

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI



**GÖRÜNTÜ İŞLEME TEKNİKLERİYLE MELANOM CİLT
KANSERİ BÖLÜTLEMESİ**

AMEERAH MUSTAFA MOHAMMED ALEZABI

YÜKSEK LİSANS TEZİ

DR. ÖĞR. ÜYESİ YASEMİN GÜLTEPE

TEMMUZ - 2021

KASTAMONU

TEZ ONAYI

Ameerah Mustafa Mohammed ALEZABI tarafından hazırlanan “**GÖRÜNTÜ İŞLEME TEKNİKLERİYLE MELANOM CİLT KANSERİ BÖLÜTLEMESİ**” adlı tez çalışmasının savunma sınavı **02.07.2021** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir

Danışman	Dr. Öğr. Üyesi Yasemin GÜLTEPE Kocaeli Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Can Doğan VURDU Kastamonu Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Cevat RAHEBİ İstanbul Ayvansaray Üniversitesi	

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitüsü Müdürü

Prof. Dr. İzzet ŞENER

.....

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Ameerah Mustafa Mohammed ALEZABI

ÖZET

YÜKSEK LİSANS TEZİ

GÖRÜNTÜ İŞLEME TEKNİKLERİYLE MELANOM CİLT KANSERİ BÖLÜTLEMESİ

AMEERAH MUSTAFA MOHAMMED ALEZABI

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI

DANIŞMAN: DR. ÖĞR. ÜYESİ YASEMİN GÜLTEPE

Melanom, cilt kanserleri arasında en az görüleni olmasına rağmen en tehlikeli cilt kanseri türüdür. Diğer taraftan, erken evrelerde teşhis edilirse tedavisinde başarı şansı oldukça yüksektir. Dermoskopi, tanı için invaziv olmayan bir görüntüleme tekniğidir. Dermatogların klinik değerlendirmesine yardımcı olmak için bilgisayar destekli teşhis sistemlerinin geliştirilmesine şu anda büyük önem verilmektedir. Görüntü bölütleme, bir görüntüyü birden çok bölüte bölmek için kullanılan bir mekanizmadır. Görüntüyü pürüzsüz ve değerlendirilmesi kolay hale getirecektir. Bölütleme işlemi ayrıca belirli bir görüntüde ilgilenilen bölgenin bulunmasına da yardımcı olur. Asıl amaç, görüntüyü daha basit ve anlamlı hale getirmektir. Bu tezde, Hastane Pedro Hispanodan (HPH) alınan dermoskopi görüntüleri kullanılmıştır. Görüntüyü azaltabilmek için görüntülere medyan filtreleme işlemi uygulanmıştır. Melanom cilt kanseri görüntüleri, Otsu eşikleme yöntemi ile bölütlenmiştir. Bu amaca yönelik olarak da grafik kullanıcı arayüzü tasarlanmıştır. Başarım analizi sonuçlarına göre önerilen yöntemin veri tabanındaki görüntüler üzerinde en yüksek %93 sınıflandırma doğruluğu elde ettiği gözlemlenmiştir.

ANAHTAR KELİMELEER:Görüntü segmentasyonu, filtreleme, eşikleme yöntemi, dermoskopi

Temmuz 2021, 53 Sayfa

ABSTRACT

MSC THESIS

MELANOMA SKIN CANCER SEGMENTATION WITH IMAGE PROCESSING TECHNIQUES

AMEERAH MUSTAFA MOHAMMED ALEZABI

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE

DEPARTMENT OF MATERIALS SCIENCE AND ENGINEERING

SUPERVISOR: ASSIST. PROF. DR. YASEMİN GÜLTEPE

Although melanoma is the least common skin cancer, it is the most dangerous type of skin cancer. On the other hand, if it is diagnosed in the early stages, the chance of success in its treatment is quite high. Dermoscopy is a non-invasive imaging technique for diagnosis. Considerable attention is currently paid to the development of computer-aided diagnostic systems to assist in the clinical evaluation of dermatologists. Image segmentation is a mechanism used to divide an image into multiple segments. It will make the image smooth and easy to evaluate. Segmentation also helps to find the region of interest in a particular image. The main goal is to make the image simpler and more expressive. In this thesis, dermoscopy images from Hospital Pedro Hispano (HPH) were used. Median filtering was applied to the images in order to reduce the noise. Melanoma skin cancer images were segmented by the Otsu thresholding method. A graphical user interface has been designed for this purpose. According to the results of the performance analysis, it was observed that the proposed method achieved the highest classification accuracy of 93% on the images in the database.

KEYWORDS:Image segmentation, filtering, thresholding method, dermoscopy

July 2021, 53 Page

TEŞEKKÜR

Bana tezimi tamamlama gücü ve sabrı veren Yüce Allah’a sonsuz şükranlarımı sunuyorum. Kastamonu Üniversitesindeki yüksek lisans eğitimim sırasında bilgi ve deneyimleriyle bana destek olan değerli danışmanım sayın Dr. Öğr. Üyesi Yasemin GÜLTEPE’ye teşekkürlerimi sunarım.

Tezin son haline gelmesinde katkılarını aldığım değerli jüri üyelerim Dr. Öğr. Üyesi Can Doğan VURDU’ya ve Dr. Öğr. Üyesi Cevat RAHEBI’ye çok teşekkür ederim.

Tez çalışmasının her aşamasında bana destek veren, çalışmamla ilgili beni yüreklendiren ve manevi hiçbir yardımlarını esirgemedi yanımda olan sevgili aileme ve yakınlarıma sonsuz teşekkürlerimi sunarım.

Çalışma süresince benimle tecrübelerini paylaşan Türkiye’deki ve Libya’daki sevgili arkadaşlarıma çok teşekkür ederim.

Kastamonu Üniversitesinde aldığım eğitim için yaptıkları destekten dolayı Libya Hükümetine ve Türkiye’deki Libya Büyükelçiliğine teşekkür ederim.

Ameerah Mustafa Mohammed ALEZABI

Kastamonu, 2021

İÇİNDEKİLER

Sayfa

TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
SİMGELER VE KISALTMALAR DİZİNİ	x
1. GİRİŞ.....	1
2. ALT YAPI VE İLGİLİ ÇALIŞMALAR.....	7
2.1 Görüntü İşleme.....	7
2.1.1 Renk Uzayı Dönüştürme	7
2.1.2 Kontrast İyileştirme	8
2.1.3 Yaklaşık Lezyon Lokalizasyonu	10
2.1.4 Artefakt Giderimi	11
2.1.5 Bölge Birleştirme	12
2.1.6 Sınır Genişletme.....	14
2.2 Görüntü Bölütlemenin Değerlendirmesi.....	14
2.3 Pedro Hispano Hastanesi (HPH) Veri Tabanı	15
2.4 Önileme Aşaması	17
2.4.1 Sınır Tespiti	17
3. GÖRÜNTÜ BÖLÜTLEME.....	19
3.1 Görüntü Bölütleme.....	19
3.2 Görüntü Bölütlemenin Temel Adımları	21
3.3 Görüntü Bölütleme Yöntemleri.....	22
3.3.1 Eşikleme Yöntemleri.....	22
3.3.2 Kümeleme Tabanlı Yöntemler	23
3.3.3 Histogram Tabanlı Yöntemler.....	23
3.4 Yapay Zeka, Makine Öğrenimi ve Derin Öğrenme	24
4. SİSTEM GERÇEKLEŞTİRİLMESİ	28
4.1 Ön İşleme Aşaması	28
4.2 Birleştirme Koşulu	31
4.3 Birleştirme Sırası	32
4.4 Algoritma Parametrelerinin Değerlendirilmesi.....	33
4.5 Bulgular ve Tartışma.....	34
4.6 Değerlendirme Sonuçları	39
5. SONUÇ VE ÖNERİLER	44
KAYNAKLAR	46
ÖZGEÇMİŞ.....	53

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1 Görüntü çözünürlüğü	5
Şekil 2.1 Lezyon çeşitleri	18
Şekil 3.1 a) Orijinal beyin MR görüntüsü b) Beyin MR bölütlenmiş görüntü	20
Şekil 3.2 U-net mimarisi	25
Şekil 4.1 a) Orijinal melanoma cilt kanseri görüntüsü b) Gri tonlamalı görüntü c) Medyan filtresinden geçirilmiş görüntü	28
Şekil 4.2 a) Orijinal melanom cilt kanseri görüntüsü b) Medyan filtresinden geçirilmiş görüntü c) Otsu eşikleme yönteminin sonucu d) Melanom cilt kanserinin tahmini lokalizasyonu	29
Şekil 4.3 Doğruluk hesaplama değerleri	34
Şekil 4.4 Görüntünün veri setinden seçilmesi	35
Şekil 4.5 Görüntünün uygulama ekranına yüklenmesi	35
Şekil 4.6 Önerilen segmentasyon yöntemi	36
Şekil 4.7 a) Bölütleme sürecinin çıktısı b) Bölütleme sürecinin sonucu	36
Şekil 4.8 Görüntünün bölütlenme süreci	37
Şekil 4.9 Bölütleme doğruluk değeri	37
Şekil 4.10 a) Orijinal görüntü b) Lezyon konumunun tespit edilmesi c) Görüntü işleme ile gerçekleştirilen bölütleme	40
Şekil 4.11 Hassasiyet, özgüllük ve doğruluk grafiği	41
Şekil 4.12 a) Orijinal melanom cilt kanseri görüntüsü b) Bölütlere ayrılmış parçalar	41
Şekil 4.13 Eğitim süreci	42
Şekil 4.14 a) Bölütlere ayrılmış orijinal görüntü b) Bölütleme sonucu c) Kesin referans bölütleme	42
Şekil 4.15 Arka plan ve lezyonun yüzdeleri	43

TABLÖLAR DİZİNİ

	<u>Sayfa</u>
Tablo 2.1 PHH veri tabanından alınmış bazı görüntüler.....	16
Tablo 4.1 Performans analizi	38



SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

&	: Ve
%	: Yüzde

Kısaltmalar

ADF	: Anizotropik Difüzyon Filtresi
BT	: Bilgisayarlı Tomografi
CAD	: Bilgisayar Destekli Tanı
CNN	: Evrişimsel Sinir Ağı
ÇSE	: Çok Seviyeli Eşikleme Algoritması
DÖ	: Derin Öğrenme
DVM	: Destek Vektör Makinesi
eMF	: Medyan Filtresi
FN	: Yanlış Pozitif
FP	: Yanlış Negatif
GF	: Gauss Filtresi
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
GPU	: Grafik İşlemci Ünitesi
GUI	: Grafik Kullanıcı Arayüzü
HSV	: Ton-Doygunluk-Değer
MF	: Ortalama Filtresi
MÖ	: Makine Öğrenimi
MR	: Manyetik Rezonans
MRA	: Markof Rastgele Alanı
MRG	: Manyetik Rezonans Görüntüleme
MSL	: Melanositik Cilt Lezyonu
NoMSL	: Melanositik Olmayan Cilt Lezyonu
PHH	: Pedro Hispano Hastanesi
RG	: Bölge Büyütme
RGB	: Kırmızı-Yeşil-Mavi
RNN	: Tekrarlayan Sinir Ağları
TN	: Gerçek Negatif
TP	: Gerçek Pozitif
YZ	: Yapay Zeka

1. GİRİŞ

Tıbbi görüntüleme teknolojisinin gelişmesi ve; hastalar ve doktorlar tarafından artan talepler ile birlikte son on yılda tanısal görüntüleme kullanımını önemli ölçüde artırmıştır. Ancak artan mevcut veri miktarı, hekimin daha önemli bir efor gereksinimine yol açmakta ve kesin tanının konulması için gereken maliyet ve süreyi artırmaktadır. Bu da uzun bekleme listelerine ve oldukça memnuniyetsiz hastalara yol açar.

Bilgisayar Destekli Tanı (CAD) sistemleri, uygun algoritmalar sayesinde veri yorumlamadaki zorlukları azaltarak veya ortadan kaldırarak bekleme sürelerinde, finansal maliyetlerde azalma ve hizmet kalitesinde artış sağlar. Bir CAD sisteminin tipik mimarisi, görüntü ön işlemeyi, ilgilenilen bölge(ler)in tanımını, özellik çıkarma ve seçimini ve sınıflandırmayı içerir (Foran vd., 2011).

Görüntü işleme, bir görüntüyü dijital formata dönüştürüp üzerinde bazı işlemler yaparak iyileştirilmiş bir görüntü elde etmek veya bu görüntüden bazı yararlı bilgiler çıkarmak için kullanılan bir yöntemdir. Bu kavramın daha doğru bir tanımı, bilgiyi insanın görme sistemiyle dijital görüntüleme cihazları arasında tercüme eden bir araç olmasıdır. Görüntü işleme sistemleri, genellikle görüntülerin iki boyutlu sinyaller olarak ele alınıp bunlara önceden belirlenmiş sinyal işleme yöntemlerinin uygulanmasını içermektedir. Günümüzde hızla gelişmekte olan teknolojilerden biridir ve herhangi bir iş alanında çeşitli amaçlarla uygulanabilmektedir.

Biyomedikal görüntü işleme, görüntü işleme tekniklerinin kullanıldığı önemli ve çok geniş alanlardan biridir. Biyomedikal görüntü işleme biyomedikal sinyal toplama, görüntü oluşturma, görüntü işleme, görüntülerin yorumlanabilecek şekilde gösterilmesi ve görüntülerden elde edilen özelliklere dayalı olarak tıbbi bir teşhis konulmasını kapsar.

Biyomedikal görüntü işleme, insan vücudunun görüntülerini oluşturmak veya anatomi ve fizyolojisini incelemek için kullanılan teknik ve süreçlerin genel adıdır.

Tıbbi teşhis için doğrudan dijital görüntüleme sistemlerinin kullanımının artmasıyla, dijital görüntü işleme sağlık hizmetleri kapsamında önemi gittikçe artan bir yer edinmiştir. Bilgisayarlı Tomografi (BT) veya Manyetik Rezonans Görüntüleme (MRG) gibi dijital olarak geliştirilen yöntemlere ek olarak, başlangıçta analog şekilde uygulanan endoskopi veya radyografi gibi görüntüleme modaliteleri günümüzde dijital sensörlerle daha da iyileştirilmiştir. Dijital görüntüler tekil piksellerden oluşur (Deklerck vd., 1993; Vennila vd., 2012).

Biyomedikal görüntü işleme, röntgen, ultrason, MRG, nükleer tıp ve optik görüntüleme teknolojileri ile elde edilen görüntülerin analizi, iyileştirilmesi ve görüntülenmesidir. Görüntüyü yeniden yapılandırmak ve modellemek için kullanılan teknikler sayesinde artık iki boyutlu görüntüleri anlık olarak işleyerek üç boyutlu görüntüler oluşturmak mümkündür (Lotufo vd., 2011). Görüntüleme tekniğine ve hangi tanının düşünüldüğüne bağlı olacak şekilde, bir görüntünün işlenmesi ve analiziyle bir tümörün veya organın çapı, hacmi ve damar yapısı, kan veya diğer sıvıların akış parametreleri ve henüz başka türlü ayırt edilemeyen mikroskobik değişiklikler tespit edilebilir (Zhang ve Dong, 2018).

Görüntü bölütleme, görüntü işlemenin en önemli bir parçasıdır. Görüntü işlemek için hemen hemen her yerde kullanılır. Böylece görüntünün içinde ne olduğunu tanıyabiliriz (Dar, 2020). Görüntü bölütleme, görüntüyü birçok bölüme veya nesneye böler (Zaitoun ve Aqel, 2015).

Görüntü bölütleme, tıbbi görüntüleme bağlamında kaçınılmaz bir ihtiyaç olmakla birlikte bu alanda hala birçok sınırlama ve zorluk bulunmaktadır. Bunlardan en önemlilerinden biri, segmentasyon işlevini tüm tıbbi görüntüleme modalitelerinde uygulayabilecek kapsamlı tek bir yöntem olmamasıdır. Belirli bir organdan belirli görüntüleme yöntemiyle elde edilen bir görüntünün belirli yöntemle işlenmesinin klinik olarak faydalı bilgiler sağladığı kanıtlanırsa bile aynı işleme yönteminin başka bir organ veya farklı bir görüntüleme yönteminde aynı performansı göstereceğini söylemek mümkün değildir. Bu ikilem, esas olarak tıbbi görüntülerin özelliklerindeki, insan anatomisi ve patolojisindeki ve bu tür görüntüleri elde etmek için kullanılan farklı tekniklerdeki büyük çeşitlilikten kaynaklanmaktadır.

Biyomedikal görüntülerin bölütlenmesinin (ya da segmentasyonunun) önemi düşünülerek, bir bölütleme tekniği, klinik kullanıma uygun olabilmek için minimum insan müdahalesi gerektirmeli ve mümkün olduğunca otomatik olmalıdır.

Tıbbi uygulamada değerlendirilmesi gereken veri miktarının çok fazla olması nedeniyle tıbbi görüntülerde organların hekimler tarafından bölütlenmesi oldukça zaman alan ve zahmetli bir iştir. Böyle bir otomatik segmentasyon algoritmasına ihtiyaç duyulması da CAD ile ilgili çalışmalar için bir başka önemli zorluğu temsil etmektedir. Tıbbi görüntüleri otomatik olarak segmentlere ayırmak amacıyla birçok algoritma geliştirilmiş olsa da bu görüntülerin karmaşıklığı nedeniyle CAD için önerilen yöntemlerin çoğunda bölütleme aşamasında insan müdahalesi gerekmektedir. Bilgisayar teknolojisindeki gelişmeler tıbbi görüntüleme alanında hatırı sayılır bir etki oluşturmakla birlikte tıbbi görüntüler hala en sağlıklı şekilde tıbbi personel tarafından yorumlanmaktadır. Son on yılda görüntü yorumlama ve tıbbi teşhiste bilgisayarların kullanımı muazzam şekilde artmıştır. CAD, “radyologlar için ikinci bir çift göz” olarak tarif edilmiş ve bilgisayarların görüntü değerlendirmede insandan daha iyi performans gösterdiği bazı durumlar kaydedilmiştir. CAD ile ilgili çalışmalar esas olarak görüntü tanıma ve sınıflandırma çerçevesinde segmentasyon ve özellik çıkarım yaklaşım ve tekniklerine odaklanmaktadır. Bu uygulamalar, göğüsten beyne vücuttaki herhangi bir organı ve ultrasondan röntgene, BT’den MRG’ye her türlü görüntüleme modalitesini içerebilir.

Bu tez çalışmasında dermoskopi görüntüleri kullanılmıştır. Epilüminesans mikroskopisi olarak da bilinen dermoskopi, optik büyütme ve sıvı daldırma ve düşük geliş açısı aydınlatması ya da çapraz polarize aydınlatma kullanan inazif olmayan bir cilt görüntüleme tekniğidir ve geleneksel klinik görüntülere kıyasla yüzey altı yapılarını daha kolay görünür hale getirir (Argenziano vd., 2002). Dermoskopi, pigment ağları, noktalar/globüller, çizgiler, mavi-beyaz alanlar ve lekeler gibi düzineceler morfolojik özelliğin tanımlanmasına izin verir (Menzies vd., 2003). En yaygın insan malignitesi olan cilt kanseri, öncelikle ilk klinik tarama ile başlayan ve potansiyel olarak dermoskopik analiz, biyopsi ve histopatolojik

inceleme ile görsel olarak teşhis edilir. Görüntüler kullanılarak cilt lezyonlarının otomatik olarak bölütlemesi ve sınıflandırılması, cilt lezyonlarının görünümündeki ince taneli değişkenlik nedeniyle oldukça zorlu bir iştir.


Bu tez çalışmasında Pedro Hispano Hastanesi veri tabanını kullanılmıştır (Silveira vd., 2009). Pedro Hispano Hastanesinin (PHH) klinik veri tabanında, çeşitli türde lezyonların dermoskopik görüntülerinden oluşan 4000’den fazla vaka mevcuttur. Kişisel bilgisayara “.bmp” formatındaki kesitler transfer edilmiştir. Sonraki adımda ön görüntü işleme adımları yapılmıştır ardından Otsu eşikleme bölütleme yöntemi uygulanarak kesitlerden tümörlü bölgeler otomatik olarak çıkarılmıştır.

Görüntü iyileştirme ve görüntü onarmadan farklı olarak görüntü bölütlemenin (segmentasyonun) amacı, bir görüntünün temsilini basitleştirmek ve/veya daha anlamlı analiz edilmesi daha kolay bir şeye dönüştürmektedir (Despotović vd., 2015). Bu anlamda görüntü bölütleme, bir görüntüyü her biri içerisinde farklı özelliklerin tutulduğu anlamlı bölüme (görüntü nesneleri olarak da bilinen piksel kümeleri) ayırma işlemidir. Bu özellikler örneğin, görüntü içerisindeki benzer parlaklıklar olabilir ve bu parlaklıklar ilgili görüntünün farklı bölgelerindeki nesneleri temsil edebilir. Görüntü segmentasyonu tipik olarak görüntülerdeki nesneleri ve sınırları (çizgiler, eğriler, vb.) konumlandırmak için kullanılır. Daha doğrusu, nokta tabanlı ya da piksel tabanlı bölütleme tekniği, bir eşikle değeri ile arka plan gürültüsünü en aza indirirken piksellere kodlanmış faydalı bilgileri çıkarmanın harika bir yoludur. Bu, orijinal gri tonlamalı görüntüyü ikiliye dönüştürmeden önce eşik değerini optimize etmek için bir geri besleme döngüsü kullanılarak gerçekleştirilir. Buradaki fikir, görüntüyü iki parçaya ayırmaktır; arka plan ve nesne (Shapiro ve Stockman, 2001; Lauren ve Lee, 2003; Zeng vd., 2012).

Piksel, bir bilgisayar ekranının veya bir bilgisayar görüntüsünün düzenlenebilen temel renkli birimidir. Her bir piksel, orijinal bir görüntünün bir numunesidir denebilir; ne kadar çok numune varsa tipik olarak orijinal görüntü o kadar doğru temsil edilmiş olacaktır. Her pikselin yoğunluğu değişkendir. Renkli görüntüleme sistemlerinde, bir renk tipik olarak kırmızı, yeşil ve mavi gibi üç bileşenin yoğunluklarıyla temsil edilmektedir.

Monitörde bu üç rengin her birini 8 bit olarak görüntüleyerek bir görüntüdeki tüm renkleri oluşturmak mümkündür. Bu durumda sistem 256 ton kırmızı, 256 ton yeşil ve 256 ton mavi rengi görüntüleyebilmektedir. Yani, olası renk kombinasyonlarının toplam sayısı $256 \times 256 \times 256 = 16.177.216$ 'dır (Luo vd., 2002). Tüm değerler 0 ise siyah renk, tüm değerler 255 iken beyaz renk elde edilir.

Piksel sayısı, görüntünün çözünürlüğünü temsil eder. Piksel küçülür ve piksel sayısı artarsa görüntü kalitesi artar. Görüntü çözünürlüğü, bir görüntünün sahip olduğu ayrıntıdır. Görüntü çözünürlüğü, Şekil 1.1'de örneklenmiştir.



Şekil 1.1 Görüntü çözünürlüğü

Yaygın olarak kullanılan birçok görüntü bölütleme algoritması vardır. Temel olarak basit bir analiz için aşağıda beş algoritma açıklanmıştır:

Eşik bölütleme, bölge tabanlı bölütleme algoritmalarında en sık kullanılan bölütleme algoritmalarında en sık kullanılan bölütleme tekniklerinden biridir (Haralick ve Shapiro, 1985). Burada belirli bir kritere göre optimal eşik otomatik olarak belirlemek ve kümelemeyi sağlamak için bu pikselleri gri seviyesine göre kullanılmaktadır.

Bölge Büyütme (RG) algoritmasının temel fikri, bölgeyi oluşturmak için benzer özelliklere sahip pikselleri birleştirmek, yani bölünecek her bölge için önce bir büyüme noktası olarak bir tohum pikseli bulmak ve sonrasında kendi alanındaki pikselin benzer özelliklerine sahip çevreleyen komşuluk ile birleştirmektir.

Kenar algılama bölütleme algoritması, görüntü bölütlemeyi elde etmek için piksel grisinin farklı bölgelerinin veya kenarın renk süreksizliği algılama alanının kullanılmasını ifade eder (Marr ve Hildreth, 1980).

Kümelemeye dayalı algoritma, sınıf bölme kriteri olarak nesneler arasındaki benzerliğe dayanır, yani örnek kümenin iç yapısına göre birkaç alt sınıfa ayrılır. Böylece aynı tür numuneler mümkün olduğunca benzer ve farklı olanlar mümkün olduğunca benzer değildir (Wu ve Leahy, 1993).

Evrişimsel Sinir Ağı (CNN) ile zayıf denetimli öğrenmeye dayalı bölütleme, görüntüdeki her piksele anlamsal bir etiket atama problemini ifade eder ve üç bölümden oluşur (Lin vd., 2016): 1) Giriş verisi olarak nesneleri (lezyonları) içeren bir görüntü elde edilir 2) Giriş nesnenin kenarlığı belirlenir 3) Görüntüdeki nesne alanı kısmi olarak piksel ile işaretlenmiştir.

Bu tez çalışmasında görüntü ön işleme adımında medyan filtresi kullanılarak bu görüntülerin temizlenmesi amaçlanmıştır. Önerilen yöntem bir RG yöntemi olarak sınıflandırılabilir. RG, basit bir bölge tabanlı görüntü bölütleme yöntemidir. Ayrıca, görüntü histogramı baz alınarak işlem yapıldığından nokta tabanlı ya da piksel tabanlı bir görüntü bölütleme yöntemi olarak sınıflandırılır.

Tezin amaçlarını üç alt başlık altında toplayabiliriz. Birincisi, melanom cilt kanseri segmentasyonu için görüntü işleme yöntemini kullanarak eşikleme yöntemine dayalı yarı otomatik bir yöntem geliştirmektir. İkincisi, başarımların analiz değerlendirmesinin yapılmasıdır. Son olarak ise önerilen yöntem, grafik kullanıcı arayüz (GUI) ile desteklenmektedir. GUI, bilgisayar yazılımı için etkileşimli görsel bileşenlerden oluşan bir sistemdir. Bir GUI, bilgi taşıyan nesneleri görüntüler ve kullanıcı tarafından gerçekleştirilebilecek eylemleri temsil eder. Kullanıcı onlarla etkileşime girdiğinde nesneler renk, boyut veya görünürlük değiştirir.

2. ALTYAPI VE İLGİLİ ÇALIŞMALAR

2.1 Görüntü İşleme

Görüntü işleme, bir görüntüyü dijital formata dönüştürüp üzerinde bazı işlemler yaparak iyileştirilmiş bir görüntü elde etmek veya bu görüntüden bazı yararlı bilgiler çıkarmak için kullanılan bir yöntemdir. Girdi kavramı, bir video karesi veya fotoğraf gibi bir görüntüyü ifade ederken çıktı kavramı, bir görüntüyü veya bir görüntüyle ilişkili özellikleri temsil edebilir. Görüntü işleme için çeşitli teknikler mevcuttur: Görüntü temsili, görüntü iyileştirme, görüntü bölütleme ve görüntü sınıflandırma gibi.

Görüntü temsili, gerçek dünyada tanımlanan bir görüntü iki gerçek değişkenin bir fonksiyonudur. Örneğin bu fonksiyon $f(x, y)$ olarak ifade edilirse f , görüntünün gerçek koordinatında (x, y) görüntünün yoğunluğunu (parlaklığını) ifade eder. $f(x, y)$ şeklinde ifade edilen görüntü N sayıda satıra ve M sayıda sütuna ayrılmıştır. Bir satır ve bir sütunun kesişme noktasına piksel denir. $[m = 0, 1, 2, \dots, M-1]$ ve $[n = 0, 1, 2, \dots, N-1]$ olacak şekilde $[m, n]$ tam sayı koordinat noktalarına atanan değer $f[m, n]$ fonksiyonudur.

Görüntü işlemede elde edilen görüntüyü kullanmadan önce daha başarılı bir sonuç elde edebilmek amacıyla görüntünün bazı ön işlemlerden geçirilmesi gerekmektedir. Bu bölümde sınır tespit işlemini kolaylaştıran ön işleme adımları olarak; renk uzayı dönüştürme, kontrast iyileştirme, yaklaşık lezyon lokalizasyonu ve artefakt giderim işlemleri açıklanmıştır (Schaefer vd., 2011).

2.1.1 Renk Uzayı Dönüştürme

Dermoskopi görüntüleri genellikle bir dermoskop takılmış olan dijital bir kamera kullanılarak elde edilir. Sayısal (tek kanallı) işleminin basitçe hesaplanabildiği ve kolayca uygulanabildiği için, elde edilen RGB (Kırmızı-Yeşil-Mavi) renkli

görüntüler genellikle aşağıdaki yöntemlerden biri kullanılarak sayısal bir görüntüye dönüştürülür:

- Yalnızca mavi kanalı seçmek (Histogram yoğunluğunun daha fazla olması ve yoğunluk frekansının daha az oluşu nedeniyle) (Silveira vd., 2009).
- Parlaklık dönüşümünün uygulanması (Celebi vd., 2009; Madooei vd., 2012).

Vektörel (çok kanallı) işlemenin tercih edildiği durumlarda RGB görüntü doğrudan kullanılabilir veya çeşitli sebeplerle farklı bir renk uzayına dönüştürülebilir. Bu sebeplere örnek olarak şunlar verilebilir: (i) Kanal sayısını azaltmak, (ii) Işıklılık (luminans) ve renk tonu (kromatiklik) bilgisini ayırtmak, (iii) Algılanan görüntünün olabildiğince muntazam olmasını sağlamak (iv) Bakış yönü, aydınlatma yoğunluğu gibi görüntüleme koşullarındaki çeşitli değişkenlerin etkisini gidermek verilebilir.

2.1.2 Kontrast İyileştirme

Dermoskopi görüntülerinde sınırların tespitini zorlaştıran faktörlerden biri kontrastın yetersiz olmasıdır. Bu sorun temel olarak iki yaklaşımla giderilmeye çalışılmıştır: Donanımsal teknikler (Møllersen vd., 2010) ve yazılım geliştirme teknikleri. Genel olarak donanımsal yaklaşım yazılım geliştirme yaklaşıma tercih edilmektedir.

Gomez vd. (2008) çalışmasında bağımsız histogram takibine dayalı bir kontrast iyileştirme yöntemi önermiştir. Bu algoritma, girdi olarak aldığı RGB görüntüyü doğrusal olarak lezyonun ve arka planındaki derinin maksimum düzeyde ayrıştırıldığı bağımsız bir renk uzayına dönüştürür.

Celebi vd. (2009) tarafından geliştirilen yöntem girdi olarak verilen RGB görüntüyü gri tonlamalı bir görüntüye dönüştürürken ideal renk ağırlıklarını belirlemek için çift modlu histogram dağılımını kullanmaktadır. Yazarlar, geliştirdikleri uyarlanabilir optimizasyon yönteminin, lezyon ve arka planda kalan deri arasındaki

kontrastı artırdığını ve Otsu eşikleme metodu uygulandığında iki bölgenin daha doğru bir şekilde ayrıştırılmasını sağladığını göstermiştir. Otsu eşikleme yöntemi, tüm olası değerlerinin yinelenmesini ve eşğin her iki tarafındaki piksel seviyeleri için bir yayılma ölçüsünün hesaplanmasını içerir (Otsu, 1979).

Madooei vd. (2012) çalışmasında dermoskopik görüntülerin otomatik analizi için yeni bir ön işleme şeması ortaya konulmuştur. Çalışma iki yönlüdür. İlk olarak, düz olmayan cilt yüzeylerinin görüntülenmesiyle indüklenen gölgelenmeyi ve dermoskopik görüntünün kenarlarına doğru ışık yoğunluğunun düşmesinin etkisini içerir. Bu da kıllar gibi artefaktların da tespit edilmesini ve çıkarılmasını kolaylaştırdığı gösterilmiştir. İkinci olarak, insan derisinin fiziğine ve biyolojisine dayanan yeni, basit ama etkili bir gri tonlama dönüştürme yaklaşımı sunulmuştur. Önerilen gri tonlamalı görüntü, pigmentli bir lezyon ile onu çevreleyen normal cilt arasında yüksek düzeyde ayrılabilirlik sağlar. Ön işleme şeması kullanılarak, basit gri seviye eşiklemeye dayalı bölütleme gerçekleştirilmiştir.

Celebi vd. (2013) çalışmasında sunulan gri tonlamalı görüntünün daha doğru bir segmentasyona olanak sağladığı gösterilmiştir. Iyatomi vd. (2011) çalışmasında HSV (Ton-Doygunluk-Değer) renk uzayına dayanan bir renk düzeltme yöntemi önerilmiştir. Bu yöntemde ilk olarak, sistemin eğitimi için hazırlanan bir görüntü setinden elde edilen çeşitli düşük seviyeli özellikler kullanılarak H, S ve V kanallarının her biri için çoklu doğrusal regresyon modeli oluşturulmaktadır. Bu regresyon modelleri kullanılarak, yöntem daha önce hiç görmediği bir görüntünün tonunu ve doygunluğunu otomatik olarak düzeltmektedir.

Abbas vd. (2011) çalışmasında deri tümörü bölütlemesi için yeni ve otomatik bir yaklaşım sunulmuştur. Önerilen teknik, esas olarak çoklu bölge algılamayı genişleten bölge tabanlı aktif kontur algoritmasına dayalıdır. Norton vd. (2012) çalışmasında dermoskopi görüntülerinde cilt lezyonlarının sınırlarını tespit etmek için otomatik bir bölütleme programı geliştirilmiştir. Çalışma, bir ön işleme aşaması, genel lezyon bölütleme aşaması ve parlak bölge bölütleme aşamasından oluşur. Yöntem, 107 adet melanositik olmayan cilt lezyonu (NoMSL) ve 319 melanositik cilt lezyonları (MSL) üzerinde test edilmiştir. NoMSL'ler için %84,5

hassasiyet; %88,5 duyarlılık; ve MSL'ler için %93,9 hassasiyet; %93,8 duyarlılık değerleri elde edilmiştir.

Sağlamlık, dermoskopi görüntüleri için tasarlanmış bilgisayar destekli tanı sistemlerinin en önemli özelliklerinden biridir. Ancak, sistemler farklı kurulumlar altında elde edilen çok kaynaklı görüntülerle çalışıyorsa bu özelliği sağlamak zordur. Aydınlatma ve yakalama cihazlarındaki değişiklikler, görüntülerin rengini değiştirir ve çoğu zaman sistemlerin performansını düşürür. Bu nedenle, herhangi bir sistemi eğitmeden ve test etmeden önce dermoskopi görüntülerinin renklerini normalleştirmek önemlidir.

Barata vd. (2015) çalışmasında dört renk sabitliği algoritması incelenmiştir: Gri dünya, maksimum-RGB, grinin tonları ve genel gri dünya. Elde edilen sonuçlar, renk sabitliğinin çok kaynaklı görüntülerin sınıflandırılmasını iyileştirdiğini, özellik olarak yalnızca 1B (bir boyutlu) RGB histogramlarını kullanarak bir özellik torbası sisteminin duyarlılığını %71'den; %79,7'ye ve özgüllüğü %55,2'den; %76'ya çıkardığını göstermiştir.

2.1.3 Yaklaşık Lezyon Lokalizasyonu

Dermoskopi görüntüleri oldukça büyük olsalar da lezyonlar genellikle nispeten küçük bir alanı kaplarlar. Lezyonu olabildiğince hassas bir şekilde aynı eksenle uzanan minimum boyuttaki bir çerçevenin içine almanın birkaç faydası vardır (Wang vd., 2010; Wang vd., 2011): (i) Bu çerçeve lezyon boyutunu tahmin etmeye yardımcı olur (bölge genişletme ve morfolojik su basma (flooding) (Sadri vd., 2013) gibi bazı görüntü segmentasyon yöntemleri bu bilgiyi sınır çizme kriterlerinden biri olarak kullanabilir) (ii) İşlem, içinde lezyonun mevcut olduğu kesin olan bir bölgeye odaklanmış olacağı için sınır tespit doğruluğunu artırabilir (aktif kontur bazlı segmentasyon yöntemleri bu bölgenin içinde/dışında uygulanabilir) (Erkol vd., 2005) (iii) İşlem genellikle tüm görüntüden daha küçük bir bölgede gerçekleştirileceği için sınır tespit süresi kısılacaktır (Abbas vd., 2012b), (iv) Çerçevenin çevresi arka plandaki deri renginin tahmin edilmesinde kullanılabilir (bu bilgi sınır tespiti sırasında ortaya çıkan hatalı bölgelerin ortadan

kaldırılması (Celebi vd., 2008) ve derideki çizgiler ve mavi-beyaz alanlar gibi dermoskopik özelliklerin tespit edilmesi dahil olmak üzere çeşitli işlemler için kullanışlı olacaktır). Birkaç yazar, dermoskopi görüntülerinde lezyonları lokalize etmek için Otsu metodu (Otsu, 1979) gibi histogram eşikleme yöntemlerini kullanmıştır (Erkol vd., 2005; Abbas vd., 2012a).

Wang vd. çalışmalarında sınırlayıcı kutuyu belirlemek için en küçük kareleri kullanarak ışıklılık görüntüsünün yatay ve dikey projeksiyonlarının her birine ikinci dereceden bir polinom yerleştirmiştir (Wang vd., 2010; Wang vd., 2011).

2.1.4 Artefakt Giderimi

Dermoskopi görüntüleri sıklıkla siyah çerçeve görüntüsü, mürekkep lekeleri, ölçekler, hava kabarcıkları gibi artefaktların yanı sıra derideki çizgiler, kan damarları ve kıllar gibi sınır tespitini etkileyebilecek intrinsik kutanöz özellikler içerirler (Thompson ve Jeyakumar, 2017). Bu unsurlar, sınır tespit prosedürünü karmaşıktırarak doğruluğu azaltır ve hesaplama süresini artırır. Bu nedenle görüntülerdeki gürültüyü gidermek için literatürde, gauss filtresi (GF), ortalama filtresi (MF), medyan filtresi (eMF), kutu filtreleme veya anizotropik difüzyon filtresi (ADF) gibi genel amaçlı bir filtreler önerilmektedir (Barbu, 2013). Bu filtreler kullanılırken dikkate alınması gereken birkaç nokta vardır:

- Skaler ve vektör işleme: Bu filtreler orijinal olarak skaler görüntüler için formüle edilmiştir. Vektör görüntüleri için, her kanala bağımsız olarak bir skaler filtre uygulayabilir ve ardından marjinal filtreleme olarak adlandırılan bir strateji olan sonuçları birleştirilebilir. Hızlı olmasına rağmen, bu şema çıktıda renk artifaktları sunar. Alternatif bir çözüm, pikselleri vektörler olarak ele alan filtreler kullanılmaktır (Celebi vd., 2007).
- Maske boyutu: Düzeltmenin miktarı, maske boyutuyla orantılıdır. Bu nedenle, aşırı büyük maskeler sınırların bulanıklaşmasına neden olarak sınır tespitinin doğruluğunu düşürebilir. Maske boyutunu görüntü boyutuyla orantılı olarak ayarlamak makul bir strateji gibi görünmektedir (Schmid, 1999a; Schmid, 1999b; Celebi vd., 2008).

- Hesaplamalı zaman: GF ve MF için maske boyutundan bağımsız olarak sabit zamanda çalışan algoritmalar geliştirilmiştir. ADF'nin uygulandığı durumlarda, hesaplama süresi maske boyutuna ve tekrar sayısına bağlıdır.

Bu tez çalışmasında medyan filtresi kullanılmıştır. Medyan filtresi, doğrusal olmayan bir filtredir ve iyi kenar koruma özellikleri ve dürtü gürültüsünü azaltma özelliği nedeniyle dijital görüntü işlemede yaygın olarak kullanılmaktadır. Medyan filtresi, bir sıralama filtresidir. Gürültü azaltma etkileri, filtreleme maskesinin boyutuna ve şekline bağlıdır; ve algoritma karmaşıklığı esas olarak medyan değerin nasıl elde edileceğine bağlıdır (Zhu ve Huang, 2012).

2.1.5 Bölge Birleştirme

Bölge birleştirme işlemleri, aynı nesneye ait bitişik bölgeleri birleştirerek hatalı sınırları ve bölgeleri ortadan kaldırmayı amaçlar. İdeal durumda bölütleme prosedürü sonucunda iki bölge elde edilmelidir: Lezyon ve arka plan. Bununla birlikte, bu bölgeler nadiren homojen olduğundan, bölütleme yöntemleri genellikle bu bölgeleri birden çok alt bölgeye ayırır.

Lezyonu tek bir nesne şeklinde görebilmek için öncelikle lezyonun bir parçası olan alt bölgeler tanımlanmalı ve ardından birleştirilmelidir. Bunun için uygulanabilecek birkaç yöntem vardır:

- Görüntünün siyah çerçevesi zaten kaldırılmışsa, görüntünün köşelerinden arka plan ten rengi tahmin edilebilir ve arka plan ten rengine benzer renge sahip alt bölgeler elimine edilebilir, yalnızca lezyonun parçası olan alt bölgeler bırakılır (Celebi vd., 2007; Celebi vd., 2008).
- Her bölgeden çeşitli renk ve doku özellikleri çıkarılabilir ve lezyonun bir parçası olan bölgeler ile arka plan derisinin bir parçası olanlar arasında hangi özelliklerin etkin bir şekilde ayırt edildiğini belirlemek için bir sınıflandırıcı eğitilebilir (Fleming vd., 1998).
- Sınırdaki normalleştirilmiş doku gradyanını en üst düzeye çıkaran bölümler ve lezyon içindeki bölgeler ile arka plan derisi içindekiler

arasındaki toplam ikili benzerlik, bir maliyet fonksiyonunu en aza indirerek belirlenebilir (Zhou vd., 2008).

Gestalt ilkeleri (aynı zamanda Gestalt yasaları olarak da adlandırılır), algısal girdinin bütünler, gruplar veya Gestalten olarak da adlandırılan üniter formlarda düzenlendiği düzenlilikleri formüle etmeyi amaçlar. Görsel algıda, bu tür formlar, bölümleri bir arada gruplanmış olarak algılanan ve böylece görsel alanın geri kalanından ayrılmış olan görsel alanın bölgeleridir. Psikologlar bu buluşsal yöntemleri “yasalar” olarak adlandırır, ancak daha kesin bir terim “algısal organizasyonun ilkeleri” olacaktır. Algısal gruplama, görsel özellikleri anlamlı parçalara (nesnelere) gruplamak için Gestalt ilkelerini kullanır. Gestalt ilkeleri şunlardır: Yakınlık, benzerlik, süreklilik, simetri, kapanış, iyi biçim, basitlik, ortak bölge ve bağlantılılık (Palmer ve Rock, 1994; Koffka, 2014).

Nesneleri bölümlere ayırmaya yönelik ilk yaklaşımlar, 2B (iki boyutlu) sahneleri nesneler halinde düzenlemek için genel Gestalt ilkelerini formüle etmeyi amaçlamıştır (Richtsfield vd., 2012). Birçok modern yaklaşım, Markov Rastgele Alanı (MRA) ile enerji minimizasyonu olarak görüntü segmentasyonunu formüle eder (Vicente vd., 2009; Bergström vd., 2011).

Kootstra vd. (2011) çalışmasında bilinmeyen ortamlarda bilinmeyen nesnelerin hızlı ve otomatik olarak algılanması ve bölütlenmesine odaklanmaktadır. Nesnelerin algılanması için bir sahnedeki göze çarpan nesneleri algılamak için şekil-zemin ayrımı için Gestalt ilkelerinden biri olan simetri kullanılmıştır. Elde edilen sonuçlar, hem nesne algılamanın hem de nesne bölümlleme yönteminin başarılı olduğunu ve mevcut yöntemlerden daha iyi performans gösterdiğini göstermiştir.

Werlberger vd. (2009) çalışmasında bir şekil temsili varyasyonel bir bölütleme çerçevesine dahil edilmiştir. Elde edilen segmentasyonun önceden sabit bir şekil için global olarak optimal olduğu gösterilmiştir ve kesin bir yakınsama kriterini tanımlayan hızlı bir ilk-çift optimizasyon prosedürü için bir Grafik İşlemci Ünitesi (GPU) uygulaması sağlanmıştır. Çerçeve, öncekinin yanlış hizalanmasıyla

nesnelerin doğru bir şekilde bölümlenmesini elde etmek için şekil konumunun yerel bir optimizasyonuna izin vermektedir.

2.1.6 Sınır Genişletme

Yapılan çeşitli araştırmalarda bilgisayarla tespit edilen sınırların genellikle dermatologların belirlediği sınırların içinde kaldığı görülmüştür. Bunun nedeni, otomatik bölütleme yöntemleri pigment değişiminin en keskin olduğu noktayı belirlerken dermatologların en dışta kalan tespit edilebilen pigmenti sınır olarak belirlemeleridir. İki sınır arasındaki tutarsızlığı azaltmak için morfolojik filtreleme (Celebi vd., 2008; Norton vd., 2012), öklid uzaklık dönüşümü veya tekrarlı bölge genişletme (Garnavi vd., 2011) yöntemleriyle bilgisayar tarafından belirlenen sınırı genişletmek mümkündür.

2.2 Görüntü Bölütlemenin Değerlendirmesi

Görüntü bölütleme algoritmalarını verim ve etkililik açısından değerlendirme önemli bir işittir. Aynı zamanda uygulama türüne göre bölütleme performansı hesaplamak da oldukça zor bir işlemdir (Kumar ve Indrayan, 2011). Çok sayıda görüntü bölütleme algoritması bulunmasına ve sayılarının artmasına rağmen bölütleme değerlendirme algoritmalarının sayısı azdır. En iyi bölütleme sonucunu veren genel bir yöntem olmadığı gibi, bölütlemenin sonucunu en iyi değerlendiren genel bir ölçütte bulunmamaktadır (Taha vd., 2014). Genel olarak değerlendirme algoritmaları öznel ve nesnel olmak üzere ikiye ayrılmaktadır.

Öznel değerlendirme, sınır tespitinden elde edilen sonuçların bir veya daha fazla insan gözlemine dayalı olarak dermatolog tarafından görsel olarak değerlendirilmesini içerir. Bölütleme yöntemlerinin sonuçlarını değerlendirmek kişiye göre değişen bir olgudur ve kişisel sezgi ile bu konuda karar vermek oldukça zordur (Xess ve Agnes, 2014).

Nesnel bir kalite ölçütü olmadığı için bu teknikte parametrelere göre ayar yapma veya otomatik sınır tespit yöntemleriyle karşılaştırma imkanı yoktur. Diğer yandan

nesnel deęerlendirme, dermatologlar tarafından belirlenen sınırlar kullanılarak sınır tespiti hatalarının nicel olarak ölçölmesini içerir. Bilgisayar tarafından tespit edilen sınırlardan otomatik sınırlar, dermatologlar tarafından belirlenen sınırlardan ise manuel sınırlar olarak bahsedilebilir.

Her bir görüntü bölütleme doğruluęunu deęerlendirmek için kullanılan çeşitli ölçütler vardır. Görüntü piksel doğruluęu, bir görüntü bölütleme modelinin ne kadar iyi performans gösterdiğini deęerlendirmenin en basit yöntemidir. Bunun için gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif deęerleri hesaplanmalıdır.

- TP (Gerçek Pozitif): Gerçek pozitif piksellerin sayısıdır. Ön plan (ilgi alanı) olarak doğru şekilde sınıflandırılan ön plan piksellerinin sayısıdır.
- TN (Gerçek Negatif): Arka plan (cilt bölgesi) olarak doğru şekilde sınıflandırılan arka plan piksellerinin sayısıdır.
- FP (Yanlış Pozitif): Hatalı pozitif piksellerin sayısıdır. Yanlış bir şekilde ön plan olarak sınıflandırılan arka plan piksellerinin sayısıdır.
- FN (Yanlış Negatif): Hatalı negatif piksellerin sayısıdır. Yanlış bir şekilde arka plan olarak sınıflandırılan ön plan piksellerinin sayısıdır.

Tez çalışmasında, bu tanımlar kullanılarak istatistiksel bazı performans metrikleri kullanılmıştır.


2.3 Pedro Hispano Hastanesi (HPH) Veri Tabanı

Bu tez çalışmasında önerilen yöntem için Portekiz'deki Pedro Hispano hastanesinden dermatoloji servisinden elde edilen görüntülerden oluşturulan veri tabanı kullanılmıştır. Pedro Hispano Hastanesinin (PHH) klinik veri tabanında, çeşitli türde lezyonların dermoskopik görüntülerinden oluşan 4000'den fazla vaka mevcuttur ve bunların hepsi Tuebinger Mole Analyzer sistemi kullanılarak ve lezyonlu bölgeler yirmi kat büyütölerek elde edilmiştir.

Veri tabanından klinik tanılarıyla birlikte rastgele toplam 90 dermoskopik görüntü seçilmiştir: 35'ine melanositik nevüs (normal), 25'ine atipik nevüs ve 30'na melanom cilt kanseri teşhisi konulmuştur. Görüntüler, $768 \times 560 = 430.080$ tane piksel 24 bit renk derinliğinde ve bir pikseldeki rengi oluşturmak için RGB (yani, bir üçlü değerler (R, G, B)) üç ana renkten oluşmaktadır.

PHH veri tabanı görüntülerinden alınan melanom cilt kanser görüntülere bazı örnekler Tablo 2.1'de verilmiştir.

Tablo 2.1 PHH veri tabanından alınmış bazı görüntüler

Görüntünün adı	Orijinal görsel	Kesin referans görüntüsü
IMD002		
IMD045		
IMD090		
IMD140		
IMD430		

2.4 Önışleme Aşaması


Veri ön işleme, görüntü işleme sürecinde önemli bir adımdır. Bu adımın amacı, sistemin daha doğru sonuçlar elde edebilmesi için dijital formata dönüştürülmüş görüntüde teşhisi zorlaştıracı sorunları (gürültü, kontrast düşüklüğü, vb.) ortadan kaldırarak sistemin daha doğru sonuç verebilmesi için gerekli görüntü kalitesinin elde edilmesi amaçlanır. Aynı zamanda görüntü üzerinde kullanılmayan tanılarının etkisini azaltılmaya çalışmaktır. Kanseri hücre görüntülerindeki şüpheli bölgelerin ayrıntılarını korurken arka plan gürültüsünün temizlenmesi, dermoskopi görüntüleri üzerindeki yaygın olarak kullanılan bir görüntü iyileştirme yöntemidir. Düzeltme işlemiyle ilgili sorunlardan biri, görüntü düzeltildiğinde görüntüdeki kenarların da bulanıklaşmasıdır.

2.4.1 Sınır Tespiti

Kenar algılama, çoğu görüntü işleme uygulamasında çerçevelerden bilgi elde etmek için özellik çıkarma ve nesne segmentasyonu için öncü bir adım olarak kullanılan temel bir araçtır. Bu işlem, bir nesnenin ana hatlarını ve nesneler ile görüntüdeki arka plan arasındaki sınırları algılar (Al-amri vd., 2010).

Sınır tespiti, sıklıkla cilt kanserinin otomatik tespitinin ilk aşamasını oluşturur. Sınır tespiti, sınır yapısından bazı klinik özelliklerin (tipik pigment ağı, globüller, mavi-beyaz bölgeler gibi) tespit edilmesi ve bu özelliklerin doğruluğunun belirlenmesi açısından önemlidir. Sınır yapısı üç parametreden oluşmaktadır: Sınır asimetrisi, sınır düzensizliği ve sınır kesim noktası.

Klinik özelliklerine göre melanomun sınırı veya kenarını tespit etmeyi zorlaştıran bazı faktörler vardır: Cilt ve kanser hücreleri arasındaki kontrastın düşük olması, düzensiz veya bulanık lezyon sınırları, kanser hücreleri arasındaki renk farklılıkları, çoklu lezyonlar ve kan damarları, ciltteki çizgiler, hava kabarcıkları, kıllar, siyah çerçeve gibi artefaktlar.



Şekil 2.1 Lezyon çeşitleri

Şekil 2.1’de çeşitli görüntü çeşitleri sunulmuştur. Sırasıyla şu şekilde sıralanabilir: (a) Lezyon ve deri arasındaki kontrastın düşük olması (b) Düzensiz sınır (c) Bulanık sınır (d) Siyah çerçeve (e) Kan damarları (f) Kabarcıklar (g) Kılılar (h) Çok renkli lezyon (i) Çoklu lezyon.


3. GÖRÜNTÜ BÖLÜTLEME

3.1 Görüntü Bölütleme

Görüntü bölütleme, bir görüntü genellikle görüntüdeki piksellerin özelliklerine dayalı olarak birden çok parçaya veya bölgeye bölmek için dijital görüntü işleme ve analizinde yaygın olarak kullanılan bir tekniktir (Ding vd., 2009). Görüntü bölütleme, bir görüntüyü, kendi içinde çeşitli özellikler açısından (ör. yoğunluk, gradyan, uzamsal ve zamansal konum, varyans, vb.) benzer olan çeşitli anlamlı bölgelere ayırmayı amaçlar.

Günümüzde görüntü bölütleme çok çeşitli amaçlarla kullanılmakta ve birçok farklı alanda, özellikle de tıp alanında ön plana çıkmaktadır. Segmentasyon görüntüde yer alan nesnelerin veya lezyonların hacminin hesaplanması, üç boyutlu görselleştirmeden önce verilerin ön işlemeden geçirilmesi, farklı görüntü türlerinde nesnelerin konumlandırılması veya sanayide bir ürünün doğru özelliklere sahip olup olmadığının kontrol edilmesi gibi çeşitli alanlarda uygulanabilir. Kan damarları, kaslar, kemikler ve beynin bölgeleri gibi anatomik yapıları ve başka pek çok yapıyı incelemek için kullanılabilir. Örneğin, görüntüde benzer ışıklı alanları olabilir ve bu ışıklı alanları, ilgili görüntünün farklı bölgelerindeki nesneleri temsil ediyor olabilir (Bernardes vd., 2011).

Şekil 3.1’de, gösterildiği şekilde uygulamaya bağlı olarak değişen segmentlere (segmentler-öğeler) örnek olarak beynin orijinal MR ve bölütlenmiş görüntüsü verilmiştir. Tüm görüntülere uygulanabilecek evrensel bir segmentasyon yöntemi olmadığı ve hiçbir segmentasyon yönteminin mükemmel olmadığı unutulmamalıdır. Diğer bir deyişle, görüntü bölütleme için tasarlanan yöntemler ve bu yöntemlerin performansı, görüntü iyileştirme ve onarım problemlerinde olduğu gibi görüntüden görüntüye ve uygulamadan uygulamaya farklılık göstermektedir. Otomatik görüntü bölütleme, görüntü işlemenin en zor işlemlerinden biridir (Kjønigsen vd., 2019).



Şekil 3.1 a) Orijinal beyin MR görüntüsü b) Beyin MR bölütlenmiş görüntü

Segmentasyon yöntemleri görüntüyü, aynı bölge içindeki pikseller çok benzer ve farklı bölgelerdeki pikseller çok farklı olacak şekilde birkaç ayrı bölgeye ayırır. Bazen otomatik görüntü bölütleme sürecinde bazı problemlerle karşılaşırız. Örneğin, bazen nesneler çeşitli yapı ve boyutlardadır, görüntüde çok fazla konuyla alakasız ayrıntı mevcuttur ve nesneler pürüzlü veya düzensiz bir yapıya sahiptir.

Mükemmel ve ideal şekilde bölütlenmiş bir görüntüde her piksel doğru nesne segmentine atanmış olacaktır. Tıp alanında, görüntü segmentasyonu, bir lezyon veya organın nicel ölçümüne ihtiyaç duyan radyolog ve cerrahlar tarafından kullanılabilecek önemli bir araçtır. Klinik uygulamada yararlı olabilmesi için böyle bir aracın hızlı ve kullanımı kolay olması gereklidir. Görüntü segmentasyonu çeşitli yöntemlere veya sınıflara ayrılabilir – piksel tabanlı, bölge tabanlı ve sınır tabanlı yöntemler. Bu yöntemler hız, doğruluk ve karmaşıklık açısından farklılık göstermektedir. Eşikleme ve sınıflandırma gibi yöntemler piksel tabanlı yöntemlerdir. Bölge genişletme, havza (watershed) ve seviye belirleme yöntemleri bölge tabanlı yöntemlerdir. Livewire ve aktif kontur (yılan) yöntemleri sınır tabanlı yöntemlerdir ve nesnelerin arasındaki sınırları tespit etmeyi amaçlar. Görüntü segmentasyonu, BDT, nicel analiz, görselleştirme ve kayıt gibi işlemler için hayati önem taşımaktadır (van Vliet, Young, & Beckers, 1989).

Segmentasyonla elde edilen bölgelerin özellikleri şu şekildedir:

- Her bölge üniformdur (tek tiptir).
- Bölgeler birbiriyle çakışmaz.
- Tek bir bölgeye dahil edilmiş tüm piksellerin ortak bir özelliği vardır.

- Komşu bölgeler, farklı özelliklere sahiptir.
- Gri tonlamalı görüntüler için segmentasyon algoritmaları: gri tonlamalıdır (parlaklık).
- Değerler görüntüdeki bölgelerin sürekliliğine ve benzerliğine dayanarak belirlenir.
- Süreksizliğe dayalı segmentasyon algoritmaları: İzole nokta, ince çizgi veya görüntülere odaklanır; kenarlar gibi süreksizlikleri (gri tonlama değerlerinde ani değişiklik olan noktalar) tespit etmek için benzer maskeleri (düşük ve yüksek filtreleme gibi) kullanmaya dayanır.
- Benzerliğe dayalı segmentasyon algoritmaları: Haritalama tabanlı, bölge genişletme veya bölgeleri bölme ve birleştirme tabanına dayanır.

3.2 Görüntü Bölütlemenin Temel Adımları

Görüntü bölütlemenin temel adımları aşağıda listelenmiştir:

- Görüntü sadeleştirme: Sadeleştirme filtresi, özellik çıkarma ve karar vermeden önce kaldırılan bilgi miktarını kontrol ettiğinden, bölütlemedeki hiyerarşi kavramını tanımlar. Bir bölütleme algoritması için, iyi bir karmaşıklık/performans filtresi, basitleştirilmiş bir alternatif sıralı sürümle yeniden oluşturma yoluyla açma-kapama üzerine kuruludur.
- Özellik çıkarma: Homojen bölgelerin varlığını tanımlayan ikili sinyaller olan işaretler üretir. Bu adım, önceki sadeleştirmenin özelliklerini dikkate alır. Daha önce gösterildiği gibi, yeniden oluşturma yoluyla aç-kapa, ani dış hatlara sahip sabit gri seviyeli bölgeler üretir. Bu, ikili bir özellik çıkarımına yol açar: Biri sabit gri seviyeli bölgeleri çıkarır ve diğeri yüksek kontrast arar.
- Karar: Havza (watershed) morfolojisinde karar aşaması algoritmalar tarafından gerçekleştirilir. Nesnenin dış hatlarını elde etmek için orijinal sinyalin morfolojik gradyanı üzerinde çalışması gerekir. Aslında, eğimin havza tarafından doğrudan bölünmesi, aşırı bir bölümlenme ile

sonuçlanır. Bununla birlikte, gradyan, yalnızca özellik çıkarma ile “işaretlenmiş” nesneleri bölümlere ayıracak şekilde değiştirilebilir.

- Kalite kestirimi: Son basamak, yani görüntü bölütleme kalite kestirimi, görüntünün bilgi içeren ve artık bilgi olarak da bilinen kısmının tespit edilmesini sağlar.

Eşik tabanlı, kenar tabanlı, küme tabanlı ve sinir ağı tabanlı gibi farklı görüntü segmentasyon teknikleri mevcuttur. Farklı teknikler arasında en etkili yöntemlerden biri kümeleme yöntemidir. Kümeleme yöntemi de kendi içinde birkaç türe ayrılır: K-means kümeleme, bulanık C-means kümeleme, “mountain” kümeleme ve çıkarımlı kümeleme. En yaygın kullanılan kümeleme algoritmalarından biri K-means kümelemedir. Hiyerarşik kümelemeden daha basit ve hesaplama süresi daha kısadır. Ayrıca çok sayıda değişkenle kullanılabilir. Ancak küme sayısı farklı olduğunda algoritmanın belirlediği kümeler de farklılık göstermektedir. Bu nedenle en başta küme sayısı (k) doğru şekilde belirlenmelidir. Yine, merkez nokta (centroid) sayısının (k) da en baştan doğru şekilde belirlenmesi gereklidir. Başlangıçta belirlenen centroid değeri değiştikçe algoritma tarafından belirlenen kümeler de değişecektir (Evans, 2005).

3.3 Görüntü Bölütleme Yöntemleri

Literatürde görüntü bölütleme tekniklerine ilişkin farklı sınıflandırmalar mevcuttur; Bu bölümde önemli görüntü bölütleme tekniklerinden bazılarını kısaca sunulmuştur.

3.3.1 Eşikleme Yöntemleri

Eşikleme yöntemleri, görüntüleri segmentlere ayırmanın en basit yöntemi kabul edilmektedir. Böyle yaklaşımlarda genellikle bir görüntü, bir eşik tanımlanarak ikili bir görüntüye dönüştürülür. Elde edilen ikili görüntünün sınırları kullanılarak görüntü segmentlere ayrılabilir. Eşikleme, muhtemelen görüntü bölütlemeye en sık kullanılan tekniktir. Eşikleme işlemi, grilik değerinin yeniden haritalanmasını içeren bir işlemdir (g) ve aşağıdaki şekilde tanımlanmıştır:

$$g(v) = \begin{cases} 0 & \text{if } v < t \\ 1 & \text{if } v \geq t \end{cases} \quad (3.1)$$

Burada v grilik deęerini, t eřik deęerini temsil eder. Eřikleme yntemi, gri tonlamalı bir grnty ikili bir grnt haline evirir. Eřikleme iřlemi tamamlandıęında, grnt sırasıyla 0 ve 1 deęerleri ile tanımlanan piksellerden oluřan iki segmente ayrılmıřtır. rnek olarak, karanlık bir arka plan zerinde parlak nesneler ieren bir grntnn bltlenmesi isteniyorsa eřikleme yntemi kullanılabilir. Birok grnt trnde nesnelerin grilik deęerleri arka planın grilik deęerinden ok farklı olduęundan, eřikleme genellikle bir grnty nesne ve arka plan řeklinde ikiye ayırmak iin uygun bir yntemdir.

3.3.2 Kmeleme Tabanlı Yntemler

Grnt bltleme, bir grntnn farklı gruplara ayrılmasıdır. Kmeleme kullanarak grnt bltleme alanında pek ok arařtırma yapılmıřtır. Kmeleme tabanlı yaklařımlarda, segmentasyon iřlemi, K-means gibi sınıflandırma yntemleriyle gerekleřtirilir. Grnty farklı kmeler halinde sınıflandırdıktan sonra, her piksel bir kmenin merkezine atanır. Piksellerin farklı kmelere atanmasıyla (genellikle yinelemeli bir řekilde) grnt istenen kme merkezlerine gre segmentlere ayrılır. Kmeleme yntemleri, o ya da bu řekilde benzer olan grntleri aynı kmelerde gruplandırmayı amalar.

3.3.3 Histogram Tabanlı Yntemler

Histogram tabanlı segmentasyon teknikleri, literatrdeki en etkili segmentasyon yntemleri arasında sayılmaktadır. Bu yntemlerde, grntnn tm pikselleri iin histogramlar hesaplanır ve histogram diyagramındaki tepe noktalarına dayanarak pikseller kategorize edilir. Pikselleri tepe noktalarına gre kategorize etme iřlemi tekrarlanarak grntde istenen alan bltlenir. Bazı grnt bltleme teknikleri řu řekildedir:

- Sınır tespit yntemleri

- Ağaç/graf tabanlı yöntemler
- Bölge ayırma yöntemleri
- Bölge genişletme yöntemleri
- Model tabanlı segmentasyon
- Sinir ağı tabanlı segmentasyon
- Grafik bölümlleme (partitioning) yöntemleri
- Havza (watershed) dönüşümü
- Çok ölçekli segmentasyon
- Olasılıkçı ve bayesci yaklaşımlar

Teknolojideki ve biyometri alanındaki gelişmelerle, tıbbi uygulamada halihazırda kullanılan bilgisayarlı yöntemlerin sayısı ve etkinliği çarpıcı şekilde gelişme göstermiştir. Tıbbi teşhis ve tedaviyle ilgili içgörü sağlama bağlamında otomatik görüntü işleme ve analizi, bilgisayar ve görselleştirme tekniklerinin en umut verici alanlarını temsil etmektedir. Bu bağlamda, klinik pratikte dermoskopi görüntülerinden melanomun yüksek çözünürlüklü görüntülerini elde etmek çoğu zaman mümkündür. Ayrıca bu görüntüler hekime teşhis ve tedavide kullanılabilecek birçok bilgi ve veri sağlayabilme potansiyeli taşımaktadır.

Tıp uzmanlarının pratikte karşılaştığı, hastalık şüphesi olan ancak teşhis konamayan melanom cilt kanseri görüntülerini böylelikle otomatik olarak değerlendirmek mümkün olacaktır. Doktorlar çok sayıda görüntüyü hızlı bir şekilde değerlendiremeyeceği için manuel değerlendirme durumunda hastalığın tanınması, yönetimi ve tedavisi gecikebilecektir.

3.4 Yapay Zeka, Makine Öğrenimi ve Derin Öğrenme

Yapay zeka (YZ), bilgisayarlarda akıllı davranışı simüle etmeyi amaçlayan bir bilgisayar bilimi dalıdır. Makine öğrenimi (MÖ) yapay zekanın, derin öğrenme (DÖ) ise MÖ'nün alt dalıdır. Yapay zeka üzerine yapılan araştırmalar genel olarak bilgisayar sistemlerini, karar vermeyle ilişkili olup normal şartlarda insan zekası gerektiren görevleri (ör. görsel algılama, konuşma tanıma ve diller arasında çeviri yapma gibi) yerine getirebilecek hale getirmeyi amaçlamaktadır. Yapay zeka

sistemlerinin karmaşıklık seviyeleri, “eğer ise değilse” ifadeleri gibi basit yapılardan karmaşık istatistiksel modellere kadar değişebilir, ancak hepsinin amacı karar verme sürecinde insan zekasını bir şekilde taklit etmektir.

Makine öğrenimi, bilgisayarların doğrudan programlanmak yerine kendilerini aldıkları verilere yanıt olarak değiştirerek “öğrenmelerini” sağlayan bir veri analizi biçimidir. Geleneksel makine öğrenimi, ham verilerden açıkça tanımlanmış özellikler çıkarmayı amaçlar. Bu özellikler, sorunla ilgili mevcut bilgilere dayanılarak insanlar tarafından tasarlanır ve tipik olarak düşük seviyeli özelliklerle sınırlıdır. Araştırmacılar, bilgilendirici görüntü özellikleri tasarlamak için ciddi miktarda çaba harcamaktadır. Makine öğrenimi genel olarak denetimli, denetimsiz, yarı denetimli ve pekiştirmeli öğrenme şeklinde sınıflandırılabilir. Denetimli bir öğrenme algoritmasına girdilerle birlikte bunlara karşılık gelen çıktılar beslenir ve algoritma tahmin edilen çıktı ile doğru çıktı arasındaki hataları en aza indirecek şekilde modeli düzenler.

Denetimli makine öğrenimi algoritmaları arasında doğrusal regresyon, en yakın komşuluk, Gaussian Naive Bayes algoritması, karar ağaçları, destek vektör makinesi (DVM) ve rastgele orman sayılabilir. Denetimsiz öğrenmede algoritma kendisine sunulan etiketlenmemiş verileri inceleyerek bunların içinde örüntüler tespit etmeye çalışır. Popüler denetimsiz öğrenme tekniklerinden bazıları kendi kendini düzenleyen haritalar, en yakın komşuluk algoritması, k-mean kümeleme ve tekil değer ayrıştırmasıdır. Yarı denetimli öğrenme, eğitim için hem etiketli hem de etiketsiz verilerin kullanımını içerir. Tipik olarak, algoritmaya az miktarda etiketlenmiş veri ve büyük miktarda etiketlenmemiş veri sağlanır (çünkü etiketlenmemiş veri elde etmek daha az çaba gerektirecektir). Yarı denetimli öğrenme, sınıflandırma, regresyon ve tahmin gibi yöntemlerle birlikte kullanılabilir ve uygulama alanları denetimli öğrenime benzerdir.

Denetimli öğrenmede, algoritma deneme yanılma yoluyla hangi eylemin en büyük ödülü verdiğini keşfeder. Uygulama alanları arasında robot bilimi, oyun geliştirme ve navigasyon sayılabilir. Bu tür öğrenmenin üç ana bileşeni vardır: özne (öğrenici veya karar verici), ortam (öznenin etkileşime girdiği her şey) ve eylem (öznenin


yapabilecekleri). Burada amaç, öznenin belirli bir süre içinde istenen ödülü en üst düzeye çıkaracak eylemleri seçmesidir. Daha iyi bir yaklaşım izlemek özneyi hedefe çok daha hızlı ulaştıracaktır. Bu nedenle, pekiştirmeli öğrenmedeki amaç en iyi yaklaşımı öğrenmektir.

Derin öğrenme, makine öğreniminin bir alt dalıdır ve nesne algılama, konuşma tanıma, tercüme, vb. görevlerde en yüksek doğruluğu sağlayabilmek için çok katmanlı yapay sinir ağlarından (YSA) faydalanır. Bilgisayar donanımındaki gelişmeler sayesinde böyle büyük YSA'lar elde etmek mümkün olmuştur. DÖ'nün geleneksel makine öğrenimi tekniklerinden ayrıldığı nokta, elle kodlanmış kurallar veya insanların o alanla ilgisi bilgisi olmadan görüntü, video veya metin gibi verilerden otomatik olarak özellik öğrenebilmesidir. DÖ'nün oldukça esnek mimari yapısı, doğrudan ham verilerden öğrenebilmelerini ve daha fazla veri sağlandığında tahminlerinin doğruluğunu artırabilmelerini mümkün kılar. DÖ sayesinde yapay zeka alanında son zamanlarda çok ciddi gelişmeler elde edilmiştir. Örneğin Google DeepMind yapay zeka şirketi tarafından geliştirilen AlphaGo, kendini süren arabalar, akıllı sanal asistanlar ve çok daha fazla teknoloji DÖ teknolojisine dayanmaktadır. Popüler derin öğrenme mimarileri arasında evrişimli sinir ağları (Krizhevsky vd., 2012), tekrarlayan sinir ağları (RNN) (Mikolov vd., 2010), otomatik kodlayıcılar, üretken düşman ağları (Mirza ve Osindero, 2014) ve derin artık ağlar (ResNet) (He vd., 2016) bulunmaktadır.

Bir tür CNN yaklaşımı olan U-Net ilk olarak biyomedikal görüntüler üzerinde daha iyi bir bölütlemeyi amaçlamaktadır. U-Net, Ronneberger vd. (2015) tarafından biyomedikal görüntü segmentasyonu için geliştirilen bir modeldir. Bu modelin mimari yapısı iki yoldan oluşmaktadır. İlk yol, görüntüdeki bağlamı yakalamak için kullanılan küçülme yoludur (kodlayıcı olarak da adlandırılır). Kodlayıcı, geleneksel evrişimli ve maksimum havuzlama katmanlarından oluşan bir yığındır. İkinci yol ise devrik evrişimleri kullanarak lezyonun kesin lokalizasyonunu sağlamayı amaçlayan simetrik genişleyen yoldur (kod çözücü olarak da adlandırılır). Bu nedenle bu yapı, uçtan uca tam evrişimli ağ (FCN) olarak adlandırılır, yani yalnızca evrişimli katmanlardan oluşur ve herhangi bir yoğun katman içermediği için herhangi bir boyuttaki görüntüyü işleyebilir. Bu genişleme, ağıın yerelleştirilmiş

sınıflandırma bilgilerini öğrenmesini sağlar. Ek olarak, genişletme yolu aynı zamanda çıktının çözünürlüğünü de artırır ve bu daha sonra tamamen parçalanmış bir görüntü oluşturmak için son bir evrişim katmanına geçirilebilir. Ortaya çıkan ağ neredeyse simetriktir ve ona U benzeri bir şekil verir.

Her mavi kutucuğun çok kanallı bir özellik haritasına karşılık geldiği U-net mimarisi Şekil 3.2’de verilmiştir (Du vd., 2020). Her mavi kutucuk, çok kanallı bir özellik haritasına karşılık gelmektedir. Kanal sayıları kutucukların üstünde belirtilmiştir. Kutucukların sol alt köşelerinde ise x-y boyutları verilmiştir. Beyaz kutucuklar, kopyalanan özellik haritalarını temsil etmektedir. Oklar çeşitli işlemleri temsil etmektedir.



Şekil 3.2 U-net mimarisi

4. SİSTEM GERÇEKLEŞTİRİLMESİ


4.1 Ön İşleme Aşaması

Medyan filtresi, istatistiklere dayalı doğrusal olmayan bir sinyal işleme teknolojisidir. Dijital görüntünün veya dizinin gürültülü değeri, komşuluğun (maske) medyan değeri ile değiştirilir. Maskenin pikselleri, gri seviyelerine göre sıralanır ve grubun medyan değeri, gürültülü değeri değiştirmek için saklanır. Denklem 4.1’de gösterildiği üzere medyan filtresi bir piksel (x,y) için tüm komşu pikselleri medyan değerle değiştirecektir.

$$f_{med}(x,y) = median\{f(s,t)\}, \quad (s,t) \in W_{xy} \quad (4.1)$$

Burada W, görüntünün merkezindeki (x, y) bitişik konumları temsil etmektedir. Melanoma cildin yüzeyinde derinin pigment üreten hücrelerinde başlayan bir kanser tipidir. Kanser, deriye renk veren melanosit hücrelerinin sınırsız ve dağınık bir şekilde büyümesiyle ortaya çıkan bir durumdur.

Şekil 4.1’de melanom cilt kanseri görüntüsüne medyan filtresi uygulanmadan önce ve uygulandıktan sonra parlaklık yoğunlukları gösterilmiştir.




Şekil 4.1 a) Orijinal melanoma cilt kanseri görüntüsü b) Gri tonlamalı görüntü c) Medyan filtresinden geçirilmiş görüntü

Eşikleme, her piksel için bir yoğunluk değeri T (eşik) tahsis ederek, amaçlanan bir nesneyi veya hedef nesneyi arka plan görüntüsünden çıkarmak için kullanılan bir yöntemdir, örneğin her piksel bir arka plan noktası veya bir nesne noktası olarak sınıflandırılır (Bangare vd., 2015).

Otsu eşikleme yöntemi, tüm güvenilir eşik değerlerinin yinelenmesini ve eşğin her iki tarafındaki piksel seviyeleri, yani ön veya arka planda bulunan pikseller için bir yayılma ölçüsünün numaralandırılmasını içerir. Otsu yöntemi, 1979'da Nobuyuki Otsu tarafından önerildi ve belge ikilileştirmede, bilgisayarla görmede ve örüntü tanımada yaygın olarak kullanılmaktadır (Otsu, 1979). Bu, bir görüntünün optimal eşikleri için hesaplama verimliliğini artırmak için önerilmiştir. Otsu yöntemi, bölümlere ayrılmış görüntünün sınıflar arası varyansını maksimize ederek en uygun eşği otomatik olarak seçer. Basit, verimli ve parametresizdir.

Bu tez çalışmasında medyan filtresi uygulandıktan sonra elde edilen görüntü, Otsu yöntemi kullanılarak ikili formata çevrilmiştir. Daha sonra melanom cilt kanseri göstergesi değiştirilmiş ve sonraki aşamada algoritmayla melanom cilt kanserinin konumu ve sınırları belirlenmiştir. Otsu eşikleme tekniği, bir global eşikleme yöntemidir ve etkili bir teknik olduğu belirtilmektedir. Bu işlemler Şekil 4.2'de gösterilmiştir.



Şekil 4.2 a) Orijinal melanom cilt kanseri görüntüsü b) Medyan filtresinden geçirilmiş görüntü c) Otsu eşikleme yönteminin sonucu d) Melanom cilt kanserinin tahmini lokalizasyonu

Otsu yöntemi, küresel eşik için en uygun değeri bulmayı amaçlar. Ayrıca sınıflar arası varyans maksimizasyonuna dayanır.

MxN görüntü histogramında;

- L yoğunluk seviyeleri, [0, ..., L-1];
- n_i yoğunluk pikselleri i:

$$MxN = \sum_{i=0}^{L-1} n_i \quad (4.2)$$

Normalleştirilmiş histogram:

$$p_i = \frac{n_i}{MxN} \quad (4.3)$$

$$\sum_{i=0}^{L-1} p_i = 1, \quad p_i \geq 0 \quad (4.4)$$

Eşik olarak k, $0 < k < L - 1$ kullanıldığında, $T=k$:

- iki sınıf: C_1 ([0, k] aralığındaki pikseller) ve C_2 ([k+1, L-1] aralığındaki pikseller)

- $P_1 = P(C_1) = \sum_{i=0}^k p_i$, C_1 sınıfının olasılığı

$$P_2 = P(C_2) = \sum_{i=k+1}^{L-1} p_i = 1 - p_1, \quad C_2 \text{ sınıfının olasılığı}$$

- m_1, c_1 'deki piksellerin ortalama yoğunluğu:

$$m_1 = \sum_{i=0}^k i \cdot P(i | c_1) \quad (4.5)$$

$$= \sum_{i=0}^k i \cdot \frac{P(c_1|i)P(i)}{P(C_1)}$$

$$= \frac{1}{P_1} \sum_{i=0}^k i \cdot p_i$$

Burada; $P(C_1|i) = 1$, $P(i) = p_i$ e $P(C_1) = P_1$.

Benzer şekilde, m_2 , C_2 sınıfındaki piksellerin ortalama yoğunluğu vermektedir:

$$m_2 = \frac{1}{P_2} \sum_{i=k+1}^{L-1} i \cdot p_i \quad (4.6)$$

Ortalama global yoğunluk olarak, m_g ;

$$m_g = \sum_{i=0}^{L-1} i \cdot p_i \quad (4.7)$$

k seviyesine kadar ortalama yoğunluk olarak, m:

$$P_1 m_1 + P_2 m_2 = m_g \quad (4.8)$$

$$P_1 + P_2 = 1$$

4.2 Birleştirme Koşulu

Bölge birleştirmede, bölgeler homojen özelliklere sahip piksel kümeleridir ve pikseller temel bölgeler olmak üzere daha küçük bölgeleri veya pikselleri birleştirerek yinelemeli olarak büyütülür. Bölge büyütme/birleştirme teknikleri, bölgelerin birleştirilmesine karar vermek için genellikle istatistiksel bir testle çalışır (Nock ve Nielsen, 2004).

Gözlenen görüntü, I , $|I|$ piksel içerir. Her biri RGB değerleri içeren, üçün herbiri $\{1, 2, \dots, g\}$ kümesine aittir. I , mükemmel bir I^* sahnesinin gözlemidir. I^* 'de optimal bölgeler, ortak bir homojenlik özelliğini paylaşan teorik nesneleri temsil eder.

I 'da N sayıda birleştirme testi yapmak için, birleştirilmesi test edilen (R, R') bölge çiftlerinin $|(\bar{R} - \bar{R}') - E(\bar{R} - \bar{R}')| \leq b(R, R')$ denklemini sağlaması gereklidir. Burada, birleşimi gözlenen R ve R' bölgelerinin aynı I^* istatistiksel bölgesinde bulunduğunun test edilmesi gereklidir.

$$|(\bar{R} - \bar{R}') - E(\bar{R} - \bar{R}')| \geq g \sqrt{\frac{1}{2Q} \left(\frac{1}{|R|} + \frac{1}{|R'|} \right) \ln \frac{2}{\delta}} \quad (4.9)$$

Denklemleri (4.6) kullanarak bir birleştirme koşulu tasarlamak için $E(\bar{R} - \bar{R}') = 0$ olmalı ve sapma $|\bar{R} - \bar{R}'|$, $b(R, R')$ değerini aşmamalıdır. Birleştirilmeye aday iki bölge olarak R ve R' ele alındığında, $b(R, R')$ birleştirme eşiği olacak şekilde eğer $|\bar{R} - \bar{R}'| \leq b(R, R')$ ise birleştirme koşulu R ve R' bölgelerini birleştirebilecektir.

$$b(R, R') \leq \sqrt{b^2(R) + b^2(R')} < b(R) + b(R') \quad (4.10)$$

Birleştirme koşulu özetle şu şekildedir:

$$p(R, R') = \begin{cases} \text{doğru} & \text{if } |\bar{R} - \bar{R}'| \leq \sqrt{b^2(R) + b^2(R')} \\ \text{yanlış} & \text{diğer} \end{cases} \quad (4.11)$$

4.3 Birleştirme Sırası

İki gerçek bölge arasında herhangi bir test gerçekleşmişse tüm testler bu iki gerçek bölgenin her birinin içinde daha önce uygulanmış demektir. Bir segmentasyon işleminde görülebilecek üç tip hata vardır. Birincisi, yetersiz birleştirmedir. Burada, elde edilen bir veya daha fazla bölge gerçekte mevcut olan bir bölgenin ayrı alt kısımları olarak sınıflandırılmıştır. İkincisi, aşırı birleştirmedir. Burada, işlem sonucu elde edilen bazı bölgeler birden fazla gerçek bölge içermektedir. Üçüncüsü ise bu iki hatanın karışımı denebilir. Burada, elde edilen bazı bölgeler, birden fazla gerçek bölgenin kısımlarını içermektedir. Bu tez çalışmada, $s^*(I)$ değerini, I görüntüsünün optimal segmentasyonunda elde edilen bölgeler kümesi olarak, $s(I)$ değerini ise yapılan bölütleme ile elde edilen bölgeler kümesi olarak tanımladık.

$\geq 1 - O(|I|\delta)$ olasılıkla, I görüntüsünün bağımsız değişken A koşulunu sağlayacak şekilde bölütlenmesi durumu, I^* 'in aşırı birleştirilmesidir. Optimal segmentasyona kıyasla oluşan hatayı nicel olarak göstermek için bu hatayı, $s^*(I)$ ve $s(I)$ arasındaki boş olmayan tüm kesişim bölgeleri arasındaki mutlak kanal farklılıklarının ağırlıklı ortalaması olarak tanımladık.

$$Errs(I)) = E_{R \cap O, R \in S(I), O \in S^*(I)} |E(O) - E(R)| \quad (4.12)$$

Burada E ilişkili olasılık ölçütüyle beklenen değeri ifade etmektedir.

$$\mu(R \cap O) = |R \cap O|/|I|$$

Renkli görüntülerde ise RGB *görüntüler* için birleştirme koşulu aşağıdaki gibidir:

$$p(R, R') = \begin{cases} \text{doğru} & \text{Eğer } \forall a \in \{R, G, B\}, \\ \text{yanlış} & |(\bar{R}'_a - \bar{R}_a)| \leq \sqrt{b^2(R) + b^2(R')} \text{ ve diğerleri} \end{cases} \quad (4.13)$$

Burada $\mathbf{R}_a$, R bölgesinde a renk kanalı için gözlemlenen ortalamayı göstermektedir.

4.4 Algoritma Parametrelerinin Değerlendirilmesi

Tıbbi görüntü segmentasyonunun etkinliğini doğrulamak için, doğrulanacak etkili performans göstergelerinin ayarlanması gerekir. Bu, bölütleme sürecinin ayrılmaz bir parçasıdır. Performansın hesaplanmasında bilinmesi gereken bazı terimler vardır. Bunlar daha sonra çeşitli metrikleri hesaplamak için kullanılabilir. Bu terimler basit bir şekilde şöyledir:

TP, algoritmanın doğru şekilde melanom cilt kanseri olarak sınıflandırdığı piksel sayısını belirtmektedir.


TN, algoritmanın doğru şekilde melanom cilt kanseri dışı olarak sınıflandırdığı piksel sayısını belirtmektedir.

FP, algoritmanın hatalı şekilde melanom cilt kanseri olarak sınıflandırdığı piksel sayısını belirtmektedir.

FN, algoritmanın hatalı şekilde melanom cilt kanseri dışı olarak sınıflandırdığı piksel sayısını belirtmektedir.

Bu parametreler Şekil 4.3’de gösterilmiştir. Burada sağdaki şekil, uzman bir hekim tarafından manuel olarak bölütlenmiş olan kesin referans görüntüsünü temsil etmektedir. Soldaki şekilse otomatik olarak melanom cilt kanseri olarak bölütlenmiş görüntüyü temsil etmektedir. Doğruluk, Denklem 4.14 ile gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif alanlarına dayanarak hesaplanır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FN+TN+FP} \quad (4.14)$$




Şekil 4.3 Doğruluk hesaplama değerleri

4.5 Bulgular ve Tartışma


Bu zorluğu ele alan sınırlı sayıda bölütleme tekniği mevcuttur. Geçmiş algoritmaların performansları, görüntü veri kümelerine bağlı olarak farklılıklar göstermektedir. Bazı yaklaşımlar algoritmayı eğitmek ve test etmek için küçük bir veri kümesi kullanırken, bazıları büyük veri kümeleri kullanmıştır. Birçok yöntem yalnızca normal melanom cilt kanseri görüntüleriyle test edilirken bazıları patolojik görüntülerle değerlendirilmiştir.

Tez çalışmasında geliştirilen uygulamada özellik çıkarma basamağı (yani görüntüden kırmızı kanalın çıkarılması, aydınlatmanın normalleştirilmesi ve kontrast iyileştirmeyi içeren ön işleme adımı) grafik kullanıcı arayüzü tarafından gerçekleştirilmiştir. Uygulamanın başlaması için, uluslararası veri tabanından

(PHH) bir görüntü seçilerek uygulamaya yüklenir. Bu işlem sırasında arayüz ekranının görüntüleri aşağıda sırasıyla Şekil 4.4 ve Şekil 4.5'te sunulmuştur.




Şekil 4.4 Görüntünün veri setinden seçilmesi




Şekil 4.5 Görüntünün uygulama ekranına yüklenmesi

Uygulama, görüntüyü 24 bitlik 2046×1214 piksellik RGB görüntüden 8 bitlik 512×302 piksellik bir görüntüye dönüştürür. Görüntü 24 bitten 8 bit'e indirgendikten sonra renkle ilişkili bilgileri korumak için orijinal RGB görüntünün yalnızca kırmızı bileşeni kullanılır. Görüntünün bölütlenme süreci geliştirdiğimiz yöntemle ekranda Şekil 4.6'daki gibi görünecektir.




Şekil 4.6 Önerilen segmentasyon yöntemi

Yönerilen yöntemin uygulandıktan sonra, Şekil 4.7’de gösterildiği gibi, görüntü ekranda farklı sayılarda bölgeden oluşan 9 farklı bölütlenmiş görüntü şeklinde görünecektir.




Şekil 4.7 a) Bölütleme sürecinin çıktısı b) Bölütleme sürecinin sonucu

Görüntü bölütleme sürecinin çıktısı, her bölge farklı bir renkle temsil edilmiştir, (b) bölütleme sürecinin sonucu olarak, bu görüntüde melanom cilt kanseri olan bölge ve arka plan olarak iki gruba ayırt edilebilmektedir. Bir görüntüden bir nesneyi çıkarmak için, kullanıcılar farenin sol düğmesini kullanarak ön plandaki pikselleri ve farenin sağ düğmesini kullanarak arka plandaki pikselleri işaretlenir.



Şekil 4.8 Görüntünün bölütlenme süreci

Melanom cilt kanseri olan bölgenin bölütleme işleminde “CancerTumor” etiketlemesi yapılırsa sonuç TP, “GroundTruth” etiketlemesi yapılırsa FN. Arka plana “CancerTumor” etiketlemesi yapılırsa FP ve son olarak arka plana “GroundTruth” etiketlemesi yapılırsa TN olur. Sonraki ekranda doğruluğu hesaplamak için Şekil 4.8’deki Doğruluk Hesaplama (Accuracy Calculation) düğmesine basılarak Şekil 4.9’da gösterilen sonuç alınır.



Şekil 4.9 Bölütleme doğruluk değeri

Bu bölümde değerlendirme için kullanılan yöntemleri ve ölçütleri tartışıyoruz. İnteraktif segmentasyon işlemini etkili bir şekilde değerlendirebilmek için dikkate alınması gereken üç kriter vardır.

Geliştirdiğimiz yöntemle bölütlenmiş yirmi beş görüntünün ilişkin ölçütlerle ilişkili performans değerleri Tablo 4.1’de sunulmuştur.

Tablo 4.1 Performans analizi

Görüntü No	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)
1	91,66865	83,57295	99,76434
2	43,20932	16,93989	69,47875
3	95,92223	92,87054	98,97392
4	20,13304	31,02163	9,244444
5	95,66084	92,06694	99,25474
6	98,49566	100	96,99132
7	55,60448	100	11,20896
8	7,734174	0,271493	15,19685
9	74,96071	93,90149	56,01993
10	96,69383	94,51817	98,8695
11	97,96819	98,24066	97,69571
12	76,35697	52,71394	100
13	95,88806	92,17742	99,5987
14	23,32551	2,192308	44,45872
15	96,80537	93,85802	99,75272
16	91,9635	84,88562	99,04137

Tablo 4.2'in devamı


Görüntü No	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)
17	84,3741	68,90195	99,84625
18	81,72522	95,08025	68,37019
19	97,14918	95,44666	98,85171
20	98,29646	97,73429	98,85863
21	96,06961	99,48929	92,64992
22	90,23315	81,40318	99,06312
23	88,54337	77,96158	99,12516
24	82,93508	73,47492	92,39523
25	70,10516	40,21032	100

Görüntünün tespit edilme yüzdeleri Şekil 4.11'de gösterilmiştir.

4.6 Değerlendirme Sonuçları


Değerlendirme üç görev altında gerçekleştirilmiştir: filtreleme, melanom cilt kanserinin yerini tanımlama ve segmentasyon. Ölçümler için fundus görüntüleme kamerasıyla elde edilen PHH adlı veri seti kullanılmıştır.

Geliştirdiğimiz segmentasyon yöntemini, söz konusu veri tabanından elde edilen bazı melanom cilt kanseri görüntüleri üzerine uyguladık. Sonuç, Şekil 4.10'de gösterilmiştir.



Şekil 4.10 a) Orijinal görüntü b) Lezyon konumunun tespit edilmesi c) Görüntü işleme ile gerçekleştirilen bölütleme

Hassasiyet, özgüllük ve doğruluk bulguları Şekil 4.11’de verilmiştir.



Şekil 4.11 Hassasiyet, özgüllük ve doğruluk grafiği

Örnek melanom cilt kanseri görüntüsü ve aynı görüntünün yamalara ayrılmış hali Şekil 4.12’te gösterilmiştir.




Şekil 4.12 a) Orijinal melanom cilt kanseri görüntüsü b) Bölütlere ayrılmış parçalar

Bu tez çalışmasında lezyon ve arka plan kısımları görüntülerde eşik değerleri ile ayrışma sağlanmaktadır. Görüntü histogramları analiz edilerek bunlar arasındaki eşikler kolayca belirlenmiştir.

Ardından geliştirilen SegNet ağı eğitmek için elde edilen tüm yamalar, ağa girdi olarak verilmiştir (Badrinarayanan vd., 2016). Ağ eğitim diyagramı, Şekil 4.13’da verilmiştir. Görüldüğü gibi eğitim ve değerlendirme aşamasında ağın doğruluk

oranı %93'ün üzerindedir. Ayrıca Eğitim sürecinin adımları da Şekil 4.13'de gösterilmiştir.



Şekil 4.13 Eğitim süreci


Uygulama için bir ağ, kesin referans (ground-truth) görüntülerinden ve gözlemlenen ölçülerden oluşan veri kümesi üzerinde eğitilir. Ağı eğittikten sonra sistemin her bir görüntüyü değerlendirmedeki etkinliğini test ettik. Bu test, orijinal görüntüden elde edilen ile referans veride lezyon olarak işaretlenmiş alanların örtüşme oranlarını temel olarak karşılaştırabilir (Bulut vd., 2018). Test için seçilen görüntünün simülasyon sonuçları Şekil 4.14'de verilmiştir.



Şekil 4.14 a) Bölütlere ayrılmış orijinal görüntü b) Bölütleme sonucu c) Kesin referans bölütleme

Genellikle MR görüntülerinde bulunan lezyon bölgesi arak plana göre oldukça küçük bir orana sahiptir. Tez çalışmasında kullanılan veri tabanındaki görüntülere

uygulanan yöntemler sonucunda elde edilen arka plan ve lezyonun yüzdeleri, Şekil 4.15’de verilmiştir.



Şekil 4.15 Arka plan ve lezyonun yüzdeleri

5. SONUÇ VE ÖNERİLER

Melanom, cilt kanserleri arasında en az görüleni olmasına rağmen en tehlikeli cilt kanseri türüdür. Diğer taraftan, erken evrelerde teşhis edilirse tedavi başarısı %98 olmaktadır (Jerant vd., 2000). Bu nedenle, literatürde melanomun teşhisi için çeşitli görüntüleme teknikleri bulunmaktadır.

Dermoskopi, melanositik lezyonların klinik tanı için kullanılan in vivo, non-invaziv bir görüntüleme tekniğidir. Dermoskopiyle yapılan teşhisin doğruluğu hayati önem taşır ancak dermatologların deneyimine de bağlıdır. Görsel muayene zaman kaybına neden olur, bu nedenle mevcut araştırmalar dermatologlara klinik değerlendirmede yardımcı olacak bilgisayar destekli teşhis sistemlerinin geliştirilmesine odaklanmıştır.

Görüntü bölütlemesi, dijital görüntü işleme ve otomatik tanı bağlamında çok önemlidir ve birçok zor sorunun, özellikle cilt kanseri gibi kronik hastalıklarla ilgili sorunların çözümünde önemli bir rol oynayacaktır. Otomatik dermoskopi görüntülerinin analizi genellikle üç aşamadan oluşur: (i) Özellik seçimi ve çıkarımı, (ii) Görüntü bölütleme ve (iii) Özellik sınıflandırma.

Bu tez, melanom cilt kanseri hakkında bilgi sunmakta ve bu bağlamda meydana gelebilecek en yaygın sorunların altını çizmektedir. Ayrıca bu tez, insan derisini etkileyebilecek hastalıkların semptomlarını ve bu hastalıkların nasıl tespit edileceğini ele almaktadır. Ayrıca bu tezde, daha önce hem teşhis hem de tedavi amacıyla görüntüyü elde etmek ve görüntülemek için kullanılan geçmiş görüntü bölütleme teknikleri tartışılmıştır. Diğer bir deyişle görüntü işleme, biyomedikal görüntü işleme ve görüntü işlemenin aşamalarından bahsedilmiştir. Sonrasında, görüntü işlemenin en önemli adımı olan görüntü bölütleme ve görüntü bölütleme için halihazırda kullanılan teknikler tartışılmıştır. Son olarak, geçmiş tekniklerin dezavantajları ele alınmış ve melanom cilt kanserinde görüntü segmentasyonunun performansını ve etkinliğini artırmak için yeni bir teknik ve algoritma önerilmiştir. Deri görüntüsünde melanomun tespiti ve segmentasyonu, otomatik cilt kanseri

taramasında önemli görevleri temsil etmektedir. Bu tezde, hızlı ve tam otomatik bir melanom cilt kanseri segmentasyon yöntemi geliştirilmiştir. Bu cilt kanseri görüntülerine görüntü işleme teknikleri uygulanmıştır.

Tıp alanında, görüntü segmentasyonu, bir lezyon veya organın nicel ölçümüne ihtiyaç duyan radyolog ve cerrahlar tarafından kullanılabilecek önemli bir araçtır. Klinik uygulamada yararlı olabilmesi için böyle bir aracın hızlı ve kullanımı kolay olması gereklidir. Bu çalışma, görüntü işleme tekniklerinin bölütleme için melanom cilt kanseri görüntülerine uygulanmasını ve uygulanan algorithmada hesaplama sürelerinin karşılaştırılmasını içermektedir. Bu algoritmanın kavramsal basitliği, verideki gürültü kaynaklı bozulmaları değiştirerek düzeltmeyi, görüntüdeki örtmeleri gidermeyi ve küresel görüntüler gibi alışılmadık verileri işlemeyi kolaylaştırmaktadır. Önerilen yöntemde geliştirilen algoritma Matlab programlama dilini kullanmaktadır. Sonuçlar, melanom cilt kanseri için bu segmentasyon yönteminin tespit doğruluğunun iyi düzeyde olduğunu göstermektedir.

KAYNAKLAR

- Abbas, Q., Celebi, M. E., Fondón García, I., & Rashid, M. (2011). Lesion border detection in dermoscopy images using dynamic programming. *Skin Research and Technology*, 17(1), 91-100.
- Abbas, Q., Celebi, M., & García, I. F. (2012a). Skin tumor area extraction using an improved dynamic programming approach. *Skin Research and Technology*, 18(2), 133-142.
- Abbas, Q., Celebi, M. E., & Garcia, I. (2012b). A novel perceptually-oriented approach for skin tumor segmentation. *International Journal of Innovative Computing, Information and Control*, 8(3), 1837-1848.
- Al-amri, S. S., Kalyankar, N. V. & Khamitkar, S. D. (2010). Image segmentation by using edge detection. *International Journal on Computer Science and Engineering*, 2(3), 804-807.
- Argenziano, G., Soyer, H. P., De Giorgi, Piccolo, D., Carli, P. & Delfino, M. (2002). Dermoscopy: a tutorial. *EDRA, Medical Publishing & New Media* 16.
- Badrinarayanan, V., Kendall, A. & Cipolla R. (2016). SegNet: A deep convolutional encoder-decoder architecture for image segmentation. arXiv: 1511.00561v3.
- Bangare, S. L., Dubal, A., Bangare, P. S. & Patil, S. T. (2015). *International Journal of Applied Engineering Research*, 10(9), 21777-21783.
- Barata, C., Celebi, M. E., & Marques, J. S. (2015). Improving dermoscopy image classification using color constancy. *IEEE Journal of Biomedical and Health Informatics*, 19(3), 1146-1152.
- Barbu, T. (2013). Variational image denoising approach with diffusion porous media flow. *Abstract and Applied Analysis*.
- Bergström, N., Björkman, M. & Kragic, D. (2011). Generation object hypotheses in natural sciences through human-robot interaction. *Intelligent Robots and Systems*, 827-833.
- Bernardes, R., Serranho, P., & Lobo, C. (2011). Digital ocular fundus imaging: A review. *Ophthalmologica*, 226(4), 161-181.

- Bulut, F., Kılıç, İ. & İnce, İ. F. (2018). Beyin tümörü tespitinde görüntü bölütleme yöntemlerine ait başarımların karşılaştırılması ve analizi. *Dokuz Eylül Üniversitesi-Fen ve Mühendislik Dergisi*, 20(58), 173-186.
- Celebi, M. E., Aslandogan, Y. A., Stoecker, W. V., Iyatomi, H., Oka, H., & Chen, X. (2007). Unsupervised border detection in dermoscopy images. *Skin Research and Technology*, 13(4), 454-462.
- Celebi, M. E., Kingravi, H. A., Iyatomi, H., Alp Aslandogan, Y., Stoecker, W. V., Moss, R. H., . . . Rabinovitz, H. S. (2008). Border detection in dermoscopy images using statistical region merging. *Skin Research and Technology*, 14(3), 347-353.
- Celebi, M. E., Iyatomi, H., & Schaefer, G. (2009). *Contrast enhancement in dermoscopy images by maximizing a histogram bimodality measure*. 16th IEEE International Conference on Image Processing.
- Celebi, M. E., Wen, Q., Hwang, S., Iyatomi, H., & Schaefer, G. (2013). Lesion border detection in dermoscopy images using ensembles of thresholding methods. *Skin Research and Technology*, 19(1), e252-e258.
- Dar, N. H. (2020). Image segmentation techniques and its application. *Image Segmentation Techniques and Its Applications*.
- Deklerck, R., Cornelis, J. & Bister, M. (1933). Segmentation of medical images. *Image and Vision Computing*, 11(8), 486-503.
- Despotović, I., Goossens, B. & Philips, W. (2015). MRI segmentation of the human brain: Challenges, methods and applications. *Computational Intelligence Techniques in Medicine*,
- Ding, J.-J., Kuo, C.-J., & Hong, W.-C. (2009). An efficient image segmentation technique by fast scanning and adaptive merging. *CVGIP*.
- Du, G., Cao, X., Liang, J. & Chen, X. (2020). Medical image segmentation based on U-Net: A review. *Journal of Imaging Science and Technology*, 64(2).
- Erkol, B., Moss, R. H., Joe Stanley, R., Stoecker, W. V., & Hvatum, E. (2005). Automatic lesion boundary detection in dermoscopy images using gradient vector flow snakes. *Skin Research and Technology*, 11(1), 17-26.
- Evans, S., Lloyd, J., Stoddard, G., Nekeber, J. & Samone, M. (2005). Risk factors for adverse drug events. *The Annals of Pharmacotherapy*, 39, 1161-1168.

- Fleming, M. G., Steger, C., Zhang J., Gao, J., Cognetta, A. B., Pollak, I. & Dyer, C. R. (1998). Techniques for a structural analysis of dermoscopic imagery. *Computerized Medical Imaging Graph*, 22(5), 375-389.
- Foran, D. J., Chen, W. & Yang, L. (2011). Automated image interpretation and computer-assisted diagnostics. *Anal Cell Pathol (Amst)*, 34(6), 279-300.
- Garnavi, R., Aldeen, M., Celebi, M. E., Varigos, G., & Finch, S. (2011). Border detection in dermoscopy images using hybrid thresholding on optimized color channels. *Computerized Medical Imaging and Graphics*, 35(2), 105-115.
- Haralick, R. M. & Shapiro, L. G. (1985). Image segmentation techniques. *Computer vision, graphics and image processing*, 29(1), 100-132.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. IEEE conference on computer vision and pattern recognition.
- Iyatomi, H., Celebi, M. E., Schaefer, G., & Tanaka, M. (2011). Automated color calibration method for dermoscopy images. *Computerized Medical Imaging and Graphics*, 35(2), 89-98.
- Jerant, A. F., Johnson, J., Sheridan, C. D. & Caffey, T. (2000). Early detection and treatment of skin cancer. *Am Fam Physician*, 62(2), 357-368.
- Kjønigsen, L. J., Harneshaug, M., Fløtten, A.-M., Karterud, L. K., Petterson, K., Skjølde, G., . . . Lauritzen, P. M. (2019). Reproducibility of semiautomated body composition segmentation of abdominal computed tomography: a multiobserver study. *European radiology experimental*, 3(1), 42.
- Koffka, K. (2014). Principles of Gestalt psychology. *Mimesis International*.
- Kootstra, G., Bergström, N. & Kragic, D. (2011). Fast and automatic detection and segmentation of unknown objects. 10th IEEE-RAS International Conference on Humanoids Robots.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.
- Kumar, R. & Indrayan, A. (2011). Receiver operating characteristic (ROC) curve for medical researchers. *Indian Pediatrics*, 277-287.
- Lauren, B. & Lee, L. W. (2003). Perceptual information processing system. Paravue Inc. U.S. Patent Application, 10/618,543.

- Lin, D., Dai, J., Jia, J., He, K. & Sun, J. (2016). ScribbleSup: Scribble-supervised convolutional networks for semantic segmentation. *Computer Vision and Pattern Recognition*, 3159-3167.
- Lotufo, R. A., Rittner, L., Audigier, R., Machado, R. C., Saúde, A. V. (2011). Biomedical Image Processing. Deserno (Eds.), *Biomedical Image Processing* (pp. 107-129). Springer.
- Luo, J., Singhal, A., Braun, G., Gray, R. T., Touchard, N. & Seignol, O. (2002). Displaying images on mobile devices: Capabilities, issues, and solutions. *Wireless Communications and Mobile Computing*, 2, 585-594.
- Marr, D. & Hildreth, E. (1980). Theory of edge detection. *Proceedings of the Royal Society of London B: Biological Sciences*, 207(1167), 187-217.
- Madooei, A., Drew, M. S., Sadeghi, M., & Atkins, M. S. (2012). Automated pre-processing method for dermoscopic images and its application to pigmented skin lesion segmentation. 20th Color and Imaging Conference.
- Menzies, S. W., Crotty, K. A., Ingwar, C. & McCarthy, W. H. (2003). An atlas of surface microscopy of pigmented skin lesions: dermoscopy. Sydney, Australia: McGra-Hill.
- Mikolov, T., Karafiát, M., Burget, L., Černocký, J., & Khudanpur, S. (2010). Recurrent neural network based language model. 11th Annual Conference of the International Speech Communication Association.
- Mirza, M., & Osindero, S. (2014). Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784*.
- Møllersen, K., Kirchesch, H. M., Schopf, T. G., & Godtliebsen, F. (2010). Unsupervised segmentation for digital dermoscopic images. *Skin Research and Technology*, h), 401-407.
- Nock, R. & Nielsen, F. (2004). Statistical region merging. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(11).
- Norton, K. A., Iyatomi, H., Celebi, M. E., Ishizaki, S., Sawada, M., Suzaki, R., . . . , Ogawa, K. (2012). Three-phase general border detection method for dermoscopy images using non-uniform illumination correction. *Skin Research and Technology*, 18(3), 290-300.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9: 62-66.

- Palmer, S. & Rock, I. (1994). Rethinking perceptual organization: The role of uniform connectedness. *Psychonomic Bulletin & Review*, 18(1): 29-55.
- Richtsfield, A., Zillich, M. & Vincze, M. (2012). Implementation of gestalt principles for object segmentation. *Pattern Recognition*.
- Ronneberger, O., Fischer, P. & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. *arXiv: 1505.04597*.
- Sadri, A. R., Zekri, M., Sadri, S., Gheissari, N., Mokhtari, M., & Kolahdouzan, F. (2013). Segmentation of dermoscopy images using wavelet networks. *IEEE Transactions on Biomedical Engineering*, 60(4), 1134-1141.
- Schaefer, G., Rajab, M. I., Celebi, M. E., & Iyatomi, H. (2011). Colour and contrast enhancement for improved skin lesion segmentation. *Computerized Medical Imaging and Graphics*, 35(2), 99-104.
- Schmid, P. (1999a). Lesion detection in dermatoscopic images using anisotropic diffusion and morphological flooding. *IEEE International Conference on Image Processing*.
- Schmid, P. (1999b). Segmentation of digitized dermatoscopic images by two-dimensional color clustering. *IEEE Transactions on Medical Imaging*, 18(2), 164-171.
- Shapiro, L. G. & Stockman, G. C. (2001). *Computer Vision*. New Jersey, Prentice-Hall, pp. 279-325.
- Silveira, M., Nascimento, J. C., Marques, J. S., Marçal, A. R., Mendonça, T., Yamauchi, S., . . . , Rozeira, J. (2009). Comparison of segmentation methods for melanoma diagnosis in dermoscopy images. *IEEE Journal of Selected Topics in Signal Processing*, 3(1), 35-45.
- Taha, A., Hanbury, A. & Toro, O. (2014). Metrics for evaluating 3D medical image segmentation: analysis, selection and tool. *BMC Medical Imaging*, 15(1).
- Thompson, F. & Jeyakumar, M. K. (2017). Vector based classification of dermoscopic images using SURF. *International Journal of Applied engineering Research*, 12(8), 1758-1764.
- van Vliet, L. J., Young, I. T., & Beckers, G. L. (1989). A nonlinear Laplace operator as edge detector in noisy images. *Computer vision, graphics, and image processing*, 45(2), 167-195.

- Vennila, G. S., Suresh, L. P. & Shunmuganathan, K. L. (2012). Dermoscopic image segmentation and classification using machine learning algorithms. *International Conference on Computing, Electronics and Electrical Technologies*, 1122-1127.
- Vicente, S., Kolmogorov, V. & Rother, C. (2009). Joint optimization of segmentation and appearance models. *International Conference on Computer Vision*, 755-762.
- Zaitoun, N. & Aqel, M. J. (2015). Survey on segmentation techniques. *Procedia Computer Science*, 65, 797-806.
- Zeng, M., Han, T., Meng, Q., Bai, Z. & Liu, Z. (2012). Image thresholding based on edge information analysis. *5th International Congress on Image and Signal Processing*, 1371-1375.
- Zhang, Y.-D. & Dong, Z. (2018). Medical imaging & image Processing II. *Technologies*, 6(2), 39.
- Zhou, H., Chen, M., Gass, R., Rehg, J., Ferris, L., Ho, J. & Drogowski, L. (2008). Feature-preserving artifact removal from dermoscopy images. *The International Society for Optical Engineering*.
- Zhu, Y. & Huang, C. (2012). An improved median filtering algorithm for image noise reduction. *International Conference on Solid State Devices and Materials Science*.
- Wang, H., Chen, X., Moss, R. H., Stanley, R. J., Stoecker, W. V., Celebi, M. E., . . . Marghoob, A. A. (2010). Watershed segmentation of dermoscopy images using a watershed technique. *Skin Research and Technology*, 16(3), 378-384.
- Wang, H., Moss, R. H., Chen, X., Stanley, R. J., Stoecker, W. V., Celebi, M. E., . . . Rabinovitz, H. S. (2011). Modified watershed technique and post-processing for segmentation of skin lesions in dermoscopy images. *Computerized Medical Imaging and Graphics*, 35(2), 116-120.
- Werlberger, M., Pock, T., Unger, M. & Bischof, H. (2009). A variational model for interactive shape prior segmentation and real-time tracking. *International Conference on Scale Space and Variational Methods in Computer Vision*.
- Wu, Z. & Leahy, R. (1993). An optimal graph theoretic approach to data clustering: Theory and its application to image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11), 1101-1113.

Xess, M. & Agnes, A. (2014). Analysis of image segmentation methods based on performance evaluation parameters. *International Journal of Computational Engineering Research*, 4(3).

