortalama sahne aydınlatması griye yaklaŐtıĐında gray world , maksimum beyaz ise max-

RGB algoritmaları renk sabitliği adına başarılı olmakla birlikte sahne rengi bu ikisinin arasında ise shades of gray algoritması etkili bir algoritmadır ve bu tez çalışmasında shades of gray algoritması aktif olarak kullanılmıştır. Bu algoritmalar Minkowski eşitsizliğini kullanarak sahne ışığını bulmak adına tahmini aydınlatma vektörünü oluşturmaya çalışmaktadır. Minkowski eşitsizliği kullanan shades of gray algoritması denklem 3.1'de ifade edilmiştir.

$$\left(\frac{\int (I_c(x))^p dx}{\int dx} \right)^{1/p} = ke_c \quad (3.1)$$

Denklem 3.1'de I_c , I görüntüsünün c . bileşenini, $x=(x,y)$ piksel konumunu, $k,e=[eR \ eG \ eB]^T$ 'nin Öklid normuna göre birim uzunluğuna sahip olmasını sağlayan bir normalleştirme sabitidir. P değeri minkowski normun derecesini belirtir. Burada p değeri 1 girildiğinde gray world denklemi, ∞ girildiğinde ise max-RGB denklemi elde edilir. Şekil 3.2'de cilt lezyon görüntüsüne uygulanmış shades of gray algoritmasının sonucu görülmektedir.



Şekil 3.2 : Shades of gray algoritması uygulanmış görüntü.

3.2.1.4 Ağırlık dağılımı ile adaptif gama doğrulama


Düşük kontrast değerleri otomatik cilt lezyon bölütleme algoritmaları için önemli bir sorun teşkil etmekte ve cilt lezyon görüntülerindeki ayrıntıların gizlenmesine neden olabilmektedir. Kontrast geliştirme cilt lezyon görüntülerinin bölütleme performansının yükseltilmesi için görsel kalitenin iyileştirilmesinde önemli bir rol oynamaktadır. Çalışmada gamma düzeltmesi olarak 2013 yılında Huang ve arkadaşları tarafından önerilen ağırlık dağılımı ile adaptif gama doğrulama algoritması kullanıldı (Huang, Cheng ve Chiu, 2013). Yönteme göre ilk olarak histogram analizi yapılarak görüntüye ait istatistiksel bilgiler elde edilir. Daha sonra ağırlık dağılımı kullanılarak görüntü üzerinde elde edilen değerler

yumuşatılır. Son olarak yumuşatılmış eğriler üzerinde gamma doğrulama adımı uygulanarak kontrast iyileştirme işlemi yapılır. Denklem 3.2 adaptif gama doğrulama, denklem 3.3 ağırlıklı dağılımı formülize etmektedir.

$$T(I) = I_{\max} (I / I_{\max})^{\gamma} = I_{\max} (I / I_{\max})^{1-cdf(I)} \quad (3.1)$$

$$pdf_w(I) = pdf_{\max} \left(\frac{pdf_I - pdf_{\min}}{pdf_{\max} - pdf_{\min}} \right)^{\alpha} \quad (3.3)$$

Denklem 3.2’de $T(I)$ önerilen adaptif gama doğrulama değerini, I_{\max} girdi görüntüsündeki en yüksek yoğunluk değeridir, I girdi görüntüsündeki her pikselin yoğunluk değeridir. CDF (Cumulative Distribution Function) kümülatif dağılım fonksiyonudur ve girdi görüntüsündeki her bir yoğunluk seviyesine sahip piksellerin sayısının toplam piksel sayısına bölümü olarak ifade edilen PDF (Probability Density Function) olasılık yoğunluk fonksiyonu sayesinde elde edilir. γ değeri histogram modifikasyonlarında kullanılan değişken, uyarlanabilir parametredir.



Şekil 3.3 : Adaptif Gama Doğrulaması Uygulanmış Lezyon Görüntüsü

3.2.2 Renk kanalı seçimi

Farklı renk uzayları, renk kümesini tanımlamak üzere farklı renk kümeleri ve kanallarından oluşurlar. Farklı renk kanalları görüntü ile ilgili farklı öznitelik değerleri ihtiva edebilmektedir. Bu farklı özniteliklerin görüntü bölütleme performansına etkilerini inceleyebilmek adına; tez çalışmasında yeryer RGB renk uzayı, RGB renk uzayından R,G,B, ve ortalama(RGB) kanalları ayrı ve birlikte kullanıldı yer yer ise RGB renk uzayına HSV, HSI, CIELAB renk uzaylarından kanallar eklendi.

3.2.3 Metasezgisel optimizasyon yöntemleri

3.2.3.1 Parçacık sürü optimizasyonu (PSO)

Parçacık sürü optimizasyon algoritmaları diğer metasezgisel optimizasyon algoritmaları gibi matematiksel optimizasyon modellerinin gerçek hayata uyarlanma zorluklarından dolayı ortaya çıkmış, doğadaki kuş ve balık sürülerinin yiyecek ararken sergiledikleri hareketlerin diğer bireyleri etkilemesi ve sürünün hedefine ulaşmasındaki başarımı arttırmasından esinlenerek, 1995 yılında Dr. Kennedy ve Dr. Eberhart tarafından geliştirilmiş popülasyon tabanlı bir optimizasyon modelidir (Eberhart ve Kennedy, 1995). PSO gözlemleri sonucuna göre, sürünün bir bölgede yiyecek arayışı, sürüdeki kuşların arama yapılacak bölgeye rastgele dağılımı ile başlar. Kuşlar yiyeceğin konumunu bilmezler. Sürüdeki kuşlar rasgelere yönlere yönelerek arama bölgesine yayılırlar ve yiyecek ararlar ve tekrar bir araya gelip yiyeceğin nerede olduğuna dair bilgi paylaşımında bulunurlar. Böylece sürüdeki tüm bireyler yiyeceğe en yakın bireyin pozisyonunu ve yiyeceğe kendilerinin ne kadar mesafede olduğunu bilirler. Her bir kuş elde ettiği bu bilgilerle hızını konumunu değiştirerek yiyeceğe ulaşmaya çalışır (Hu, Shi ve Eberhart, 2004). PSO, sürüdeki bireylerin birbirleriyle ve çevresiyle etkileşimleri paracık zekasını, sürüdeki her bir birey parçacığı, herbir parçacığın konumu lokal bir çözümü, herbir parçacığın konumundaki değişim miktarı parçacığın hızını temsil eder. Şekil 3.4 PSO'nun esinlendiği kuş ve balık sürülerini göstermektedir.



Şekil 3.4 : Parçacık sürüsü optimizasyonun esinlendiği davranış modelleri.

PSO algoritmasında parçacıklar, verilen bir çözüm uzayında rastgele konum ve hız değerleri olarak arama işlemine başlarlar. Her bir iterasyon sonunda bir uygunluk fonksiyonu yardımı ile her bir parçacığın uygunluk değeri hesaplanır ve en iyi uygunluk değerine (z_i) sahip parçacık belirlenir. Bunun dışında sahip olunan hafıza sayesinde her bir parçacık tüm iterasyonlar boyunca elde ettiği en iyi değeri (p_i) hafızasında tutar. Herbir parçacığın en iyi değeri ve sürüde elde edilen en iyi uygunluk değeri kullanılarak bütün parçacıkların konum

ve hız değerleri güncellenir. Bu süreç verilen çalışma kısıtları tamamlanıncaya kadar devam eder ve bu şekilde tüm bireyler verilen en iyi çözümü bulmaya çalışırlar. PSO algoritmasının adımları şu şekilde gösterilebilir;

- 1) Parçacıklar arama işlemine başlamak üzere, çözüm uzayında rastgele konum ve hız bilgileriyle dağıtılır ve ardından her parçacık için uygunluk değeri hesaplanır.
- 2) Her bir parçacık için yerel en iyi uygunluk değeri (p_i) ve sürüdeki tüm parçacıklara bakılarak genel en iyi uygunluk değeri (z_i) bulunur. Denklem 3.4 yerel en iyi uygunluğu, Denklem 3.5 genel en iyi uygunluğu göstermektedir.

$$p_i(t+1) = \begin{cases} p_i(t), & \text{ise } f(x_i(t+1)) \geq f(p_i(t)) \\ x_i(t+1), & \text{ise } f(x_i(t+1)) < f(p_i(t)) \end{cases} \quad (3.4)$$

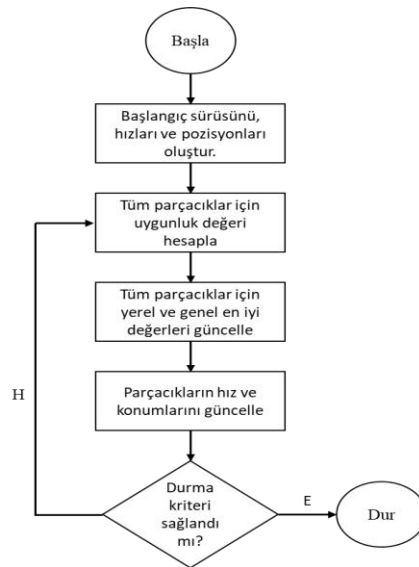
$$z_i(t) \in \{ p_1(t), p_2(t), \dots, p_m(t) \} = \min \{ f(p_1(t)), f(p_2(t)), \dots, f(p_m(t)) \} \quad (3.5)$$

- 3) Parçacıkların pozisyon ve hızları Denklem 3.6 ve Denklem 3.7 yardımı ile güncellenir. Denklem 3.6'da w ; eylemsizlik, r_1 ve r_2 0 ile 1 aralığında seçilen rastgele sayıları, c_1 ve c_2 ivmelenme katsayılarını ifade etmektedir.

$$v_i(t+1) = wv_i(t) + c_1r_1(p_i(t) - x_i(t)) + c_2r_2(z_i(t) - x_i(t)) \quad (3.6)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3.7)$$


- 4) Durdurma kriteri sağlanıncaya kadar adım 1, 2 ve 3 her iterasyonda tekrarlanır. Şekil 3.5 PSO algoritmasının akış diyagramını göstermektedir.



Şekil 3.5 : PSO akış diyagramı.

3.2.3.2 Benzetimli tavlama algoritması

Benzetilmiş tavlama algoritması, 1983 yılında Kirkpatrick ve arkadaşları tarafından önerilmiş, olasılık tabanlı ve sezgisel bir optimizasyon algoritmasıdır (Kirkpatrick, Gelatt ve Vecchi, 1987). Metallerin fiziksel tavlama işlemi ile optimizasyon sürecindeki olası çözüm uzayı arasında benzerlikten ilham alınarak oluşturulmuş olup, katıların ısıtılıp belli bir süre bekledikten sonra yavaş yavaş soğutulması esasına dayanır. Şekil 3.6’da tavlama işlemindeki ısı işlem kademeleri gösterilmektedir.



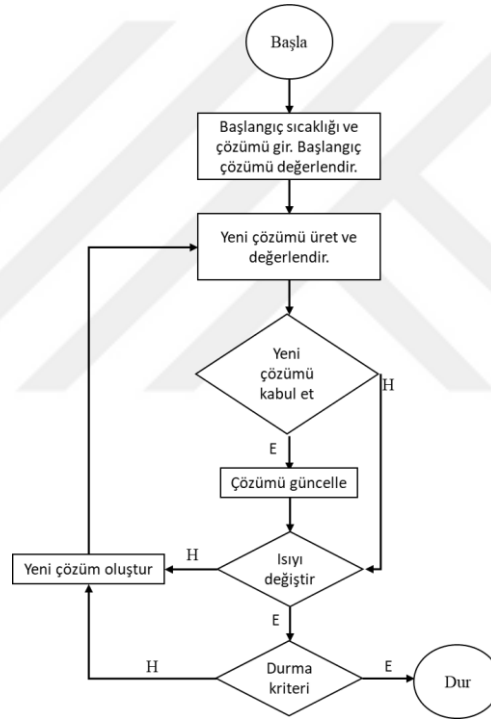
Şekil 3.6 : Isıl işlem aşamaları

ω , Ω çözüm uzayında bir başlangıç noktası, $f : \Omega \rightarrow R$ çözüm uzayında tanımlı amaç fonksiyonumuz olmak üzere, BT optimizasyon tekniğinde, çözüm $T = t_0 \geq 0$ başlangıç sıcaklığında rastgele bir ω başlangıç noktası ile başlatılır. Ardından bir N komşuluk fonksiyonu yardımı ile ω mevcut çözüm değerinden bir $\omega' \in N(\omega)$ aday çözüm değeri üretilir. $f(\omega)$ ’den $f(\omega')$ ’ne değişim istenilen yönde ise üretilen komşu çözüm mevcut çözüm olarak güncellenir. Değişim istenilen yönde olmadığı durumda komşu çözüm elenmek yerine “Metropolis Kriteri” ile elde edilen olasılık değeri yardımı ile kabul edilir (Metropolis, Rosenbluth, Rosenbluth, Teller ve Teller, 1953). Metropolis kriteri yardımı ile istenilmeyen yönde olan değişimlerin de belirli olasılıkla mevcut çözüm olarak kabul edilmesi BT’nin kritik bir noktasını teşkil eder ve yerel aramalarda yaşanan yerel en iyiyi takılıp global eniyiyi bulamamasının önüne geçer. Komşu çözüm $\omega' \in N(\omega)$ ’nin mevcut çözüm olarak seçilme olasılığı, Denklem 3.8 yardımı ile belirlenir.

$$\omega' = \begin{cases} \exp[-(f(\omega') - f(\omega))/t_k] & \text{if } f(\omega') - f(\omega) \geq 0 \\ 1 & \text{if } f(\omega') - f(\omega) \leq 0 \end{cases} \quad (3.8)$$

Denklem 3.15’te k sıcaklık değişim sayacını; t_k , sıcaklık değişim çizelgesini; T bir başlangıç sıcaklığını ve ω , Ω çözüm uzayında bir başlangıç noktasını, ω' ise ω ’nin komşuluğunda elde edilen aday çözümü ifade etmektedir. Temel bir BT optimizasyon algoritması ana hatları ile aşağıdaki gibidir;

- 1) Bir T başlangıç sıcaklık değeri üretilir.
- 2) Ω çözüm uzayında rastgele bir ω , başlangıç çözümü üretilir ve $f(\omega)$ hesaplanır.
- 3) N komşuluk fonksiyonu yardımı ile mevcut ω çözüm değerinden bir $\omega' \in N(\omega)$ aday çözümü üretilir.
- 4) $f(\omega') < f(\omega)$ ise hareket kabul edilir, değilse metropolis kriteri kullanılarak aday çözüm için kabul edilme olasılığı oluşturulur.
- 5) Yeni aday çözümler için adım 3 ve 4 tekrarlanır.
- 6) Amaç fonksiyonu minimum yapan ω^* değeri bulunur.
- 7) Durdurma koşulu sağlanıncaya kadar T sıcaklık değeri azaltılıp adım 2-adım 6 arası tekrarlanır



Şekil 3.7 : Benzetimli tavlama algoritması akış diyagramı.

3.2.3.3 Harmoni arama algoritması

Geem ve arkadaşları tarafından 2001 yılında geliştirilen harmoni arama algoritması müzisyenlerin çaldığı notalardan esinlenerek geliştirilmiş ve en iyi melodinin elde edilmesini amaçlayan metasezgisel temelli bir algoritmadır (Geem, 2001). Nasıl ki müzisyen müzik yaparken notaları farklı dizilerde kullanarak güzel bir melodi oluşturmaya çalışıyor ve güzel melodi yakaladığında bunu kaydediyor ise harmoni arama optimizasyonda da her bir değişken çözüm kümesinden değerler ile başlar ve bu değerler birlikte bir çözüm vektörünü oluştururlar. Eğer bu çözüm vektörü iyi bir harmoni oluşturursa kaydedilir, kötü bir harmoni

oluşturursa atılır ve yeni bir çözüm vektörü oluşturulur. Bunun yanında bazen müzisyenler yeni harmoni oluşturmak yerine, eski harmoni üzerinde bazı notaların yerlerini değiştirerek veya bazı notaları değiştirerek te güzel harmoni yakalayabilir. Aynı şekilde harmoni aramada da çözüm vektöründeki bir veya birden çok çözüm değişkeni yerdeğiştirebilir veya kaldırılıp yerine yeni değişken atanabilir. Yöntemin önemli bir avantajı arama uzayını küçültmemesi böylece lokal minimumdan sakınmada başarılı olmasıdır. Algoritmada HMS harmoni bellek miktarı, HMCR harmoni belleğini dikkate alma oranı, PAR ton ayarlama oranı olarak ifade edilir. Harmoni arama algoritmasının ana hatları aşağıdaki gibidir;

1: Problem ortaya konulur, optimizasyonu yapılacak amaç fonksiyon oluşturulur ve harmoni arama için çözüm parametreleri belirlenir.

2: Çözüm uzayı göz önünde bulundurularak, HA hafızası oluşturulur; Denklem 3.9 çözüm vektörlerinden oluşan bir HA hafızasını gösterir.

$$\begin{bmatrix} x_1^1 & x_2^1 & \dots & x_N^1 \\ x_1^2 & x_2^2 & \dots & x_N^2 \\ \dots & \dots & \dots & \dots \\ x_1^{HMS} & x_2^{HMS} & \dots & x_N^{HMS} \end{bmatrix} = \begin{bmatrix} f(x^1) \\ f(x^2) \\ \dots \\ f(x^{HMS}) \end{bmatrix} \quad (3.9)$$

Denklem 3.9'da, x parametresi çözüm uzayındaki çözüm değişkenlerini, f , çözüm uzayındaki çözüm değişkenleri kullanılarak oluşturulan her bir harmoni için inşa edilen amaç fonksiyonu ifade etmektedir. Çözüme karşılık gelen amaç fonksiyon çıktıları Denklem 3.9 yardımı ile hesaplanır.

3: Yeni harmonilerin oluşturulması. Yeni harmonilerin oluşturulması adımında harmoniyi oluşturan çözüm değişkenlerinin harmoni belleğinde bulunan çözüm değişkenlerinden mi seçileceği yoksa harmoni belleği dışında fakat çözüm uzayı içinde bulunan değişkenlerden mi seçileceğine HA'nın HMCR parametresi yardımı ile karar verilir. Denklem 3.10, yeni harmoninin nereden seçileceğine karar vermede kullanılan HMCR parametresinin seçimi nasıl gerçekleştirdiğini göstermektedir.


$$x'_i = \begin{cases} x'_i \in \{x_i^1, x_i^2, \dots, x_i^{HMS}\} & \text{HMCR rassal} \\ x'_i \in X_i & \text{diğer rassal} \end{cases} \quad (3.10)$$

HMCR ile harmoni vektörüne yeni çözüm değişkenleri eklendikten sonra eklenen herbir değişen için tonlamaya gereksinim olup olmadığına bakılır. Bu adım PAR parametresi yardımı ile gerçekleşir. Denklem 3.11 PAR parametresi yardımı ile tonlama yapılıp yapılmayacağına nasıl karar verileceğini ifade eder.

$$x'_i = \begin{cases} x' \pm Rnd(0;1) * bw & PAR \\ x'_i & diger \end{cases} \quad (3.11)$$

Denklem (3.11)'de, bw rassal olarak elde edilen bant genişliğini; $Rnd(0;1)$, 0 ile 1 arasında rassal olarak üretilen sayıyı ifade etmektedir. Uygun yeni harmoni oluşturma işlemi HMCR ile yeni çözüm değişkenlerinin eklenmesi ve PAR ile eklenen değişkenlere tonlama yapıp yapılmayacağına karar verilmesinin ardından, elde edilen uygun $x' = (x'_1, x'_2, \dots, x'_N)$ biçimindeki harmonilerle son bulmuş olur.

4: Bu adımda oluşturulan yeni harmoninin, bellekte tutulan en kötü harmoniden iyi olup olmadığına bakılır ve eğer yeni harmoni bellekteki en kötü harmoniden iyise atılır ve yeni harmoni oluşturulur. Yeni harmoni bellekteki en kötü harmoniden iyise bellekteki en kötü harmoni atılır ve yeni üretilen harmoni belleğe alınır. Adım 3 ve 4 sonlandırma kriteri sağlayıncaya kadar tekrar eder. Şekil 3.8 HA yönteminin akış diyagramını göstermektedir.




Şekil 3.8 : Harmoni arama yöntemi akış diyagramı.

3.2.4 SegNet

SegNet sinir ağı, Cambridge Üniversitesi bilgisayar görmesi ve robotik grubu üyelerince geliştirilen, anlamsal piksel bilgi etiketleme yada anlamsal bölütleme için kullanılan evrimsel sinir ağının (CNN) bir versiyonudur (Badrinarayanan, Kendall ve Cipolla, 2017).

Şekil 3.9'da gösterildiği gibi SegNet, karşılık gelen bir kod çözücü ağına sahip bir kodlayıcı ağı ve ardından son piksel olarak bir sınıflandırma katmanını içerir.



Şekil 3.9 : SegNet ağının mimarisi.

Kodlayıcı ağı, VGG16 ağında bulunan ilk 13 evrişimsel katman ile aynı olan 13 evrişimli katmandan oluşur (Simonyan ve Zisserman, 2015). Bu tür kodlayıcı ağını kullanarak SegNet, tamamen bağlı katmanları atlayabilir. Buna karşılık, daha yüksek çözünürlüklü özellik haritaları kodlayıcı ağında daha derin tutulabilir. Bu aynı zamanda kodlayıcı ağının (Shelhamer, Long ve Darrell, 2017) ve (Noh, Hong ve Han, 2015) 'te bulunan diğer mimarilere kıyasla kullanılan parametre sayısını önemli ölçüde azaltmasına izin verir. Kod çözücü ağı ayrıca her bir kodlayıcı katmanı karşılık gelen bir kod çözücü katmanına sahip olduğu için 13 katmandan oluşur. Son kod çözücü katmanının çıktısı daha sonra bir görüntüdeki her piksel için sınıf olasılıklarını üreten çok sınıflı bir Soft-Max sınıflandırıcıya beslenir.

Kodlayıcı ağına daha yakından bakıldığında, her kodlayıcı katmanı bir dizi özellik haritası üretmek için bir filtre bankası ile bir evrişim gerçekleştirir. Bu özellik haritaları daha sonra bir Batch Normalization (BN) katmanına ve oradan da Rectified Linear Unit (RELU) katmanına gönderilir. Burada Relu fonksiyonu öğrenme için aktivasyon fonksiyonu olarak görev yapar ve 0'dan büyük girdiler için girdi değerini küçük girdiler için ise 0 değerini döndürerek sinir hücrelerinin aktifleşmesi için gerekli koşulu yerine getirir. BN ve RELU adımlarını takiben, maksimum havuzlama, 2 adımlı bir 2x2 pencere kullanılarak gerçekleştirilir. Bu, görüntünün uzamsal boyut temsilini azaltarak ağıdaki parametre ve hesaplama miktarını düşürür, böylece daha verimli hesaplamalar elde edilir. Girilen görüntüyü alt örnekleyerek, özellik haritasındaki her piksel için görüntünün daha geniş bir içeriği kapsanabilir. Maksimum-havuzlama ve alt örnekleme birkaç katmanı daha fazla çeviri değişmezliği elde edebilse de, bu yaklaşım özellik haritalarında uzamsal çözünürlükte, özellikle sınır detaylarında önemli kayıplara neden olur. Sonuç olarak, herhangi bir alt

örnekleme gerçekleştirilmeden önce görüntüdeki sınır bilgilerinin yakalanması ve kodlayıcı ağının özellik haritalarında saklanması gerekir. Bu sınırlamanın üstesinden gelmek için, SegNet, her bir kodlayıcı özellik haritasından maksimum havuzlama indekslerini, her havuzlama penceresindeki maksimum özellik değerinin konumlarını yeniden kullanır. Bu, SegNet'i U-Net'e kıyasla çok daha fazla bellek verimli hale getirir, çünkü yalnızca maksimum havuzlama indeksleri tüm kodlayıcı özelliklerinin aksine kopyalanır. SegNet ayrıca ağın kod çözücü kısmında maksimum havuzlama indekslerini kullanabilir.

Mimarinin kod çözücü ağının her bir kod çözücüsü, giriş özellik haritalarını yukarı örnekleme için karşılık gelen kodlayıcı özellik haritasından maksimum havuzlama indekslerini kullanabilir.

SegNet, özellik haritasının tamamını öğrenmeden özellik haritası üzerinde örnek sıklama (upsampling) yapmak için maksimum havuzlama indekslerini yeniden kullanabilir. Bu yukarı örneklenmiş özellik haritaları, daha sonra yoğun özellik haritaları üretmek için, eğitilebilir bir kod çözücü filtre bankası ile evrişim (convolution) işlemine tabi tutulur. Yoğun özellik haritaları da toplu olarak normalleştirilir. Bu işlem ağın nihai kod çözücüsüne ulaşılan kadar tekrarlanır. Son kod çözücünün çıktısı daha sonra her bir pikseli bağımsız olarak sınıflandırabilen eğitilebilir bir Soft-Max sınıflandırıcıya beslenir. Soft-Max sınıflandırıcı olasılıkların bir K kanal görüntüsünü verir; burada K görüntüde bulunan sınıfların sayısına karşılık gelir. Daha sonra her piksel, öngörülen bölütleme ile sonuçlanan maksimum olasılıkla sınıfa atanır. Böylece, öngörülen sınıf etiketlerini temsil eden parçalı bir görüntü üretilir.

3.2.5 Otsu eşikleme

1979 yılında Nobuyuki Otsu tarafından önerilen yöntem, sınıflar arası varyans ölçütüne dayanan ve gri seviyeli görüntüler üzerinde uygulanan eşikleme tabanlı yöntemlerdendir (Otsu, 1973). Bu yöntemin cilt lezyonlarına uygulanmasında görüntü lezyon bölgesi ve arka plan olarak iki sınıfa ayrılır ve bu iki sınıfı birbirinden en iyi şekilde ayıran eşik değeri hesaplanmaya çalışılır. Bunun için görüntü gri seviyeye dönüştürülür ve histogramı elde edilir. Elde edilen histogramda 1'den 255'e kadar olan gri seviye değerleri içinde görüntüyü en iyi ayıran eşik değerini bulmak için sırası ile eşik değeri belirlenir ve belirlenen eşik değerine göre görüntü iki sınıfa ayrıştırılır. Bu aşamada sınıf içi varyans değerini minimum yapan değer ya da sınıflar arası varyansı maksimum yapan değer en iyi eşik değeri olarak seçilir. Çalışmamızda, hesaplama kolaylığından dolayı sınıflar arası varyansı maksimum


yapan değer hesaplanarak eşikleme yapıldı. İteratif olarak gri seviye değerleri ([0 , 255]) eşik değeri olarak alınıp sınıflar arası varyans değeri hesaplandı ve maksimum varyans değerine atandı. Sonraki gri seviye değeri için hesaplanan sınıflar arası maksimum varyans değeri öncekinden büyük ise gri seviye değeri arttırılarak maksimum varyans değeri güncellendi. Sonraki gri seviye değeri için hesaplanan sınıflar arası maksimum varyans değeri öncekinden küçük ise gri seviye değeri arttırılarak maksimum varyans değerinde güncelleme işlemi uygulanmadı. Denklem 3.12, 3.13 ve 3.14 histogram eşiklemesi için Otsu eşikleme yönteminde kullanılan denklemleri göstermektedir.

$$\eta = \frac{\sigma_B^2}{\sigma_T^2} \quad (3.12)$$

$$\sigma_B^2 = P(C_0)P(C_1)(\mu_0 - \mu_1)^2 \quad (3.13)$$

$$k^* = \operatorname{argmax}_B^2(k) \quad 1 < k < L \quad (3.14)$$

Denklem 3.12'de ; σ_B^2 , sınıflar arası varyans değerini, σ_T^2 , görüntünün toplam varyans değerini gösterir. Görüntüdeki toplam varyans değeri sabit olduğundan sınıflar arası varyans değeri arttıkça bölütleme performansı artacaktır. Denklem 3.13, C_0 ve C_1 sınıfları için sınıflar arası varyans değerini; μ_0 ve μ_1 ise sınıfların ortalama gri seviye değerlerini gösterir. Şekil 3.14 Görüntünün histogramı yardımı ile Otsu eşiklemesinin uygulanması ve görüntünün bölütlenmesini gösterir.



Şekil 3.10 : Otsu eşikleme için (a) görüntü histogramı (b) eşik değeri (c) bölütlenmiş görüntü.

3.2.6 Kapur yöntemi

Kapur yönteminde, Otsu yönteminde olduğu gibi resmin gri seviye histogramı elde edilerek, histogram bilgisine göre en iyi eşik değeri hesaplanmaya çalışılır (Pun, 1980). Kapur yöntemi en iyi eşik değerini, Otsu Yönteminden farklı olarak, varyans bilgisine göre değil entropi bilgisine bakarak bulmaya çalışır. Çalışmamızda görüntü lezyon bölgesi ve lezyon olmayan bölge olarak iki sınıfa ayrıştırılır. 0 siyah, 255 beyaz olmak üzere her bir gri seviye

değeri için iteratif olarak entropi değeri hesaplanır. Çalışma bitene kadar her iterasyonda elde edilen entropi değeri önceki entropi değerinden büyükse maksimum entropi değeri güncellenir ve sonraki iterasyon geçer. Entropi değeri önceli entropi değerinden küçük ise maksimum entropi güncellenmez ve iterasyon artırılır. Tüm iterasyonlar bittiğinde, elde edilen maksimum entropi değeri görüntüyü sınıflara ayırmakta kullanılacak eşik değeri olarak kullanılır. Denklem 3.4, 3.5 ve 3.6 kapur yönteminde kullanılan denklemleri ifade etmektedir.

$$J(t) = H_0 + H_1 \quad (3.15)$$


Denklem 3.15'te H_0 ve H_1 lezyon bölgesi ve arka plan olmak üzere iki sınıfın entropi değerlerini temsil etmekte olup detayları Denklem 3.16 ve 3.17'da verilmiştir. Çalışmamızda Shannon entropi kullanılmış olup denklemi 3.18'de gösterilmiştir.

$$H_0 = - \sum_{i=0}^{t-1} \frac{P_i}{W_0} \cdot \ln \frac{P_i}{W_0} \cdot W_0 = \sum_{i=0}^{t-1} P_i \quad (3.16)$$

$$H_1 = - \sum_{i=t}^{L-1} \frac{P_i}{W_1} \cdot \ln \frac{P_i}{W_1} \cdot W_1 = \sum_{i=t}^{L-1} P_i \quad (3.17)$$

$$H(x) = - \sum_{i=0}^{N-1} P_i \cdot \log_2 P_i \quad (3.18)$$

Denklem 3.16 ve 3.17 da H_0 lezyon sınıfının entropisini, H_1 lezyon olmayan sınıfın entropisini, t değeri eşik değerini P_i i'inci gri seviyenin görülme olasılığını, W_0 lezyon sınıfındaki tüm gri seviyelerin görülme olasılıklarının toplamını, W_1 lezyon olmayan sınıftaki tüm gri seviyelerin görülme olasılıklarının toplamını ifade eder. Şekil 3.11 görüntünün histogramı yardımı ile Kapur eşikleme uygulaması ve görüntünün bölütlenmesini göstermektedir.



Şekil 3.11 : Kapur yöntemi için (a) görüntü histogramı (b) eşik değeri (c) bölütlenmiş görüntü.

3.2.7 Minimum hata eşikleme yöntemi

1986 yılında Kittler ve Illingworth tarafından önerilen bu yönteme göre görüntü üzerindeki farklı nesnelerin farklı standart sapma ve varyans değerlerinin olacağı tezi öne sürülmüş olup, görüntünün gri seviye istatistik değerler bilindiği takdirde istatistiksel karar teorisi sonuçları kullanılarak minimum hata eşiklerinin elde edilebileceği savunulmuştur (Kittler ve Illingworth, 1986; Zhou ve Zong, 2009). Bu şekilde görüntü histogramı, lezyon bölgesi olarak belirlenen sınıfa ait olan piksellerin ve lezyon olmayan bölge olarak belirlenen sınıfa ait piksellerin gri seviyelerinden oluşan bir karışımın olasılık yoğunluk fonksiyonu olarak değerlendirilir. Ardından görüntüye ait histogram dağılımının normal dağılıma uyduğu düşünülerek histogram dağılımının normal dağılıma göre farkı hata olarak döndürülür. Böylece, hata oranı düşürüldükçe görüntüyü ayıran en iyi eşik değerine yaklaşılr.


Kittler ve Illingworth'un minimum hata algoritmasına göre, histogram $h(g)$, gri düzeylerde nesne ve arka plan piksellerini içeren karışım popülasyonu olan $p(g)$ olasılık yoğunluğu fonksiyonunun bir tahmini olarak görülür. Burada $g = [0, 255]$ aralığındaki gri seviye değerlerini ve $i = \{0,1\}$ olmak üzere iki sınıfı temsil etmek koşulu ile, karışım fonksiyonu $P(g|i)$ 'nin her iki sınıf için, normal dağılıma uyacak şekilde ortalama μ_i , standart sapma σ_i ve prior olasılık p_i ile dağıtıldığı varsayılır. Denklem 3.19 ve 3.20 olasılık yoğunluk fonksiyonu ve normal dağılım denklemlerini göstermektedir.

$$P(g) = \sum_{i=1}^2 P_i \cdot p(g|i) \quad (3.19)$$

$$p(g|i) = \frac{1}{\sqrt{2\pi\sigma_i}} \cdot \exp\left(-\frac{(g - \mu_i)^2}{2\sigma_i^2}\right) \quad (3.30)$$

Tez çalışmamızda, Poisson dağılımını Normal dağılım yerine kullanıp eşikleme başarımına etkileri test edildi. Poisson dağılımı formülü Denklem 3.21'de gösterildiği gibidir;

$$f(k, \lambda) = \frac{\lambda^k \cdot e^{-\lambda}}{k!} \quad (3.41)$$



Şekil 3.12 : Minimum hata eşikleme yöntemi için (a) görüntü histogramı (b) eşik değeri (c) bölütlenmiş görüntü.

Burada Euler sayısı, e ; olasılığı fonksiyon ile verilmekte olan olayın ortaya çıkma sayısı, k ve verilen sabit aralıkta ortaya çıkma sayısının beklenen değeri, λ ile ifade edilir. Şekil 3.12 görüntünün histogramı yardımı ile minimum hata eşikleme yönteminin uygulanması ve görüntünün bölütlenmesini gösterir.

3.2.8 Bayes optimizasyon

2012 yılında Ryan Adams ve arkadaşları tarafından ileri sürülen bayes optimizasyonu (BO) doğrusal olmayan ve matematiksel denklemlerle çözümü zor olan problemlerde yaygın olarak kullanılan hızlı ve etkili bir olasılıksal optimizasyon yöntemidir. Matematiksel olarak ifade etmek gerekirse Denklem 3.22'de gösterilen minimizasyon veya maksimizasyon problemlerini çözmek için kullanılır;

$$X^* = \arg \min_{x \in X} f(x) \quad (3.52)$$

Bayes optimizasyonun çoğu optimizasyon algoritmalarından farklı yanı olasılıksal bir model oluşturarak çözüm uzayında, gelecekteki en iyi amaç fonksiyonu veren değişkeni bulmaya çalışırken bu olasılık modelinden faydalanmasıdır. Bu sayede elde edilmek istenen amaç fonksiyondan sapmayı minimize ederek en iyi çözümü bulmaya çalışan metodların düştüğü en kötü durum yaklaşımındaki maliyet artışı gibi sorunlar ile karşılaşmaz. Bayes optimizasyonu temel olarak amaç fonksiyon üzerinde bir prior dağılımın tanımlanması ve elde etme fonksiyonu olmak üzere iki bileşenden oluşur (Brochu, Cora ve de Freitas, 2010). Prior dağılımı, bu tez çalışmasında derin öğrenme tabanlı Seg-Net ağının hiper parametrelerini girdi olarak alan çıktı olarak ilgili ağın kayıp değerini tahmin eden bir fonksiyon olarak kullanıldı. Burada yaygın olarak prior Gauss Süreci kullanıldı. İkinci bileşen olan Elde Etme Fonksiyonu ise, model sonrası(model posterior), bir sonraki değerlendirilecek noktanın hangisi olduğunu belirlememizde kullanılır. Yine tez çalışmamızda Seg-Net ağında göz önünde bulundurulacak bir sonraki hiper parametre setini belirlemek için kayıp fonksiyonu modelini örneklemede kullanılır.

$f : X \rightarrow R$ olacak şekilde kullanılan Gaussian süreci , fonksiyonlar üzerinde güçlü, esnek, uyarlaması kolay, aşırı uyuma yakalanma ihtimali düşük prior dağılımlardır. Gauss sürecini şu matematiksel olarak tanımlamak gerekirse ; X sınırlı bir küme olmak üzere, X kümesi üzerinde, $\{x_n \in X\}_{n=1}^N$ şeklinde verilen N adet nokta, R^N üzerinde çok değişkenli bir Gauss

dağılımına yol açar. N adet noktadan, n 'incisi $f(x_n)$ fonksiyon değeri olarak alınır ve Gauss Dağılımı yardımıyla kapalı formda hesaplanır. Neticede meydana gelen dağılımın fonksiyonlara katkısı, $X \times X$ 'ten R 'ye tanımlanmış belirli bir pozitif $K: X \times X \rightarrow R$ kovaryans fonksiyonu ve X 'ten R 'ye tanımlanmış bir $m: X \rightarrow R$ ortalama fonksiyonu ile belirlenir. Denklem 3.23 ve 3.24, Gauss Prosesine ait ortalama fonksiyonunu ve öngörücü(predictive) kovaryans fonksiyonunu gösterir;

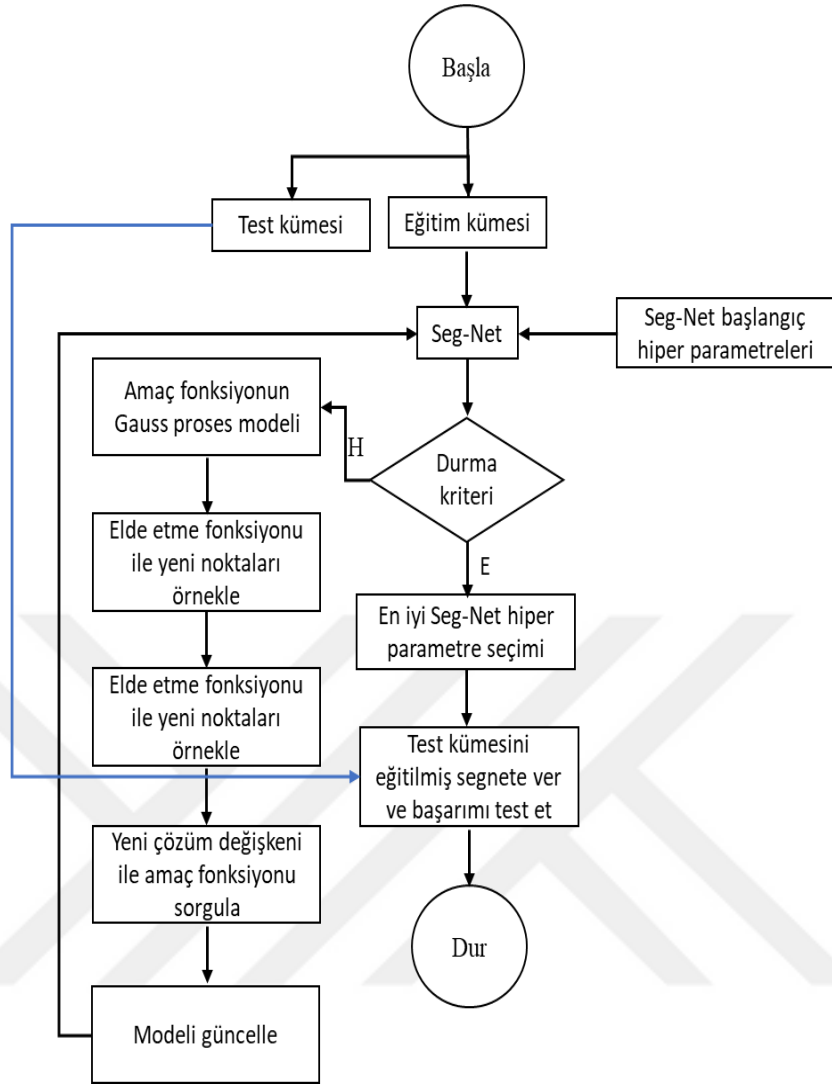
$$\mu(x; \{x_n, y_n\}, \theta) = K(X, x)^T K(X, X)^{-1} (y - m(X)) \quad (3.63)$$

$$\Sigma(x, x'; \{x_n, y_n\}, \theta) = K(x, x') - K(X, x)^T K(X, X)^{-1} K(X, x') \quad (3.74)$$

Gauss proses kullanarak $f(x)$ fonksiyonumuzu elde ettikten ve N adet nokta için gözlem yaptıktan sonra elde edilen veriler ile prior fonksiyonlar üzerinde posterior bilgi çıkartabiliriz. Elde etme fonksiyonu olarak adlandırdığımız, $a: X \rightarrow R^+$ şeklinde gösterilen bu fonksiyon, X çözüm kümesinde hangi çözüm değişkeninin sonraki adımda hesaplanacağını belirler. Bu amaçla bayes optimizasyonda probability of improvement, expected improvement, gaussian process upper confidence bound gibi elde etme fonksiyonları sıklıkla kullanılmaktadır. Denklem 3.22 elde etme fonksiyonlarından expected improvement fonksiyonunun denklemini gösterir;

$$EI(x \setminus D) = \int_{f_{best}} (y - f_{best}) p(y \setminus x, D) dy \quad (3.85)$$

Şekil 3.13 BO algoritması ile Segnet ağıının optimizasyon akış diyagramını gösterir.



Şekil 3.13 : Bayes optimizasyonu ile Segnet ağına optimizasyonu.

4. DENEYSEL SONUÇLAR

4.1 Performans Ölçütleri

Dermoskopi görüntülerinde elde edilen bölütleme sonuçlarının başarımlarının değerlendirilmesi, uzman hekim tarafından lezyon bölgesinin tespit edildiği referans(ground truth) ile elde edilen bölütleme çıktılarının karşılaştırılması neticesinde elde edilir. Tez çalışmasında karmaşıklık matrisinden elde edilen doğruluk, hassasiyet, özgüllük, dice skor ve jaccard skor gibi performans matrislerinin yanı sıra, iki vektör arasındaki açıya bakarak benzerlik sonucu üretmeye yarayan cosinüs benzerliğinden yararlanıldı. Karmaşıklık matrisi kesin referans ile elde edilen bölütleme çıktılarını karşılaştırarak önerilen modelin başarımlarını ölçmemize yardımcı eder. Çizelge 4.1 karmaşıklık matrisini göstermektedir.

Çizelge 4.1 : Karmaşıklık Matrisi.

		Model Çıktısı	
		Pozitif	Negatif
Kesin Referans	Pozitif	DP	DN
	Negatif	YP	YN

Bu tabloda, doğru pozitifler (DP): Pozitif sınıfa ait olan ve pozitif sınıfa doğru bir şekilde dahil edilen piksellerdir. Doğru negatif (DY), negatif sınıfa ait olan ve negatif sınıfa doğru bir şekilde dahil edilen piksellerdir. Yanlış pozitifler (YP), negatif sınıfa ait olan ve pozitif sınıfa yanlış bir şekilde dahil edilen piksellerdir. Yanlış negatifler (YN), pozitif sınıfa ait olan ve negatif sınıfa yanlış bir şekilde dahil edilen piksellerdir.

Çizelge 4.2 : Bölütleme için kullanılan performans ölçütleri.

Doğruluk (Accuracy):	Hassasiyet (Sensitivity):	Jaccard katsayısı:
$AC = \frac{DP + DN}{DP + YP + DN + YN}$	$SE = \frac{DP}{DP + YN}$	$JA = \frac{DP}{DP + YP + YN}$

Özgüllük (Specificity):

$$SP = \frac{DN}{DN + YP}$$

Dice katsayısı:

$$DI = \frac{2 * DP}{2 * DP + YP + YN}$$

Kosinüs benzerliği

$$Cos\theta = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \|\vec{B}\|}$$

Karmaşıklık matrisi kullanılarak elde edilen doğruluk, hassasiyet, özgüllük, dice skoru, jaccard skoru ve kosinüs benzerliği denklemleri Çizelge 4.2’de gösterildiği gibi hesaplanır.

4.2 Tez Kapsamında Yapılan Deneysel Çalışmalar

Tez çalışması temel olarak 4 farklı deneysel çalışmadan oluşmaktadır. Birinci çalışmada klasik eşikleme tabanlı yöntemlerin farklı renk kanalları yardımı ile cilt lezyon bölütleme başarımları incelenerek en iyi renk kanalı ve cilt lezyon bölütlemesinde hangi klasik eşikleme metodunun daha performanslı olduğu incelendi. İkinci çalışmada, metasezgisel yöntemler klasik otsu eşiklemesine uygulanarak bölütleme performansı ve bölütleme süresine göre klasik yöntem ile kıyaslama gerçekleştirildi. Üçüncü çalışmada derin öğrenme temelli yöntemlerden SegNet ağı farklı derinlikler, farklı renk kanalları ve ön işleme adımları kullanılarak cilt lezyon bölütlemesine katkıları gözlemlendi. Ve son çalışmada SegNet ağına Bayes Optimizasyon kullanılarak hiper parametre optimizasyonu gerçekleştirildi ve ağ optimizasyonunun SegNet mimarisinin bölütleme performansına katkısı değerlendirildi.

4.2.1 Renk kanallarının eşikleme tabanlı yöntemlerin performansı üzerine etkisi

Tez çalışması kapsamında yapılan ilk çalışmada, dermoskopi yöntemi ile elde edilmiş cilt lezyon görüntüleri farklı renk kanalları kullanılarak eşikleme tabanlı yöntemler yardımı ile bölütlenmiştir. Farklı renk kanallarının ve farklı eşikleme yöntemlerinin bölütleme performansına etkileri incelenmiştir.

Ön işleme adımında kıl silme ve siyah çerçeve silme algoritmaları kullanılan lezyon görüntüleri daha sonra kırmızı, yeşil, mavi ve gri renk kanalları kullanılarak eşikleme işlemine tabi tutuldu. Otsu, kapur ve minimum hata eşikleme yöntemleri kullanılmıştır. Çalışma ISBI 2016 veri kümesinden alınan 30 adet lezyon görüntüsü üzerinde gerçekleştirilmiştir. Çalışmanın literatüre katkıları aşağıdaki gibi özetlenebilir.

- Kapsam olarak literatürde varyans tabanlı, entropi tabanlı ve hata tabanlı yöntemlerin bir arada sunulup performans karşılaştırmasının yapıldığı çalışma bulunmamaktadır.


Çalışma farklı eşikleme tabanlı yöntemlerini bir arada değerlendirmesi bakımından literatürdeki öncü çalışmalardan biridir.

- Genel olarak cilt lezyon bölütlemesinde minimum hata tabanlı eşikleme yöntemleri hata değeri belirlenirken kendilerine Gauss dağılımını kullanılırken, yapılan çalışmada Poisson-dağılımı tabanlı minimum hata eşikleme algoritması kullanılmıştır.

Performans ölçütü olarak kosinüs benzerliği kullanılan çalışmada, 30 görüntü için sınıflar arası varyans değerini kullanan Otsu eşikleme yöntemi, entropi kazancı kullanan Kapur eşikleme yöntemi ve Poisson dağılıma göre minimum hata değeri kullanan minimum hata eşikleme yönteminin farklı renk kanallarında elde ettiği ortalama kosinüs benzerliği (KB) değerleri Çizelge 4.3’de gösterilmiştir.

Çizelge 4.3 : Otsu, kapur ve minimum hata eşiklemesinin renk kanallarına göre başarımı.

Kanal	OTSU				KAPUR				MINIMUM ERROR			
	K	Y	M	Gri	K	Y	M	Gri	K	Y	M	Gri
KB	0.781	0.884	0.906	0.871	0.703	0.847	0.868	0.824	0.564	0.775	0.869	0.811



Şekil 4.1 : Her bir görüntü için bölütleme başarımları.


Çizelge 4.3 ve Şekil 4.1 incelendiğinde renk kanalları içerisinde en iyi sonuç mavi kanalda elde edilmiş olup bu mavi kanalın cilt lezyon bölütlemesinde yeşil gri ve kırmızı kanallara göre daha anlamlı olduğunu göstermiştir. Ayrıca kullanılan eşikleme yöntemleri yakın sonuçlar verse de mavi kanal incelendiğinde otsu metodunun diğer iki metoda göre daha iyi sonuç verdiği görülmüştür. Daha sonra minimum hata gelse de kapur metoduyla çok yakın değerlerde olduğu için anlam ifade edebilecek bir üstünlük sağlanamadığı gözlemlenmiştir.

4.2.2 Klasik otsu temelli metasezgisel yöntemlerin cilt lezyon bölütlemesine etkisi

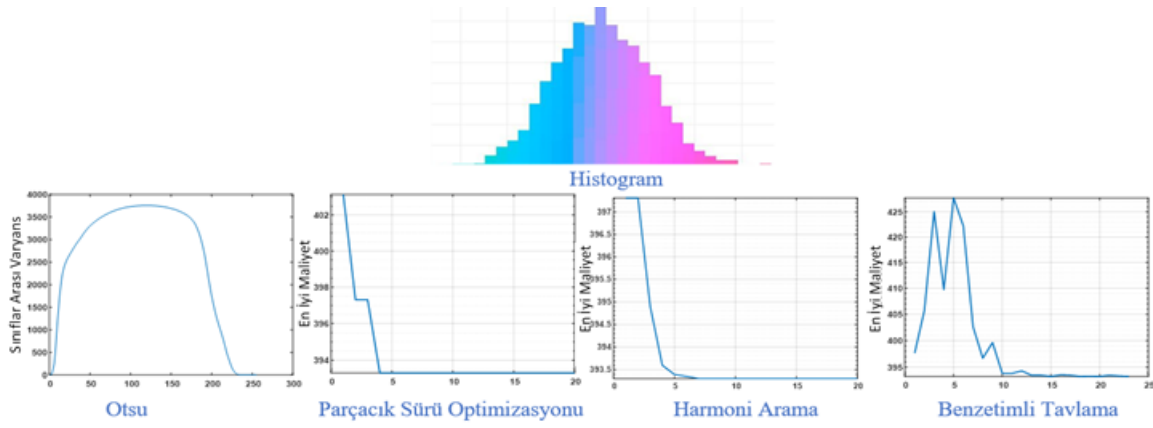
Tez kapsamında yapılan ikinci çalışmada, dermoskopi yöntemi ile elde edilmiş cilt lezyon görüntülerinin histogram bilgileri hesaplanarak, maksimizasyon ve minimizasyon problemi olarak ele alınan klasik otsu yöntemini amaç fonksiyonu olarak kullanan metasezgisel temelli HA, PSO ve BT optimizasyon algoritmaları yardımıyla bölütlenmiştir. Çalışmada ISBI veri kümesinden alınan görüntüler kullanılmıştır.

Adil karşılaştırma için metasezgisel temelli yöntemler yaklaşık 20 iterasyon boyunca çalıştırılmıştır. PSO algoritmasında, parametre değerleri parçacık sayısı=10, birey ivmelenmesi=2 ve popülasyon ivmelenmesi=2 olarak belirlenmiştir. HA algoritmasında, parametre değerleri HMS=10, HMCR=0.8, PAR=0.4 olarak belirlenmiştir. SA algoritmasında ise parametre değerleri, başlangıç sıcaklığı $T=100$, soğutma değeri $T*0.7$ ve durma sıcaklığı $(1e-2) * 4$ olarak belirlenmiştir. Şekil 4.2 önerilen yöntemin akış şemasını göstermektedir. Çalışmanın literatüre katkıları aşağıdaki gibi özetlenebilir.

- Cilt lezyonları üzerinde klasik otsu, popülasyon temelli metasezgisel yöntem ve popülasyon temelli olmayan metasezgisel yöntemlerin bir arada karşılaştırılması, kapsam genişliği açısından bakıldığında literatürde gerçekleştirilen ilk çalışmalardan biridir.
- Harmoni arama algoritması bilindiği kadarı ile literatürde ilk kez cilt lezyon bölütlemesinde kullanılmış olup performansı ve diğer optimizasyon yöntemlerine üstün zayıf yönleri değerlendirilmiştir.



Şekil 4.2 : Yöntemin akış şeması

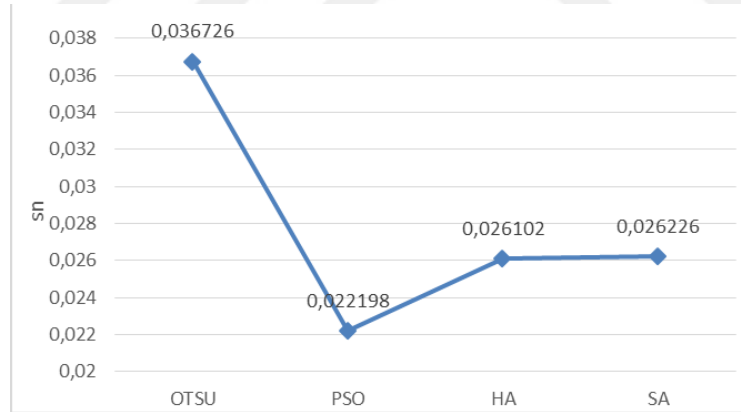


Şekil 4.3 : En iyi eşik değerinin bulunması süreci.

Elde edilen ortalama bölütleme başarımları Çizelge 4.4’te, bölütleme işlemi için herbir algoritmanın saniye cinsinden harcadığı zaman Şekil 4.4’te gösterilmiştir.

Çizelge 4.4 : Her bir algoritma için dice skoru ve kosinüs benzerliği başarımları

	Dice-Otsu	Dice-PSO	Dice-HA	Dice-BT	Cosine-Otsu	Cosine-PSO	Cosine-HA	Cosine-BT
Average	0.901	0.901	0.901	0.901	0.907	0.907	0.907	0.907



Şekil 4.4 : Saniye cinsinden harcanan ortalama süre.

Çizelge 4.4 ve Şekil 4.4 incelendiğinde klasik otsu yöntemini kullanan metasezgisel temelli yöntemlerin 20 iterasyon çalıştırılmaları sonucunda, klasik otsu eşiklemesinin başarımını daha kısa sürede elde ettikleri gözlemlenmiştir. Bununla birlikte çalışmada dikkati çeken esas nokta kullanılan metasezgisel yöntemlerin klasik otsu yönteminin bölütleme performansını; PSO için ortalama 4.3 adımda, HA için ortalama 5.1 adımda, BT için ortalama 17.3 adımda yakalayabildiğidir. Elde edilen sonuçlar birlikte değerlendirildiğinde PSO algoritmasının Klasik Otsu yönteminden %40, HA algoritmasının Klasik Otsu yönteminden %29 ve BT

algoritmasının Klasik Otsu yönteminden %28.5 daha bölütleme yapabildiği gözlemlendi. Elde edilen sonuç küçük veri kümeleri için çok anlam ifade etmese de hızla büyüyen veri kümeleri göz önüne alındığında optimizasyon algoritmalarının çok kısa adımlarda sonuca ulaşabilmesinden kaynaklı, kısa zamanda bölütleme yapabilmeleri onları klasik yöntemlere önemli bir alternatif haline getirmektedir.

4.2.3 Önişleme, kodlayıcı derinliği ve renk kanallarının SegNet ağının performansına etkisi

Tez kapsamında yapılan üçüncü çalışmada, güncel derin öğrenme mimarilerinden olan SegNet ağının farklı kodlayıcı derinliği ve farklı renk kanalları ile eğitilmesinin cilt lezyon bölütlemesi üzerindeki etkileri incelenmiştir. Ayrıca cilt lezyon görüntüleri üzerinde veri büyütme kontrast iyileştirme, kıl silme işlemleri gibi önişleme adımları uygulanarak SegNet ile bölütleme adımına katkıları geniş bir çerçeveden incelenmiştir. SegNet ağının eğitilmesi ve test edilmesinde ISBI 2016 veri kümesi kullanıldı. Eğitim/test oranı %70'e %30 olarak belirlenmiştir. Çalışmada öncelikle veri kümesi hiçbir önişleme adımına tabi tutulmadan, kodlayıcı derinliği 4 ve RGB kanalı kullanılarak eğitilmiştir. Daha sonra kontrast iyileştirme, kıl silme, veri büyütme önişleme adımları uygulanarak eğitilerek önişleme adımlarının etkisi gözlemlenmiştir. Sonrasında, önişleme uygulanmış lezyon görüntüleri farklı derinlik ve renk kanalları eklenmiş SegNet ağları yardımıyla eğitilerek derinlik ve renk kanalları seçiminin SegNet ağının bölütleme performansına etkileri gözlemlenmiştir. Çalışmanın literatüre katkıları aşağıdaki gibi özetlenebilir.


- Farklı kodlayıcı derinliği ve renk kanallarının eklenmesinin, güncel bir derin öğrenme tabanlı SegNet mimarisinin lezyon bölütlemesindeki etkileri incelenmiş ve uygun renk kanalları belirlenmiştir.
- Uygulanan boyutlandırma, renk sabitliği, kontrast iyileştirme, veri büyütme, kıl silme gibi önişleme adımlarının güncel derin öğrenme tabanlı yöntemlere katkısı ortaya konulmuştur.

Çalışmadaki bütün görüntüler önişlemeye tabi tutulmasın 192x256 boyutuna indirilerek ağ eğitiminin hızlanması amaçlanmıştır. Çalışmadaki bütün görüntüler boşluk doldurma ve küçük bölgelerin silinmesi adımlarını içeren sonişlemeye tabi tutulmuşlardır. Şekil 4.5, önerilen modelin akış diyagramını göstermektedir.




Şekil 4.5 : Önerilen yöntem akış şeması.

Şekil 4.6 ve 4.7 sırasıyla SegNet ağının eğitilmesi sürecini ve SegNet ağına ait ağ altyapısını göstermektedir.



Şekil 4.6 : Ağın eğitim süreci.



Şekil 4.7 : SegNet ağı altyapısı

Çizelge 4.5, SegNet ağının eğitilmesinde kullanılan hiper parametre değerlerini göstermektedir.

Çizelge 4.5 : SegNet ağının eğitiminde kullanılan hiperparametre değerleri.

Parametre	Optimizer	MaxEpochs
Değer	Adam	100
Parametre	InitialLearnRate	MiniBatchSize
Değer	5e-4	8
Parametre	LearnRateDropFactor	LearnRateDropPeriod
Değer	0.95	5

Çizelge 4.6 veri büyütme, kontrast iyileştirme, renk sabitliği gibi ön işleme adımlarının, Çizelge 4.7 farklı derinliklerin ve Çizelge 4.8 farklı renk kanallarının SegNet bölütleme başarımına etkilerini göstermektedir.

Çizelge 4.6 : Ön işleme adımları ve veri büyütmenin SegNet bölütleme performansına etkileri.

	Doğruluk	Hassasiyet	Dice	Jaccard	Özgüllük
SegNet	0,907	0,846	0,823	0,732	0,911
VB+SegNet	0,930	0,900	0,871	0,792	0,915
VB+OnIs+ SegNet	0,935	0,879	0,884	0,806	0,932

Çizelge 4.7 : SegNet ağında farklı derinlik değerlerinin bölütleme performansına etkisi.

Kodlayıcı Derinliği	Doğruluk	Hassasiyet	Dice	Jaccard
4	0,905	0,839	0,819	0,7255
5	0,920	0,886	0,855	0,768
6	0,925	0,906	0,867	0,783

Çizelge 4.8 : Farklı renk kanallarının ve çok kanallılığın bölütleme performansına etkisi.

Renk Kanalları	Kodlayıcı Derinliği	Doğr.	Has.	Dice	Jac.
RGB	5	0,942	0,904	0,898	0,827
RGB+H	5	0,942	0,912	0,897	0,826
RGB+I+G	5	0,941	0,878	0,894	0,819
RGB+H+I+G	5	0,948	0,917	0,906	0,838
RGB+HSV+L	5	0,943	0,896	0,900	0,829
RGB+LAB	5	0,938	0,896	0,889	0,814


Çizelge 5.4 göz önüne alındığında, görüntü işlemede kabul görmüş veri büyütme adımı ve önışleme adımlarının bölütleme performansını arttırdığı görülmüştür. Çizelge 5.5'e her ne kadar derinlik arttırmanın ağıın başarımını arttırdığı düşünülse de derinlik 4'ten 5'e yükseldiğinde meydana gelen artışın derinlik 5'ten 6'ya yükseltildiğinde hızla düştüğü gözlemlenmiştir. Bu bizi derinliğin belli bir noktadan sonra ağıın performansını arttırmak yerine düşürmeye başladığı hipotezine götürmektedir. Kaldı ki farklı renk kanalları eklendiğinde ağıın elde ettiği en iyi sonuçların derinlik değeri 5 iken gerçekleştiği gözlemlendi. Çizelge 5.6 incelendiğinde ise RGB+H+I+G kanalları kullanıldığında eğitilmiş ağıın en iyi bölütleme sonuçlarını elde ettiği gözlemlendi. Çalışma çoklu renk kanalı kullanımının SegNet ağının bölütleme başarımını arttırdığını göstermesi açısından önem arz etmektedir. Ayrıca veri büyütme ve önışleme adımları ile birlikte kullanıldığında normal SegNet ağının bölütleme başarısında %7'nin üzerinde iyileşme kaydedildiği gözlemlendi.

4.2.4 Bayes yöntemi ile hiper-parametre optimizasyonunun SegNet ağıının performansı üzerine etkisi

Tez kapsamında yapılan dördüncü çalışmada, güncel derin öğrenme yöntemlerinde ağıın eğitiminde kullanılacak hiper-parametrelerin ağıın bölütleme başarımını arttıracığından yola çıkılarak SegNet mimarisi ve Bayes optimizasyon yöntemleri kullanılarak yeni bir model önerilmiştir. Cilt lezyon görüntüleri kıl silme ve renk sabitliği algoritmaları yardımı ile bir dizi önışleme adımına tabi tutulduktan sonra bir SegNet ağı girişine verilmiştir. Elde edilen ağıın başarımı test kümesi üzerinde test edilerek doğruluk ölçütü yardımı ile hata değeri elde edildi ve elde edilen hata değeri Bayes optimizasyona giriş olarak verildi. Bayes optimizasyon modülü gelen hata değerlerine göre bir sonraki aşamada seçilecek en iyi hiper parametreleri kestirmede kullanıldı. Elde edilen en iyi ağı yardımı ile test görüntüleri bölütlenerek, bölütlenen görüntüler sonışleme tabi tutuldu. Nihayi sonuç için elde edilen bölütleme sonuçları son işleme tabi tutulduktan sonra bölütleme başarımları elde edildi. Çalışmada Bayes Optimizasyon için durma kriteri olarak 30 iterasyon seçildi. SegNet ağıının eğitilmesi ve test edilmesinde ISBI 2016 veri kümesi kullanıldı. Eğitim/doğrulama/test oranı sırasıyla %70 / %15 / %15 olarak seçildi. Çalışmanın literatüre katkıları aşağıdaki gibi özetlenebilir.

- Cilt lezyon bölütlemesinde güncel bir derin ağı modeli olan SegNet ağı ile Bayes Optimizasyon kullanılarak ilk kez hiper parametre optimizasyonu yapılmıştır. Çalışma literatürde her ne kadar farklı derinlik ve mimarilerde yeni ağı modelleri sunulsa da, yeni ağı mimarilerinde parametre optimizasyonu yapmanın bölütleme başarımını arttırdığını göstermesi bakımından anlamlıdır.

Şekil 4.8 SegNet ağıının Bayes Optimizasyon ile parametre optimizasyonu için önerilen modelin akış diagramını göstermektedir.




Şekil 4.8 : Sunulan yönteme ilişkin akış diagramı.

Çizelge 4.9 optimizasyon işlemi için seçilen değişkenler ve Seg-Net seçeneklerini göstermektedir.

Çizelge 4.9 : Optimizasyon parametreleri ve Seg-Net seçenekleri.

Seçenek	Derinlik	Initial Learn Rate	Learn Rate Drop Factor	L2 Regularization	Momentum	Optimize edici	Edinim fonksiyonu
S1	[5 7]	[1e-5 1e-2]	0.1	[1e-10 1e-2]	-	ADAM	EIPPS
S2	[5 7]	[1e-5 1e-2]	0.1	[1e-10 1e-2]	[0.1 0.9]	SGDM	EIPPS
S3	[5 7]	[1e-5 1e-2]	[0.1 0.9]	[1e-10 1e-2]	-	ADAM	EIPPS
S4	[5 7]	[1e-5 1e-2]	[0.1 0.9]	[1e-10 1e-2]	[0.1 0.9]	SGDM	EIPPS
S5	[5 7]	[1e-5 1e-2]	0.1	[1e-10 1e-2]	-	ADAM	EIP
S6	[5 7]	[1e-5 1e-2]	0.1	[1e-10 1e-2]	[0.1 0.9]	SGDM	EIP

Şekil 4.9, 6 farklı seçenek ile optimize edilen Seg-Net ağında, Bayes Optimizasyonun 30 iterasyon boyunca minimizasyon problemi olarak düzenlenmiş amaç fonksiyonunda meydana gelen azalmayı göstermektedir.



Şekil 4.9 : 6 farklı seçenek ile eğitilen SegNet ağında bayes optimizasyonun 30 iterasyon boyunca amaç fonksiyonundaki değişim.

Farklı 6 seçenek ile yapılan deneyler sonucunda S1 seçeneğinin 30 iterasyon sonunda en iyi bölütleme performansını elde ettiği gözlemlenmiştir. Çizelge 5.8 ve 5.9 sırası ile S1’de elde edilen en iyi bölütleme sonucunu ve en iyi bölütlemeyi veren hiper parametre değerlerini göstermektedir.

Çizelge 4.10 : S1 seçeneğinde elde edilen en iyi bölütleme için performans ölçütleri.


Doğruluk	Hassasiyet	Özgünlük	Jaccard	Dice
0,951074369	0,908978156	0,958484511	0,849210409	0,913671412

Çizelge 4.11 : S1 için en iyi başarıyı veren ağı parametre değerleri.

SectionDepth	InitialLearnRate	LearnRateDropFactor	L2Regularization
6	0.00062001	0.1	8.2027e-10

Sonuçlar ADAM optimizator ve SectionDepth, InitialLearnRate, L2Regularization hiper parametreleri ve acquisition function EIPPS kullanan S1’in başarımının diğer beş seçenekten daha iyi olduğunu gösterdi. Fakat tüm altı ağ için de yaklaşık değerler elde edilmiş olup göze çarpan bir üstünlük sağlanamadı. Bununla beraber S1’de elde edilen sonuçlar Seg-Net ile Bayes Optimizasyon kullanılmasının cilt lezyon başarımında hatırı sayılır iyileştirme

sağladığını ve güncel yöntemlerin başarımını yakaladığını göstermektedir. Şekil 5.10 örnek görüntüler üzerinde SegNet ile Bayes optimizasyon bölütlemesi için doğru bölütleme aşırı uyum ve yetersiz öğrenme durumlarını göstermektedir.



Şekil 4.10 : SegNet ve Bayes optimizasyon bölütlemesi: a) doğru öğrenme b) aşırı öğrenme ve yetersiz öğrenme.

Çizelge 5.10, SegNet ağında hiperparametre optimizasyonunun, literatürdeki çalışmalara kıyasla başarımını göstermektedir.

Çizelge 4.12 : Literatürdeki çalışmalar ve önerilen çalışma.

ISBI 2016	Doğruluk	Hassasiyet	Özgünlük	Jaccard	Dice
EXB (Yu, Chen, Dou, Qin ve Heng, 2017)	0.953	0.910	0.965	0.843	0.910
Bi-Team (Bi ve diğerleri, 2017)	0.955	0.922	0.965	0.846	0.912
MSCA	0.856	0.783	0.913	0.661	0.758
SSLS (Ahn ve diğerleri, 2015)	0.846	0.700	0.973	0.572	0.699
FCN	0.941	0.917	0.949	0.814	0.886
SegNet (Peng, Wang, Wang ve Wang, 2019)	0.900	0.860	0.920	0.730	0.840
Önerilen Yöntem	0.951	0.908	0.958	0.849	0.913

5. SONUÇ VE ÖNERİLER

Melanom vakaları son yıllarda özellikle güneş ışınlarına maruz kalan beyaz tenli insanlarda hızla artış göstermiştir. Dermoskopi, melanom erken teşhisinde önemli araçlardan biri olarak kabul edilmekte ve bu nedenle klinisyenler tarafından yaygın olarak kullanılmaktadır. Tıbbi verileri yorumlamak ve anlamlı bilgiler sağlamak için bilgisayar destekli tıbbi araştırmalar gün geçtikçe önem kazanmaktadır. Manuel olarak gerçekleştirilen, tıbbi görüntülerin analizi zaman alıcı, sıkıcı, öznel ve insan faktöründen kaynaklı kusurlara sahip olabilir. Melanom teşhisinde bilgisayar destekli tanı sistemlerinin kullanımı dermatologlara cilt lezyonları hakkında faydalı bilgiler sunarak yardımcı olmak amacıyla son yıllarda önemli bir araştırma alanı haline gelmiştir. Cilt lezyonlarının bilgisayar destekli tanı sistemleri yardımı ile etkili segmentasyonu, dermatologların tanı sürecinde ihtiyaç duydukları zamanı azaltarak verimliliğini artırabilir. Bununla birlikte cilt lezyonlarının otomatik bölütlenmesi ciltte bulunan kıl, yağ dokusu ve hava kabarcıkları gibi kalıntılardan, farklı ışık kaynakları altında elde edilen görüntülerden, cilt lezyonlarında yaygın görülen düşük kontrast değerlerinden ötürü zorlu bir süreç olabilmektedir. Bu tez çalışmasında cilt lezyon bölütlemesinde, geleneksel eşikleme tabanlı yöntemler ve güncel derin öğrenme tabanlı SegNet mimarisinin performansları detaylı olarak incelenmiştir. Ayrıca metasezgisel optimizasyon algoritmaları hem geleneksel ve güncel yöntemlere uygulanarak bölütleme performansına etkileri gözlemlenmiştir.

Sonuç olarak, geleneksel eşikleme tabanlı yöntemlerin cilt lezyonlarında karşılaşılan problemlerin tamamıyla başetmekte yetersiz kalmasına rağmen derin öğrenme tabanlı SegNet ağının cilt lezyon bölütlemesinde daha iyi sonuçlar verdiği gözlemlenmiştir. SegNet ağına farklı renk kanalları eklemenin renk kanallarının içerdiği farklı özelliklerden faydalanmanın SegNet bölütleme katkıları sunulmuş olup son adımda ise Segnet ağına hiper-parametre optimizasyonun bölütleme sonuçlarında anlamlı iyileştirme sağladığı gösterilmiştir. Çalışma derin öğrenme yöntemlerinin geleneksel yöntemlere göre daha geliştirilebilir ve başarılı sonuçlar ürettiğini göstermiştir. Ayrıca sürekli geliştirilen yeni ağların üretilmesine karşın mevcut ağlarda parametre optimizasyonu yapılmasının mevcut ağların başarımını arttırdığını göstermesi açısından oldukça önemlidir.

Bu tez kapsamında yapılan işlemlerin dışında gelecekte yapılacak olan çalışmalarda derin öğrenme temelli mimariler üzerinde farklı optimizasyon teknikleri kullanarak hiperparametre optimizasyonu yapılması düşünülmektedir. Ayrıca ayrıştırılabilir bloklardan oluşan yeni derin öğrenme tabanlı yöntemler incelenerek yeni bir ayrıştırılabilir yöntem önerilmesi planlanmaktadır. Bu sayede derin öğrenme temelli yöntemlerin temelini oluşturan örnek seyreltme ve sıklama aşamalarında bir yandan daha az veri kaybına uğrarken diğer yandan daha etkili indeks kullanımı sayesinde hızlı sonuçlar alabilen yeni bir derin öğrenme mimarisi temelli ağ modelinin oluşturulması planlanmaktadır.



KAYNAKÇA

- Abbas, Q., Garcia, I. F., Emre Celebi, M., Ahmad, W. ve Mushtaq, Q. (2013). A perceptually oriented method for contrast enhancement and segmentation of dermoscopy images. *Skin Research and Technology*, 19(1), 1–8. doi:10.1111/j.1600-0846.2012.00670.x
- Agarwal, A., Issac, A., Dutta, M. K., Riha, K. ve Uher, V. (2017). Automated skin lesion segmentation using k-Means clustering from digital dermoscopic images. *2017 40th International Conference on Telecommunications and Signal Processing, TSP 2017* içinde (C. 2017-January, ss. 743–748). Institute of Electrical and Electronics Engineers Inc. doi:10.1109/TSP.2017.8076087
- Ahn, E., Bi, L., Jung, Y. H., Kim, J., Li, C., Fulham, M. ve Feng, D. D. (2015). Automated saliency-based lesion segmentation in dermoscopic images. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2015-Novem*, 3009–3012. doi:10.1109/EMBC.2015.7319025
- Ahn, E., Kim, J., Bi, L., Kumar, A., Li, C., Fulham, M. ve Feng, D. D. (2017). Saliency-Based Lesion Segmentation Via Background Detection in Dermoscopic Images. *IEEE Journal of Biomedical and Health Informatics*, 21(6), 1685–1693. doi:10.1109/JBHI.2017.2653179
- Al-masni, M. A., Al-antari, M. A., Choi, M. T., Han, S. M. ve Kim, T. S. (2018). Skin lesion segmentation in dermoscopy images via deep full resolution convolutional networks. *Computer Methods and Programs in Biomedicine*, 162, 221–231. doi:10.1016/j.cmpb.2018.05.027
- Argenziano, G., Catricalà, C., Ardigo, M., Buccini, P., De Simone, P., Eibenschutz, L., ... Zalaudek, I. (2011). Seven-point checklist of dermoscopy revisited. *British Journal of Dermatology*, 164(4), 785–790. doi:10.1111/j.1365-2133.2010.10194.x
- Argenziano, G., Fabbrocini, G., Carli, P., De Giorgi, V., Sammarco, E. ve Delfino, M. (1998). Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions: Comparison of the ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis. *Archives of Dermatology*, 134(12), 1563–1570. doi:10.1001/archderm.134.12.1563
- Argenziano, G. ve Soyer, H. P. (2001). Dermoscopy of pigmented skin lesions - a valuable tool for early diagnosis of melanoma. *Lancet Oncology*, 2(7), 443–449. doi:10.1016/S1470-2045(00)00422-8

- Badrinarayanan, V., Kendall, A. ve Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481–2495.
doi:10.1109/TPAMI.2016.2644615
- Barata, C., Celebi, M. E. ve Marques, J. S. (2015). Improving dermoscopy image classification using color constancy. *IEEE Journal of Biomedical and Health Informatics*, 19(3), 1146–1152. doi:10.1109/JBHI.2014.2336473
- Barata, C., Ruela, M., Francisco, M., Mendonca, T. ve Marques, J. S. (2014). Two systems for the detection of melanomas in dermoscopy images using texture and color features. *IEEE Systems Journal*, 8(3), 965–979. doi:10.1109/JSYST.2013.2271540
- Benvenuto-Andrade, C., Dusza, S. W., Agero, A. L. C., Scope, A., Rajadhyaksha, M., Halpern, A. C. ve Marghoob, A. A. (2007). Differences between polarized light dermoscopy and immersion contact dermoscopy for the evaluation of skin lesions. *Archives of Dermatology*, 143(3), 329–338. doi:10.1001/archderm.143.3.329
- Bi, L., Kim, J., Ahn, E., Feng, D., Fulham, M., Medicine, N., ... Hospital, A. (2016a). Automatic Melanoma Detection via Multi-scale Lesion-biased Representation and Joint Reverse Classification School of Information Technologies , University of Sydney , Australia Sydney Medical School , University of Sydney , Australia Med-X Research Instit. *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*, 1055–1058. doi:10.1109/ISBI.2016.7493447
- Bi, L., Kim, J., Ahn, E., Feng, D., Fulham, M., Medicine, N., ... Hospital, A. (2016b). Automated Skin Lesion Segmentation via Image-wise Supervised Learning and Multi-Scale Superpixel Based Cellular Automata School of Information Technologies , University of Sydney , Australia Sydney Medical School , University of Sydney , Australia Med-X R, 1059–1062.
- Bi, L., Kim, J., Ahn, E., Kumar, A., Fulham, M. ve Feng, D. (2017). Dermoscopic Image Segmentation via Multistage Fully Convolutional Networks. *IEEE Transactions on Biomedical Engineering*, 64(9), 2065–2074. doi:10.1109/TBME.2017.2712771
- Brahmbhatt, P. ve Rajan, S. N. (2019). Skin Lesion Segmentation using SegNet with Binary Cross- Entropy, 14–15.
- Brochu, E., Cora, V. M. ve de Freitas, N. (2010). A Tutorial on Bayesian Optimization of Expensive Cost Functions, with Application to Active User Modeling and Hierarchical Reinforcement Learning, 1–49. <http://arxiv.org/abs/1012.2599>
adresinden erişildi.

- Campos-do-carmo, G. ve Ramos-e-silva, M. (2008). Dermoscopy : basic concepts, 712–719.
- Cancer, M. (2013). *Sigma* 31 , (212), 555–570.
- Castillejos, H., Ponomaryov, V., Nino-De-Rivera, L. ve Golikov, V. (2012). Wavelet transform fuzzy algorithms for dermoscopic image segmentation. *Computational and Mathematical Methods in Medicine*, 2012. doi:10.1155/2012/578721
- Celebi, M. E., Kingravi, H. A., Iyatomi, H., Aslandogan, Y. A., Stoecker, W. V., Moss, R. H., ... Menzies, S. W. (2008). Border detection in dermoscopy images using statistical region merging. *Skin Research and Technology*, 14(3), 347–353. doi:10.1111/j.1600-0846.2008.00301.x
- Cognetta, A. B., Vogt, T., Landthaler, M., Braun-Falco, O. ve Plewig, G. (1994). The ABCD rule of dermatoscopy: High prospective value in the diagnosis of doubtful melanocytic skin lesions. *Journal of the American Academy of Dermatology*, 30(4), 551–559. doi:10.1016/S0190-9622(94)70061-3
- Corona, R., Sera, F., Binder, M. ve Cerroni, L. (2003). Dermoscopy of pigmented skin lesions : Results of a consensus meeting via the Internet, 679–693. doi:10.1067/mjd.2003.281
- Dalila, F., Zohra, A., Reda, K. ve Hocine, C. (2017). Segmentation and classification of melanoma and benign skin lesions. *Optik*, 140, 749–761. doi:10.1016/j.ijleo.2017.04.084
- Eberhart, R. ve Kennedy, J. (1995). New optimizer using particle swarm theory. *Proceedings of the International Symposium on Micro Machine and Human Science*, 39–43. doi:10.1109/mhs.1995.494215
- Emre-Celebi, M., Hwang, S., Iyatomi, H. ve Schaefer, G. (2010). Robust border detection in dermoscopy images using threshold fusion. *Proceedings - International Conference on Image Processing, ICIP*, 2541–2544. doi:10.1109/ICIP.2010.5653514
- Feldman, S. R., Fleischer, A. B. ve Coldiron, B. M. (2015). Incidence Estimate of Nonmelanoma Skin Cancer in the United States, 2006, 146(3), 283–287.
- Geem, Z. W. (2001). 1-D Optimization Algorithms. *Optimization*, 35–54. doi:10.1201/b18469-3
- Geller, A. C., Swetter, S. M., Brooks, K., Demierre, M., Yaroch, A. L. ve Alto, P. (2007). Screening, early detection, and trends for melanoma: Current status (2000-2006) and future directions, 555–572. doi:10.1016/j.jaad.2007.06.032
- Hu, X., Shi, Y. ve Eberhart, R. (2004). Recent advances in particle swarm. *Proceedings of*

- the 2004 Congress on Evolutionary Computation, CEC2004, 1*, 90–97.
doi:10.1109/cec.2004.1330842
- Huang, S., Cheng, F. ve Chiu, Y. (2013). Efficient Contrast Enhancement Using Adaptive Gamma Correction With Weighting Distribution, *22*(3), 1032–1041.
- Humayun, J., Malik, A. S. ve Kamel, N. (2011). Multilevel thresholding for segmentation of pigmented skin lesions. *2011 IEEE International Conference on Imaging Systems and Techniques, IST 2011 - Proceedings*, 310–314. doi:10.1109/IST.2011.5962214
- Kasmi, R. ve Mokrani, K. (2016). Classification of malignant melanoma and benign skin lesions: Implementation of automatic ABCD rule. *IET Image Processing*, *10*(6), 448–455. doi:10.1049/iet-ipr.2015.0385
- Kawahara, J. ve Hamarneh, G. (2016). Multi-resolution-tract CNN with hybrid pretrained and skin-lesion trained layers. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* içinde (C. 10019 LNCS, ss. 164–171). Springer Verlag. doi:10.1007/978-3-319-47157-0_20
- Kirkpatrick, S., Gelatt, C. D. ve Vecchi, M. P. (1987). *Optimization by Simulated Annealing. Readings in Computer Vision*. Morgan Kaufmann Publishers, Inc. doi:10.1016/b978-0-08-051581-6.50059-3
- Kittler, J. ve Illingworth, J. (1986). #, T , = [.. ~ h (g) g]/ P ,(T) a ~ (T) = [. =~ { g - u , ~ T) } 2, *19*(1), 41–47.
- Kruk, M., Świdorski, B., Osowski, S., Kurek, J., Słowińska, M. ve Walecka, I. (2015). Melanoma recognition using extended set of descriptors and classifiers. *Eurasip Journal on Image and Video Processing*, *2015*(1), 1–10. doi:10.1186/s13640-015-0099-9
- Lee, T., Ng, V., Gallagher, R., Coldman, A. ve McLean, D. (1997). Dullrazor®: A software approach to hair removal from images. *Computers in Biology and Medicine*, *27*(6), 533–543. doi:10.1016/S0010-4825(97)00020-6
- Li, C., Xu, C., Gui, C. ve Fox, M. D. (2010). Distance regularized level set evolution and its application to image segmentation. *IEEE Transactions on Image Processing*, *19*(12), 3243–3254. doi:10.1109/TIP.2010.2069690
- Lin, B. S., Michael, K., Kalra, S. ve Tizhoosh, H. R. (2018). Skin lesion segmentation: U-Nets versus clustering. *2017 IEEE Symposium Series on Computational Intelligence, SSCI 2017 - Proceedings, 2018-Janua*, 1–7. doi:10.1109/SSCI.2017.8280804
- Marghoob, Ashfaq A., Braun, Ralph P., Kopf, A. W. (2012). *An Atlas of Dermoscopy*,

Second Edition.

https://books.google.com.tr/books/about/An_Atlas_of_Dermoscopy_Second_Edition.html?id=VBvsGgAACAAJ&redir_esc=y adresinden erişildi.

- Menzies, S. W., Ingvar, C., Crotty, K. A. ve McCarthy, W. H. (1996). Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features. *Archives of Dermatology*, 132(10), 1178–1182. doi:10.1001/archderm.132.10.1178
- Metropolis, N., Rosenbluth, A. W., Rosenbluth, M. N., Teller, A. H. ve Teller, E. (1953). Equation of state calculations by fast computing machines. *The Journal of Chemical Physics*, 21(6), 1087–1092. doi:10.1063/1.1699114
- Mustafa, S., Dauda, A. B. ve Dauda, M. (2017). Image processing and SVM classification for melanoma detection. *Proceedings of the IEEE International Conference on Computing, Networking and Informatics, ICCNI 2017, 2017-Janua*, 1–5. doi:10.1109/ICCNI.2017.8123777
- Noh, H., Hong, S. ve Han, B. (2015). Learning deconvolution network for semantic segmentation. *Proceedings of the IEEE International Conference on Computer Vision, 2015 Inter*, 1520–1528. doi:10.1109/ICCV.2015.178
- Nowak, L. A., Ogorzałek, M. J. ve Pawłowski, M. P. (2012). Pigmented network structure detection using semi-smart adaptive filters. *2012 IEEE 6th International Conference on Systems Biology, ISB 2012*, 310–314. doi:10.1109/ISB.2012.6314155
- Oliveira, R. B., Papa, J. P., Pereira, A. S. ve Tavares, J. M. R. S. (2018). Computational methods for pigmented skin lesion classification in images: review and future trends. *Neural Computing and Applications*, 29(3), 613–636. doi:10.1007/s00521-016-2482-6
- Otsu, N. (1973). Pourazowe zniekształcenie przednich zębów stałych i związane z tym trudności lecznicze. *Czasopismo stomatologiczne*, 26(8), 855–860.
- Peng, Y., Wang, N., Wang, Y. ve Wang, M. (2019). Segmentation of dermoscopy image using adversarial networks. *Multimedia Tools and Applications*, 78(8), 10965–10981. doi:10.1007/s11042-018-6523-2
- Pun, T. (1980). A new method for grey-level picture thresholding using the entropy of the histogram. *Signal Processing*. doi:10.1016/0165-1684(80)90020-1
- Shelhamer, E., Long, J. ve Darrell, T. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4), 640–651. doi:10.1109/TPAMI.2016.2572683

- Siegel, R. L., Miller, K. D. ve Jemal, A. (2015). *Cancer Statistics* , 2015, 65(1), 5–29.
doi:10.3322/caac.21254.
- Siegel, R. L., Miller, K. D. ve Jemal, A. (2016). *Cancer Statistics* , 2016, 66(1), 7–30.
doi:10.3322/caac.21332.
- Silveira, M., Mendonca, T., Marcal, A. R. S., Vieira, A., Nascimento, J. C., Marques, J. S. ve Rozeira, J. (2009). Comparison of segmentation methods for automatic diagnosis of dermoscopy images. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, 3(1), 6573–6576.
- Simonyan, K. ve Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14.
- Stolz, W., Reimann, A. ve Cognetta, A. B. (1994). ABCD rule of dermatoscopy: a new practical method for early recognition of malignant melanoma.
- Tang, P., Liang, Q., Yan, X., Xiang, S., Sun, W., Zhang, D. ve Coppola, G. (2019). Efficient skin lesion segmentation using separable-Unet with stochastic weight averaging. *Computer Methods and Programs in Biomedicine*, 178, 289–301.
doi:10.1016/j.cmpb.2019.07.005
- Thiers, B. H. (y.y.). B. H. Thiers, MD The CASH (color, architecture, symmetry, and homogeneity) algorithm for dermoscopy, 344–345.
- Ünver, H. M. ve Ayan, E. (2019). Skin lesion segmentation in dermoscopic images with combination of yolo and grabcut algorithm. *Diagnostics*, 9(3).
doi:10.3390/diagnostics9030072
- Venugopal, S. S., Peter Soyer, H. ve Menzies, S. W. (2011). Results of a nationwide dermoscopy survey investigating the prevalence, advantages and disadvantages of dermoscopy use among Australian dermatologists. *Australasian Journal of Dermatology*, 52(1), 14–18. doi:10.1111/j.1440-0960.2010.00708.x
- Wighton, P., Lee, T. K., Lui, H., McLean, D. I. ve Atkins, M. S. (2011). Generalizing common tasks in automated skin lesion diagnosis. *IEEE Transactions on Information Technology in Biomedicine*, 15(4), 622–629. doi:10.1109/TITB.2011.2150758
- Wong, A., Scharcanski, J. ve Fieguth, P. (2011). Automatic skin lesion segmentation via iterative stochastic region merging. *IEEE Transactions on Information Technology in Biomedicine*, 15(6), 929–936. doi:10.1109/TITB.2011.2157829
- Yu, L., Chen, H., Dou, Q., Qin, J. ve Heng, P. A. (2017). Automated Melanoma

- Recognition in Dermoscopy Images via Very Deep Residual Networks. *IEEE Transactions on Medical Imaging*, 36(4), 994–1004. doi:10.1109/TMI.2016.2642839
- Yuan, Y., Chao, M. ve Lo, Y. C. (2017). Automatic Skin Lesion Segmentation Using Deep Fully Convolutional Networks with Jaccard Distance. *IEEE Transactions on Medical Imaging*, 36(9), 1876–1886. doi:10.1109/TMI.2017.2695227
- Yüksel, M. E. ve Borlu, M. (2009). Accurate segmentation of dermoscopic images by image thresholding based on type-2 fuzzy logic. *IEEE Transactions on Fuzzy Systems*, 17(4), 976–982. doi:10.1109/TFUZZ.2009.2018300
- Zalaudek, I., Argenziano, G., Soyer, H. P., Corona, R., Sera, F., Blum, A., ... Seidenari, S. (2006). Three-point checklist of dermoscopy: An open internet study. *British Journal of Dermatology*, 154(3), 431–437. doi:10.1111/j.1365-2133.2005.06983.x
- Zhou, D. ve Zong, J. (2009). Minimum error thresholding based on two dimensional histogram. *2009 WRI World Congress on Computer Science and Information Engineering, CSIE 2009*, 7, 169–175. doi:10.1109/CSIE.2009.797
- Zornberg, A., Celebi, M. E. ve Member, S. (2012). Automated Quantification of Perceptually Significant Colors in Dermoscopy Images and Its Application to Skin Lesion Classification, 8(3), 1–10.

ÖZGEÇMİŞ

Ad-Soyad : Nurullah ŞAHİN
Doğum Tarihi ve Yeri : 26.05.1984
E-posta : nursahin.net@gmail.com

ÖĞRENİM DURUMU:

- **Lisans:** Selçuk Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği, 2009

MESLEKİ DENEYİM:

- **2010-2012 Araştırma görevlisi (Yalova Üniversitesi, İstanbul Teknik Üniversitesi).**
- **2012-2020 Mühendis (Tarım ve Orman Bakanlığı).**