

**LAZER EPİLASYON İÇİN OPTİK GÖRÜNTÜLEME İLE ÖZNİTELİK
TABANLI KIL BÖLGESİ TESPİTİ**

MURAT AVŞAR

**YÜKSEK LİSANS TEZİ
ELEKTRİK ve ELEKTRONİK MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

NİSAN 2015

ANKARA

Fen Bilimleri Enstitü onayı

Prof. Dr. Osman EROĞUL

Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığını onaylarım.

Prof. Dr. Murat ALANYALI

Anabilim Dalı Başkanı

Murat AVŞAR tarafından hazırlanan LAZER EPİLASYON İÇİN OPTİK GÖRÜNTÜLEME İLE ÖZNİTELİK TABANLI KIL BÖLGESİ TESPİTİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Doç. Dr. İmam Şamil YETİK

Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Doç. Dr. Ali Cafer GÜRBÜZ

Üye : Doç. Dr. İmam Şamil YETİK

Üye : Dr. Yusuf ARTAN

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Murat AVŞAR

Üniversitesi : TOBB Ekonomi ve Teknoloji Üniversitesi
Enstitüsü : Fen Bilimleri
Anabilim Dalı : Elektrik ve Elektronik Mühendisliği
Tez Danışmanı : Doç. Dr. İmam Şamil YETİK
Tez Türü ve Tarihi : Yüksek Lisans – Nisan 2015

Murat AVŞAR

LAZER EPİLASYON İÇİN OPTİK GÖRÜNTÜLEME İLE ÖZNETELİK TABANLI KIL BÖLGESİ TESPİTİ

ÖZET

Lazer epilasyon, kıl folikülüne ve shaftına termal yolla hasar verilerek, bu yapıların kalıcı bir şekilde yok edilmesini amaçlayan ve son yıllarda kullanımı oldukça yaygınlaşmış olan cerrahi olmayan bir operasyondur. Lazer epilasyon tekniğinin temel amacı kıl foliküllerinin hasarlanması olmasına rağmen, günümüzde kullanılmakta olan lazer epilasyon cihazları çevresel deri katmanlarını da sağlık riski oluşturacak şekilde etkilemektedir. Lazer epilasyon işleminin cilt üzerindeki yan etkilerinin asgari düzeye indirgenebilmesi için lazer ışınının sadece önceden tespit edilmiş kıl bölgelerine yönlendirilmesi önerilmektedir. Bu tez çalışmasının amacı, önerilmekte olan lazer epilasyon yönteminin bir alt parçası olarak kullanılmak üzere, optik bant görüntü üzerinden görüntü işleme ve örüntü tanıma teknikleri kullanılarak kıl bölgelerinin tespit edilmesidir. Kıl bölgesi tespit işlemi için, makine öğrenme tekniklerine dayanan öznetelik tabanlı iki basamaklı sınıflandırma yöntemi önerilmektedir. Önerilmekte olan iki basamaklı sınıflandırma yöntemi sayesinde, sınıflandırıcı performansının artırılması hedeflenmektedir. Yöntem başarımları, denek-taşı oluşturulmuş görüntüler üzerinde algoritma sonuçlarının duyarlılık ve özgüllük analizlerinin yapılması ve sınıflandırma işlem süresinin hesaplanması ile belirlenmektedir. Elde edilen sonuçlar, önerilmekte olan sınıflandırma tekniğinin öznetelik tabanlı kıl bölgesi tespit işleminde performans artışı sağlayabildiğini göstermektedir.

Anahtar Kelimeler: Görüntü işleme, Makine öğrenmesi, Lazer epilasyon, Kıl tespiti

University : TOBB Economics and Technology University
Institute : Institute of Natural and Applied Sciences
Science Programme : Electrical and Electronics Engineering
Supervisor : Doç. Dr. İmam Şamil YETİK
Degree Awarded and Date : M.Sc. – April 2015

Murat AVŞAR

**FEATURE-BASED HAIR REGION LOCALIZATION
FOR LASER HAIR REMOVAL APPLICATIONS
WITH OPTICAL IMAGING**

ABSTRACT

Laser hair removal is a popular nonsurgical hair removal procedure, where the aim is to remove hair permanently by damaging the hair follicle and shaft thermally. However, currently available laser hair removal systems affect the superficial skin layers in addition to hair follicles causing health risks. Side effects of laser-assisted hair removal can be minimized by directing the laser beam only to the detected hair regions. This study aims to develop a feature-based hair region localization method by using image processing and pattern recognition techniques as an integral part of the proposed laser hair removal system. We propose to detect hair regions by using two-stage feature based classification method based on machine learning techniques. The proposed two-stage classification method is aimed to improve the performance of the classifier. Performance of the proposed classifier is tested by using sensitivity and specificity values of the method and by measuring the processing time of the classifier. The results obtained from the proposed technique showed performance increase in hair region classification process.

Keywords: Image processing, Machine learning, Laser hair removal, Hair detection

TEŐEKKÖR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Doç. Dr. İmam Őamil YETİK'e, yine kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü öğretim üyelerine teşekkürü bir borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
İÇİNDEKİLER.....	vi
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	x
KISALTMALAR.....	xiii
SEMBOL LİSTESİ.....	xiv
1. GİRİŞ	1
2. KALICI EPİLASYON TEKNİKLERİ VE LAZER EPİLASYON SİSTEMLERİ. 3	
2.1. Kılın Anatomik Yapısı ve Büyüme Döngüsü	3
2.2. Kıl Büyüme Döngüsü ve Kalıcı Epilasyon İlişkisi	6
2.3. Cilt Tipleri - Fitzpatrick Skalası.....	7
2.4. Kıl Giderme Yöntemleri	8
2.5. Kalıcı Epilasyon Yöntemleri.....	9
3. MOTİVASYON, PROBLEM TANIMI VE TEZİN AMACI	21
3.1. Lazer Epilasyonun Yan Etkileri	21
3.2. Küçük Spot Boyutlu, Akıllı Lazer Epilasyon Sisteminin Avantajları	22
3.3. Kıl Tespiti Literatür Çalışmaları	24
3.4. Tez Çalışmasının Amacı	26
4. GELİŞTİRİLEN YÖNTEM.....	27
4.1. Yöntem Özeti	27
4.2. Görüntü Alma.....	30
4.3. Kıl ve Deri Bölgesi Doğruluk Tablolarının Oluşturulması.....	30
4.4. Öznitelik Vektörü Oluşturma.....	31
4.5. Öznitelik Seçimi.....	55
4.6. Sınıflandırma.....	56
4.7. Kullanılan Sınıflandırma Modelleri ve Bu Modellerin Performansının Değerlendirmesi	68

5. DENEYSEL SONUÇLAR VE TARTIŞMA.....	77
5.1. Veri Setinin Oluşturulması.....	77
5.2. Hızlı ve Yavaş Özniteliklerin Belirlenmesi	78
5.3. Sınıflandırma Yönteminin Belirlenmesi	82
5.4. Öznitelik Seçme	85
5.5. Tek Basamaklı ve İki Basamaklı Sınıflandırma Modelleri İçin Çapraz Doğrulama Sonuçları	88
5.6. İki Basamaklı ve Tek Basamaklı Sınıflandırma Modellerinin İşlem Süreleri	93
5.7. Görsel Değerlendirme	94
5.8. Sonuç.....	96
KAYNAKLAR.....	98
EKLER	102
ÖZGEÇMİŞ.....	119

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Vücut bölgelerine göre kıl özellikleri [7].....	6
Çizelge 2.2. Fitzpatrick cilt sınıflandırma skalası [13]	7
Çizelge 2.3. Lazer atım süresi ve hedefin termal gevşeme zamanı ilişkisi.....	14
Çizelge 2.4. Bazı lazer hedeflerinin termal gevşeme zamanları [34]	14
Çizelge 2.5. Epilasyonda kullanılan bazı lazerler ve ışık kaynakları [37]	17
Çizelge 4.1. Belirlenen özneliklerin değişmezlik özellikleri.....	50
Çizelge 4.2. Kıl ve deri sınıfları karışıklık matrisi.....	72
Çizelge 4.3. Kıl ve deri sınıfları maliyet matrisi.....	75
Çizelge 5.1. 15x15 piksellik pencere boyutundaki girdi örüntüsü için özneliklerin ortalama işlem süreleri.....	81
Çizelge 5.2. Tüm özneliklerin kullanılması ile yapılan çapraz doğrulama işleminin sonuçları	83
Çizelge 5.3. Sınıflandırma modellerinin tüm özneliklerin kullanıldığı tek bir öznelik vektörünü sınıflandırma süreleri	84
Çizelge 5.4. Öznelik Kümesi 1 (ÖK1).....	86
Çizelge 5.5. Öznelik Kümesi 2 (ÖK2).....	87
Çizelge 5.6. TBSM1 için performans analiz sonuçları	88
Çizelge 5.7. TBSM2 için performans analiz sonuçları	88
Çizelge 5.8. Taraflı İBSM'nin birinci basamağında kullanılmakta olan sınıflandırıcının performans analiz sonuçları	91
Çizelge 5.9. Birinci basamak sınıflandırıcısı Denklem (5.2)'de gösterilmekte olan maliyet matrisi kullanılarak eğitilmiş olan İBSM için performans analiz sonuçları	92
Çizelge 5.10. TBSM1, TBSM2 ve İBSM için performans analiz sonuçları.....	92
Çizelge 5.11. İBSM, TBSM1 ve TBSM2'nin 630x480 piksellik bir cilt görüntüsünü tahmini sınıflandırma süresi	93
Çizelge 5.12. İBSM, TBSM1 ve TBSM2'nin 630x480 piksellik cilt görüntülerini ortalama sınıflandırma süresi (Uygulama sonuçları)	94
Çizelge A.1. Birinci basamak kıl ve deri sınıfları karışıklık matrisi.....	102

Çizelge A.2. İkinci basamak sınıflandırma işlemi sonucunda oluşan kıl ve deri sınıfları karışıklık matrisi.....	103
Çizelge B.1. Bu çalışmada sınıflandırma işlemlerinde kullanılmakta olan Matlab fonksiyonları.....	108
Çizelge D.1. Tek bir öznelik vektörünün sınıflandırılma süreleri.....	118

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Bilgisayar destekli akıllı lazer epilasyon sistemi çalışma şeması	2
Şekil 2.1. Tipik bir terminal (sert) kıl anatomisi [5].....	4
Şekil 2.2. Kıl büyüme döngüsü [5]	5
Şekil 2.3. İğneli epilasyon [18]	9
Şekil 2.4. İğneli epilasyon doğru ve yanlış kullanım örnekleri [3]	11
Şekil 2.5. Üç ana cilt kromoforunun emilim spektrumları [34]	13
Şekil 2.6. 400-2000 nm arasındaki dalga boylarının insan derisine penetrasyonu [36]	16
Şekil 3.1. Büyük ve küçük spot boyutlu lazer epilasyon uygulamalarında lazer ışmasına maruz kalan cilt bölgeleri.....	23
Şekil 4.1. Test görüntülerinde bölgelerin kıl veya deri olarak sınıflandırılması için kullanılan mekanizma	28
Şekil 4.2. Örtüşen ve örtüşmeyen pencereler ile görüntü tarama işlemi.....	29
Şekil 4.3. Eğitim setinde bulunan kıl ve deri örüntülerine ait bazı örnekler.....	32
Şekil 4.4. Örnek kıl ve deri örüntülerine ait histogram dağılımları	33
Şekil 4.5. “Yeğnliklerin varyansı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	34
Şekil 4.6. “Normalize edilmiş karşıtlık değeri” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini.....	35
Şekil 4.7. “Normalize edilmiş, ortalamadan büyük aykırı piksellerin sayısı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	37
Şekil 4.8. “Normalize edilmiş, ortalamadan küçük aykırı piksellerin sayısı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	38
Şekil 4.9. Örnek kıl ve deri örüntüleri için ortalama altı ve ortalama üstü piksel sayıları	39
Şekil 4.10. “Ortalama altı piksel sayısının ortalama üstü piksel sayısına oranı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	39

Şekil 4.11. “Normalize edilmiş, ortalama altı piksel sayısının ortalama üstü piksel sayısına oranı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini.....	40
Şekil 4.12. “Ortalama yeğnlik ve minimum yeğnlik farkı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini.....	41
Şekil 4.13. “Görüntü modu ve mod frekansı çarpımı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	42
Şekil 4.14. Örnek kıl ve deri örüntüleri için “bastırılmış bölgesel minimum değişimi” özniteliği hesaplamaları	43
Şekil 4.15. Eğitim setindeki örüntüler için “Bastırılmış Bölgesel Minimum Değişimi” özniteliğinin histogram görüntüsü ve çekirdek yoğunluğu tahmini.....	44
Şekil 4.16. “Entropi” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	45
Şekil 4.17. “Normalize edilmiş üçüncü merkezsels moment” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini.....	46
Şekil 4.18. “Çeyrekler açıklığı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini	47
Şekil 4.19. Örnek kıl ve deri örüntüleri için “yerel minimum filtreleme değişimi” özniteliği hesaplamaları	49
Şekil 4.20. “Yerel minimum filtreleme değişimi” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini.....	49
Şekil 4.21. Ölçek değişmezliğinin sağlandığı ve sağlanamadığı farklı komşuluk penceresi boyutları	51
Şekil 4.22. Bazı ikili özniteliklere ait serpilme diyagramları.....	54
Şekil 4.23. İki boyutlu ve iki sınıflı bir örnek için DAA	58
Şekil 4.24. Standart DAA ayrıştırıcı yüzeyi (solda), Fisher’ın DAA ayrıştırıcı yüzeyi (sağda) [55]	59
Şekil 4.25. 8-NN sınıflandırma örneği.....	61
Şekil 4.26. İki boyutlu ve iki sınıflı örnek veri uzayı (solda) ve ilgili karar ağacı modeli (sağda).....	62
Şekil 4.27. İki sınıflı ve iki boyutlu, doğrusal ayrıştırılabilir durum için DVM karar yüzeyi	66

Şekil 4.28. Hızlı öznelikler kümesinde yapılan öznelik seçme işleminin çıktısı...	69
Şekil 4.29. Hızlı ve yavaş tüm özneliklerin bulunduğu kümede yapılan öznelik seçme işleminin çıktısı	69
Şekil 4.30. İki basamaklı sınıflandırma modeli (İBSM)	69
Şekil 4.31. Tek basamaklı sınıflandırma modeli 1 (TBSM1)	70
Şekil 4.32. Tek basamaklı sınıflandırma modeli 2 (TBSM2)	70
Şekil 5.1. Ortalama işlem süresi 0,13 milisaniyenin altında olan öznelikler.....	80
Şekil 5.2. Ortalama işlem süresi 0,13 milisaniyenin üstünde olan öznelikler	80
Şekil 5.3. 15x15 piksellik pencere boyutundaki girdi örüntüsü için özneliklerin ortalama işlem süreleri ve hızlı-yavaş öznelik ayırımının yapılacağı eşik seviyesi.....	82
Şekil 5.4. Maliyet matrisinin $M_{1,2}$ değerindeki değişimim İBSM'nin birinci basamak duyarlılık değeri üzerindeki etkisi.....	90
Şekil 5.5. Maliyet matrisinin $M_{1,2}$ değerindeki değişimim İBSM'nin birinci basamak özgüllük değeri üzerindeki etkisi	90
Şekil 5.6. (a) 630x480 piksellik örnek cilt görüntüsü, (b) Doğruluk tablosu (Beyaz pikseller kıl bölgelerini, siyah pikseller deri bölgelerini temsil ediyor) ...	95
Şekil 5.7. (a) Elle işaretlenmiş kıl bölgeleri, (b) TBSM1 tarafından bulunan kıl bölgeleri, (c) TBSM2 tarafından bulunan kıl bölgeleri, (d) İBSM tarafından bulunan kıl bölgeleri	96
Şekil D.1. Örnek bir cilt görüntüsü için kıl bölgesi yoğunluğu.....	117

KISALTMALAR

Kısaltmalar Açıklama

FDA	Amerikan Gıda ve İlaç Dairesi (U.S. Food and Drug Administration)
ASAPS	Amerikan Estetik Plastik Cerrahi Topluluğu (American Society for Aesthetic Plastic Surgery)
IPL	Intense Pulse Light
TGZ	Termal gevşeme zamanı
DAA	Doğrusal Ayrıştırma Analizi
K-NN	K-En Yakın Komşu Algoritması
KA	Karar Ağacı
NB	Naive Bayes Sınıflandırıcı
DVM	Destek Vektör Makineleri
ID3	Iterative Dichotomiser 3
MARS	Multivariate Adaptive Regression Splines
CART	Classification And Regression Tree
CHAID	CHi-squared Automatic Interaction Detector
MAP	En Büyük Sonsal Olasılık (Maximum a Posteriori)
QP	Karesel Programlama (Quadratic Programming)
ÖK1	Öznelik Kümesi 1
ÖK2	Öznelik Kümesi 2
İBSM	İki Basamaklı Sınıflandırma Modeli
TBSM1	Tek Basamaklı Sınıflandırma Modeli 1
TBSM2	Tek Basamaklı Sınıflandırma Modeli 2
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif

SEMBOL LİSTESİ


Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
$I(x, y)$	Görüntünün (x, y) pikselindeki yeğinlik değeri
N	Görüntü penceresi içindeki toplam piksel sayısı
R	Görüntü penceresi içindeki tüm pikseller
μ_I	I görüntüsü içindeki piksellerin yeğinlik değerlerinin ortalaması
σ_I	I görüntüsü içindeki piksellerin yeğinlik değerlerinin standart sapması
$hmin(I, th)$	th eşik seviyesini kullanan, h-minima dönüşüm fonksiyonu
$E[.]$	Beklenen değer operatörü
$moment_k$	k 'inci merkezsiz moment
$I_{yerelMin}$	I görüntüsüne 3×3 'lük yerel minimum filtreleme işlemi uygulandığında elde edilen görüntü
$M_{i,j}$	Maliyet matrisinin i . satır ve j . kolonunda bulunan eleman

1. GİRİŞ

1996 yılında Amerikan Gıda ve İlaç Dairesi'nin (FDA), lazerin epilasyonda kullanımına, ilk kez, izin vermesinden bu yana lazer epilasyon cihazları hızla yaygınlaşmıştır. Amerikan Estetik Plastik Cerrahi Topluluğu'nun (ASAPS) verilerine göre lazer epilasyon işlemi, günümüzde en çok başvurulan cerrahi olmayan estetik operasyonlardan birisi olarak gösterilmektedir [1]. Lazer epilasyon tekniği, kıl folikülü ve shaftının termal yolla hasarlanarak kalıcı bir şekilde yok edilmesini amaçlayan bir operasyondur. Ancak, lazer epilasyon işlemi sırasında lazer ışınları yalnızca kıl folikülü ve shaftını değil, aynı zamanda kıl foliküllerinin etrafında yer alan çevresel deri katmanlarını da sağlık riski oluşturacak şekilde etkilemektedir [2]. Günümüzde kullanılmakta olan lazer epilasyon cihazlarının çalışma prensiplerinden farklı olarak, lazer ışınının yalnızca önceden tespit edilmiş kıl bölgelerine yönlendirilmesi ile deri bölgeleri lazer ışınmasından daha az etkilenecek ve lazer epilasyon işleminin yan etkileri önemli ölçüde ortadan kaldırılabilecektir. Bunun yanı sıra, yalnızca kıl bölgelerine atış yapabilen verimli epilasyon sistemleri sayesinde, daha düşük güçte lazerlerin epilasyonda kullanılabilmesi ve bu cihazların maliyet ve bakım masrafları azaltılabileceği düşünülmektedir.

Bu tez çalışmasında, Şekil 1.1'de çalışma şeması gösterilmekte olan bilgisayar destekli lazer epilasyon sistemi için deri üstü optik görüntüleme ile çalışan öznitelik tabanlı kıl bölgesi tespit algoritmasının geliştirilmesi amaçlanmaktadır. Gerçek zamanlı uygulamalarda kullanılması planlanan kıl bölgesi tespit algoritmasının işlem hızının artırılabilmesi için klasik sınıflandırma yöntemlerinden farklı olarak iki basamaklı sınıflandırma tekniğinin kullanılması önerilmektedir. Önerilmekte olan sınıflandırma tekniği sayesinde sınıflandırıcının kıl tespit başarımı ciddi ölçüde azalmazken, sınıflandırma hızının artırılması hedeflenmektedir.



Şekil 1.1. Bilgisayar destekli akıllı lazer epilasyon sistemi çalışma şeması

Kalıcı epilasyon tekniği ve günümüzde kullanılan lazer epilasyon sistemlerinin çalışma prensiplerinin bilinmesi, bu tez çalışması kapsamında sunulmakta olan problemin ve bu problemin çözümü için önerilmekte olan yöntemlerin doğru anlaşılabilmesi için önem taşımaktadır. Bu nedenle, Bölüm 2’de kalıcı epilasyon tekniği ile ilgili temel bilgiler ve günümüzde kullanılmakta olan kalıcı epilasyon sistemlerinin çalışma prensipleri özetlenmektedir. Günümüz lazer epilasyon sistemlerinin cilt üzerinde bıraktığı yan etkiler ve bu yan etkilerin ortadan kaldırılması için önerilmekte olan bilgisayar destekli küçük spot boyutlu lazer epilasyon sisteminin olası avantajları Bölüm 3’te anlatılmaktadır. Bu tez çalışmasının kapsamı ve optik görüntüleme ile kıl bulmaya yönelik literatür çalışmaları da Bölüm 3’te özetlenmektedir. Bölüm 4’te ise bu çalışmada önerilmekte olan kıl bölgesi tespit yöntemi ve bu yöntemin değerlendirilmesi için kullanılmakta olan teknikler anlatılmaktadır. Bu tekniklerin kullanılması ile elde edilen sonuçlar ve önerilmekte olan sınıflandırma yönteminin performansı Bölüm 5’te değerlendirilmektedir.

2. KALICI EPİLASYON TEKNİKLERİ VE LAZER EPİLASYON SİSTEMLERİ

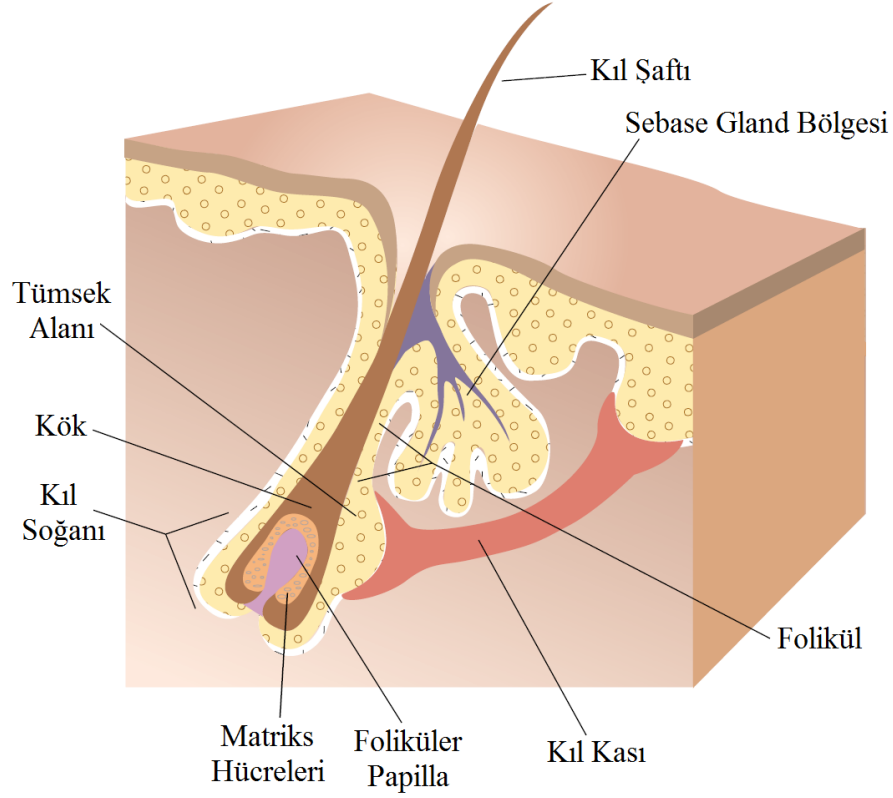
Lazer epilasyon ve diğer kalıcı epilasyon tekniklerinin çalışma prensiplerinin doğru anlaşılabilmesi için kıl foliküllerinin anatomik yapısı, kılın büyüme döngüsü ve cilt tipleri ile ilgili temel bilgilerin bilinmesi önem taşımaktadır. Bu nedenle, Bölüm 2.1 ve Bölüm 2.3 arasında bu konular özetlenmektedir. Günümüzde kullanılan kalıcı epilasyon teknikleri ve lazer epilasyon sistemlerinin çalışma prensipleri ise sırasıyla Bölüm 2.4 ve Bölüm 2.5'te anlatılmaktadır.

2.1. Kılın Anatomik Yapısı ve Büyüme Döngüsü

Keratin yapılı ince liflerin bir araya gelmesi ile oluşan kalın life, kıl adı verilmektedir [3]. İnsan vücudundaki kıllar, buldukları bölgelere ve işlevlerine göre yapısal çeşitlilik göstermektedir. Oldukça karmaşık ve benzersiz bir yapıya sahip olan kıl folikülü, geleneksel olarak, cilt yüzeyinden deri altına doğru üç bölüme ayrılarak incelenmektedir: Üst kısım (infundibulum), orta kısım (istmus) ve alt kısım (inferior) [4]. Kıl folikülünün alt kısmı, kıl kasının bağlandığı bölgenin altında kalan, kıl soğanı ve foliküller papillayı içeren bölgedir. Kıl folikülünün orta kısmı kıl kasının bağlandığı bölgenin üzerinden yağ bezi (sebase bezi) kanal girişine kadar olan bölgedir. Üst kıl bölgesi ise yağ bezi kanal girişinin üzerinde kalan kısımdır ve deri yüzeyi ile doğrudan ilişkilidir.

Şekil 2.1'de tipik bir sert kılın anatomik yapısı gösterilmektedir [5]. Şekilde gösterilen her bir yapının özel bir görevi olmasına rağmen vücuda damar yoluyla bağlantılı olan kıl soğanı (bulbus), kılın metabolik aktivitelerinin düzenlenmesinden sorumlu olan en önemli kısımdır. Kılın alt kısmını oluşturan soğan benzeri bu yapı foliküler papilla (dermal kıl papillası), kök (matriks) hücreler ve melanin pigmenti içeren renk hücrelerinden (melanositler) oluşmaktadır. Yumurta şeklinde kıl soğanı içerisine doğru çıkıntılı olan foliküler papilla, içerdiği damar ağ yapısı sayesinde kılın metabolik ihtiyaçlarını karşılamaktadır. Kıl soğanı içindeki bir diğer yapı olan kök hücreleri ise çoğalarak kılın büyümesini sağlamaktadır. Kök hücreleri arasında, kıla rengini veren

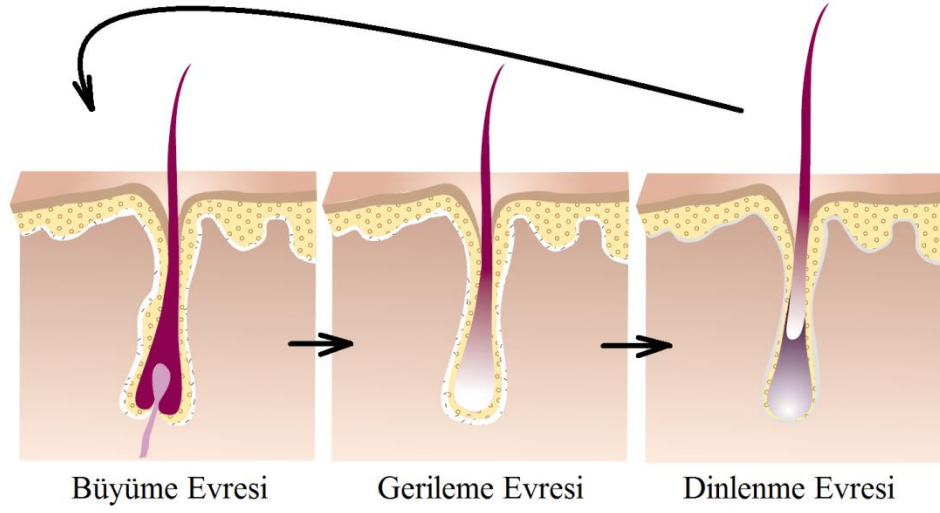
ve ışıklı epilasyon sistemleri için oldukça önemli olan melanositler de bulunmaktadır [3].



Şekil 2.1. Tipik bir terminal (sert) kıl anatomisi [5]

Kıl folikülleri büyüme (anagen), gerilme (catagen, regresyon) ve dinlenme (telogen) evrelerinden oluşan döngüsel bir büyüme modeli göstermektedir (Şekil 2.2). Büyüme evresi, kök hücrelerinin bölünmesindeki artışla başlar. Kıl soğanı içinde bulunan kök hücreler, hızla çoğalarak kıl shaftını yukarı doğru iterler. Büyüme evresinde kıl soğanı, alt deri (subkutan doku) içinde cildin 2-7 mm altında bulunmaktadır [4]. Büyüme evresinin sonunda kıl kılıfında programlanmış bir hücre ölümü (apoptozise) gerçekleşir ve hücre gerileme evresine girer [3]. Gerileme evresinde, kök hücreler arasında bulunan melanositler de dâhil olmak üzere kılın alt kısmında hücre ölümleri gerçekleşir [6]. Bu evrede foliküler papillanın ucu kısılır ve kök hücreler kaybolur. Kılın büyümesi durur, ancak, kıl shaftı yukarı doğru ilerlemeye devam eder ve kıl shaftı kıl soğanından tamamen ayrılır. Bu evrede, kıl soğanı sadece kıl kılıfından oluşur ve tohum hücre (germinal) kesesinde yeni kıl soğanı tekrar üretilmeye başlanır [3].

Gerileme evresi sadece birkaç haftada tamamlanır ve kıl dinlenme evresine girer [7]. Tohum (germ) hücreleri, kıl kılıfı tabanında yeni kılı oluşturmaya devam ederken, kıl kökünden ayrılmış eski kılın büyük bir kısmı cilt üzerine çıkar. Bu evrenin sonunda kıl kendiliğinden dökülür. Bu aşamadan sonra kıl tekrar büyüme evresinin başlangıcına döner.



Şekil 2.2. Kıl büyüme döngüsü [5]

Vücudun farklı bölgelerindeki kıllar, farklı sürelerle büyüme, gerileme ve dinlenme evrelerinde bulunurlar. Kafa derisi üzerinde kılların büyük bir çoğunluğu (%80-85) büyüme evresindedir, geri kalan kıl folikülleri ya gerileme (%2) ya da dinlenme (%10-15) evresindedir. Kafa derisi dışındaki diğer bölgelerde, kılların büyüme evresinde olma dağılımları, buldukları bölgeye göre %20-50 arasında değişmektedir. Dinlenme evresi yüz bölgesinde birkaç ay sürerken, bacak ve uyluk bölgesinde çok daha uzun sürebilir [7,8] (Çizelge 2.1). Çalışma [8]'de kıl büyüme evrelerinin ortalama değerlerinin standardize edilmediği için yazarlar arasında bu değerlerin ciddi farklılıklar gösterdiği belirtilmektedir. Kılların buldukları evre ve bu evrelerin dönüşüm süreleri, kalıcı epilasyon uygulamalarının parametre ayarlamalarında etkili hale gelmektedir. Bir sonraki bölümde, kılların büyüme evresi ve kalıcı epilasyon ilişkisi ile ilgili daha detaylı olarak bilgi verilmektedir.

Çizelge 2.1. Vücut bölgelerine göre kıl özellikleri [7]

Vücut Konumu	Büyüme Evresindeki Kıllar(%)	Gerileme Evresi Süresi
Sakal	70	10 hafta
Dudak üstü bölge	65	6 hafta
Koltuk Altı	30	3 hafta
Kollar	20	18 hafta
Bacaklar/Uyluklar	20	24 hafta

2.2. Kıl Büyüme Döngüsü ve Kalıcı Epilasyon İlişkisi

Elektroliz ve lazer epilasyon gibi uygulamalarda, kalıcı epilasyon, ancak, kılın yeniden oluşumundan sorumlu olan tohum hücrelerinin yok edilmesi ile mümkündür. Tohum hücrelerinin konumu ile ilgili yapılan ilk çalışmalarda, bu hücrelerinin kıl soğanı matriksi içinde veya yakınında bulunduğu ileri sürülmüştür [9,10].Ancak daha sonra yapılan çalışmalarda bu hücrelerinin, kıl kılıfının altındaki kalıcı kısımda bulunduğu görülmüştür [11]. Kalıcı epilasyonun sağlanabilmesi için hasarlanması gereken kıl tohumlarının konumu kadar kılın hangi evrede olduğu da oldukça önemlidir. Çünkü sadece büyüme evresinde olan kıllar kimyasal, sitostatik, fiziksel, hormonal, enfeksiyöz veya inflamatuvar etkilere karşı duyarlıdır [12]. Başka bir deyişle, kıl kılıfı ve kıl kılıfı içindeki tohum hücreleri, ancak, büyüme evresinde yok edilebilmektedir [8]. Kıl dinlenme evresinde iken uygulanan herhangi bir epilasyon yöntemi yeni kılların çıkmasına engel olamayabilir.

Kalıcı epilasyon uygulamalarının başarımı, ancak, kılların dinlenme evresinin tamamlanmasından sonra, kılların yeniden oluşumu üzerine gerçekleştirilen gözlemlerle doğrulanmaktadır. Bu sebeple, dinlenme evresinin en uzun sürdüğü bacak bölgesinde, bu sürenin 6 ay kadar olduğu düşünülürse, kıl dökme tedavisinden yaklaşık 6 ay kadar sonra epilasyonun kalıcı mı yoksa geçici mi olduğu anlaşılabilir [4].

Çizelge 2.1’de gösterildiği gibi vücudun farklı bölgelerindeki kıllar farklı sürelerle büyüme evresinde bulunurlar. Bu da kalıcı epilasyondan sonuç alınabilmesi için vücudun farklı bölgelerine farklı aralıklarla epilasyon uygulanması gerektiğini

gösterir. Kılların büyüme evrelerinin süresi kişiden kişiye de değişiklik göstermektedir. Bu nedenle kişiye özel uygulamalarda kalıcı epilasyon için önemlidir [3].

2.3. Cilt Tipleri - Fitzpatrick Skalası

Özellikle ışıklı epilasyon sistemlerinin kalıcı epilasyonda kullanılabilmesi için önemli olan bir diğer konu da uygulama yapılan cilt tipleridir. Dermatolojik araştırmalarda gerçekliliği olan ve güzellik merkezlerince de kullanılan cilt sınıflandırma yöntemlerinden birisi, Fitzpatrick Skalasının kullanılmasıdır (Çizelge 2.2) [13]. Bu skala, 1975 yılında Thomas B. Fitzpatrick tarafından, farklı cilt tiplerindeki insanların güneşe maruz kalmaları durumunda, ciltlerinde oluşan yanık ve bronzlaşma derecesi göz önüne alınarak oluşturulmuştur [14].

Çizelge 2.2. Fitzpatrick cilt sınıflandırma skalası [13]

Cilt Tipi	Deri Rengi ve Diğer Özellikler	Karakteristiği
I	Beyaz veya çok açık ten rengi; sarı veya kızıl saç; mavi göz rengi; çilli deri tipi	Güneşte her zaman yanar, hiçbir zaman bronzlaşmaz
II	Beyaz ten; sarı veya kızıl saç; mavi, ela ya da yeşil göz rengi	Güneşte genellikle yanar, güçlükle bronzlaşır
III	Buğday ten; göz ve saç rengi fark etmez	Güneşte bazen hafif yanar, yavaş yavaş bronzlaşır
IV	Kahverengi; tipik Kafkas Akdeniz cilt tipi	Güneşte nadiren yanar, kolaylıkla bronzlaşır
V	Koyu kahverengi; Orta doğu cilt tipi	Güneşte çok nadir yanar, çok kolay bronzlaşır
VI	Siyah	Güneşte hiçbir zaman yanmaz, çok kolay bronzlaşır

2.4. Kıl Giderme Yöntemleri

Kıl giderme¹ vücut kıllarının, uygulanan yöntem göre, kökünden veya cilt üzerinden, geçici veya kalıcı olarak giderilmesi işlemidir. Kullanılan kıl giderme yöntemleri genel olarak epilasyon ve depilasyon olmak üzere iki başlık altında incelenmektedir.

Epilasyon; istenmeyen vücut kıllarının kalıcı ya da uzun süreli olarak giderilmesi işlemi ve bu amaçla uygulanan yöntemlere verilen genel isimdir. Epilasyon yöntemleri ile kılın deri üzerinde kalan kısmı ile birlikte deri altındaki kök kısmı da ortadan kaldırılmaktadır. Bilinen epilasyon yöntemleri şunlardır: ağda, çekme, epilator, ilaçla tedavi, iğneli epilasyon, ışıklı epilasyon yöntemleri.

Depilasyon ise vücut kıllarının sadece cilt yüzeyi üzerinde kalan kısımlarının giderilmesi işlemi ve bu amaçla uygulanan yöntemlere verilen genel isimdir. En bilinen depilasyon yöntemi tıraşlamadır. Bunun dışında, tüy dökücü kremler ile kılın protein yapısı bozularak da depilasyon sağlanabilmektedir.

Vücut kılı giderme yöntemlerinin, epilasyon ve depilasyon şeklinde sınıflandırılmasının yanı sıra kalıcı ve geçici kıl giderme yöntemleri olarak da bir sınıflandırma yapılmaktadır. Yukarıda bahsedilen yöntemlerden sadece iğneli epilasyon (elektroliz) ve ışıklı epilasyon (lazer epilasyon, foto epilasyon) teknikleri istenilen bölgelerde kalıcı epilasyon sağlayabilmektedir. Cımbız, ağda, tıraşlama gibi geleneksel yöntemlerin sağladığı kıl gidermenin kısa süreli etkinlik göstermesi, ağırlı ve zahmetli yöntemler olması, deriye zarar vermesi, kıl köklerinde iltihaplanmaya sebep olması, kılların sertleşmesine neden olması gibi sebeplerden dolayı, kalıcı kıl giderme yöntemleri bu yöntemlere tercih edilmektedir. Aşağıdaki bölümlerde kalıcı kıl giderme yöntemleri daha detaylı olarak incelenmektedir.

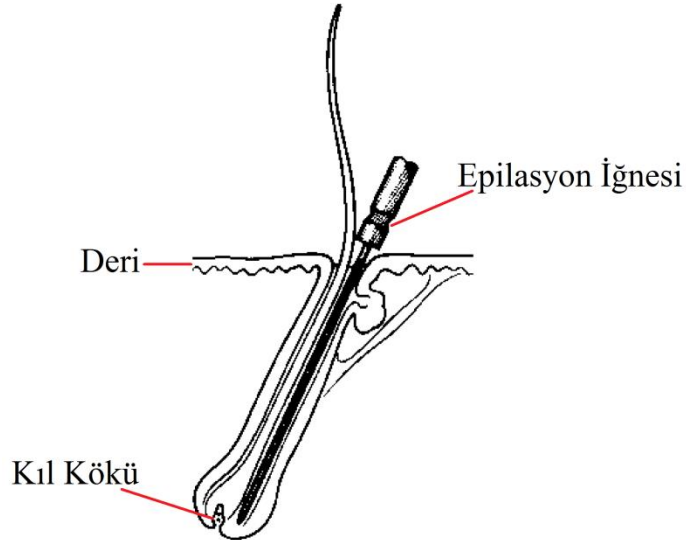
¹ İngilizce kaynaklarda “hair removal” olarak kullanılan tanımın, Türkçe’de yaygın olarak kullanılan karşılığı “epilasyon” kelimesidir. Türk dil kurumunun epilasyonu, “Vücutta istenmeyen tüyleri alma” olarak tanımlaması da bu kullanıma uygundur. Ancak İngilizce kaynaklardaki “epilation” kelimesinin karşılığı olan işlemin, “hair removal” işleminin bir alt başlığı olarak tanımlanması nedeniyle, bu çalışmada “hair removal” tabiri yerine en yakın karşılığı olan “kıl giderme” tabiri kullanılmaktadır.

2.5. Kalıcı Epilasyon Yöntemleri

Günümüzde kullanılan kalıcı epilasyon yöntemleri iğneli epilasyon ve ışıklı epilasyon başlıkları altında sınıflandırılmaktadır. Bölüm 2.5.1 ve Bölüm 2.5.2’de her iki yöntem de çalışma prensipleri ile birlikte incelenmektedir.

2.5.1. İğneli Epilasyon Yöntemleri

Mağara çizimlerindeki sakalsız erkek tasvirleri geçici kıl giderme yöntemlerinin tarih öncesi çağlara dayandığını göstermektedir. Benzer şekilde tarihteki birçok toplumda dini, tıbbi, sosyal ve cinsel sebeplerden dolayı geçici kıl giderme yöntemlerinin kullanıldığı bilinmektedir [15]. Kalıcı kıl giderme yöntemlerinin kullanımının ise daha yakın zamanlara dayandığı bilinmektedir. Yaklaşık 130 yıllık bir geçmişi olan elektrolizin kalıcı epilasyonda kullanılan ilk yöntem olduğu kabul edilmektedir [16]. Elektroliz yönteminin yanı sıra termaliz ve karma (blend) yöntemleri de iğneli epilasyon sınıfında değerlendirilmektedir. Her üç yöntem de elektrik akımı ileten bir prob veya küçük bir iğnenin kıl folikülü (kılıfı) içine sokulması sonucu kıl kılıfının hasar görmesine dayanan yöntemlerdir [17]. Şekil 2.3’te iğneli epilasyon şematik olarak gösterilmektedir [18].




Şekil 2.3. İğneli epilasyon [18]

Elektroliz tekniđi, kıl kılıfı ierisine sokulmuř olan problara dřuk dođru akım ya da galvanik akım uygulayarak, prob evresindeki dokularda kimyasal bir tepkime oluřturmaktadır. Oluřan bu kimyasal tepkime kıl kılıfının tahribatına neden olmakta ve kalıcı epilasyon sađlamaktadır. Kısaca elektroliz olarak da isimlendirilen, galvanik elektroliz tekniđi, etkili bir yntem olmasına rađmen olduka yavařtır. Her bir kıl kknde tahrip oluřması yaklařık 1 dakika srmektedir. Bu yntemin avantajı ise daha az ađrı oluřturması ve ciltte iz bırakma riskinin az olmasıdır [3,7,19].

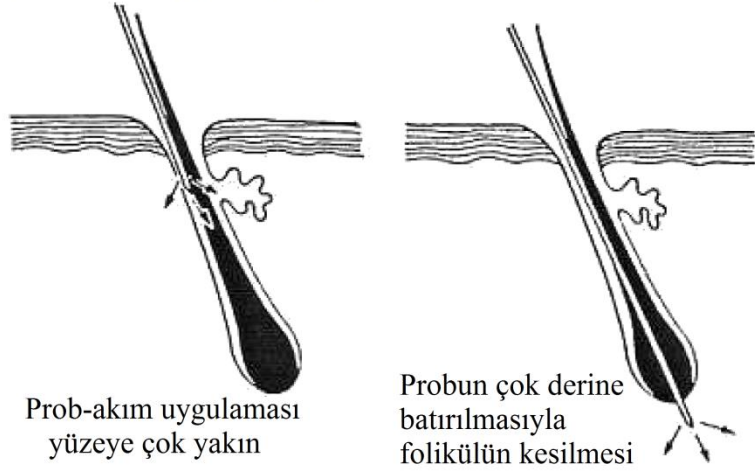
Diđer bir iđneli epilasyon tekniđi olan termoliz ynteminde ise proba dođru akım yerine dřuk voltaj ve yksek frekansa sahip alternatif akım uygulanarak kıl kılıfının elektroliz ynteminde olduđu gibi kimyasal olarak deđil, termal olarak hasar grmesi sađlanmaktadır. Termal hasar kıl kılıfının ierdiđi su molekllerinin titreřmesiyle aıđa ıkan ısı sonucu olur. Modern cihazlardaki geliřmelere rađmen, termoliz ynteminin ciltte iz bırakma ve ađrı oluřturma riski elektroliz ynteminden daha yksektir. Termoliz yntemin elektrolize gre daha hızlı olması ise bu yntemin bir avantajıdır [3,8,20,21].

Karma epilasyon yntemi ise yavař fakat bařarılı elektroliz tekniđi ile daha hızlı olan termoliz tekniđinin avantajlarını bir arada kullanmaktadır. Karma yntem ile kıl kılıfı hem kimyasal hem de termal olarak tahrip edilir. Termoliz ve elektrolizin birleřimi olan bu yntemin, her iki ynteme gre de kılların kalıcı olarak giderilmesinde daha etkili olduđu ve daha az acıya sebebiyet verdiđi literatrde yer alan alıřmalarda belirtilmektedir [17,22].

Yukarıda rnekleri verilen iđneli epilasyon yntemleri zamanla geliřme gstermiř olsa da bu yntemin kullanılması ile yapılan epilasyon iřlemi olduka uzun srmekte ve operatrn teknik becerisi bařarı oranlarını byk lde belirlemektedir [16]. Őekil 2.4'te operatr becerisine bađlı olarak epilasyon iđnesinin dođru ve yanlıř kullanım rnekleri gsterilmektedir [3]. Iđneli epilasyonda operatr becerisine duyulan yksek ihtiya nedeniyle, kalıcı epilasyon sađlamak iin iđneli epilasyona alternatif olarak sunulan ıřıklı epilasyon yntemleri, gnmzde daha yaygın Őekilde kullanılmaya bařlanmıřtır.



Yanlış açıyla girilmesiyle yağ salgılayan bezin kesilmesi İğnenin çok dik girmesiyle folikül duvarının kesilmesi Doğru açıyla giriş



Prob-akım uygulaması
yüzeye çok yakın

Probun çok derine
batırılmasıyla
folikülün kesilmesi

Şekil 2.4. İğneli epilasyon doğru ve yanlış kullanım örnekleri [3]

2.5.2. Işıklı Epilasyon Yöntemleri

Işıklı epilasyon sistemleri, kıl foliküllerini foto termal, foto kimyasal veya foto mekanik etkiyle tahrip ederek, kalıcı epilasyon sağlayabilen sistemlerdir. Işıklı epilasyon sistemlerinde, tek bir ışık atımı ile birden fazla kıl folikülü kalıcı olarak tahrip edilebilmektedir. Bu nedenle ışıklı epilasyon tekniği, diğer bir kalıcı epilasyon yöntemi olan iğneli epilasyon tekniğine göre çok daha hızlı uygulanabilmektedir. Işıklı epilasyon sistemleri Foto epilasyon (IPL) ve lazer epilasyon olmak üzere iki ayrı kategoriden oluşmaktadır. IPL ve lazer epilasyon sistemleri arasındaki temel fark, bu sistemlerin kullandığı ışık kaynaklarıdır. IPL sistemlerinde kullanılan lambalar lazerden farklı olarak tek bir dalga boyunda değil, daha geniş bir spektrumda ışık yaymaktadır. IPL cihazları, her ne kadar lazer kullanmasa da, her iki sistemin çalışma


prensipindeki benzerlikler nedeniyle, bu çalışmada ve literatürdeki birçok çalışmada, IPL ve lazer epilasyon sistemleri ile birlikte incelenmektedir [23-26].

Albert Einstein'ın 1916 yılında yayınladığı "stimulating radiant energy" teorisine dayanan Laser (Light Amplification by the Stimulated Emission of Radiation), dönemin fizikçi ve elektrik mühendislerinin birlikte çalışması ile 1960 yılında işlevsel bir model haline getirilmiştir. Lazer ışınının biyolojik etkileri ve muhtemel operasyonel kullanım alanları ilk olarak göz doktorları ve dermatologlar tarafından araştırılmıştır. Lazerin icadından önce, güneş ışığını ve diğer ışık kaynaklarını dermatolojik hastalıkların tedavisinde kullanan araştırmacıların lazeri kullanması ile bu alandaki ilk dermatolojik çalışmalar da yapılmıştır [27]. Lazerin icadından hemen sonra, Dr. Leon Goldman lazerin istenmeyen tüylerin giderilmesinde kullanılabilmesi için araştırmalara başlamış ancak lazerle çevre dokulara zarar vermenden kıl giderme işleminin yapılabilmesi yaklaşık 30 yılı bulmuştur [28]. Resmi olarak epilasyonda kullanılan ilk lazer, 1996 yılında kullanılan 694-nm ruby lazer olmuştur [29]. Ancak, bu lazer kullanılması ile gerçekleştirilen kıl giderme işleminin uzun sürmesi, bu sistemin pratik kullanımını engellemiştir [26]. 1996 yılında, kıldaki melanin maddesini hedef alan diğer lazer epilasyon ve IPL cihazlarının FDA tarafından onaylanması ile seçici fototermaliz teorisine dayalı ışıklı epilasyon sistemleri hızla yaygınlaşmıştır [30].

Işıklı epilasyon sistemleri kırmızı ve yakın kızılötesi aralığındaki dalga boylarını (600-1100 nm) kullanmaktadır. Genellikle foto termal etki ile kıl kılıfını tahrip eden bu sistemlerin seçici fototermaliz teorisine uygun olarak çalıştığına inanılsa da, bu sistemlerin biyolojik çalışma mekanizmasının çok daha karmaşık bir yapıda olduğuna inanan araştırmacılar da bulunmaktadır [31]. Bir sonraki bölümde seçici fototermaliz teorisi dayanan ışıklı epilasyon cihazlarının çalışma prensipleri detaylı olarak incelenmektedir.

2.5.2.1. Seçici Fototermaliz Teorisi ve Işıklı Epilasyon Sistemlerinin Çalışma Prensipleri

Seçici fototermaliz teorisi Anderson ve Parrish tarafından 1983 yılında önerilmiştir [32]. Grotthus-Draper yasasına göre ışımının bir maddeyi kimyasal olarak değiştirebilmesi için ışığın madde tarafından emilimi şarttır. Kıl folikülünün foto termal olarak hasar görebilmesi için de lazer ışığının enerjisinin kıl içerisindeki maddeler tarafından emilerek yoğun bir ısıya dönüştürülmesi gerekmektedir. Maddeye renk veren ve belli dalga boyundaki ışığı emen atom grubuna genel olarak kromofor denilmektedir. İnsan derisinde bulunan üç ana kromofor melanin, (oxy)hemoglobin ve sudur [33]. Üç ana cilt kromoforunun 400-1400 nm arasındaki dalga boyları için emilim spektrumları Şekil 2.5'te gösterilmektedir [34].



Şekil 2.5. Üç ana cilt kromoforunun emilim spektrumları [34]

Lazer epilasyon uygulamalarında, ciltte yoğun olarak bulunan (oxy)hemoglobin ve suyun daha az ışın emdiği, kılda yoğun olarak bulunan melaninin ise daha çok ışın emdiği kırmızı ve yakın kızılötesi dalga aralıkları özellikle kullanılmaktadır. Böylece, yalnızca kıl shaftındaki melaninin ısıtılması sağlanırken, cildin daha aza hasar görmesi hedeflenmektedir. Bu şekilde, uygun dalga boylarının seçilerek, doğrudan belirli kromofor atomların hedef alınabilmesi, seçici fototermaliz teorisinin önemli bir kısmını oluşturmaktadır. Seçici fototermaliz teorisini ilgilendiren bir diğer konu ise ışık atım süresinin doğru ayarlanmasıdır. Teoriye göre kromofor hedefteki termal

hasarı sınırlandırmak için ışık atım süresinin, hedefin termal gevşeme zamanına (TGZ) eşit ya da daha kısa olması gerekmektedir. Termal gevşeme zamanı ışığı emen hedefte oluşan ısının %50'sinin çevre dokuya ısı transferi yapmadan kaybedebilmesi için gereken zamandır. Küçük cisimler büyük cisimlerden daha çabuk soğurlar, kıl folikülü için milisaniyeler seviyesinde olan termal gevşeme zamanı, cisimlerin çapının karesi ile doğru orantılıdır. Eğer lazer atım süresi TGZ'den daha uzun olursa, hedeflenen dokuda hasar oluşmadan ısı çevre dokulara yayılmaktadır. Lazer atım süresi TGZ'den çok kısa olursa, hedeflenen dokuda aşırı hasar oluşabilir ve eğer bu süre TGZ'nin biraz altında olursa, hedef kromofor madde kazandığı ısıyı dışarıya yayamaz ve termal hasar sadece hedefle sınırlı kalır [35].

Çizelge 2.3. Lazer atım süresi ve hedefin termal gevşeme zamanı ilişkisi

Atım Süresi	Sonuç
<<TGZ	Seçili hedefte aşırı hasar
<~TGZ	Seçili hedefte uygun termal hasar
>>TGZ	Seçili hedefte hasar oluşmaz

Hedef kromofor maddeye bağlı olarak farklılık gösteren TGZ değeri için bazı örnekler Çizelge 2.4'te verilmiştir.

Çizelge 2.4. Bazı lazer hedeflerinin termal gevşeme zamanları [34]


	Boyut, μm	TGZ (yaklaşık değerler)
Dövme mürekkep partikülü	0.5-4	10 ns
Melanozom	0.5-1	1 μs
Eritrosit	7	2 μs
Damar	50	1 ms
Damar	100	5 ms
Damar	200	20 ms
Kıl folikülü	200	10-100 ms

Seçici fototermaliz teorisini ilgilendiği üçüncü konu ise kıl folikülünde hasara yol açılabilmesi için birim alana düşen enerjiye (fluens) bağlı olarak lazer atım süresinin uygun olarak ayarlanmasıdır. Lazer epilasyon cihazlarının çalışma prensibini oluşturan seçici fototermaliz teorisi kısaca; lazer dalga boyunun, lazer atım süresinin

ve lazer fluensinin uygun bir şekilde belirlenmesi durumunda, hedef kromofor maddede kalıcı termal hasar oluşturulabileceği ve diğer kromofor maddelerin lazer ışımından daha az etkileneceğidir.

Seçici fototermaliz teorisinin önerdiği yapıya uygun olarak çalışan günümüz lazer epilasyon cihazları, kıldaki kromofor madde olan melaninde termal hasar oluşturarak kalıcı epilasyon sağlayabilmektedir. Ancak, bu cihazlarda kullanılan dalga boyları kıldaki melanin tarafından emildiği gibi derideki melanin pigmentleri tarafından da emilmektedir. Bu cihazlarda kullanılan lazer ışının deriye zarar vermeden, sadece kılı hedef alabilmesi için derideki melanin sayısının düşük, kıldaki melanin sayısının ise yüksek olması gerekmektedir. Bu nedenle beyaz ten yapısına ve koyu renkli kıl yapısına sahip olan insanlar lazer epilasyonun en başarılı olduğu grubu oluşturmaktadır. Fitzpatrick skalasında cilt tipi III bu tanıma en yakın olan cilt tipidir (Çizelge 2.2). Kızıl ve sarışın insanlarda kıl folikülünün içerdiği melanin miktarının düşük olması nedeniyle lazer ışması kılı yakmakta başarısız olurken, esmer ve koyu tenli insanlarda ise ciltteki melanin miktarının yüksek olması nedeniyle lazer ışması sadece kıl da değil, deride de yanıklara yol açmaktadır [3]. Bahsedilen bu problemler günümüzde kullanılan kalıcı lazer epilasyon teknolojisiyle ilgili en temel sıkıntıları oluşturmaktadır. Günümüz lazer epilasyon uygulamalarının yan etkileri, Bölüm 3.1’de ayrıca incelenmektedir.

Işıklı epilasyon sistemlerinin temel çalışma prensiplerinden bazıları seçici fototermaliz teorisi başlığı altında incelendi. Anlatılan bu prensiplerin dışında kalan, bir diğer önemli konu ise epilasyon sistemlerinde kullanılan ışık kaynağının dalga boyunun kıl kökü derinliğine nüfuz edebilecek seviyede olmasıdır. 400-2000 nm arasındaki dalga boylarının insan derisine penetrasyonu Şekil 2.6’da gösterilmektedir [36].



Şekil 2.6. 400-2000 nm arasındaki dalga boylarının insan derisine penetrasyonu [36]

Yukarıda kısaca bahsedilen nedenlerden dolayı bir lazerin kalıcı epilasyonda kullanılabilmesi için fluens, atım süresi ve dalga boyunun birlikte incelenmesi gerekmektedir. Ayrıca epilasyon sisteminin istenilen başarıda çalışabilmesi için uygun lazer spot boyutu (cilde çarptıkları alan boyutu) ve uygun cilt soğutma sisteminin de seçilmesi gerekmektedir.

2.5.2.2. Işıklı Epilasyon Sistemlerinde Kullanılan Işık Kaynakları

Işıklı epilasyon sistemlerinin FDA tarafından onaylanmasından bu yana, lazer destekli kalıcı kıl giderme yöntemleri gelişmeye devam etmektedir. Cilde zarar vermeden kalıcı epilasyon sağlayabilmek için farklı dalga boylarında ışık kaynakları ile bu ışık kaynaklarının ideal çalışma parametrelerinin bulunması için testler yapılmıştır. Işıklı epilasyonda kullanılan bazı sistemler ve bu sistemlerde kullanılan ışık kaynakları kullandıkları parametrelerle birlikte Çizelge 2.5'te verilmiştir [37].

Çizelge 2.5. Epilasyonda kullanılan bazı lazerler ve ışık kaynakları [37]

Işık Kaynağı	Dalga Boyu (nm)	Sistem Adı	Atım Süresi	Fluens (J/cm²)	Spot Boyutu (mm)
Uzun-atımlı Ruby Lazer	694	E2000 (Palomar Medical Technologies, Lexington, MA)	3, 100 ms	10-40	10, 20
		EplTouch Ruby (ESC, Needham, MA)	1.2 ms	10-40	3-6
Uzun-atımlı Alexandrite Lazer	755	Apogee (Cynosure Inc, Chelmsford, MA)	5, 10, 20, 40 ms	5-50	10, 12.5, 15
		GentleLose (Candela, Wayland, MA)	3 ms	10-100	8,10,12,15
Diode Lazer	800	LightSheer (Coherent)	5-100 ms	10-60 (2900W)	12x12
		Apex-800 (Iriderm, Mountain View, CA)	10-30 ms	Up to 60W	2, 4
Q-switched Nd:YAG Lazer	1064	Softlight (Thermolase, San Diego, CA)	10 ns	1-3	7
Uzun-atımlı Nd:YAG Lazer	1064	CoolGlide (Altus, Mento Park, CA)	10-100 ms	Up to 100	9x9
Genişbant IPL Işık Kaynakları	590-1200	EpiLight (ESC)	15-100 ms	Up to 45	10x45, 8x35

Kalıcı epilasyon amacıyla günümüze kadar kullanılmış ve FDA tarafından da onaylanmış olan ışık kaynakları şunlardır: (i) Uzun-atımlı (Long-pulsed) Ruby lazer (694 nm), (ii) uzun-atımlı Alexandrite lazer (755 nm), (iii) Diode lazer (800-810 nm),

(iv) Q-switched Nd:YAG lazer (1064 nm), (v) uzun-atımlı Nd:YAG lazer (1064 nm), (vi) IPL ışık kaynakları (590-1200 nm) [29].

Üretilmiş ilk lazer olan Ruby lazer, aynı zamanda, 1960'lerde Dr. Leon Goldman tarafından dermatolojik kullanımları rapor edilmiş ilk lazerdir [38]. Daha önce pigmente lezyon tedavisi ve dövme silme işlemlerinde kullanılan Ruby lazerin, FDA tarafından epilasyonda kullanımının onaylanmasıyla birlikte, diğer ışıklı epilasyon sistemlerinin de önünü açılmıştır [4]. Ruby lazerin çalıştığı 694 nm dalga boyunun yüksek melanin emilimi nedeniyle, bu lazer, daha çok, açık tenli (Fitzpatrick skalası cilt tipi I, II, III) ve siyah kıl rengine sahip insanlarda başarılı olmuştur [37]. Esmer tenli insanlarda deride pigmentasyona sebep olması ve ciltte yanık oluşturma riskinin yüksek olması, sistemin yavaş olması ve kullandığı dalga boyunun deriye penetrasyonunun düşük olması nedeniyle, Ruby lazerin epilasyonda kullanımı büyük ölçüde terk edilmiştir [3,4,39].

755 nm dalga boyunda çalışan Alexandrite lazer, Ruby lazere göre cildin daha derinlerine nüfuz edebilmektedir (Şekil 2.6) ve kullanılan bu dalga boyunun melanin pigmenti tarafından emilimi Ruby lazer ışınının emilimine göre daha düşüktür (Şekil 2.5). Bu nedenle Alexandrite lazer ile ciltteki melanin pigmentlerine daha az zarar verilerek, kıl kökleri daha rahat hasarlanabilmektedir. Alexandrite lazerin bu özelliği daha esmer insanlara da epilasyon uygulanabilmesine imkân sağlamıştır [39]. Bu lazerin fiber optik başlığı sayesinde rahat ve hızlı kullanımı da mümkündür. Ancak, Alexandrite lazer ile ince kılları yakabilmek için lazerin daha yüksek güçlerde çalışması gerekmektedir, bu durumda cilde zarar verme riski artmakta ve yüksek güçte özellikle vücudun hassas yerlerinde duyulan ağrı rahatsız edici seviyelere ulaşabilmektedir [3,40].

800-810 nm dalga boyunda çalışan Diode lazer ışığının melanin seçiciliğinin düşük olması nedeniyle Alexandrite lazerdeki benzer avantajlar, Diode lazer sistemlerinde de bulunmaktadır. Diode lazer ışığının Alexandrite lazer ışığına göre derinin daha alt katmanlarına nüfuz edebilmesi, son yıllarda bu sistemlerin daha esmer hatta bronzlamış insanlarda da kullanılmasına imkân sağlamıştır [39]. Diode lazerlerdeki fiber optik başlık imkânı kullanım kolaylığı açısından önemlidir. Klinik çalışmalarda

Diode lazerin siyahî (Fitzpatrick skalası cilt tipi V) insanlarda dahi, daha az yan etki ile epilasyon sağlayabildiği görülmüştür [41]. Alexandrite lazer epilasyon sistemlerindeki benzer sebeplerden dolayı ince kılları yakmak için daha yüksek güçte çalışması gerekmekte ve bu nedenle ciltte yanık riski artmaktadır.

Uzun-atımlı Nd:YAG lazerlerin çalıştığı 1064 nm dalga boyunda melanin emilim oranı diğer lazerden daha düşüktür, bu nedenle bu lazerlerin etkili olabilmesi için daha yüksek fluens ile çalışması gerekmektedir. Uygun cilt soğutucularla birlikte çalışıldığında istenilen uzun süreli epilasyonu sağladığı klinik çalışmalarla ispatlanmıştır [42]. Bu lazer ışığının, yüzeysel dokular tarafından emiliminin düşük olması nedeniyle 5 mm genişliğe kadar dağılarak aynı anda pek çok kıl folikülüne hasar verilebilmektedir [3].

1064 nm dalga boyunda çalışan Q-switched Nd:YAG lazer epilasyon sisteminin çalışma prensibi diğer lazer sistemlerinden farklıdır. Karbon içeren çözeltinin cilde sürülerek kıl köküne girmesi sağlanır. Bunun için ya ağda yapılarak kıl kökünün bulunduğu yer boşaltılır ya da içerdiği karbon parçacıkları daha ufak olan özel bir çözelti ağdasız olarak cilt yüzeyine sürülerek, çözeltinin kıl köküne girmesi sağlanır. Daha sonra cilt üzerinde kalan fazla çözelti temizlenir. Kıl köküne girmiş olan bu çözelti melanin yerine hedef kromofor madde olarak kullanılmaktadır. Diğer lazer sistemlerindeki benzer bir şekilde, kromofor çözeltinin ışığı ısıya çevirerek kıl köküne hasar verilmesi ile epilasyon sağlanmaktadır. Bu sistemin en önemli avantajı koyu renkli cilt tiplerinde düşük yan etki riski ile çalışması ve kıldaki melanin miktarı az olan sarışın ve kızıl insanlarda da çalışabilmesidir. Ancak, işlem öncesinde ağda yapılması ve karbon solüsyon uygulanması, epilasyon işlemi yavaşlatmakta ve işlem maliyetini arttırmaktadır. Bu sistemlerin kalıcı epilasyon sağlamakta istenilen başarıya ulaşamadığı bilinmektedir [37,40].

IPL ışık kaynakları (590-1200 nm) kullanan epilasyon sistemleri lazer tabanlı sistemlerden farklı olarak, geniş bant xenon flash lambayı optik filtreler ile görünür-infrared dalga boyu aralığında noncoherent bir ışığa çevirerek kullanılmaktadır. IPL cihazlarının çalışma prensibi de lazer epilasyon cihazlarınınki gibi fototermaliz teorisine dayanmaktadır. Ancak kullanılmakta olan geniş dalga aralığı nedeniyle, IPL

cihazları aynı anda birçok cilt kromoforunu etkilemektedir. Filtrelerle çalışılan dalga boyu ayarlanabilir olan bu sistemlerin deneyimsiz operatörler tarafından yanlış kullanımı durumunda ise ciltte ciddi hasarlar oluşabilmektedir [3,43]. IPL tabanlı epilasyon sistemlerinin, lazer tabanlı sistemlere göre avantajları düşük maliyetli olması ve büyük spot boyutu sayesinde kol, bacak gibi bölgelerde daha hızlı çalışabilmesidir. Ancak lamba ve lamba soğutucuların bulunduğu el cihazının ağır olması nedeniyle manevra kabiliyeti düşüktür. Teknik olarak en önemli dezavantajlarından birisi de IPL cihazlarının her ışık atımında tutarsız fluens ve dalga boyunda ışık yayması nedeniyle, klinik sonuçların öngörülemez olmasıdır [44]. Ayrıca, melanin emiliminin yüksek olduğu düşük dalga boylarından başlayan bir dalga aralığına sahip olan IPL cihazlarının koyu tenlilerde kullanımı oldukça tehlikelidir [43].

Yukarıda anlatılmış olan sebeplerden dolayı, koyu ten rengine sahip olan cilt tiplerinde kullanımı genellikle sakıncalı olan günümüz lazer epilasyon sistemlerinin yan etkilerinin en az indirilebilmesi için lazer spot boyutunun küçültülerek yalnızca kıl bölgelerinin lazer ışımından etkilenmesi gerekmektedir. Ancak küçük spot boyutlu sistemler kullanılarak yapılan epilasyon uygulamasının yavaş olması ve bu uygulamanın operatörün teknik becerisine olan bağımlılığı, küçük spot boyutlu sistemlerin tercih edilmesini engellemektedir. Bu tez çalışmasında küçük spot boyutlu sistemlerin dezavantajlarının ortadan kaldırılarak, lazer epilasyon uygulamasının cilt üzerindeki yan etkilerinin daha az olduğu bir yöntemin geliştirilebilmesi için küçük spot boyutlu bilgisayar destekli akıllı lazer epilasyon sistemi önerilmektedir (Şekil 1.1). Önerilmekte olan sistem makine öğrenmesi teknikleri kullanarak cilt üzerindeki kıl bölgelerini tespit etmekte ve yalnızca önceden tespit edilmiş kıl bölgeleri üzerine lazer ışınması yapılmaktadır. Bu sayede deri bölgeleri lazer ışımından daha az etkilenmekte ve lazer epilasyon uygulamasının ten rengine olan bağımlılığı en aza indirilebilmektedir. Bu tez çalışmasında önerilmekte olan bilgisayar destekli lazer epilasyon sisteminin detayları Bölüm 3'te anlatılmaktadır. Bu sistemin bir alt parçası olarak kıl bölgelerinin tespit edilmesi işleminde kullanılması önerilen öznetelik tabanlı kıl bölgesi tespit algoritmasının detayları ise Bölüm 4'te tarif edilmektedir.

3. MOTİVASYON, PROBLEM TANIMI VE TEZİN AMACI

Günümüzde kullanılan lazer epilasyon sistemlerinin çalışma prensipleri, Bölüm 2.5.2.1’de özetlenen, seçici fototermaliz teorisine dayanmaktadır. Belirli cilt tiplerinde uzun süreli epilasyon sağlamayı başarabilmiş olan bu sistemler, ciltteki melanin sayısının yüksek seviyelerde olması durumunda epidermiste kalıcı yan etkiler bırakabilmektedir. Bölüm 2’de çalışma prensipleri anlatılan günümüz lazer epilasyon sistemlerinin yan etkileri, bu tez çalışması için motivasyonu oluşturmakta olduğundan Bölüm 3.1’de bu yan etkiler detaylıca anlatılmaktadır. Bölüm 3.2’de bu problemin çözümü olarak önerilen, optik görüntüleme ile kıl bölgesi tespitine dayalı, küçük spot boyutlu, akıllı lazer epilasyon sistemi ve avantajları anlatılmaktadır. Optik görüntüleme ile kıl tespitine yönelik literatür çalışmaları Bölüm 3.3’te özetlenmekte ve Bölüm 3.4’te bu tez çalışmasının amacı ve kapsamı belirlenmektedir.

3.1. Lazer Epilasyonun Yan Etkileri

Günümüzde kullanılan lazer epilasyon cihazları, milisaniyeler seviyesinde lazer ışın atımları ile seçici fototermaliz teorisine uygun bir şekilde kıldaki melanin pigmentlerini hedef almakta ve kalıcı epilasyon sağlayabilmektedir. Ancak, lazer epilasyon cihazlarında kullanılan elektromanyetik spektrumun kırmızı ve kızılötesi bölgelerindeki (600-1100 nm) dalga boyları yalnızca kıldaki melanin tarafından değil aynı zamanda deride bulunan melanin ve keratin tarafından da emilmektedir. Bu nedenle epilasyon işlemi sırasında istenmeyen epidarmal hasarlar oluşabilmektedir. Epidermiste oluşabilecek termal hasarın önüne geçmek için, Bölüm 2.5.2.1’de anlatılan, lazer dalga boyu, fluens ve atım süresinde yapılan hassas ayarlamaların yanı sıra lazer epilasyon işlemi sırasında, çeşitli cilt soğutma yöntemleri de kullanılmaktadır. Bu soğutma yöntemlerinden bazıları: Cilde buz veya soğutulmuş sulu jel sürülmesi, içerisinde soğuk su sirkülasyonu olan safir camın cilde teması, soğutucu sprey kullanılması, cilde soğuk hava üflenmesidir [45]. Ayrıca, hidrokinon, tretinoin, azelaik asit ve kolik asit gibi topikal cilt rengi açıcılar kullanılarak, epidarmal melanin sayısı azaltılmakta ve lazer epilasyon işleminin yan etkileri önlenmeye çalışılmaktadır [2]. Cildi korumaya yönelik alınan tüm önlemlere rağmen, lazer epilasyon uygulamaları deri üzerinde kalıcı hasarlara yol açabilmektedir [46-48]. Cilt


tipi, lazerin uygulandıđı vücut bölgesi ve bronzlaşma seviyesine göre deđişen lazer epilasyonun bilinen bazı yan etkileri şunlardır: Hipo/hiperpigmentasyon (açık/koyu lekelenme), geçici eritem, perifoliküler ödem, ağrı, purpura gelişimi, kabuklanma, yara [2].

Lazer destekli epilasyon uygulamalarında, yukarıda bahsedilen yan etkilerin oluşmasının en önemli nedeni, kıl ile birlikte cildin de lazer ışığının spot bölgesi içinde kalmasıdır. Lazerin spot boyutu küçültülerek, derinin daha az miktarda lazer ışığına maruz kaldığı sistemler geliştirilmiştir. Ancak lazer spot boyutunun küçük olduđu epilasyon sistemlerinde uygulama süresinin uzun olması, bu sistemlerin, var olan avantajlarına rağmen, tercih edilmelerini engellemektedir.

Lazer epilasyon uygulamalarında oluşan yan etkileri belirleyen bir diđer unsur da operatörün teknik becerisidir. Lazer epilasyon işleminde, operatörün teknik becerisi, Bölüm 2.5.1'te anlatılan, bir diđer kalıcı epilasyon tekniđi olan iğneli epilasyon uygulamalarında olduđu kadar önemli deđildir. Ancak, operatörün cilt tipini doğru tespit edebilmesi, uygulama yapılan cilt tipine en uygun olan lazeri kullanması, uygun lazer atım gücünü belirleyebilmesi, lazer uygulaması yapılan bir bölgeye kısa süre aralıkla ikinci defa uygulama yapmaması gibi teknik becerilere sahip olması, oluşabilecek yan etkilerin azaltılması için önem taşımaktadır.

3.2. Küçük Spot Boyutlu, Akıllı Lazer Epilasyon Sisteminin Avantajları

Günümüzde yaygın olarak kullanılan büyük spot boyutlu lazer epilasyon sistemlerinin cilt üzerinde oluşturduđu yan etkiler, küçük spot boyutlu lazer epilasyon sistemleri ile önemli ölçüde ortadan kaldırılabilir. Büyük ve küçük spot boyutlu lazer epilasyon uygulamalarında, lazer ışımaya maruz kalan bölgeler, örnek bir cilt kesiti için, Şekil 3.1'de gösterilmektedir. Verilen örnek görüntüden de anlaşılabilir gibi, lazer spot boyutunun küçültülmesi ile lazer ışımından doğrudan etkilenen cilt bölgelerinin miktarı önemli ölçüde azaltılabilmekte ve epidermal hasar riski de düşürülebilmektedir.



Şekil 3.1. Büyük ve küçük spot boyutlu lazer epilasyon uygulamalarında lazer ışımaya maruz kalan cilt bölgeleri²

Küçük spot boyutlu lazer epilasyon sistemlerinin, sağlık risklerini azaltmak dışında, sağladığı diğer önemli avantajlar ise:

- Düşük güçte (düşük maliyetli) lazerlerle çalışabilmesi,
- Enerji verimliliğinin yüksek olması,
- Lazer ömrü boyunca, epilasyon uygulanan bölge miktarının yüksek olması (Toplam lazer atış sayısının yüksek olması),
- Cilt soğutma yöntemlerine ihtiyaç duymamasıdır.

Bu sistemlerinin en önemli dezavantajı ise, uygulama hızının, büyük spot boyutlu sistemlere göre, oldukça düşük olmasıdır. Bu nedenle, küçük spot boyutlu cihazların sahip olduğu önemli avantajlara rağmen, bu cihazlar güzellik merkezleri tarafından tercih edilmemektedir. Bu sistemlerinin uygulama hızının, büyük spot boyutlu sistemlerin uygulama hızına ulaşması ise, ancak, otomatik kıl tespiti ve lazer atımı yapabilen sistemlerle mümkün olabilir. Bu sayede, epilasyon uygulamasının başarımını ve hızını doğrudan etkileyen insan faktörü de önemli ölçüde ortadan kaldırılabilir.

Bu tez çalışmasında, lazer epilasyon uygulamalarındaki sağlık risklerinin en aza indirilmesi ve hız sıkıntısı yaşamadan, küçük spot boyutlu epilasyon sistemlerinin sağladığı avantajlardan faydalanılabilmesi için, Şekil 1.1’de çalışma şeması

² Bu resimlerde, lazer ışığının saçılım ve emilim özellikleri dikkate alınmamıştır.

verilen nokta atımlı bilgisayar destekli akıllı lazer epilasyon sisteminin kullanılması önerilmektedir.

Bilgisayar destekli lazer epilasyon sistemi için tasarlanan bu çözüm, mekanik hizalaması gerçekleştirilmiş lazer atım sistemi, görüntü işleme ünitesi, lazer kontrol ünitesi ve bir adet görünür bant kameradan oluşmaktadır (Şekil 1.1). Kameradan elde edilen görüntülerde tespit edilen kıl bölgelerinin pozisyon bilgileri, lazer atım yönlendirme ünitesine iletilerek lazer atımının sadece kıl bölgelerini kapsayacak şekilde gerçekleştirilmesinin mümkün olacağı değerlendirilmektedir. Önerilen lazer epilasyon sisteminin başarımı, kıl bölgelerini yüksek doğruluk oranında tespit edebilen ve gerçek zamanlı çalışma gereksinimlerini karşılayabilecek bir algoritmanın koşturulmasına bağlıdır. **Bu tez çalışmasının hedefi, önerilen sistemin bir alt parçası olan optik görüntüleme ile kıl bölgesi tespit yazılımının geliştirilmesi için, hız ve başarı kriterlerini birlikte sağlayan öznitelik tabanlı bir kıl lokalizasyon algoritmasının geliştirilmesidir.** Bilgisayarlı kıl tespitine yönelik, literatürde bulunan çalışmalar bir sonraki bölümde özetlenmektedir.

3.3. Kıl Tespiti Literatür Çalışmaları

Literatürde yer alan kıl tespit yöntemleri temel olarak kanser tespiti için incelenen deri lezyonlarının otomatik olarak tespit edilmesini engelleyen kılların belirlenerek görüntüden kaldırılmasını amaçlamaktadır [49]. Kıl tespit yöntemlerinin başarımları el ile işaretlenmiş kıl bölgeleri üzerinden algoritmaların tespit başarımlarının yüzde olarak çıkarılması ile elde edilmektedir.

Çalışma [49]'da kıl tespiti için çok basamaklı bir tespit yöntemi kullanılmaktadır. İlk aşamada Gauss süzgeçten geçirilmiş imgenin türevinin alınması ile kıl bölgeleri kabaca tespit edilmektedir. İkinci basamakta ise doğru bağlama fonksiyonu ile kırık doğruların birleştirilmesi, istenmeyen piksellerin morfolojik yöntemlerle silinmesi ve doğrulardaki boşlukların morfolojik geriçatma (reconstruction) işlemi ile doldurularak, kıl pikselleri çıkarılabilmektedir.

Çalışma [50]'de kıl bölgelerinin tespiti için ilk olarak top-hat operatörü kullanılmakta, daha sonra bir karar ağacı yapısı ile belirli morfolojik nitelikleri sağlamayan noktalar

elenmekte ve son olarak deri ile düşük renk farkına dayalı olarak ortaya çıkmış kırık kıl bölümlerinin birleştirilmesi işlemleri gerçekleştirilmektedir. Çalışmada, morfolojik işlemlerin dönmeden bağımsız olmaması sebebiyle birbiriyle 45° açı farkıyla oluşturulmuş 4 adet doğrusal yapıda, yapısal eleman kullanılmakta ve top-hat süzgecinde fark işlemi sırasında en yüksek değerli morfolojik işlem sonucu kullanılmaktadır. Top-hat süzgeci sonucu elde edilen değerlerinden ikili bir imge oluşturulması içinse Otsu eşikleme (thresholding) yöntemi kullanılmaktadır. Karar ağacı kullanılarak noktanın yoğunluğu, küreselliği ve konveks gövde küreselliği düğümler olarak tanımlanmakta ve değer aralığı kıl için önceden belirlenmiş bölgeler içinde kalmayan noktalar elenmektedir.

Zou ve ekibinin yapmış olduğu çalışmada büyüyen bölge (region growing) tabanlı bir kıl tespit yöntemi önermektedir [51]. Önerilen yöntemde ilk olarak yatay ve dikey kenar süzgeçleri kullanılarak kenar noktaları çıkarılmakta ve elde edilen kenar imgesi [0-255] aralığına eşleştirilmektedir. Alan büyüme algoritması için tohum seçme öncesi gürültülü noktaların temizlenmesi için sabit eşikleme yöntemi kullanılmıştır. İkinci bir eşikleme yöntemi olarak piksel süreklilik değerleri hesaplanmış ve eşik değeri 5-15 arasında seçilerek sadece kıl bölgelerine ait piksellerin kalması sağlanmıştır. Daha sonra büyüyen alan yöntemi kullanılarak kıllara ait bölgelerin tespit edilmesi sağlanmıştır.

Nguyen ve ekibinin yapmış olduğu çalışmada ise dermoskopik görüntülerdeki koyu ve açık renkli kılların, kıl tipi ile ilgili herhangi bir ön bilgi olmaksızın tespit edilebilmesi için evrensel bir kıl tespit algoritması önerilmektedir [52]. Önerilen kıl tespit yönteminde ilk adımda eşleşen süzgeçleme (matched filtering) yöntemi ile 18 farklı süzgeç içerisinde en yüksek cevap değeri oluşturan işlem sonucu piksel değeri olarak atanmaktadır. İlk basamakta kullanılan bu yöntem sayesinde koyu ten üzerindeki açık renk kıllar veya açık ten üzerindeki koyu renk kıllar tespit edilebilmektedir. Süzgeçleme yöntemi sonucu elde edilen cevap imgesi Gauss filtre ile düzgelenebilir (normalize) ve entropi yöntemi ile eşikleme işlemi gerçekleştirilmektedir. Elde edilen ikili imgedeki küçük boyutlu yanlış pozitifler uzunluk süzgeçleme ile elenmektedir. Uygulanan morfolojik inceltme işlemi ile kıl

iskeletleri elde edilmektedir. Kıl bölgelerinin tespiti için iskeleti oluşturulmuş ikili kıl imgesine Gauss eğri uydurma ve uzunluk süzgeçleme işlemleri son basamakta uygulanarak kıl bölgeleri elde edilmektedir.

3.4. Tez Çalışmasının Amacı

Bu tez çalışması kapsamında, Şekil 1.1’de çalışma şeması verilen bilgisayar destekli nokta atımlı lazer epilasyon sistemi için, deri üstü görüntüleme ile öznitelik tabanlı bir kıl bölgesi tespit algoritmasının geliştirilmesi amaçlanmaktadır. Bu amaçla görüntü işleme ve makine öğrenmesi teknikleri bir arada kullanılmaktadır. Ülkemizde de sık görülen ve günümüz lazer epilasyon uygulamalarında Bölüm 3.1’de belirtilen yan etkilerin sıklıkla oluşabildiği Kafkas Akdeniz cilt tipi (Fitzpatrick skalası cilt tipi IV) (Çizelge 2.2) hedef cilt tipi olarak belirlenmiştir.

Belirtilen kıl bölgesi tespit algoritmasının geliştirilmesinde kullanılacak yöntemler Bölüm 4’te özetlenmekte ve elde edilen deneysel sonuçlara Bölüm 5’te yer verilmektedir.

4. GELİŞTİRİLEN YÖNTEM

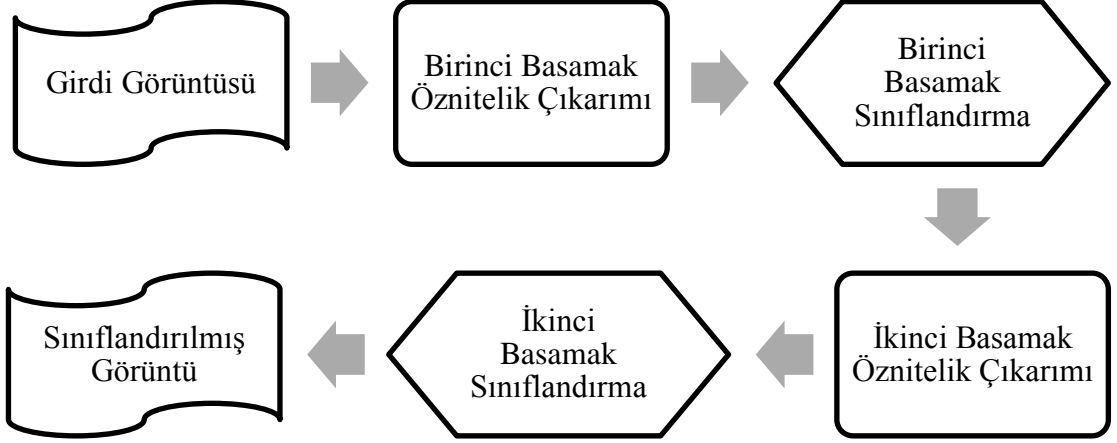
Bu tez çalışmasının amacı olan, öznelik tabanlı kıl bölgesi tespit algoritmasının geliştirilmesi ve test edilmesi için izlenecek yöntemler bu bölümde incelenmektedir. Bu çalışmada kullanılmakta olan makine öğrenmesine dayalı kıl bölgesi tespit yöntemi Bölüm 4.1’de özetlenmektedir. Test çalışmalarında faydalanılan görüntü kütüphanesinin oluşturulması için kullanılan görüntü alma teknikleri Bölüm 4.2’de anlatılmaktadır. Bölüm 4.3’te ise cilt görüntülerindeki kıl ve deri bölgelerinin etiketlenmesinde kullanılan yöntem açıklanmaktadır. Kıl ve deri görüntülerini ayrıştırmak için belirlenmiş olan öznelikler detaylı olarak Bölüm 4.4’te incelenmekte, Bölüm 4.5’te ise kullanılan öznelik seçme yöntemi anlatılmaktadır. Bölüm 5’te başarımları test edilecek olan makine öğrenmesi algoritmalarının çalışma prensipleri, Bölüm 4.6’da tarif edilmektedir. Kullanılan özneliklerin ve sınıflandırma algoritmalarının başarımlarının karşılaştırılmasında yararlanılacak olan değerlendirme ölçütleri ise Bölüm 4.7’de incelenmektedir.

4.1. Yöntem Özeti

Bu çalışma kapsamında önerilen ve Şekil 1.1’de çalışma şeması verilen bilgisayar destekli lazer epilasyon cihazının gerçek hayatta kullanılabilir olması için, bu sistemin bir alt parçası olarak geliştirilmekte olan kıl bölgesi tespit algoritmasının tespit hızı ve tespit başarımının yüksek olması gerekmektedir. Önerilmekte olan öznelik tabanlı ve görüntü tanıma tekniklerinin uygulandığı kıl bölgesi tespit yönteminin, ad-hoc yöntemlerle kıyaslandığında daha başarılı olabileceği değerlendirilmektedir. Ancak lazer epilasyon uygulamalarında kullanılacak olan kıl bölgesi tespit algoritmasının başarımının yüksek olmasının yanı sıra, yöntemin gerçek zaman uygulama koşullarını da sağlaması gerekmektedir. Bu nedenle, dokusal özellikleri ifade etmekte, genellikle, daha başarılı olabilen, işlemsel karmaşıklığı yüksek öznelikler yerine, yüksek ayırt etme gücüne sahip ve işlem karmaşıklığı düşük özneliklerin belirlenmesi sistemin başarısı için oldukça önemlidir.

Bu çalışmada, hız ve başarı kriterlerini birlikte sağlayabilen özneliklere öncelik tanınmaktadır. Bunun yanı sıra, işlem karmaşıklığı yüksek olmasına rağmen, yüksek ayırt etme gücüne sahip olan özneliklerin de sisteme entegre edilebilmesi için Şekil

4.1’de karar verme mekanizması verilen iki basamaklı kıl-deri sınıflandırma yönteminin kullanılması önerilmektedir.




Şekil 4.1. Test görüntülerinde bölgelerin kıl veya deri olarak sınıflandırılması için kullanılan mekanizma

Önerilen iki basamaklı sınıflandırma yönteminin ilk aşamasında, düşük işlemsel karmaşıklığa sahip öznitelik grubu kullanılarak kıl bölgelerinin kabaca tespiti gerçekleştirilmektedir. İkinci aşamada ise kabaca tespiti gerçekleştirilmiş kıl bölgeleri üzerinden, yüksek işlemsel karmaşıklığa sahip öznitelikler de kullanılarak, iyileştirilmiş kıl bölgesi tespiti gerçekleştirilmektedir. Bu sayede, kıl-deri ayrıştırma işleminde daha yüksek başarı gösterebilen karmaşık öznitelikler de ciddi bir hız sıkıntısı oluşturmadan kullanılabilir.

Önerilen sınıflandırma yönteminin bir alt parçası olan özniteliklerin çıkarılması aşamasında, işlemsel karmaşıklığı artıran disk, sekizgen, altıgen vb. şekillere sahip komşuluk pencereleri yerine, hız ve başarı kriterlerini birlikte sağlayabilen kare komşuluk penceresi kullanılmaktadır.

Bu çalışmada, her ne kadar uygulamaya yönelik önlemler alınmış olsa da, çalışmanın temel hedefi önerilmekte olan öznitelik tabanlı iki basamaklı kıl tespit algoritmasının başarısının incelenmesidir. Bu nedenle öznitelik çıkarma işlemi öncesinde, komşuluk penceresinin çıkarılacağı bölgelerin belirlenmesi için herhangi bir anahtar nokta tespit yöntemi önerilmemektedir. Bunun yerine, görüntünün tamamının taranması işlemi

yapılmaktadır. Gerçek zamanlı uygulamalarda, sınıflandırma hızını düşürme tehlikesi nedeniyle, kullanımı sakıncalı olan görüntü tarama yöntemi, testler sırasında sonuçların daha rahat yorumlanabilmesini sağlayacaktır. Bu amaca yönelik olarak uygulanan bir diğer algoritmik yöntem ise görüntünün örtüşen pencereler ile taranması yerine, örtüşmeyen pencereler kullanılarak taranmasıdır. Bahsedilen iki farklı tarama yöntemi Şekil 4.2’de gösterilmektedir.



Şekil 4.2. Örtüşen ve örtüşmeyen pencereler ile görüntü tarama işlemi

Önerilmekte olan sınıflandırma yöntemi, görüntü içindeki bölgeleri kıl ve deri bölgeleri olarak iki sınıfa ayırmaktadır. Deri enfeksiyonu, uçuk, dövme, benler, leke, yara vb. bölgeler sınıflandırma işlemi sonucu deri bölgesi olarak işaretlenmektedir. Bu sayede, lazer epilasyon işleminin riskli olduğu bu bölgelere ışın yapılmasının önüne geçilmektedir. Şekil 4.1’de karar verme mekanizması kabaca gösterilen iki basamaklı sınıflandırma yöntemi ile ilgili daha detaylı tartışmalara Bölüm 4.7’de yer verilmektedir.

4.2. Görüntü Alma

Bu çalışmada kullanılmakta olan görüntüler, Point Grey Flea3 model 3.2 MP mono kamera ile 25 mm kompakt sabit odak uzaklıklı lens kullanılarak elde edilmiştir. Cilt yüzeyinin ışıklandırılması için halojen ışık kaynağı kullanılmıştır. Kameradan alınan görüntüler cilt yüzeyinin bir cam yardımıyla düzleştirilmesi ile elde edilmiştir. Cilt yüzeyinin düzleştirilmesi sayesinde, zeminin tamamında düzgün bir dağılım gösteren aydınlatma sağlanabilmektedir. Kullanılan kamera ve aydınlatmayı sağlayan ışık kaynağı cilt yüzeyine dik olmayacak şekilde aynı açı ile yan yana yerleştirilmiştir. Bu sayede cilt yüzeyinden ve cilt düzleştirmekte kullanılan camdan gelen yansımaların kamera tarafından doğrudan alınması engellenmektedir. Kamera yaklaşık 10 cm sabit uzaklıktaki bir cilt bölgesinden görüntü almaktadır. Alınan görüntülerde, yaklaşık 1,6 cm²'lik bir cilt bölgesi 640x480 piksel ile temsil edilmektedir. Cilt yüzeyinden görüntü alınmadan önce kılların uzunluğu yaklaşık 1mm olacak şekilde kıllar tıraşlanmıştır.

Yukarıda bahsedilen yöntemler sayesinde, bu çalışmada kullanılmakta olan test görüntüleri sabit koşullar ile elde edilebilmiştir. Yapılacak olan testler için, sabit görüntüleme koşulları önemli olmakla birlikte, önerilen kıl tespit yöntemleri ve kullanılan ayırt edici öznelikler kamera uzaklığında, kamera açısında ve kullanılan ışık kaynağının fluensindeki değişikliklere karşı oldukça esneklerdir.

Hedef cilt tipi olarak belirlenmiş olan Kafkas Akdeniz cilt tipine sahip olan 10 kişinin kol, bacak ve yüz bölgelerinden, yukarıda belirtilmekte olan koşullar altında görüntüler alınarak bir görüntü kütüphanesi oluşturulmuştur. Oluşturulan kütüphanedeki cilt görüntüleri bu çalışmada yapılmakta olan testlerde kullanılmaktadır.

4.3. Kıl ve Deri Bölgesi Doğruluk Tablolarının Oluşturulması

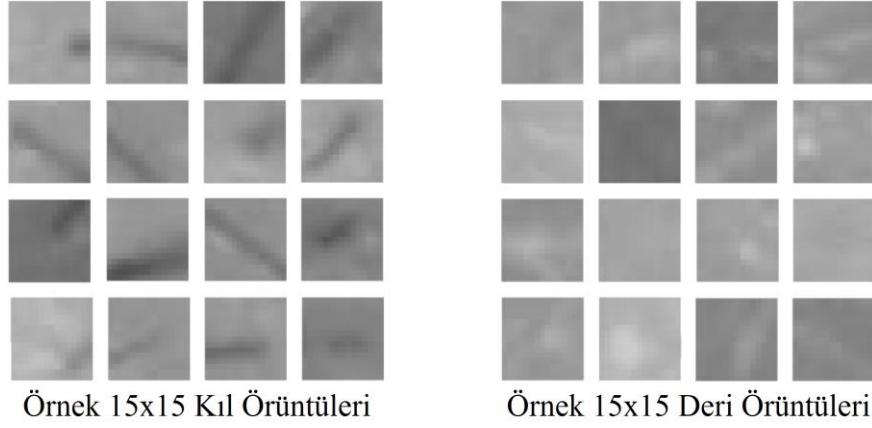
Bu tezde kullanılmış olan cilt görüntülerindeki kıl bölgeleri ve deri (kıl olmayan) bölgelerinin etiketlenmesi işlemi gözle yapılmaktadır. Bu yöntemle oluşturulan doğruluk tablosu, bu çalışmada yapılmakta olan sınıflandırıcı eğitim ve test işlemlerinde kullanılmaktadır.

4.4. Öznitelik Vektörü Oluşturma

Görüntüdeki kıl ve deri bölgeleri arasında yüksek ayırt etme özelliğine sahip olan öznitelikler kullanılarak iki farklı öznitelik vektörü oluşturulmakta ve sınıflandırma işlemi bu öznitelik vektörleri yardımıyla yapılmaktadır. Görüntü kare ve birbiriyle kesişmeyen bloklar halinde işlenmekte ve her bir blok için birinci aşama öznitelikler hesaplanmakta, daha sonra yapılan sınıflandırmada kıl olarak tespit edilmiş bölgeler için ikinci aşama öznitelikler hesaplanarak, ikinci bir sınıflandırma işlemi daha gerçekleştirilmektedir. Birinci ve ikinci aşama öznitelikler, işlem karmaşıklıkları dikkate alınarak öznitelik seçme algoritması ile belirlenmektedir. Öznitelik seçme aşamasından önce, belirlenmiş olan bütün öznitelikler tek başlık altında Bölüm 4.4.1’de incelenmektedir. Belirlenen özniteliklerin değişmezlik (invariance) özellikleri Bölüm 4.4.2’de değerlendirilmektedir. Belirlenmiş olan özniteliklerin hızlı ve yavaş başlıkları altında sınıflandırılabilmesi için izlenecek olan yöntem Bölüm 4.4.3’te özetlenmektedir. Bölüm 4.4.4’te ise belirlenen özniteliklerin ikili eşleşmelerinden bazıları için serpilme diyagramları (scatter plot) gösterilmektedir.

4.4.1. Öznitelikler

Kıl ve deri bölgelerinin ayırt edilmesi amacıyla belirlenmiş olan öznitelikler, görüntüler üzerinde herhangi bir ön işleme yapılmaksızın, doğrudan ham görüntünün kullanılması ile hesaplanmaktadır. Rotasyondan, boyuttan ve belirli aralıklar içinde cilt tipi ve renginden, kıl tipi ve renginden, parlaklıktan bağımsız öznitelikler belirlenmiştir. Bu amaçla bazı öznitelikler üzerinde normalleştirme işlemi de yapılmaktadır. İşlem karmaşıklığı düşük olmasına rağmen, cilt ve kıl rengindeki ufak değişimlerden kolaylıkla etkilenen yeğinliklerin ortalaması gibi öznitelikler doğrudan kullanılmamaktadır.

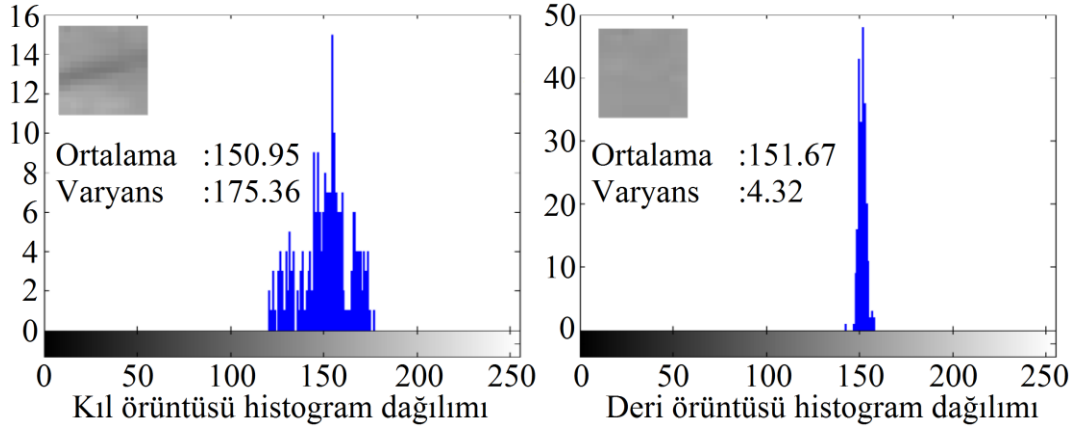


Şekil 4.3. Eğitim setinde bulunan kıl ve deri örüntülerine ait bazı örnekler

Şekil 4.3'te bazı örnekleri gösterilen, kıl ve deri örüntülerine ait eğitim setinin kullanılması ile belirlenen bu öznelikler, aşağıda, ayrı başlıklar altında incelenmektedir. Bu başlıklar altında her bir öznelik için eğitim seti kullanılarak elde edilen histogram dağılım fonksiyonları ve bu histogramlara ait çekirdek yoğunluğu tahminleri de (kernel density estimation) gösterilmektedir. Eğitim setinde eşit sayıda kıl ve deri örüntüsü kullanıldığı için her bir öznelik için verilmekte olan bu çizimler, aynı zamanda kıl ve deri sınıflarının karşılıklı olasılık dağılımları ile örtüşmektedir.

4.4.1.1. Yeğliliklerin Varyansı

Yeğliliklerin varyansı, komşuluk penceresi içindeki piksellerin yeğlilik değerlerinin ortalama etrafında ne derece yayıldıklarını göstermektedir. Şekil 4.4'te gösterilmekte olan örnek kıl ve deri bölgesi histogramlarında olduğu gibi, kıl bölgesinin yeğlilik değerleri, deri bölgesine göre daha geniş bir istatistiksel yayılım göstermektedir.



Şekil 4.4. Örnek kıl ve deri örüntülerine ait histogram dağılımları


Görüntü alma aşamasında, cildin doğru aydınlatılmaması durumunda cilt üzerindeki kırışıklıklar deri bölgelerinin varyans değerini artırabilmektedir. Ayrıca, cilt üzerindeki küçük lekeler de deri bölgelerinin varyansının yükselmesine neden olmaktadır. Ancak, siyah kıl rengine sahip olan Kafkas Akdeniz cilt tipinde, yeğniliklerin varyansı bu durumlarda dahi, kıl ve deri bölgeleri için ayırt edici özellik göstermektedir. Yeğniliklerin varyansı özneliği, toplam piksel sayısı N olan $I(x, y)$ girdi görüntüsü için R bölgesinde aşağıdaki gibi hesaplanmaktadır:

$$\text{öznelik}_1 = \sigma_I^2 = \frac{1}{N} \sum_R (I(x, y) - \mu_I)^2 \quad (4.1)$$

Burada σ_I , I görüntüsünün standart sapması ve σ_I^2 , I görüntüsünün varyansıdır, μ_I ise I görüntüsünün ortalama yeğnilik değeridir ve aşağıdaki gibi hesaplanmaktadır:

$$\mu_I = \frac{1}{N} \sum_R I(x, y) \quad (4.2)$$

Eğitim setinde eşit sayıdaki kıl ve deri örüntüleri için Denklem (4.1) ile hesaplanan yeğniliklerin varyansı özneliğinin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.5'te gösterilmektedir.



Şekil 4.5. “Yeğnliklerin varyansı” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.2. Normalize Edilmiş Karşıtlık Değeri

Karşıtlık değeri (kontrast), görüntü penceresi içindeki en yüksek ve en düşük yeğnlik değerleri arasındaki farka eşittir. Varyans gibi karşıtlık da istatistiksel bir yayılım ölçütüdür. Ancak, karşıtlık değeri, görüntü penceresi içindeki aykırı yeğnlik değerlerine karşı daha hassas bir özneliktir.

Karşıtlığın hesaplanması için kullanılmakta olan en yüksek yeğnlik değeri, testlerde kullanılan kıl ve deri sınıflarındaki örüntülerin tamamında deri piksellerinin yeğnlik değerleri tarafından belirlenmektedir. Bu nedenle en yüksek yeğnlik değeri her iki sınıfa ait örüntüler için yakın değerlere sahiptir. Ancak, en düşük yeğnlik değeri, kıl ve deri sınıflarındaki örüntüler için farklılık göstermektedir. Kıl örüntülerinde en düşük yeğnlik değeri, kıl piksellerindeki koyuluğa bağlı olarak daha düşük çıkarken, deri örüntülerinde ise bu değer daha yüksek çıkmaktadır. Bu nedenle en düşük ve en yüksek yeğnlik değerleri arasındaki fark kıl ve deri sınıfları için ayırt edici özellik taşımaktadır.


Cilt rengindeki ve aydınlatmadaki değişikliklere bağlı olarak en yüksek yeğnlik değeri, farklı cilt tiplerinde artıp azalabilmektedir. Bu değişim, deri sınıfındaki örüntülerin karşıtlık değerinde ciddi bir etki oluşturmamaktadır. Çünkü deri sınıfındaki örüntüler için en düşük yeğnlik değeri, en yüksek yeğnlik değeri gibi cilt rengine bağlı olarak artıp azalmaktadır. Ancak kıl sınıfındaki örüntülerde, en düşük yeğnlik değerinin cilt rengine bağlı olmaması nedeniyle karşıtlık değeri bu sınıftaki

örüntüler için cilt rengine ve aydınlatmaya bağlıdır. Karşıtlık değerinin farklı cilt renklerinde ayırt edici özelliğini koruyabilmesi için bu değerinin cilt rengine bağlı olarak normalleştirilmesi önemlidir.

Bu çalışmada kullanılmakta olan kıl ve deri örüntülerinde, örüntü pencerelerindeki ortalama yeğinlik değeri yaklaşık olarak cilt rengindeki değişimleri yansıtılmaktadır. Cilt renginin açılması ile örüntülerin ortalama yeğinlik değeri artarken, cilt renginin koyulaşması ile örüntülerin ortalama yeğinlik değeri azalmaktadır. Aynı zamanda, yukarıda bahsedilen nedenlerden dolayı, özellikle, kıl sınıfındaki örüntülerde, cilt renginin açılması ile karşıtlık değeri artarken, cilt renginin koyulaşması ile karşıtlık değeri azalmaktadır. Bu doğrusal ilişki nedeniyle, bulunan karşıtlık değerinin, doğrudan, ortalama yeğinliğe bölünmesi ile başarılı bir normalleştirme sağlanabilmektedir.

$$\text{öznitelik}_2 = \frac{(\max(I(x, y)) - \min(I(x, y)))}{\mu_I} \quad (4.3)$$

Denklem (4.3)'teki gibi hesaplanan normalize edilmiş karşıtlık değeri, cilt rengindeki değişimlere karşı tam bir bağımsızlık göstermese de kısmi bir bağımsızlık gösterebilmektedir. Eğitim setindeki bütün örüntüler için hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.6'da gösterilmektedir.



Şekil 4.6. “Normalize edilmiş karşıtlık değeri” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

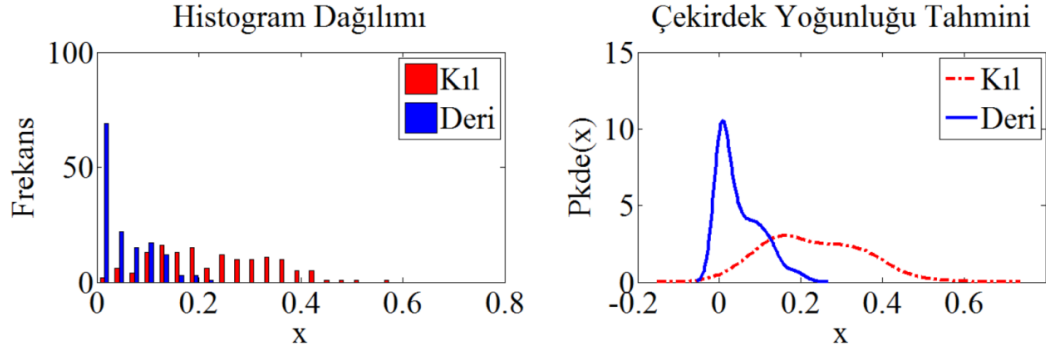
4.4.1.3. Normalize Edilmiş, Ortalamadan Büyük Aykırı Piksellerin Sayısı

Betimsel istatistikte aykırı değer (outlier), veri setinde bulunan diğer değerlerden daha uzakta bulunan uç gözlem noktalarına verilen isimdir. Aykırı değerlerin belirlenmesi için uygulama esaslı olarak farklı kriterler kullanılabilir. Bu çalışmada aykırı değerler, ortalamanın %5'inden büyük veya küçük olan değerler olarak belirlenmiştir.

Ortalamadan büyük aykırı piksellerin sayısı özneliği, görüntü penceresindeki yeğinlik değerleri temel alınarak ve ölçek değişmezliği sağlanacak şekilde normalize edilerek aşağıdaki gibi hesaplanmaktadır:

$$\text{öznitelik}_3 = \frac{\#(I(x, y) > 1.05 * \mu_I)}{N} \quad (4.4)$$

Görüntü penceresi ortalama yeğinlik değerinin %5'inden daha büyük olan piksellerin sayısı, deri örüntülerinde kıl örüntülerine nazaran daha düşük çıkmaktadır. Bu durumun nedeni, Şekil 4.4 gösterilen örnek kıl ve deri histogram dağılımlarından da anlaşılacağı gibi, kıl örüntülerindeki piksel yeğinlik değerlerinin, deri örüntülerine göre daha geniş bir yayılım göstermesidir. Ancak, cilt üzerinde açık renkli lekeler bulunması durumunda, deri örüntülerindeki piksel yeğinlik değerleri de histogram üzerinde geniş bir yayılım göstermektedir. Bu durumda, bu özneliğin kıl-deri ayırt etme kapasitesi düşmektedir. Fakat veri setindeki, muhtemel cilt tipi örnekleri ile yapılan testlerde bu durumun ayırt etme başarımını ciddi ölçüde etkilemediği görülmüştür. Eğitim setindeki bütün örüntüler için hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.7'de gösterilmektedir.




Şekil 4.7. “Normalize edilmiş, ortalamadan büyük aykırı piksellerin sayısı” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.4. Normalize Edilmiş, Ortalamadan Küçük Aykırı Piksellerin Sayısı

Bir önceki bölümde anlatılmakta olan aykırı değer belirleme kriterleri, bu özneliğin hesaplanması için de kullanılmaktadır. Ortalamadan küçük aykırı piksellerin sayısı özneliği, görüntü penceresindeki ortalama yeşinlik değerinin %5’inden daha küçük olan piksellerin sayısının, görüntü boyutu ile normalize edilmesi sonucunda aşağıdaki gibi hesaplanmaktadır:

$$\text{öznelik}_4 = \frac{\#(I(x, y) < 0.95 * \mu_I)}{N} \quad (4.5)$$

Bu öznelik de, bir önceki bölümde anlatılmakta olan ortalamanın üstündeki aykırı piksellerin sayısı özneliği ile benzer sebeplerden dolayı kıl ve deri örüntüleri için ayırt edici özellik taşımaktadır. Ancak, kullanılan örüntülerdeki kıl bölgelerine ait pikseller, bu özneliğin sonuçlarını daha belirgin şekilde etkilemektedir. Ayrıca, cilt üzerindeki açık renkli lekeler bu özneliğin sonuçlarını daha az etkilemektedir. Eğitim setindeki bütün örüntüler için hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.8’de gösterilmektedir.

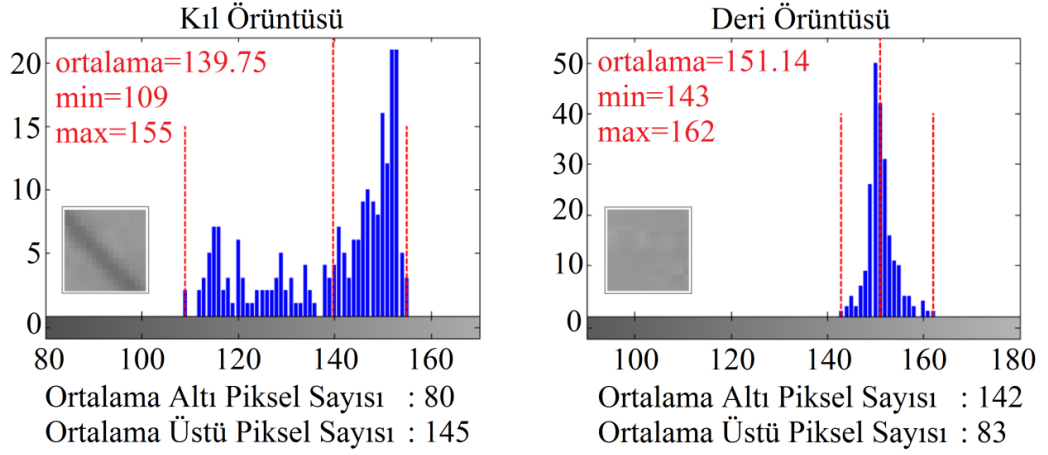


Şekil 4.8. “Normalize edilmiş, ortalamadan küçük aykırı piksellerin sayısı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

Bu çalışmada aykırı piksellerin sayısı ortalamanın altında ve ortalamanın üstünde olmak üzere iki başlık altında incelenmektedir. Bunun nedeni, ortalamanın altındaki ve ortalamanın üstündeki aykırı piksel sayılarının kıl ve deri ayırt ediciliğinin farklı özellikler taşıması ve her iki değerın toplanarak bir arada kullanılması durumunda ayırt ediciliğın düştüğünün görülmesidir.

4.4.1.5. Normalize Edilmiş, Ortalama Altı Piksel Sayısının Ortalama Üstü Piksel Sayısına Oranı


Ortalama altı piksel sayısının, ortalama üstü piksel sayısına oranı, görüntü penceresindeki piksel yeğınlik verisinin, histogramın sağına doğru ne kadar asimetric olduğunu belirlemektedir. Bu özniteliğın kıl ve deri sınıfları için ayırt edici olduğu ve elde edilen sonuçların sınıflar içinde tutarlılık gösterdiği gözlenmiştir. Kafkas Akdeniz cilt tipine ait bir kıl örüntüsünde, koyu renkli olan ve görüntü penceresi içinde aykırılık gösteren kıl bölgelerine ait pikseller, ortalama yeğınlik değerini düşürmekte ve ortalamanın üstünde kalan piksel sayısının artmasına neden olmaktadır. Bu değışim görsel olarak Şekil 4.9’da örnek kıl ve deri örüntülerine ait histogram dağılımları üzerinde gösterilmektedir.




Şekil 4.9. Örnek kıl ve deri örüntüleri için ortalama altı ve ortalama üstü piksel sayıları

$$\text{öznitelik}_5 = \frac{\#(I(x, y) < \mu_I)}{\#(I(x, y) > \mu_I) \times \sigma_I^2} \quad (4.6)$$

Ortalama yeğniliğin üstündeki piksellerin sayısının ortalama yeğniliğin altındaki piksellerin sayısına oranı, cilt üzerindeki kırıksıklık gibi lekelerden kolay etkilenmektedir. Bu özniteliğin Denklem (4.6)'da gösterildiği gibi varyans ile normalize edilerek kullanılması, cilt lekelerinin sonuçlar üzerindeki etkisi azaltılabilmektedir. Varyans ile normalize edilmemiş sonuçlara ait histogram dağılımı Şekil 4.10'da gösterilirken, normalizasyon işlemi hesaplanan bu özniteliğin histogram dağılımı Şekil 4.11'de gösterilmektedir. Her iki dağılım arasındaki değişimden anlaşılacağı gibi normalizasyon işlemi sonucunda kıl ve deri sınıflarına ait veriler daha rahat ayırt edilebilir hale gelmektedir.



Şekil 4.10. “Ortalama altı piksel sayısının ortalama üstü piksel sayısına oranı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini




Şekil 4.11. “Normalize edilmiş, ortalama altı piksel sayısının ortalama üstü piksel sayısına oranı” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.6. Ortalama Yeğnlik ve Minimum Yeğnlik Farkı

Kıl bölgelerine ait piksellerin yeğnlik değerinin düşük olması nedeniyle, örüntü penceresindeki minimum yeğnlik değeri kıl ve deri örüntüleri için ayırt edici özellik taşımaktadır. Ancak minimum yeğnlik değeri, aydınlatma yöntemi ve cilt rengindeki değişimlerden kolay etkilenmektedir. Bu nedenle, cilt renginden ve aydınlatmadan daha az etkilenmekte olan ortalama yeğnlik ve minimum yeğnlik farkı daha etkili bir özneliktir.

$$\text{öznelik}_6 = \mu_I - \min(I(x, y)) \quad (4.7)$$

Eğitim setindeki bütün örüntüler için Denklem (4.7) kullanılarak hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.12’de gösterilmektedir.



Şekil 4.12. “Ortalama yeğnlik ve minimum yeğnlik farkı” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.7. Görüntü Modu ve Mod Frekansı Çarpımı

Bir görüntünün modu, görüntüde en sık tekrar eden yeğnlik değeridir ve bu yeğnlik değerinin görüntüdeki tekrar sayısı mod frekansı olarak isimlendirilmektedir. Görüntü modu ve mod frekansı, görüntü histogramı üzerinde görsel olarak daha rahat değerlendirilebilir. Görüntü histogramının tepe noktası mod frekansını belirlerken, tepe noktasının ait olduğu yeğnlik değeri ise görüntü modunu belirlemektedir.

Şekil 4.4 ve Şekil 4.9’da verilmiş olan histogram görüntülerinden de anlaşılacağı gibi hem kıl hem de deri örüntülerine ait histogramların tepe noktaları genel olarak deri pikselleri tarafından belirlenmektedir. Kıl örüntüleri içerisindeki deri piksellerinin sayısının azalmasıyla orantılı olarak histogramın tepe noktasındaki değeri düşmektedir. Bu nedenle kıl ve deri örüntülerine ait histogramların tepe noktası ayırt edici bir özellik taşımaktadır. Ancak, kıl piksellerinin kendi içindeki varyansının düşük olduğu bazı durumlarda, histogramın tepe noktası kıl pikselleri tarafından belirlenmekte ve yanıltıcı bir durum ortaya çıkmaktadır. Bu nedenle histogramın tepe noktası değerinin, o tepe noktasının ait olduğu yeğnlik değeri ile beraber değerlendirilmesi daha uygundur. Bu amaçla, görüntü histogramının tepe noktası değeri, o noktanın ait olduğu yeğnlik değeri ile çarpılabilir. Başka bir deyişle görüntünün modu ile mod frekansını çarpılabilir ve bu sayede kıl ve deri sınıfları için ayırt edici bir öznelik elde edilebilir. Ancak bu durumda elde edilen sonuçlar, Bölüm 4.4.1.2’de anlatılan karşıtlık değeri özneliğinde olduğu gibi cilt rengindeki değişimlerden kolay etkilenmektedir. Bu özneliğin cilt rengindeki değişimlerden

daha az etkilenmesi için ortalama yeğnliğe bölerek renk normalizasyonu yapılmaktadır. Ölçek normalizasyonunun da yapılması ile bu öznitelik aşağıdaki gibi hesaplanmaktadır:


$$\text{öznitelik}_7 = \frac{\max(\text{hist}_I(k)) \times \arg \max_k \text{hist}_I(k)}{N \times \mu_I} \quad (4.8)$$

Burada verilen $\text{hist}_I(k)$ fonksiyonu, görüntünün histogram dağılım fonksiyonunu temsil etmektedir ve L farklı yeğnlik değeri alabilen bir görüntü için aşağıdaki gibi hesaplanmaktadır:

$$\text{hist}_I(k) = n_k, \quad k \in [0, 1, \dots, L - 1] \quad (4.9)$$

Burada n_k , k yeğnlik değerine sahip olan piksellerin sayısıdır.

Eğitim setindeki bütün örüntüler için hesaplanan bu özniteliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.13’de gösterilmektedir.



Şekil 4.13. “Görüntü modu ve mod frekansı çarpımı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini













4.4.1.8. Bastırılmış Bölgesel Minimum Değişimi

Bu öznitelik, h-minima dönüşümü olarak da bilinen, derinliği belirli bir eşik seviyesinin altında olan bölgesel minimumların bastırılması işlemi ile elde edilen örüntü ile orijinal örüntü arasındaki toplam farkı belirtmektedir. Bölgesel minimumların bastırılması işlemi gri seviye morfolojik geri çatma (morphological reconstruction) kullanılarak yapılmaktadır. Bu işlem için Vincent tarafından, çalışma

[53]'de açıklanan hızlı melez gri seviyeli geriçatma (fast hybrid grayscale reconstruction) algoritması kullanılmaktadır. Bu özneliğin çıkarılması için kullanılan denklem aşağıdaki gibidir:

$$\text{öznitelik}_8 = \frac{1}{N} \sum_R (\text{hmin}(I, th) - I(x, y)) \quad (4.10)$$


Burada $\text{hmin}(I, th)$ fonksiyonu, th eşik değerini kullanarak I girdi görüntüsünün h-minima dönüşümünü bulmaktadır. h-minima dönüşüm işleminde, uyarlanır (adaptive) eşik seviyesinin ortaya çıkarabileceği bilinmezlikleri engellemek ve aşırı bastırmanın önüne geçmek için, th eşik seviyesi sabit ve düşük bir değer olarak belirlenmiştir. Kullanılan eğitim verisi ile yapılan denemelerde $th = 30$ eşik seviyesinin uygun olduğu görülmüştür. Örnek kıl ve deri görüntüleri için, eşik değerinin 30 olarak alındığı durumda, bu özneliğe ait bazı hesaplamalar Şekil 4.14'de gösterilmektedir.

h-minima Dönüşümü $\text{hmin}(I, th)$	Girdi Görüntüsü $I(x, y)$	h-minima Dönüşümü $\text{hmin}(I, th)$	Girdi Görüntüsü $I(x, y)$
$\frac{1}{N} \sum_R$ ( - ) = 0,91		$\frac{1}{N} \sum_R$ ( - ) = 20,38	
$\frac{1}{N} \sum_R$ ( - ) = 1,09		$\frac{1}{N} \sum_R$ ( - ) = 18,26	
$\frac{1}{N} \sum_R$ ( - ) = 0,74		$\frac{1}{N} \sum_R$ ( - ) = 20,35	

Şekil 4.14. Örnek kıl ve deri görüntüleri için “bastırılmış bölgesel minimum değişimi” özneliği hesaplamaları

Şekil 4.14'de görüldüğü gibi kıl görüntüleri için bastırma işlemi sadece kıl bölgesinde yoğunlaşmışken, deri görüntülerinde ise görüntünün tamamında bastırma işlemi yapılmaktadır. Bu nedenle girdi görüntüsü ile bastırılmış görüntü arasındaki fark, deri görüntülerinde kıl görüntülerine göre daha yüksek çıkmaktadır ve bu öznelik kıl ve deri görüntüleri için ayırt edici özellik taşımaktadır.

Eğitim setindeki bütün görüntüler için Denklem (4.10) kullanılarak hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.15'te gösterilmektedir.



Şekil 4.15. Eğitim setindeki örüntüler için “Bastırılmış Bölgesel Minimum Değişimi” özneliğinin histogram görüntüsü ve çekirdek yoğunluğu tahmini

4.4.1.9. Entropi

Bir görüntünün entropisi veya taşıdığı ortalama bilgi seviyesi, görüntünün dokusunu karakterize etmekte sıkça kullanılan istatistiksel bir rastgelelik veya düzensizlik ölçüsüdür. Bu çalışmada görüntünün ortalama bilgi seviyesinin bulunması için, görüntüdeki yeğlilik değerlerinin rastlanma sıklığını temsil eden, histogram bilgisi kullanılmıştır. Görüntünün entropisi aşağıdaki gibi hesaplanmaktadır [54]:

$$\text{öznelik}_9 = - \sum_{k=0}^{L-1} p_k \log_2 (p_k) \quad (4.11)$$

Burada, L , görüntüdeki toplam gri seviye sayısını temsil etmektedir ve bu çalışma için 256'dır, p_k ise k gri seviyesi ile ilişkili olasılık değeridir ve histogram bilgisi kullanılarak aşağıdaki gibi hesaplanmaktadır:


$$p_k = \frac{\text{hist}_I(k)}{\sum_{i=0}^{L-1} \text{hist}_I(i)} \quad (4.12)$$

Burada, $\text{hist}_I(k)$, I görüntüsünün histogram fonksiyonunu temsil etmektedir ve Denklem (4.9)'da gösterildiği gibi hesaplanmaktadır.

Görüntü histogramında, yeğlilik frekans değerleri beklenmedik şekilde değişiyorsa, görüntüdeki rastgelelik yüksektir ve bu görüntünün entropisi yüksek çıkmaktadır. Benzer şekilde, görüntü histogramındaki yeğlilik frekans değerleri çok sık değişmiyorsa görüntüdeki rastgelelik düşüktür ve bu görüntünün entropisi de düşük

çıkmaktadır. Şekil 4.4'te gösterilmekte olan kıl ve deri örüntüsü histogram dağılımlarında da anlaşılacağı gibi, rastgeleliğin yüksek olduğu kıl örüntülerinin entropisi yüksek çıkarken, daha düzgün bir dokuya sahip olan deri örüntülerinin entropisi düşük çıkmaktadır.

Eğitim setindeki bütün örüntüler için Denklem (4.11) kullanılarak hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.16 gösterilmektedir.



Şekil 4.16. “Entropi” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.10. Normalize Edilmiş Üçüncü Merkezsel Moment

Ortalama etrafındaki k'inci moment olarak da adlandırılan, k'inci merkezsel moment, reel değerli X rassal değişkeni için, E beklenen değer operatörü olmak koşulu ile aşağıdaki gibi hesaplanmaktadır:

$$moment_k = E[(X - \mu_X)^k] \quad (4.13)$$

İki boyutlu dijital bir görüntü için ise k'inci merkezsel moment aşağıdaki hale gelmektedir:

$$moment_k = \frac{1}{N} \sum_R (I(x, y) - \mu_I)^k \quad (4.14)$$


Dijital bir görüntünün üçüncü merkezsel momenti, genellikle standart sapmanın üçüncü kuvvetine bölünerek kullanılmaktadır. Elde edilen bu değer betimsel istatistikte Fisher çarpıklık ölçütü (skewness) olarak bilinmektedir:

$$\gamma_I = \frac{moment_3}{\sigma_I^3} \quad (4.15)$$

Denklem (4.15)'te formülü verilen çarpıklık değeri, görüntü histogramının merkez yeğinlik değeri etrafında, hangi yöne doğru ve ne kadar asimetric olduğunun belirlenmesi için kullanılmaktadır. Çarpıklık değeri görüntünün tanımlanması için sıkça kullanılan bir özniteliktir. Ancak bu çalışmada kullanılan veri seti için üçüncü merkezel momentin, varyans (σ_I^2) ile normalleştirilmesi durumunda elde edilen değer, Fisher çarpıklık değerine göre daha başarılı sonuçlar verdiği görülmüştür. Bu nedenle normalize edilmiş üçüncü merkezel moment özniteliği, Fisher çarpıklık değerinden farklı olarak aşağıdaki gibi hesaplanmaktadır:

$$\text{öznitelik}_{10} = \frac{moment_3}{\sigma_I^2} \quad (4.16)$$

Eğitim setindeki bütün örüntüler için hesaplanan bu özniteliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.17'de gösterilmektedir.



Şekil 4.17. “Normalize edilmiş üçüncü merkezel moment” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.11.Çeyrekler Açıklığı

Bu öznitelik, betimsel istatistikte kullanılmakta olan karşıtlık ve varyans gibi diğer yayılma ölçütlerine göre, veri setindeki aykırı değerlerden daha az etkilenmektedir. Çeyrekler açıklığı, görüntüdeki sıralanmış yeğinlik değerlerinin ilk çeyreğinde ve

üçüncü çeyreğinde bulunan yeğlilik değerleri arasındaki farka eşittir ve aşağıdaki gibi hesaplanmaktadır:


$$\text{öznitelik}_{11} = Q_3 - Q_1 \quad (4.17)$$

Denklem (4.17)'de verilmiş olan Q_1 ve Q_3 değerleri, görüntüdeki yeğlilik değerlerinin sıralanmış olarak bulunduğu bir dizide aşağıdaki gibi bulunabilir:

$$Q_1 = \left(\frac{N+1}{4}\right)' \text{ üncü terim}, \quad (4.18a)$$

$$Q_3 = \left(\frac{3(N+1)}{4}\right)' \text{ üncü terim}. \quad (4.18b)$$

Bu öznitelik, yeğliliklerin varyansı özniteliğine nazaran cilt üzerindeki kırışıklıklardan daha az etkilenmektedir. Eğitim setindeki bütün örüntüler için hesaplanan bu özniteliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.18'de gösterilmektedir.



Şekil 4.18. “Çeyrekler açıklığı” özniteliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini

4.4.1.12. Yerel Minimum Filtreleme Değişimi

Yerel minimum filtreleme, görüntüdeki her piksele 3×3 'lük komşuluk penceresi içindeki en küçük yeğlilik değerini atayan, doğrusal olmayan bir filtreleme işlemidir. Bu işlem sonucunda oluşan $I_{yerelMin}(x, y)$ görüntüsündeki her piksel aşağıdaki gibi hesaplanmaktadır:

$\forall x, y \in R$ için,

$$I_{yerelMin}(x, y) = \min \{I(x-1, y-1), I(x, y-1), I(x+1, y-1), \\ I(x-1, y), I(x, y), I(x+1, y), \\ I(x-1, y+1), I(x, y+1), I(x+1, y+1)\} \quad (4.19)$$

Denklem (4.19)'da gösterilen yerel minimum filtreleme işlemi öncesinde, sınır pikselleri tekrarlanarak görüntü genişletilmiştir. İşlem sonrasında kenar pikselleri tekrar atılmıştır.

Yerel minimum filtreleme işlemi sonucunda yeğnlik değeri düşük olan kıl pikselleri genişletilirken, yeğnlik değeri daha yüksek olan cilt kırıxıklıkları gibi görüntüde parlayan bölgeler küçültülmektedir. Cilt kırıxıklıkları, kıllara nazaran daha küçüktür ve deri bölgeleri ile arasındaki yeğnlik farkı daha azdır. Bu nedenle, yerel minimum filtreleme işlemi sonucunda kıl örüntülerinde, kıl bölgelerinin büyüklüğüne bağılı olarak, görüntünün toplam yeğnliğı ciddi ölçüde azalırken, deri örüntülerinde ise kırıxıklık ve küçük cilt lekeleri tarafından belirlenen bu azalma daha düşük seviyelerde olacaktır. Bu nedenle Denklem (4.20)'de formülü verilen bu öznelik kıl ve deri örüntüleri için ayırt edici özellik taşımaktadır.

$$\text{öznelik}_{12} = \frac{1}{N} \sum_R (I(x, y) - I_{yerelMin}(x, y)) \quad (4.20)$$


Bu özneliğın ayırt ediciliğı ve yerel minimum filtreleme işlemi sonucunda kıl ve deri örüntülerinde oluşan değışim, Şekil 4.19'da bazı örnekler için gösterilmektedir.

	Girdi Görüntüsü $I(x, y)$	Yerel Minimum Filtreme Sonucu $I_{yerelMin}(x, y)$		Girdi Görüntüsü $I(x, y)$	Yerel Minimum Filtreme Sonucu $I_{yerelMin}(x, y)$
$\frac{1}{N} \sum_R ($			$-$		
$) = 3,46$				$) = 2,68$	
$\frac{1}{N} \sum_R ($			$-$		
$) = 3,49$				$) = 3,04$	
$\frac{1}{N} \sum_R ($			$-$		
$) = 3,63$				$) = 2,19$	

Şekil 4.19. Örnek kıl ve deri örüntüleri için “yerel minimum filtreleme değişimi” özneliği hesaplamaları

Yerel minimum filtreleme değişimi özneliğinin en önemli dezavantajı örüntü penceresinin boyutundaki değişimlerden kolay etkilenmesidir. Örüntü penceresinin boyutu arttıkça kıl piksellerinin etkisi azalmakta ve elde edilen fark değeri daha çok derideki parlak bölgelerin bastırılması sonucu belirlenmektedir. Buna rağmen, her cilt tipi için kendi içinde tutarlı sonuçlar alınabilmekte, fakat farklı cilt tiplerinde bu özneliğin ayırt etme gücü, pencere boyutu arttıkça, düşmektedir.

Eğitim setindeki bütün örüntüler için hesaplanan bu özneliğin histogram dağılımı ve bu histograma ait çekirdek yoğunluğu tahmini Şekil 4.20’de gösterilmektedir.



Şekil 4.20. “Yerel minimum filtreleme değişimi” özneliğinin histogram dağılımı ve çekirdek yoğunluğu tahmini


4.4.2. Özniteliklerin Değişmezlik Özellikleri

Belirlenen özniteliklerin değişmezlik özelliklerinden bazıları, bu özniteliklerin tanıtıldığı başlıklar altında, Bölüm 4.4.1’de incelenmektedir. Bu özniteliklerin ölçek, dönme, parlaklık, cilt rengi ve kıl rengi varyasyonlarına karşı gösterdikleri değişmezlik özellikleri Çizelge 4.1’de gösterilmektedir

Çizelge 4.1. Belirlenen özniteliklerin değişmezlik özellikleri

#	Öznitelik İsmi	Ölçek	Dönme	Parlaklık	Cilt Rengi	Kıl Rengi
1	Yeşinliklerin Varyansı	✓	✓	✓	✗	✗
2	Normalize Edilmiş Karşıtlık Değeri	✓	✓	Kısmen	Kısmen	Kısmen
3	Normalize Edilmiş, Ortalamadan Büyük Aykırı Piksel Sayısı	✓	✓	✓	Kısmen	Kısmen
4	Normalize Edilmiş, Ortalamadan Küçük Aykırı Piksel Sayısı	✓	✓	✓	Kısmen	Kısmen
5	Normalize Edilmiş, Ortalama Altı Piksel Sayısının Ortalama Üstü Piksel Sayısına Oranı	✓	✓	✓	✗	✗
6	Ortalama Yeşinlik ve Minimum Yeşinlik Farkı	✓	✓	✓	Kısmen	Kısmen
7	Görüntü Modu ve Mod Frekansı Çarpımı	✓	✓	Kısmen	Kısmen	Kısmen
8	Bastırılmış Bölgesel Minimum Değişimi	Kısmen	✓	Kısmen	Kısmen	Kısmen
9	Entropi	✓	✓	Kısmen	Kısmen	Kısmen
10	Normalize Edilmiş Üçüncü Merkezsel Moment	Kısmen	✓	Kısmen	✗	✗
11	Çeyrekler Açıklığı	✓	✓	Kısmen	Kısmen	Kısmen
12	Yerel Minimum Filtreleme Değişimi	Kısmen	✓	Kısmen	Kısmen	Kısmen

Kullanılan özniteliklerin ölçekten bağımsızlığı, bu özniteliklerin örüntü penceresi boyutundaki değişimlerden ve kameranın cilde olan uzaklığındaki değişimlerden ne kadar az etkilendiğini temsil etmektedir. Çizelge 4.1’de görüldüğü gibi belirlenen öznitelikler, ölçek varyasyonlarına karşı kısmen veya tam bir değişmezlik gösterebilmektedir. Ancak, bu çalışmada ölçek değişmezliği belirli sınırlar içerisinde değerlendirilmektedir. Ölçek değişmezliğinin sağlanabilmesi için, kullanılan kıl örüntülerinde örüntü penceresinin bir kısmı cilt bölgesine ait pikselleri de içermeli ve örüntü penceresi, farklı bölgelerde bulunan kılları bir arada içermemelidir. Bu tanıma uygun olan ve olmayan bazı kıl örüntüleri Şekil 4.21’de gösterilmektedir.



Şekil 4.21. Ölçek değişmezliğinin sağlandığı ve sağlanamadığı farklı komşuluk penceresi boyutları

Kılların kamera görüntüsü üzerindeki yönelimlerinin değişmesi veya örüntü penceresinin yöneliminin değişmesi, belirlenen özniteliklerin ayırt edici özelliğini bozmamaktadır. Bu nedenle, Çizelge 4.1’de verilen özniteliklerin tamamı dönmeden bağımsızdır.

Belirlenen öznitelikler, kamera piksellerinin doyuma ulaşmamış olmaması şartı ile parlaklık değişimlerine karşı kısmen veya tam bir değişmezlik gösterebilmektedir. Farklı dalga boylarında ışık kaynakları ile cildin aydınlatılması durumunda, bu dalga boylarının cilt tarafından emilim ve yansıtılma özellikleri değişebilmektedir. Bu nedenle, farklı aydınlatma kaynakları için parlaklık değişiminin etkisi ayrıca incelenmemiştir. Bu çalışmada alınan sonuçlar gün ışığı LED ve halojen lamba ile aydınlatma sağlanması durumunda doğrulanmaktadır.

Belirlenen özniteliklerin tamamı, kıl ve cilt rengindeki varyasyonlardan etkilenmektedirler. Ancak, bu çalışmada kıl ve cilt rengindeki değişimlerin Kafkas Akdeniz cilt tipi ile sınırlandırılması nedeniyle belirlenen özniteliklerin kıl ve cilt rengindeki değişimlere karşı gösterdiği değişmezlik kısmen tanımı ile incelenmektedir. Yeğİnliklerin varyansı, varyans ile normalize edilmiş olan ortalama altı piksel sayısının ortalama üstü piksel sayısına oranı ve varyans ile normalize edilmiş üçüncü merkezsel moment öznitelikleri, pratikte Kafkas Akdeniz cilt tipine ait kıl ve deri rengi değişimlerinden ciddi ölçüde etkilenmezken, teoride cilt ve kıl rengindeki varyasyonlara karşı değişimsiz değildir. Bu durumun nedeni, yeğİnliklerin varyansı özniteliğİ örüntü penceresindeki renk dağılımına doğrudan bağımlı olduğı halde, belirlenen cilt tipi için kıl ve deri renginde değişimler bu özniteliğİn ayırt edici özelliğİni ciddi ölçüde değıştirmesidir.

4.4.3. Hızlı ve Yavaş Özniteliklerin Belirlenmesi

Bu çalışmada, belirlenmiş olan öznitelikler hızlı ve yavaş başlıkları altında iki ayrı kategoriye ayrılarak incelenmektedir. Özniteliklerin hızlı ve yavaş olarak tanımlanmasına bağılı olarak, iki basamaklı sınıflandırma modelinin birinci ve ikinci basamak sınıflandırma işlemlerinde kullanılmak üzere içerisinden seçim yapılacak olan öznitelik kümeleri belirlenmektedir. Birinci ve ikinci basamak sınıflandırma işlemlerinde kullanılacak olan öznitelikler, Bölüm 4.5'te anlatılan öznitelik seçme tekniğİ kullanılarak belirlenmektedir. Birinci basamak öznitelikler yalnızca hızlı öznitelikler kümesi içerisinden seçilirken, ikinci basamak öznitelikler ise hızlı ve yavaş özniteliklerin bulunduğı küme içerisinden seçilmektedir.

Hızlı ve yavaş özniteliklerin belirlenmesi işlemleri görsel olarak, öznitelik hızlarının karşılaştırılması ve hızlı-yavaş öznitelik ayrımı için en uygun eşik seviyesinin belirlenmesi ile yapılmaktadır.


Bu çalışmada kullanılan bütün özniteliklerin hesaplanması için, Matlab kütüphanelerinde bulunan ve optimizasyonu yapılmış vektör tabanlı yerleşik (built-in) fonksiyonlar kullanılmaktadır. Bu fonksiyonları kullanan öznitelik hesaplama

yöntemlerinin işlem hızlarının belirlenmesi için, belirli boyutlardaki bir örüntüden ilgili özneliğin çıkarılması için geçen zaman hesaplanmaktadır.

Hızlı ve yavaş özneliklerin sınıflandırması işleminde yapılan çalışmalar detaylı olarak Bölüm 5.2’de anlatılmaktadır. Bölüm 5.2’de anlatılmakta olan yöntemlerin kullanılması neticesinde Çizelge 4.1’de gösterilmekte olan özneliklerden 1, 2, 3, 4, 5 ve 6 numaralı öznelikler hızlı öznelikler olarak belirlenmişken, 7, 8, 9, 10, 11 ve 12 numaralı öznelikler ise yavaş öznelikler olarak belirlenmiştir.

4.4.4. Özneliklerin Serpilme Diyagramları

Belirlenen öznelikler arasından seçilmiş olan bazı ikililer için serpilme diyagramları Şekil 4.22’de gösterilmektedir. Şekillerde öznelik isimleri yerine Çizelge 4.1’de verilen öznelik numaraları kullanılmaktadır. Şekil 4.22’de gösterilmekte olan ikili serpilme diyagramları incelendiğinde, tek başına ayırt etme gücü düşük olan bazı özneliklerin diğer özneliklerle birlikte kullanılması durumunda, kıl ve deri verilerinin daha rahat ayrıştırılabilir bir hal aldığı gözlenmektedir. Şekil 4.22’de verilmiş olan öznelik ikilileri gelişigüzel belirlenmiştir. Elde edilen serpilme diyagramlarında tek başına kıl ve deri ayrıştırma gücü oldukça yüksek olan 4, 8 ve 10 numaralı özneliklerin diğer özneliklerle birlikte kullanılması durumunda ayrıştırılması daha kolay olan kıl ve deri öbeklerinin oluştuğu gözlenmektedir.



Şekil 4.22. Bazı ikili özniteliklere ait serpilme diyagramları

4.5. Öznitelik Seçimi

Öznitelik seçme işleminde, belirlenen öznitelikler arasından, veriyi en başarılı şekilde temsil eden alt öznitelik kümesi veya kümeleri bulunmaya çalışılmaktadır. Öznitelik seçme algoritmalarının kullandığı temel varsayım, veri setinde gereksiz veya ayırıcı özelliği olmayan özniteliklerin de var olduğudur. Gereksiz öznitelikler, önceden kullanılmakta olan özniteliklerin içerdiği bilgiden daha fazlasına sahip olmayan ve sınıflandırma performansını daha fazla geliştiremeyen özniteliklerdir. Gereksiz özniteliklerin elimine edildiği öznitelik seçme işlemi sayesinde sınıflandırma modeli ve kullanılan veri daha rahat yorumlanabilmekte, daha hızlı ve düşük maliyetli modeller oluşturulabilmekte ve aşırı eğitim (overfitting) probleminin de önüne geçilebilmektedir.

Özellikle, öznitelik sayısının çok fazla olduğu ve eğitim verisi elde etmenin zor olduğu durumlarda, çok boyutluluğun laneti (curse of dimensionality) [55] olarak da adlandırılan problemin önüne geçilebilmesi için, öznitelik seçimi ve benzeri yöntemler ile öznitelik boyutunun azaltılması bir zorunluluk haline almaktadır. Bu çalışmada eğitim verisinin elde edilmesi veya öznitelik boyutunun çok yüksek olması ile ilgili ciddi bir sıkıntı bulunmamaktadır. Ancak sınıflandırma performansının artırılabilmesi, işlem masraflarının azaltılması ve sonuçların daha doğru yorumlanabilmesi için öznitelik seçimi yapılmaktadır.

Sınıflandırma işleminde kullanılan öznitelikler ayrı ayrı düşük performans gösterirken, bir arada yüksek performans gösterebilirler. Benzer şekilde tek başına yüksek performans gösteren bir öznitelik, diğer özniteliklerle beraber kullanıldığı zaman, sınıflandırma performansında bir artış olmayabilir. Bu nedenle sınıflandırma performansının, farklı öznitelik kombinasyonları kullanılarak değerlendirilmesi oldukça önemlidir.

Bir öznitelik kümesinde detaylı öznitelik seçimi yapılması durumunda, bu kümenin, boş küme hariç, tüm alt kümeleri için performans analizinin yapılması, en başarılı öznitelik kümesi veya kümeleri bulunmalıdır. Dolayısı ile n elemanlı bir öznitelik kümesinde, $(2^n - 1)$ miktarında alt küme için performans analizinin yapılması

gerekmektedir. Ancak, öznitelik sayısının artması ile alt küme sayısı ciddi oranda artmaktadır ve her bir alt küme için performans analizinin yapılması mümkün olmamaktadır. Bu nedenle, bütün öznitelik kombinasyonlarını analiz eden yorucu öznitelik seçme yöntemi yerine, belirli kriterlere uygun olan öznitelik kombinasyonlarını analiz ederek yüksek boyutlu veri uzayında daha hızlı öznitelik seçme imkânı sunan birçok algoritma geliştirilmiştir [56]. Fakat bu çalışmada belirlenmiş olan öznitelik sayısının düşük olması nedeniyle daha ayrıntılı analiz imkânı sağlayan, yorucu (exhaustive) öznitelik seçme metodu kullanılarak muhtemel tüm kümeler için performans analizi yapılmaktadır.

Bu çalışmada, Bölüm 4.4.3'te belirtildiği gibi, tüm öznitelikler hızlı ve yavaş başlıkları altında incelenmektedir. Birinci aşama öznitelikler hızlı öznitelikler kümesinden seçilirken, ikinci aşama öznitelikler ise tüm öznitelikler arasından seçilmektedir. Öznitelik seçme işlemi Bölüm 4.6'da anlatılan sınıflandırma teknikleri kullanılarak, Bölüm 4.7.2'de anlatılan k-katlamalı çapraz doğrulama yöntemi (k-fold cross validation) ile yapılmaktadır. Öznitelik seçme işleminin sonuçlarına deneysel sonuçlar bölümünde yer verilmektedir (Bölüm 5).

4.6. Sınıflandırma

Bu tez çalışmasında, öznitelik vektörleri ile temsil edilen dermatolojik örüntülerin, kıl ve deri olarak sınıflandırılması için makine öğrenmesi veya örüntü tanıma başlığı altında incelenen gözetimli öğrenme (supervised learning) metotları kullanılmaktadır. Gözetimli öğrenme algoritmaları, her biri, bir sınıf ile etiketlenmiş öznitelik vektörlerinden oluşan eğitim verilerini kullanarak, gözlemlenen yeni nesnelere (örüntü) ait öznitelik vektörlerini bir sınıf ile eşleştirebilecek olan sınıflandırıcı modelleri üretmektedir. Oluşturulan sınıflandırıcı modellerinin başarımları, etiketlenmiş veri setinin, kendi içinde farklı eğitim ve test setlerine ayrılması ile önceden tahmin edilebilmektedir. Bu amaçla kullanılan yöntemlerden birisi olan k-katlamalı çapraz doğrulama yöntemi Bölüm 4.7.2'de ayrıca incelenmektedir.

Bu çalışmada test edilen gözetimli öğrenme yöntemleri: Doğrusal Ayrıştırma Analizi (DAA), K-En Yakın Komşu Algoritması (K-NN), Karar Ağacı (KA), Naive Bayes

Sınıflandırıcı (NB), Destek Vektör Makineleri (DVM). Bu sınıflandırma yöntemlerinin temel çalışma prensipleri bu bölümde kısaca özetlenmektedir. Bu teknikler ile ilgili daha detaylı tartışmalara, Bishop [55], Alpaydın [57] ve Theodoridis'in [58] kitaplarında yer verilmiştir.


4.6.1. Doğrusal Ayırıştırma Analizi

DAA, eğitim verilerinin doğrusal kombinasyonunu kullanarak, yeni verileri sınıflandırabilecek ayırıcı yüzeyi hesaplayan bir sınıflandırma yöntemidir. Bu algoritma aynı zamanda, 1936'da yayınlanan makale nedeniyle Fisher'ın doğrusal ayırıştırması (Fisher's linear discriminant) olarak da bilinmektedir [59]. DAA, doğrusal ayırıştırmanın mümkün olduğu durumlar için büyük veri setlerinde dahi oldukça hızlı bir şekilde sınıflandırma yapabilmektedir.

İki sınıflı durumda doğrusal ayırıştırıcının en basit temsili, girdi öznitelik vektörünün doğrusal bir fonksiyonunun alınması ile elde edilir. l -boyutlu bir öznitelik uzayında karar hiperyüzeyi, aşağıdaki gibi bir hiperdüzlemdir:


$$g(x) = w^T x + w_0 = \sum_{i=1}^l w_i x_i + w_0 = 0 \quad (4.21)$$

Burada, $x = [x_1, x_2, \dots, x_l]^T$ girdi öznitelik vektörünü temsil etmekte, $w = [w_1, w_2, \dots, w_l]^T$ ağırlık vektörü, w_0 ise eşik değeri olarak isimlendirilmektedir. Denklem (4.21)'de verilen karar yüzey fonksiyonu kullanılarak, x girdi vektörü için, $g(x) > 0$ ise \mathcal{C}_1 sınıfı, aksi halde \mathcal{C}_2 sınıfı seçilmektedir. İki boyutlu uzayda, $g(x)$ karar yüzeyi bir doğru şeklindedir (Şekil 4.23).



Şekil 4.23. İki boyutlu ve iki sınıflı bir örnek için DAA

Fisher'ın doğrusal ayırıştırıcısı, karar yüzeyini hesaplarken sınıf içi varyansı en düşük seviyede tutmaya çalışırken, sınıfların ortalamaları arasındaki mesafeyi en yüksek hale getirmeye çalışmaktadır. Şekil 4.24'de kırmızı ve mavi ile gösterilmiş olan iki sınıflı uzayda, iki farklı ayırıcı hat ve bu hatlara dik olarak sınıfların histogram dağılımları gösterilmektedir [55]. Soldaki çizimde, sınıfların ağırlık merkezlerini birleştiren çizginin orta noktasından geçen ve bu çizgiye dik olan bir ayırıcı yüzey seçilmiştir. Sağdaki çizimde ise ayırıcı yüzey, Fisher'ın doğrusal ayırıştırma yöntemi kullanılarak belirlenmiştir. Soldaki histogram dağılımında sınıflar arasında ciddi bir çakışma varken, sağdaki çizimde ise Fisher'ın yöntemi sayesinde bu çakışma ortadan kaldırılabilmektedir. Bu çalışmada da, Fisher'ın ayırıştırma yöntemi kullanılarak ayırıcı yüzey hesaplanmaktadır.



Şekil 4.24. Standart DAA ayrıştırıcı yüzeyi (solda), Fisher'ın DAA ayrıştırıcı yüzeyi (sağda) [55]

Fisher'ın yöntemini kullanan DAA, sınıfları ortalama ve varyanslarına göre tanımladığı için veri setindeki doğrusal olmayan, geometrik bozulmalara karşı hassastır. Ancak bu çalışmada elde edilen görüntülerin sabit koşullar altında alınmış olması ve DAA'nın oldukça hızlı sınıflandırma yapabilen bir yöntem olması nedeniyle, bu yöntem elde edilen veriler üzerinde test edilmektedir.

4.6.2. K-En Yakın Komşu

K-NN gibi örnek tabanlı (bellek tabanlı) sınıflandırıcılar, bilinmeyen örneklerin sınıflandırılması için bilinen ve bilinmeyen örnekler arasındaki mesafe/benzerlik ilişkilerini kullanırlar. K-NN sınıflandırma yönteminin kullandığı temel yaklaşım, örnek uzayında birbirine yakın olan örneklerin aynı sınıfta olma ihtimalinin, birbirinden çok uzakta bulunan örneklerin aynı sınıfta olma ihtimalinden daha yüksek olmasıdır [60].

Birçok gözetimli öğrenme algoritmasının aksine, K-NN gibi örnek tabanlı sınıflandırıcıların belirli bir eğitim modeli yoktur ve tüm hesaplamalar sınıflandırma aşamasına kadar ertelenmektedir. Bu özellikleri nedeniyle örnek tabanlı sınıflandırıcılar tembel öğrenciler (lazy learners) olarak da adlandırılmaktadır [61].

K-NN algoritması, sınıflandırılacak olan örneğe en yakın olan k tane eğitim verisini belirlemekte ve bulunan k tane komşunun çoğunluğunun sınıfını, yeni gözlemin sınıfı olarak atamaktadır. Her bir komşunun eşit oy hakkına sahip olduğu bu yöntem


çoğunluk oylaması (majority voting) yöntemi olarak da bilinmektedir. Literatür çalışmalarında, çoğunluk oylaması yönteminden farklı olarak her bir komşuya, yeni gözleme olan uzaklıklarına göre ağırlıklı oy hakkı verilerek, yakındaki komşuların öneminin artırılması gibi farklı oylama yöntemleri de kullanılmaktadır [62]. Bu çalışmada K-NN sınıflandırma işlemi çoğunluk oylaması yöntemi kullanılarak yapılmaktadır.

K-NN algoritmasında, k değerinin doğru belirlenmesi, uygun uzaklık ölçüm yönteminin kullanılması, eğitim setindeki verilerin yeterli sayıda ve uygun bir şekilde dağılmış olması gibi kriterler sınıflandırma başarımını doğrudan etkilemektedir. Ayrıca örnek uzayındaki verilerin tamamının aynı ölçek ile normalleştirilmesi de gerekmektedir [63]. Bu çalışmada her bir öznitelige ait veriler, kendi içerisinde $[-1,1]$ aralığında normalleştirilerek, K-NN algoritmasında kullanılmaktadır. Uzaklık ölçüm yöntemi olarak, aşağıda verilmekte olan Öklid mesafesi kullanılmaktadır:

$$D(x, y) = \sqrt{\sum_{i=1}^l (x_i - y_i)^2} \quad (4.22)$$

Burada, l örnek uzayının boyutunu (öznitelik sayısı), $x = (x_1, x_2, \dots, x_l)$ ve $y = (y_1, y_2, \dots, y_l)$ örnek uzayındaki iki noktayı temsil etmektedir.

Şekil 4.25'de, C_1 (kırmızı yıldız) ve C_2 (mavi daire) sınıflarına ait verilerin iki boyutlu uzaydaki dağılımları gösterilmektedir. Öklid uzaklığı ve çoğunluk oylaması yöntemleri kullanılarak, 8-NN algoritması ile sınıflandırma yapılması durumunda, Şekil 4.25'de gösterilen bilinmeyen siyah üçgenin sınıfı en yakın 8 komşusunun çoğunluğunun sınıfı olan C_2 olarak belirlenmektedir.




Şekil 4.25. 8-NN sınıflandırma örneği

En basit sınıflandırma algoritmalarından birisi olan K-NN yöntemi, eğitim kümesinde yeterli sayıda veri bulunması ve doğru parametrelerin kullanılması durumunda, gürültülü verilerde dahi oldukça başarılı sonuçlar verebilmektedir. Ancak, K-NN algoritmasında tüm hesaplamaların sınıflandırma aşamasında yapılması nedeniyle, sınıflandırma hızı istekli öğrenicilere (eager learners) göre daha düşüktür.

4.6.3. Karar Ağaçları

İsmi ağaç benzeri karar verme modelinden alan KA algoritması, girdi uzayındaki verileri art arda bölümlere ayırarak sınıflandırma problemini çözmeye çalışmaktadır. KA yönteminde, sınıflandırma işlemi bir dizi kararın verilmesi ile yapılmaktadır. Şekil 4.26'da KA algoritması ile bölünmüş 2 boyutlu ve 2 sınıflı bir veri uzayı ve ilgili KA modeli gösterilmektedir. Verilen KA modeli üzerinde, en alttaki yapılar yaprak düğümü (leaf node), en üstteki yapı kök düğümü (root node) ve bunların arasındaki düğümler ise karar düğümleri (decision node) olarak adlandırılmaktadır [57]. Bu yapı içerisinde, yapraklar sınıfları, her bir düğüm ise karar testlerini temsil etmektedir. Yeni bir örneğin sınıflandırılması işlemine en tepedeki kök düğümünden başlanmakta ve model üzerinde bir yaprağa ulaşıncaya kadar alt düğümlerdeki karar testlerine devam edilmektedir.



Şekil 4.26. İki boyutlu ve iki sınıflı örnek veri uzayı (solda) ve ilgili karar ağacı modeli (sağda)

Genellikle bir veri kümesinin birden fazla karar ağacı modeli ile temsil edilmesi mümkündür, ancak oluşturulan bazı ağaç modelleri, diğer modellere göre daha başarılı sınıflandırma sonuçları verecektir. Bu nedenle KA modelinin oluşturulması için kullanılan algoritmanın, daha yüksek başarı gösteren ağaç modellerini tespit edebilmesi önemlidir. En bilinen karar ağacı öğrenme algoritmalarından bazıları; ID3 (Iterative Dichotomiser 3) [64], C4.5 (ID3'ün ileri versiyonu) [65], MARS (Multivariate adaptive regression splines) [66], CART (C&RT) () [67], CHAID (CHI-squared Automatic Interaction Detector) [68], Quest (Quick, Unbiased, Efficient, Statistical Tree) [69] algoritmalarıdır.

Bu çalışmada, oldukça popüler ve başarılı KA öğrenme algoritmalarından birisi olan CART algoritması kullanılmaktadır. CART öğrenme algoritması, ağaç yapısındaki dallanmanın tek bir değişkene bağlı ve ikili bölünmeler şeklinde olması prensibi ile çalışmaktadır. Bu algoritma ile bir düğümdeki en başarılı ikili bölünmenin nasıl yapılacağına bulunması için katışıklık ölçümlerinden (impurity measures) faydalanılmaktadır. Bir düğüm altında bulunan elemanlar sadece bir sınıfa ait ise, bu düğümdeki elemanlar homojen bir şekilde dağılmıştır ve düğüm katışıklık değeri 0 olacaktır. Kullanılan, düğüm katışıklık ölçütlerinden bazıları Gini (çeşitlilik) indeksi, entropi ve yanlış sınıflandırma hatasıdır. Bu çalışmada ve birçok CART algoritma

uygulamasında kullanılan düğüm katışıklık ölçütü, aşağıda formülü verilmiş olan Gini indeksidir:

$$GINI(t) = 1 - \sum_j [P(j | t)]^2 \quad (4.23)$$

Burada, $P(j | t)$, KA modeli üzerindeki t düğümünde j sınıfına ait elemanların bulunma olasılığıdır.

Bir KA modelinde p düğümünün k parçaya bölünmesi durumunda, bölünme kalitesi aşağıda verilen kazanç formülü ile hesaplanmaktadır:

$$Kazanç_{Bölünme} = GINI(p) - \sum_{i=1}^k \frac{n_i}{n} GINI(i) \quad (4.24)$$

Burada, p üst düğümü (parent node), i ise p düğümünün altındaki düğümleri (child nodes) temsil etmektedir. n_i , i alt düğümündeki toplam eleman sayısı, n ise p üst düğümündeki toplam eleman sayısıdır.

CART algoritması Denklem (4.24)'de verilen kazanç formülünü maksimum yapan veya Denklem (4.23)'de verilen Gini indeks değerini minimum yapan bölünmeyi, en başarılı bölünme olarak kabul etmekte ve homojen (tek sınıflı) bir düğüm elde edilinceye kadar alt düğümlerde de aynı algoritmayı kullanarak ağaç modelini oluşturur. KA modellerinde, ağaç boyutunun çok yüksek olması durumunda algoritmanın sınıflandırma hızı düşmektedir. Bu nedenle model oluşturulduktan sonra uçtan köke bir budama işlemi yapılarak ağaç boyutu düşürülebilir. Bu amaçla eğitim verisinden bağımsız bir test verisi kullanılarak, en başarılı budama şekli bulunabilir [70].

4.6.4. Naive Bayes

En basit istatistiksel öğrenme algoritmalarından birisi olan Naive Bayes, aşağıda formülü verilen Bayes teoremine dayanmaktadır [57]:

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \quad (4.25)$$

Burada, $P(A)$ ve $P(B)$, A ve B olaylarının gerçekleşme olasılıklarını, $P(A|B)$ ve $P(B|A)$ ise sırasıyla, B biliniyorken A olayının ve A biliniyorken B olayının gerçekleşme olasılıklarını temsil etmektedir. $P(A)$ ve $P(B)$, önsel olasılık (prior probability) veya marjinal olasılık olarak da isimlendirilmektedir. Bayes teoreminin sınıflandırma problemine uygulanması durumunda aşağıda verilen formül elde edilmektedir:

$$P(C_i|x) = \frac{P(x|C_i) \times P(C_i)}{P(x)} \quad (4.26)$$

$x = \{x_1, x_2, \dots, x_l\}$ öznitelik vektörü olan Denklem (4.26)'da, $P(C_i)$ her bir sınıfın önsel olasılığını, $P(x|C_i)$ ise C_i sınıfı biliniyorken x 'in olabilirliğini temsil etmektedir. $P(x)$ değeri ise olasılık yoğunluk fonksiyonudur ve aşağıda gösterildiği gibi hesaplanmaktadır:

$$P(x) = \sum_{i=1}^l P(x|C_i) \times P(C_i) \quad (4.27)$$

Burada, l veri uzayındaki sınıf sayısıdır.

NB sınıflandırmasında farklı özniteliklerin birbirinden kuvvetli bağımsız olduğu varsayılmaktadır. Bu varsayım altında, Denklem (4.26)'da verilen formül aşağıda gösterildiği gibi yazılabilir:

$$P(C_i|x) = \frac{P(C_i) \prod_{j=1}^n P(x_j|C_i)}{P(x)} \quad (4.28)$$

Burada, n öznitelik sayısını temsil etmektedir.

NB sınıflandırıcısında, en büyük sonsal olasılık (MAP) karar kuralını kullanarak en muhtemel sınıfı seçecek olursak, aşağıdaki sınıflandırma formülü elde edilir:

$$Y \leftarrow \arg \max_{C_i} P(C_i|x) = \arg \max_{C_i} \frac{P(C_i) \prod_{j=1}^n P(x_j|C_i)}{P(x)} \quad (4.29)$$

Pratikte Denklem (4.29)'da sadece pay kısmı önemlidir, çünkü paydadaki $P(x)$ değeri \mathcal{C}_i 'ye bağlı değildir ve x vektörü bilindiği için $P(x)$ sabit bir değerdir. Bu durumda NB sınıflandırıcısı aşağıdaki gibi olacaktır:

$$Y \leftarrow \arg \max_{\mathcal{C}_i} P(\mathcal{C}_i) \prod_{j=1}^n P(x_j | \mathcal{C}_i) \quad (4.30)$$

Bayes teoreminden yola çıkılarak, MAP karar kuralına göre Denklem (4.30)'da gösterildiği gibi sınıflandırma formülü hesaplanan NB sınıflandırma yöntemi oldukça hızlıdır. NB sınıflandırma algoritmasının kolay yorumlanabilir olması, bağımsız uzay boyutunun fazla olduğu durumlarda iyi çalışması ve kolay kullanımı bu algoritmanın daha karmaşık sınıflandırma yöntemlerine tercih edilmesine neden olmaktadır. Bunun yanı sıra, NB algoritmasında kullanılmakta olan özniteliklerin birbirinden kuvvetli bağımsız olduğu varsayımının gerçek dünya problemlerine uygulanması, çoğu zaman oldukça zordur.

4.6.5. Destek Vektör Makineleri

Vapnik tarafından önerilen DVM sınıflandırma tekniği, standart makine öğrenme tekniklerine göre birçok alanda daha iyi performans göstermeyi başarmıştır [71]. DVM tekniğinin temel yaklaşımı, mümkün olduğunca büyük bir marjin ile örnek uzayındaki verileri ayırabilen bir hiperdüzlem bulmaktır. DVM öğrenme algoritması, örnek uzayındaki sınıf dizilerini ayıran, en uygun doğrusal ayırıcı yüzeyi (karar yüzeyi) bulmaya çalışmaktadır. Ayırıcı hiperdüzlemi belirleyen en önemli veriler, destek vektörleri olarak adlandırılmaktadır. Doğrusal ayrıştırılabilir bir veri uzayı için, ayırıcı hiperdüzlem aşağıdaki gibi temsil edilebilir:

$$w^T x + b = 0 \quad (4.31)$$

Burada, x örnek uzayındaki bir nokta (öznitelik vektörü), w ağırlık katsayı vektörü, b ise yanlılık terimidir (bias term). İki sınıflı durum için DVM karar fonksiyonu Denklem aşağıdaki gibi yazılabilir:

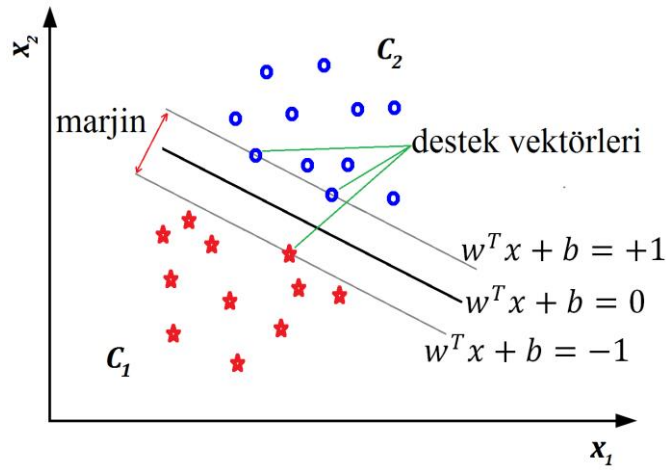
$$f(x) = \text{sign}(w^T x + b) \quad (4.32)$$

Bu durumda Denklem (4.31)'de verilen karar yüzeyinin üstünde kalan x değerleri $f(x) = +1$ ve karar yüzeyinin altında kalan x değerleri ise $f(x) = -1$ olarak etiketlenmektedir.

DVM algoritması, Denklem (4.31)'de verilen karar hiperdüzlemi ile destek vektörleri (karar düzlemine en yakın veriler) arasındaki uzaklıkla da ilgilenmektedir. Bu nedenle karar düzleminin altında ve üstünde birer tane daha hiperdüzlem belirlenmektedir (Denklem (4.33a), Denklem (4.33b)).

$$w^T x + b = +1 \quad (4.33a)$$

$$w^T x + b = -1 \quad (4.33b)$$



Şekil 4.27. İki sınıflı ve iki boyutlu, doğrusal ayrıştırılabilir durum için DVM karar yüzeyi

Şekil 4.27'de örnek veri kümesi için gösterilmekte olan $w^T x + b = -1$ düzlemi üzerinde herhangi bir x_1 noktası belirlendikten sonra $w^T x + b = +1$ düzlemi üzerinde x_1 noktasına en yakın olan x_2 noktasını seçildiğinde, x_2 noktasından x_1 'e çizilen çizgi her iki düzleme de dik olacaktır. Ayrıca w vektörü, her zaman, her iki düzleme de dik olduğu için, x_2 aşağıda gösterildiği gibi x_1 cinsinden ifade edilebilmektedir:

$$x_2 = x_1 + \lambda w \quad (4.34)$$

Burada λw , x_1 'i x_2 'ye bağlayan çizgi parçasıdır. Destek vektörlerinin bulunduğu düzlemlerin arasındaki en kısa mesafe x_1 ve x_2 arasındaki uzaklık olan $\lambda \|w\|$ 'dir. Yukarıda verilen denklemleri kullanarak λ 'yı hesaplırsak:

$$\begin{aligned}
&\rightarrow w^T(x_1 + \lambda w) + b = 1, \\
&\rightarrow (w^T x_1 + b) + \lambda w^T w = 1 \quad ; (w^T x_1 + b = -1), \\
&\rightarrow \lambda w^T w = 2, \\
&\rightarrow \lambda = \frac{2}{w^T w} = \frac{2}{\|w\|^2}
\end{aligned} \tag{4.35}$$

Bu durumda destek vektörlerinin bulunduğu düzlemler arasındaki en kısa mesafe Denklem (4.36)'da gösterildiği gibi olacaktır.

$$\lambda \|w\| = \frac{2}{\|w\|} = \frac{2}{\sqrt{w^T w}} \tag{4.36}$$

Denklem (4.36)'da hesaplanan uzaklık, Şekil 4.27'de gösterilen marjindir. DVM öğrenme algoritmasının amacı marjinin maksimum değeri alması ve bu sayede sınıflandırma hatalarının en aza indirilmesidir. Bu haliyle DVM öğrenme algoritması bir optimizasyon problemine dönüşmüştür ve tekdüze bir fonksiyon olan karekökün atılması ile bu problem aşağıdaki gibi ifade edilebilmektedir:

$$\min_{w,b} \left(\frac{w^T w}{2} \right), \tag{4.37}$$

$$\text{kısıtlamalar : } y_i(w^T x_i + b) \geq 1, \quad i = 1, 2, \dots, n$$

Burada, $y_i = f(x_i)$ (Denklem (4.32)) olarak kullanılmıştır ve n eğitim setindeki veri sayısıdır.

Karesel programlama (QP) problemi olarak da anılan bu problem, Lagrange çarpanı metodu ile çözülebilmektedir. Daha detaylı tartışmaların Theodoridis'in [58] kitabında bulunabileceği, Lagrange dönüşüm işlemi sonucunda Denklem (4.37)'de verilen küçükleme problemi, aşağıda gösterildiği gibi bir büyükleme problemine dönüştürülebilmektedir:

$$\max_{\alpha} \left(\sum_{i=1}^n \alpha_i + \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j \right), \quad (4.38)$$

$$\text{kısıtlamalar} : \sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i, \quad i = 1, 2, \dots, n$$

Burada α_i Lagrange katsayısıdır. Denklemden kullanılmış olan w , $w = \sum_{i=1}^n \alpha_i y_i x_i$ formülü ile elde edilebilir.

Yukarıda, yalnızca, doğrusal ayrıştırılabilir durum için gösterilmiş olan DVM sınıflandırma algoritması ile ilgili daha detaylı tartışmalara Bishop [55], Alpaydın [57] ve Theodoridis'in [58] kitaplarında yer verilmiştir.

Doğrusal ayrıştırılabilir durum için öğrenme ve sınıflandırma algoritması anlatılmış olan DVM sınıflandırma tekniği, öğrenme aşamasında oldukça yavaş bir yöntemdir ve DVM tekniğinin bellek gereksinimi eğitim verilerinin sayısının karesi ile orantılı olarak artmaktadır. Ayrıca elde edilen sonuçların yorumlanması oldukça zordur. Bu dezavantajlarının yanında, DVM sınıflandırma yöntemi bilinen makine öğrenmesi algoritmaları arasında en başarılı ve gürbüz olanlardan birisidir.

4.7. Kullanılan Sınıflandırma Modelleri ve Bu Modellerin Performansının Değerlendirmesi

Bu çalışmada önerilmekte olan iki basamaklı sınıflandırma modelinin başarısı, tek basamaklı sınıflandırma modelinin hız ve başarımları ölçümleri temel alınarak değerlendirilmektedir. Her iki sınıflandırma modelinin performans analizlerinin yapılabilmesi için, öncelikle, bu sınıflandırma modellerinde kullanılacak olan en başarılı öznitelik kümeleri, Bölüm 4.5'te anlatılmakta olan yorucu öznitelik seçme yöntemi kullanılarak belirlenmektedir. Öznitelik seçme işlemi Bölüm 4.5'te bahsedildiği gibi iki farklı kategori için yapılmaktadır. Öznitelik seçme işlemi sonucunda elde edilen sonuçlar "Öznitelik Kümesi 1" (ÖK1) ve "Öznitelik Kümesi 2" (ÖK2) başlıkları altında incelenmektedir.

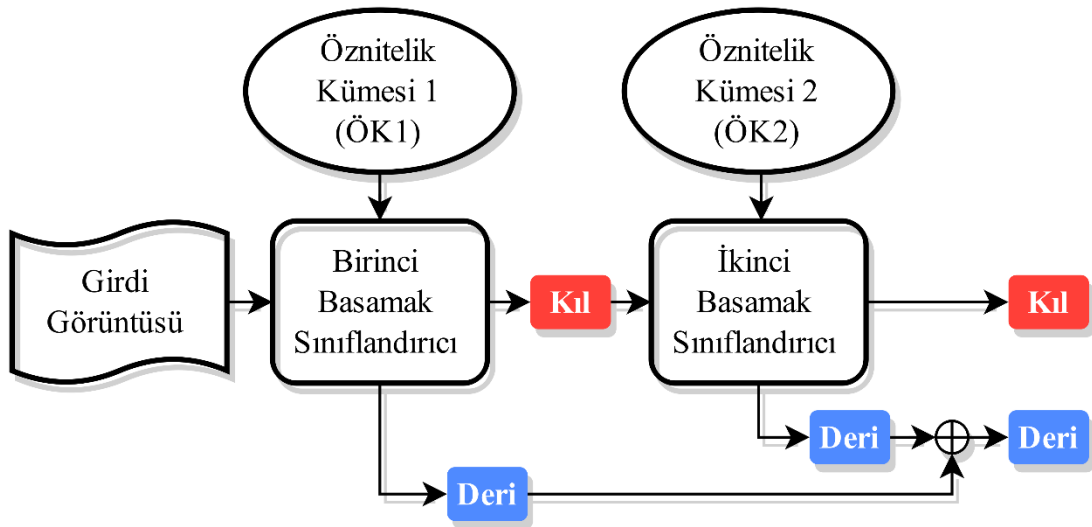


Şekil 4.28. Hızlı öznitelikler kümesinde yapılan öznitelik seçme işleminin çıktısı



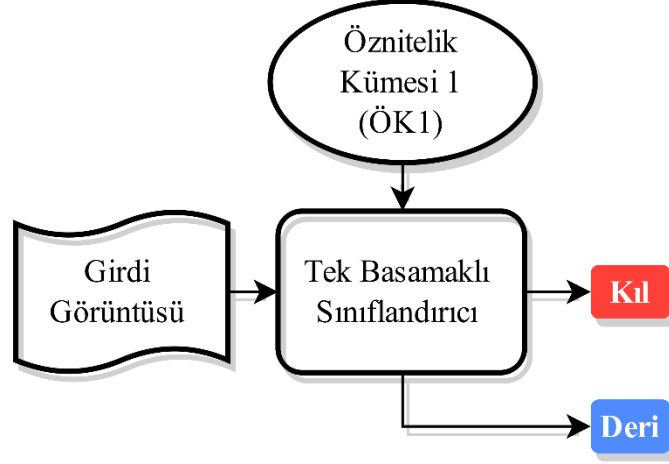
Şekil 4.29. Hızlı ve yavaş tüm özniteliklerin bulunduğu kümede yapılan öznitelik seçme işleminin çıktısı

Şekil 4.28 ve Şekil 4.29’da gösterildiği gibi hızlı öznitelikler kümesi içerisinde seçilen öznitelikler ÖK1 olarak adlandırılırken, hızlı ve yavaş tüm özniteliklerin bulunduğu küme içerisinde seçilen öznitelikler ise ÖK2 olarak adlandırılmaktadır. ÖK1 ve ÖK2 bu çalışmada önerilmekte olan ve “İki Basamaklı Sınıflandırma Modeli” (İBSM) olarak isimlendirilen model üzerinde Şekil 4.30’de gösterildiği gibi kullanılmaktadır.




Şekil 4.30. İki basamaklı sınıflandırma modeli (İBSM)

ÖK1 ve ÖK2 olarak isimlendirilmiş olan iki farklı öznitelik seçme işlemi sonuçlarının, tek basamaklı bir model üzerinde kullanılması durumunda ise Şekil 4.31 ve Şekil 4.32’te gösterilmekte olan iki ayrı sınıflandırma modeli elde edilebilmektedir.



Şekil 4.31. Tek basamaklı sınıflandırma modeli 1 (TBSM1)



Şekil 4.32. Tek basamaklı sınıflandırma modeli 2 (TBSM2)

Şekil 4.31’de gösterilmekte olan ve “Tek Basamaklı Sınıflandırma Modeli 1” (TBSM1) olarak isimlendirilen modelin yalnızca hızlı öznitelikler arasından seçilmiş öznitelik kümesini kullanıyor olması nedeniyle oldukça hızlı çalışması beklenmektedir. Şekil 4.32’te gösterilmekte olan ve “Tek Basamaklı Sınıflandırma Modeli 2” (TBSM2) olarak isimlendirilen modelin ise işlem karmaşıklığı daha yüksek olan öznitelikleri de kullanıyor olması nedeniyle bu modelin TBSM1’e göre daha yavaş çalışması fakat bu modelin kıl-deri sınıflandırma başarımının TBSM1’e göre daha yüksek olması beklenmektedir.

Yukarıda anlatıldığı gibi sırasıyla ÖK1 ve ÖK2'yi kullanılmakta olan TBSM1 ve TBSM2'nin işlem hızlarının ve sınıflandırma başarımlarının birbirinden farklı olması beklenilmektedir. Bu nedenle ÖK1 ve ÖK2'yi birlikte kullanan İBSM'nin performansının, TBSM1 ve TBSM2'nin performansları ile ayrı ayrı karşılaştırılması gerekmektedir.

Bu çalışmada önerilmekte olan İBSM'nin sınıflandırma hızının TBSM1'in sınıflandırma hızından daha düşük olacağı bilinmektedir. Fakat İBSM'nin sınıflandırma hızının TBSM2'in sınıflandırma hızından daha yüksek olması beklenilmektedir. TBSM2'ye göre hız avantajı sağlaması beklenen İBSM'nin başarılı bir yöntem olduğunun gösterilebilmesi için İBSM'nin kıl tespit başarımının TBSM1'in kıl tespit başarımından yüksek ve TBSM2'nin kıl tespit başarımına yakın olması gerekmektedir. Bu durumun gerçekleşebilmesinin, Bölüm 4.7.3'te detaylı olarak anlatılmakta olan İBSM'nin birinci basamağında kullanılan sınıflandırıcının kıl tespit başarımının artırılması şartına bağlı olduğu değerlendirilmektedir.

Tek basamaklı ve iki basamaklı sınıflandırma modellerinin başarımlarının analizlerinin yapılabilmesi için bu çalışmada kullanılmakta olan performans ölçütleri Bölüm 4.7.1'de, bu performans ölçütlerinin uygulama öncesinde öngörülebilmesi amacıyla kullanılmakta olan k-katlamalı çapraz doğrulama yöntemi ise Bölüm 4.7.2'de özetlenmektedir. Bölüm 4.7.3'te İBSM'nin kıl tespit başarımının artırılabilmesi için önerilmekte olan yöntem anlatılmaktadır. Sınıflandırma modellerinin işlem sürelerinin uygulama öncesinde öngörülebilmesi için kullanılmakta olan formüllere Bölüm 4.7.4'te yer verilmektedir.

4.7.1. Performans Ölçütleri

Bu çalışmada kullanılan sınıflandırıcıların ve öznelik kümelerinin performanslarının analiz edilebilmesi ve karşılaştırmalarının yapılabilmesi için duyarlılık (sensitivity), özgüllük (specificity) ve hata oranı (error rate) ölçümlerinden faydalanılmaktadır. Bu ölçümler, karışıklık matrisi (confusion matrix) olarak da bilinen temel veri yapısı üzerinden elde edilebilmektedir. Bu çalışmada kullanılan iki sınıflı karışıklık matrisi Çizelge 4.2'de gösterilmektedir. Kıl sınıfına ait örnekler bu çalışmanın temel tespit

amacı olması nedeniyle pozitif olarak isimlendirilirken, deri sınıfına ait örnekler negatif olarak isimlendirilmektedir. Doğru pozitif (DP) ve doğru negatif (DN), sırasıyla, gerçekte kıl ve deri sınıflarında olan ve sınıfı doğru tahmin edilebilmiş örnekleri temsil etmektedir. Yanlış pozitif (YP) ve yanlış negatif (YN), sırasıyla, gerçekte deri ve kıl sınıflarında olan ve sınıfı yanlış tahmin edilmiş örnekleri temsil etmektedir.

Çizelge 4.2. Kıl ve deri sınıfları karışıklık matrisi

		Tahmin Edilen Sınıf	
		Kıl (Pozitif)	Deri (Negatif)
Gerçek Sınıf	Kıl (Pozitif)	DP	YN
	Deri (Negatif)	YP	DN

Bu çalışmada kullanılmakta olan performans ölçütleri karışıklık matrisine dayanarak aşağıdaki gibi hesaplanmaktadır:

$$Duyarlılık = \frac{DP}{DP + YN} \quad (4.39a)$$

$$Özgüllük = \frac{DN}{DN + YP} \quad (4.39b)$$

$$Hata Oranı = \frac{YP + YN}{DP + DN + YP + YN} \quad (4.39c)$$

Yukarıda verilen performans ölçütleri bir sonraki bölümde anlatılmakta olan k-katlamalı çapraz doğrulama yöntemi kullanılarak hesaplanmaktadır.

4.7.2. K-Katlamalı Çapraz Doğrulama

K-katlamalı çapraz doğrulama tekniği sınıflandırıcı performansının tahmin edilmesi için yaygın olarak kullanılan bir yöntemdir. İçerisinde m tane örneğin bulunduğu bir test setinde k-katlamalı çapraz doğrulama işlemi tek bir çalışmada sırasıyla aşağıdaki işlemleri yapmaktadır:

- 1) Eğitim setindeki örnekler rastgele bir şekilde yeniden düzenlenir.
- 2) Eğitim setindeki örnekler her parçada yaklaşık olarak m/k tane örnek olacak şekilde sıralı olarak k tane bölüme ayrılır.
- 3) $i = 1, 2, \dots, k$ için,
 - i bölümünde olmayan bütün örnekler kullanılarak sınıflandırıcı eğitilir.
 - Eğitimi yapılmış sınıflandırıcı kullanılarak, i bölümündeki bütün örnekler test edilir.
 - Sınıflandırma işleminde öğrenilmek istenilen parametreler (sınıflandırıcı performans ölçütleri), testler sırasında kaydedilir. Örneğin yanlış sınıflandırma sayısı n_i olarak kaydedilir.
- 4) Her bölme için hesaplanmış olan parametre değerleri toplanır. Elde edilen değer veri setindeki toplam örnek sayısına bölünerek, ilgili sınıflandırıcı performans ölçütü tahmini olarak hesaplanır. Örneğin sınıflandırıcı hata oranı, yukarıda bahsedilen n_i değeri kullanılarak aşağıdaki gibi hesaplanır.

$$hata\ oranı = \frac{\sum_{i=1}^k n_i}{m} \quad (4.40)$$

Yukarıda bahsedilen işlemlerin yapılması ile öğrenilmek istenilen sınıflandırıcı performans ölçütleri Denklem (4.40)'de gösterilen hata oranı örneğinde olduğu gibi hesaplanabilmektedir. Yukarıda, k-katlamalı çapraz doğrulama algoritmasının bir seferlik çalışması için sıralanmış olan işlemler birden fazla sayıda tekrar edilerek ortalama değerler hesaplanabilmektedir. Bu sayede, k-katlamalı çapraz doğrulama işlemi ile veri setindeki örneklerin farklı rastgele sıralamaları için de testler yapabilmekte ve daha kesin sonuçlar elde edilebilmektedir.

K-katlamalı çapraz doğrulama işlemi sayesinde, test aşamasından önce eğitim verilerinin kullanılması ile sınıflandırıcı performansı öngörülebilmektedir. Ayrıca, bu yöntem aşırı öğrenme probleminin sınıflandırma testleri üzerindeki etkisini azaltılabilmekte ve sınıflandırma modelinin bağımsız veri kümelerinde nasıl performans göstereceği ile ilgili genellemeler yapılmasına izin vermektedir.

4.7.3. İBSM'nin Duyarlılık Değerinin Artırılması

İBSM'nin hata oranı, duyarlılık ve özgüllük değerleri EK A'da verilmekte olan formüller yardımıyla İBSM'nin birinci ve ikinci basamağında kullanılmakta olan sınıflandırıcıların hata oranı, duyarlılık ve özgüllük değerleri üzerinden uygulama testleri öncesinde öngörülelebilmektedir. EK A'da yapılmakta olan tartışmalar ışığında İBSM'nin duyarlılık değerinin (kıl bulma başarımının) TBSM1'in duyarlılık değerinden daha yüksek olamayacağı bilinmektedir. Aynı zamanda İBSM'nin sınıflandırma hızının TBSM1'in sınıflandırma hızından daha yüksek olması da mümkün değildir. Bu nedenle, İBSM'nin TBSM1'e göre duyarlılık ve hız kriterleri üzerinden herhangi bir avantaj sağlayamayacağı öngörülelebilmektedir.

Bu çalışmada önerilmekte olan İBSM'nin sınıflandırma hızının TBSM2'nin sınıflandırma hızından daha yüksek olabileceği düşünülmektedir. Ancak İBSM'nin TBSM2'ye göre daha avantajlı bir yöntem olduğunun gösterilebilmesi için İBSM'nin duyarlılık değerinin TBSM1'in duyarlılık değerinin üzerine çıkması ve kıl-deri ayırt etme gücü daha yüksek olan öznelikleri de kullanmakta olan TBSM2'nin duyarlılık değerine yaklaşması gerekmektedir. Bu durum ancak İBSM'nin birinci basamak sınıflandırıcısının duyarlılık değerinin TBSM1'in duyarlılık seviyesinin üzerine çıkarılması ile mümkündür.

Bu çalışmada, İBSM'nin birinci basamağında kullanılmakta olan sınıflandırıcısının duyarlılık değerinin yükseltilmesi için maliyet fonksiyonu kullanılmaktadır. Maliyet fonksiyonu yardımı ile kıl bölgelerinin yanlış sınıflandırılmasının deri bölgelerinin yanlış sınıflandırılmasından daha kritik olduğu İBSM'nin birinci basamağında kullanılmakta olan sınıflandırıcıya öğretilmektedir. Maliyet fonksiyonunun sınıflandırma teknikleri üzerindeki etkisi ile ilgili daha detaylı tartışmalara Theodoridis'in [58] kitabında yer verilmiştir.

Bu çalışmada, Bölüm 4.6'da belirlenmiş olan sınıflandırma tekniklerinin eğitilmesi için EK B'de verilmiş olan yerleşik Matlab fonksiyonları kullanılmaktadır. İlgili sınıflandırma tekniklerinin maliyet fonksiyonu kullanılarak eğitilmesi için EK B'de verilmiş olan Matlab fonksiyonlarının 'Cost' parametresinden yararlanılmaktadır. İki

sınıflı durum için bu parametrenin girdisi Çizelge 4.3'te gösterilmekte olan maliyet matrisidir.

Çizelge 4.3. Kıl ve deri sınıfları maliyet matrisi

		Tahmin Edilen Sınıf	
		Kıl (Pozitif)	Deri (Negatif)
Gerçek Sınıf	Kıl (Pozitif)	$M_{1,1}$	$M_{1,2}$
	Deri (Negatif)	$M_{2,1}$	$M_{2,2}$

Çizelge 4.3'te $M_{1,1}$ gerçekte kıl olan örüntülerin doğru sınıflandırılması durumunda, $M_{1,2}$ gerçekte kıl olan örüntülerin yanlış sınıflandırılması durumunda, $M_{2,1}$ gerçekte deri olan örüntülerin yanlış sınıflandırılması durumunda ve $M_{2,2}$ ise gerçekte deri olan örüntülerin yanlış sınıflandırılması durumunda verilecek olan cezaları temsil etmektedir. Bu çalışmada kullanılmakta olan sınıflandırma modelleri ile kıl ve deri sınıfları arasında tarafsız bir seçim yapılması durumunda $M_{1,1} = 0$, $M_{1,2} = 1$, $M_{2,1} = 1$ ve $M_{2,2} = 0$ değerleri kullanılmaktadır.

İBSM'nin birinci basamağında kullanılmakta olan sınıflandırıcının kıl lehine karar verebilmesi için ise $(M_{1,2} \div M_{2,1})$ değerinin 1'in üzerinde olması gerekmektedir. Ancak $(M_{1,2} \div M_{2,1})$ değerinin çok yüksek olması durumunda sınıflandırıcının deri tespit başarımı ciddi oranda düşecektir. İBSM'nin birinci basamağındaki sınıflandırıcının deri tespit başarımının düşük olması durumunda ise İBSM'nin sınıflandırma hızının düşmesi beklenmektedir. Bu nedenle $(M_{1,2} \div M_{2,1})$ değeri yavaş yavaş artırılmalı ve İBSM'nin birinci basamağındaki sınıflandırıcının deri tespit başarımındaki azalma ve kıl tespit başarımındaki artma dikkate alınarak en uygun $(M_{1,2} \div M_{2,1})$ değeri tespit edilmelidir. Bu sayede İBSM'nin birinci basamağında kullanılmakta olan sınıflandırıcının deri tespit başarımının ciddi oranda düşmesinin önüne geçilebilecektir. Önerilmekte olan yöntemde $M_{1,1} = 0$, $M_{1,2} = c$, $M_{2,1} = 1$ ve $M_{2,2} = 0$ olarak kullanılmakta ve c değeri yavaş yavaş artırılarak en uygun $(M_{1,2} \div M_{2,1})$ değeri bulunmaya çalışılmaktadır.

Önerilen yöntem sayesinde İBSM'nin duyarlılık değerinin TBSM1'in duyarlılık değerinin üzerine çıkması ve TBSM2'nin duyarlılık değerine yaklaşması beklenmektedir.

4.7.4. İki Basamaklı ve Tek Basamaklı Sınıflandırma Modellerinin İşlem Sürelerinin Belirlenmesi

Bu çalışmada, İBSM, TBSM1 ve TBSM2'nin işlem sürelerinin uygulama testleri öncesinde öngörülebilmesi için EK C'de yapılmakta olan varsayımlar altında Denklem (C.4), (C.5) ve (C.6)'da verilmekte olan formüller kullanılmaktadır. Denklem (C.4), (C.5) ve (C.6)'nın kullanılması ile elde edilen işlem sürelerinin uygulama testlerinin sonuçları ile uyumlu olması beklenmektedir.

5. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde, Bölüm 4'te belirtilen kıl tespit yöntemlerinin test edilmesi için gerçekleştirilmiş olan çalışmalar anlatılmaktadır. Test çalışmalarında kullanılmakta olan veri setinin oluşturulması için faydalanılan yöntemler Bölüm 5.1'de özetlenmektedir. Hızlı ve yavaş özniteliklerin belirlenmesi işlemi Bölüm 5.2'de yapılmaktadır. Testlerde kullanılacak olan sınıflandırma tekniği Bölüm 5.3'te belirlenmektedir. Belirlenen sınıflandırma tekniği kullanılarak yapılan öznitelik seçme işlemine Bölüm 5.4'te yer verilmektedir. İki basamaklı ve tek basamaklı sınıflandırma modellerinin kıl-deri tespit başarımları ve işlem süreleri sırasıyla Bölüm 5.5 ve Bölüm 5.6'da incelenmektedir. Bölüm 5.7'de ise modellerin görsel değerlendirmesi örnek bir cilt görüntüsü kullanılarak yapılmaktadır. Bu çalışmada önerilmekte olan İBSM hakkındaki son değerlendirmelere Bölüm 5.8'de yer verilmektedir.

Bölüm 4'te belirlenmiş olan öznitelikler bu bölümde, Çizelge 4.1'de verilmiş olan öznitelik numaraları ile temsil edilmektedir.

5.1. Veri Setinin Oluşturulması

Eğitim setinin oluşturulması için kullanılmakta olan kıl ve deri örüntüleri, cilt görüntüsünün alındığı kişi, bu kişinin cilt bölgesi, cilt tipi ve rengi, kıl tipi ve rengi gibi birçok faktöre bağlı olarak farklılık göstermektedir. Ancak, insan cildinin doğası gereği, cilt tipi çok farklı olan kişilerden elde edilen bazı kıl ve deri örüntüleri arasında dahi yüksek benzerlik bulunması beklenmektedir. Kullanılan örüntüler arasındaki benzerlikler dikkate alınmadan veri setinin oluşturulması durumunda, test sonuçlarında aşırı eğitim adı verilen problemin ortaya çıkması kaçınılmazdır. Bu nedenle eğitim setinde yüksek benzerlik gösteren örüntülerin elenmesi, çapraz doğrulama sonuçlarının doğru yorumlanabilmesi için önemlidir.

Ayrıca, bu alanda yapılması muhtemel çalışmalarla, bu çalışmada elde edilen sonuçların karşılaştırılabilmesi için veri setinin oluşturulması sırasında ortak bir yöntem kullanılması gerekmektedir. Aksi halde, aynı öznitelikler ve sınıflandırma yöntemlerinin kullanılması durumunda dahi veri setinin oluşturulmasındaki farklılıklardan dolayı farklı sonuçların elde edilmesi muhtemeldir.

Bu çalışmada, benzer verilerin elenmesi için, öncelikle, veri setindeki bütün öznitelik kümeleri aşağıda gösterilmekte olan normalleştirme formülü kullanılarak [0,1] aralığına ölçeklenmektedir:

$$x' = \left\{ \frac{x_1 - \min(x)}{\max(x) - \min(x)}, \frac{x_2 - \min(x)}{\max(x) - \min(x)}, \dots, \frac{x_l - \min(x)}{\max(x) - \min(x)} \right\} \quad (5.1)$$

Burada, $x = \{x_1, x_1, \dots, x_l\}$ 'dir.

Denklem (5.1)'de x bir öznitelik kümesindeki verilerin tamamından oluşan kümeyi, x' ise normalleştirilme işlemi sonucunda elde edilen öznitelik kümesini temsil etmektedir.

Normalleştirme işlemi sonucunda farklı ölçeklerdeki özniteliklerin, bu çalışmada benzerlik hesaplamak için kullanılan ve Denklem (4.22)'de formülü verilen Öklid uzaklığını farklı ölçülerde etkilemesinin önüne geçilmektedir. Veri setine eklenecek olan yeni bir öznitelik vektörü ile veri setine önceden eklenmiş olan öznitelik vektörlerinden herhangi biri arasındaki Öklid uzaklığı 1'den daha küçük ise bu öznitelik vektörleri benzer kabul edilmekte ve yeni öznitelik vektörü veri setine eklenmemektedir. Yapılan bu işlem sayesinde eğitim setine gereğinden fazla verinin eklenmesinin önüne geçilmektedir.

Bu çalışmada, yukarıda bahsedilen yöntem kullanılarak, Şekil 4.3'te bazı örnekleri gösterilen 170 tane kıl ve 170 tane deri örüntüsüne ait öznitelik vektörlerinden oluşan bir eğitim seti oluşturulmuştur. Oluşturulan eğitim seti öznitelik seçme ve sınıflandırıcı performansı değerlendirme testlerinde kullanılmaktadır.


5.2. Hızlı ve Yavaş Özniteliklerin Belirlenmesi

Bu çalışmada belirlenmiş olan öznitelikler, hızlı ve yavaş başlıkları altında iki farklı kategoriye ayrılarak incelenmektedir. Öznitelikler arasında bu sınıflandırmanın yapılabilmesi için önceden belirlenmiş boyutlardaki girdi görüntüleri için her bir özniteliliğin işlem süresi hesaplanmakta ve hızlı-yavaş ayrımının yapılabileceği bir eşik seviyesi, görsel olarak, belirlenmektedir.


Testler için oluşturulmuş olan kütüphanedeki görüntülerin çözünürlükleri dikkate alındığında, Bölüm 4.4.2’de anlatılan ölçek değişmezliğinin sağlanabildiği komşuluk penceresi boyutları yaklaşık 7x7 piksel ile 35x35 piksel aralığında olmalıdır. Bu aralık, 1,6 cm²’lik bir cilt bölgesinin yaklaşık 640x480 piksel ile temsil edildiği, kıl kökleri arasındaki ortalama açıklığın 2 mm’nin üzerinde olduğu ve kesilmiş kılların yüzeydeki uzunluğunun 1 mm civarında olduğu durum için geçerlidir. Ölçek değişmezliğinin sağlanabildiği komşuluk penceresi boyutları, görüntüleme birimine, görüntünün alındığı cilt bölgesine ve kesilmiş kılların yüzeydeki uzunluğuna bağlı olarak belirlenmiştir.

Belirlenen özniteliklerin hesaplanması için, Matlab kütüphanelerinde bulunan ve optimizasyonu yapılmış vektör tabanlı yerleşik fonksiyonlar kullanılmaktadır.

Belirlenmiş olan 7x7 ve 35x35 piksel aralıklarındaki girdi örüntüsü için her bir öznitelik fonksiyonunun işlem süresi hesaplanmıştır. Kullanılan cilt görüntülerindeki dokusal değişikliklerin işlem hızına olan etkisinin en aza indirilebilmesi için, alınan sonuçlar iki defa yürüyen ortalama (moving average) filtresinden geçirilmiştir. Elde edilen sonuçlar Şekil 5.1 ve Şekil 5.2’de, özniteliklerin Çizelge 4.1’deki numaralandırılmaları kullanılarak gösterilmektedir. Gösterilen sonuçlar dikkate alındığında 2 ve 6 numaralı özniteliklerin diğer özniteliklere göre daha hızlı çalıştığı ve ortalama işlem sürelerinin 35x35 piksellik örüntü için 0,08 milisaniyenin altında olduğu görülmektedir (Şekil 5.1). 12 numaralı özniteliğin ise diğer özniteliklere göre çok daha yavaş olduğu ve ortalama işlem süresinin 7x7 piksellik örüntü için 0,5 milisaniyenin üzerinde olduğu gözlenmektedir (Şekil 5.2).



Şekil 5.1. Ortalama işlem süresi 0,13 milisaniyenin altında olan öznelikler



Şekil 5.2. Ortalama işlem süresi 0,13 milisaniyenin üstünde olan öznelikler

Şekil 5.1 ve Şekil 5.2'de, belirli pencere boyutu aralıkları için işlem süreleri gösterilmekte olan öznelikler arasında, 5 numaralı özneliğin pencere boyutundaki değişimlerden diğer özneliklere göre daha çok etkilendiği gözlemlenmektedir. Bu nedenle örüntü pencere boyutunun 35x35 pikselin üzerine çıkması durumunda bu özneliğin işlem süresinin tekrar incelenmesi önem taşımaktadır.

Şekil 5.1 ve Şekil 5.2'de, 7x7 ile 35x35 piksel aralıklarındaki girdi örüntüleri için gösterilmekte olan öznelik işlem süreleri, özneliklerin hesaplanma hızlarının komşuluk penceresi boyutundaki değişimden nasıl etkileneceğinin görülmesi için önemlidir. Ancak, özneliklerin hızlı ve yavaş şeklinde öbeklenebilmesi için belirlenecek olan eşik seviyesinin, bu çalışmada varsayılan pencere boyutu olan 15x15 piksel boyutundaki örüntüler için elde edilmiş veriler ışığında yapılması daha uygun bulunmaktadır. Belirlenmiş olan bütün özneliklerin 15x15 piksellik girdi


örüntüsünde hesaplanabilmesi için ihtiyaç duyulan işlem süresi, sıralı şekilde, en hızlı özniteliğin işlem süresi ile karşılaştırılarak Çizelge 5.1’de gösterilmektedir.

Çizelge 5.1. 15x15 piksellik pencere boyutundaki girdi örüntüsü için özniteliklerin ortalama işlem süreleri

Öznitelik Numarası (Çizelge 4.1)	İşlem Süresi (ms)	İşlem Süresinin En Hızlı Özniteliğin İşlem Süresine Oranı
6	0,0671	1,000
2	0,0673	1,003
4	0,0790	1,177
3	0,0793	1,182
1	0,0907	1,352
5	0,0984	1,466
7	0,1485	2,213
10	0,1896	2,826
9	0,2083	3,104
11	0,2124	3,165
8	0,3723	5,549
12	0,5838	8,700

Çizelge 5.1’deki gösterilmekte olan özniteliklerin işlem süreleri incelendiğinde, hızlı ve yavaş öznitelikleri ayırmak için kullanılacak olan eşik seviyesinin 0,1 milisaniye olarak belirlenmesinin uygun olabileceği değerlendirilmektedir. Bu şekilde bir ayırıştırma yapılması durumunda en hızlı özniteliğin işlem süresinin yaklaşık 1,5 katından daha yüksek işlem süresine sahip olan öznitelikler yavaş öznitelikler olarak kabul edilirken, daha düşük işlem süresine sahip olanlar ise hızlı öznitelikler olarak kabul edilmektedir. 0,1 milisaniye işlem süresinin eşik seviyesi olarak belirlenmesi durumunda, Şekil 5.1 ve Şekil 5.2’de gösterilmekte olan 1,3 milisaniyenin altı ve üstü şeklindeki öbeklemelerle de uyumlu bir sınıflandırma yapılabilmektedir. Bu durumda 1, 2, 3, 4, 5 ve 6 numaralı öznitelikler hızlı öznitelikler olarak kabul edilirken, 7, 8, 9, 10, 11 ve 12 numaralı öznitelikler ise yavaş öznitelikler olarak kabul edilmektedir. Hızlı özniteliklerin tamamının birlikte kullanılması durumunda bu özniteliklerin hesaplanması için harcanan toplam süre 0,418 milisaniyedir. Yavaş özniteliklerin tamamının birlikte hesaplanması durumunda ise bu özniteliklerin hesaplanması için harcanan toplam süre 1,7149 milisaniyedir. Hızlı özniteliklerin tamamının

hesaplanması işlemi, yavaş özniteliklerinin tamamının hesaplanması işleminden yaklaşık 4 kat daha çabuk gerçekleşmektedir.



Şekil 5.3. 15x15 piksellik pencere boyutundaki girdi örüntüsü için özniteliklerin ortalama işlem süreleri ve hızlı-yavaş öznitelik ayrımının yapılacağı eşik seviyesi

Yukarıda anlatıldığı gibi, eşik seviyesi yapılan değerlendirmeler sonucunda 0,1 milisaniye olarak belirlenmiştir. Ancak, belirlenmiş olan eşik seviyesinin verimsiz olması ihtimali bulunmaktadır. Eşik seviyesinin verimsiz olması durumunda aşağıdaki problemlerden birisi ortaya çıkacaktır:

- 1) Eşik seviyesinin düşük seçilmiş olması nedeniyle, İBSM'nin başarımını artırabilecek bazı öznitelikler birinci basamak sınıflandırma işleminde kullanılmayacak ve İBSM'nin birinci basamak sınıflandırma başarımı oldukça düşük çıkacaktır.
- 2) Eşik seviyesinin yüksek seçilmiş olması nedeniyle İBSM'nin hızı, TBSM2'nin hızının altına düşecektir.

Bu nedenle yukarıda görsel olarak tespit edilmiş eşik seviyesinin verimsiz olduğunun anlaşılması durumunda eşik seviyesi artırılarak veya azaltılarak, hızlı ve yavaş özniteliklerin yeniden düzenlenmesi gerekebilecektir.

5.3. Sınıflandırma Yönteminin Belirlenmesi

Bu çalışmada kullanılacak olan sınıflandırma yöntemi, tüm özniteliklerin kullanılması ile yapılan çapraz doğrulma işleminin sonuçları ve sınıflandırma yöntemlerinin tek bir

öznitelik vektörünü sınıflandırmaları için ihtiyaç duydukları ortalama işlem süreleri dikkate alınarak belirlenmektedir. Bu amaçla Bölüm 4.6’da anlatılan her bir sınıflandırma yöntemi için, Bölüm 4.7.1’de anlatılmakta olan hata oranı, özgüllük ve duyarlılık performans ölçütleri 5-katlamalı çapraz doğrulama işlemi kullanılarak hesaplanmaktadır. Çapraz doğrulama işlemi kullanılarak, ilgili performans ölçüleri hesaplanırken 500 tekrar yapılmakta ve Denklem (4.40)’ta gösterildiği gibi sonuçların ortalaması alınmaktadır. Bu sayede elde edilen sonuçların kesinliği artırılmaktadır. Aynı zamanda sonuçların kesinliği hakkında yorum yapılabilmesi için her bir öznitelik kümesi için yapılmakta olan çapraz doğrulama işleminin farklı tekrarları ile elde edilen sonuç kümesinin standart sapması da hesaplanmaktadır. Çapraz doğrulama işleminde, Bölüm 5.1’de anlatılmakta olan koşullara uygun olarak oluşturulmuş 170 kıl ve 170 deri örüntüsünden oluşan bir veri seti kullanılmaktadır. Tüm özniteliklerin kullanılması ile yapılmış olan çapraz doğrulama işleminin sonuçları Çizelge 5.2’de gösterilmektedir. Tabloda en başarılı sonuçlar yeşil ile, en başarısız sonuçlar ise kırmızı ile işaretlenerek gösterilmektedir. K-NN sınıflandırma yöntemi için en başarılı sonuçlar, 5 en yakın komşunun çoğunluk oylaması yapması ile elde edilmiştir. Bu nedenle yalnızca 5-NN yöntemi için performans analiz sonuçları gösterilmektedir.

Çizelge 5.2. Tüm özniteliklerin kullanılması ile yapılan çapraz doğrulama işleminin sonuçları

Sınıflandırma Tekniği	Hata Oranı		Duyarlılık		Özgüllük	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
DAA	0,0167	0,0015	0,9775	0,0028	0,9890	0,0008
NB	0,0274	0,0013	0,9838	0,0015	0,9613	0,0024
DVM (Doğrusal)	0,0142	0,0029	0,9896	0,0040	0,9818	0,0037
KA	0,0289	0,0057	0,9725	0,0086	0,9695	0,0072
5-NN	0,0124	0,0016	0,9895	0,0020	0,9856	0,0025

Çizelge 5.2’de gösterilmekte olan sonuçların standart sapmasının genel olarak düşük çıktığı gözlenmektedir. Bu nedenle elde edilen sonuçların farklı eğitim ve test setleri için benzerlik gösterdiği söylenebilir. Çapraz doğrulama işlemi sonucunda, en düşük hata oranı ve en yüksek özgüllük değerinin 5-NN yöntemi ile, en yüksek duyarlılık değerinin ise doğrusal çekirdek fonksiyonu kullanan DVM tekniği ile elde edildiği görülmektedir. KA ve NB sınıflandırma tekniklerinin kıl ve deri tespit başarımlarının ise diğer yöntemlere göre daha düşük çıktığı gözlenmektedir.

Bu çalışmada kullanılacak sınıflandırma yönteminin belirlenmesi için dikkate alınacak olan bir diğer kıstas, her bir sınıflandırma yönteminin tek bir öznitelik vektörünü sınıflandırabilmeleri için ihtiyaç duydukları ortalama işlem süreleridir. Bu değerlerin öngörülebilmesi için Çizelge 5.2’de verilmiş olan tüm sınıflandırma yöntemleri, belirlenmiş olan tüm öznitelikler kullanılarak 169 kıl ve 169 deri örüntüsüne ait veriler ile eğitilmiştir. Eğitim işlemi sonucunda oluşturulmuş olan sınıflandırıcıların, eğitim setinde kullanılmayan 1 adet kıl ve deri örüntüsünü sınıflandırma süresi hesaplanmış ve bu sürelerin ortalaması ilgili sınıflandırıcının tek bir öznitelik vektörünü sınıflandırma süresi olarak alınmıştır. Elde edilen sonuçların kesinliğinin artırılabilmesi için yukarıda anlatılmakta olan işlem farklı eğitim ve test kümeleri kullanılarak 100 defa tekrarlanmış ve elde edilen sonuçların ortalaması alınmıştır. Çizelge 5.3’te gösterilmekte olan değerler ilgili sınıflandırma yöntemi için tek bir öznitelik vektörünü sınıflandırma süresi olarak belirlenmiştir. Bu çalışmada kullanılan sınıflandırıcıların işlem sürelerinin hesaplanması için, Matlab kütüphanelerinde bulunan vektör tabanlı yerleşik fonksiyonlar kullanılmıştır. İlgili sınıflandırma tekniklerinin eğitilmesi için kullanılan Matlab fonksiyonları EK B’de verilmiştir.

Çizelge 5.3. Sınıflandırma modellerinin tüm özniteliklerin kullanıldığı tek bir öznitelik vektörünü sınıflandırma süreleri

Sınıflandırma Tekniği	DAA	NB	DVM (Doğrusal)	KA	5-NN
Tek Bir Öznitelik Vektörünün Sınıflandırılma Süresi (saniye)	~0,0011	~0,0006	~0,0009	~0,0013	~0,0018

Çizelge 5.3'te gösterilmekte olan sonuçlar incelendiğinde, en yüksek kıl-deri tespit başarımlarının elde edildiği DVM ve 5-NN sınıflandırma modelleri arasında ciddi bir hız farkı olduğu görülmektedir. DVM tekniği 5-NN tekniğine göre yaklaşık 2 kat daha hızlı sınıflandırma yapabilmektedir. K-NN tekniğinin eğitim aşamasının bulunmaması ve tüm sınıflandırma işlemlerini test aşamasında yapıyor olması bu hız farkının en önemli nedenidir. DVM ve 5-NN modellerinin tek bir öznitelik vektörünü sınıflandırma süreleri arasındaki fark milisaniyeler seviyesinde olmasına rağmen, uygulama sırasında onlarca öznitelik vektörünün sınıflandırılması gerekeceği için her iki modelin işlem süreleri arasındaki bu farkın uygulama sırasında saniyeler seviyesine çıkması beklenmektedir. **Bu nedenle, 5-NN tekniği yerine, bu yöntemle oldukça yakın sınıflandırma başarımlarının elde edildiği doğrusal çekirdek fonksiyonu kullanan DVM tekniğinin sınıflandırma işleminde kullanılmasının daha uygun olduğu düşünülmektedir.**

Aşağıdaki bölümlerde iki basamaklı ve tek basamaklı sınıflandırma modellerinin performanslarının karşılaştırılması için yapılmakta olan testlerde, bu bölümde en uygun sınıflandırma tekniği olarak belirlenmiş olan doğrusal çekirdek fonksiyonu kullanan DVM tekniği kullanılmaktadır.

5.4. Öznitelik Seçme

Bölüm 5.3'te anlatılmakta olan sınıflandırma yöntemi seçme işlemi sonucunda, Bölüm 4.6'te anlatılmakta olan sınıflandırma teknikleri arasından bu çalışma için en uygun olan tekniğin doğrusal çekirdek fonksiyonu kullanan DVM sınıflandırma yöntemi olduğuna karar verilmiştir. Bu bölümde, DVM sınıflandırma tekniği kullanılarak Bölüm 4.5'te anlatılmakta olan yorucu öznitelik seçme yöntemi ile İBSM, TBSM1 ve TBSM2 için en başarılı öznitelik kombinasyonları belirlenmektedir. Bu amaçla Bölüm 4.7.1'de anlatılmakta olan hata oranı performans ölçütünü en düşük yapan öznitelik kümesi belirlenmeye çalışılmaktadır (Denklem (4.39c)). Performans analiz yöntemi olarak kullanılmakta olan k-katlamalı çapraz doğrulama işlemi için k değeri 5 olarak belirlenmiştir. Çapraz doğrulama işleminde her bir öznitelik kümesi için hata oranı hesaplanırken 100 tekrar yapılmakta ve Denklem (4.40)'da gösterildiği gibi sonuçların ortalaması alınmaktadır. Bu sayede elde edilen sonuçların kesinliği artırılmaktadır.

Aynı zamanda sonuçların kesinliği hakkında yorum yapabilmesi için her bir öznitelik kümesi için yapılmakta olan çapraz doğrulama işleminin farklı tekrarları ile elde edilen sonuç kümesinin standart sapması da hesaplanmaktadır. Çapraz doğrulama işlemi, Bölüm 5.1’de anlatılmakta olan koşullara uygun olarak oluşturulmuş 170 kıl ve 170 deri örüntüsünden oluşan bir veri seti kullanılmaktadır.

Öznitelik seçme işlemi Bölüm 4.7’de anlatıldığı gibi iki farklı kategori için yapılmaktadır. İlk olarak, hızlı öznitelikler kümesi içerisinde ÖK1 belirlenmektedir (Şekil 4.28). Bir diğer öznitelik seçme işlemi ise belirlenmiş olan tüm özniteliklerin bulunduğu kümenin kullanılması ile ÖK2 belirlenmektedir (Şekil 4.29).

ÖK1’in belirlenmesi için içerisinde öznitelik seçimi yapılacak olan hızlı öznitelikler, Bölüm 5.2’de yapılan değerlendirme sonucunda 1, 2, 3, 4, 5 ve 6 numaralı öznitelikler olarak belirlenmiştir. Hızlı öznitelikler kümesinin her bir alt kümesinin performans analizi yukarıda belirtilen yöntemler kullanılarak, doğrusal çekirdek fonksiyonu kullanan DVM tekniği için yapılmıştır. DVM sınıflandırma tekniği ile kullanıldığında en düşük hata oranının elde edildiği hızlı öznitelik kombinasyonu Çizelge 5.4’te gösterilmektedir.

Çizelge 5.4. Öznitelik Kümesi 1 (ÖK1)

Sınıflandırma Tekniği	En Düşük Hata Oranını Veren Öznitelik Kümesi (Öznitelik Numaraları)	Hata Oranı	
		Ortalama	Standart Sapma
DVM (Doğrusal)	{2, 3, 4, 6}	0,0120	0.0014

Çizelge 5.4’te en başarılı öznitelik kümesi için gösterilmekte olan hata oranının standart sapmasının düşük çıktığı gözlenmektedir. Bu durum elde edilen sonuçların, farklı eğitim ve test setleri ile yapılan tekrarlar sırasında çok az değiştiğini göstermektedir. Hızlı öznitelikler arasında yapılan öznitelik seçme işlemi sonucunda 1 ve 5 numaralı özniteliklerin sınıflandırma performansını olumlu yönde etkilemediği görülmektedir.

Bir diğ er öznitelik seç me iş lemi ise hızlı ve yavaş tüm özniteliklerin bulunduğ u öznitelik kümesi içerisinden ÖK2'nin belirlenmesi için yapılmaktadır. Bölüm 4.4.1'de anlatılmakta olan 12 adet özniteliğ in bulunduğ u kümenin her bir alt kümesinin performans analizi yukarıda belirtilen yöntemler kullanılarak, doğrusal çekirdek fonksiyonu kullanan DVM tekniğ i için yapılmıştır. DVM sınıflandırma tekniğ i ile kullanıldığında en düşük hata oranının elde edildiğ i öznitelik kombinasyonu Çizelge 5.5'te ÖK2 baş lığ ı altında gösterilmektedir.

Çizelge 5.5. Öznitelik Kümesi 2 (ÖK2)

Sınıflandırma Tekniğ i	En Düşük Hata Oranını Veren Öznitelik Kümesi (Öznitelik Numaraları)	Hata Oranı	
		Ortalama	Standart Sapma
DVM (Doğrusal)	{2, 5, 8, 10}	0,0099	0.0025

Çizelge 5.5'te en başarılı öznitelik kümesi için gösterilmekte olan hata oranının standart sapmasının düşük çıktığı gözlenmektedir. Bu durum elde edilen sonuçların, farklı eğitim ve test setleri ile yapılan tekrarlar sırasında çok az değ iş tiğ ini göstermektedir. Tüm öznitelikler arasında yapılan öznitelik seç me iş lemi sonucunda 1, 3, 4, 6, 7, 9, 11 ve 12 numaralı özniteliklerin sınıflandırma performansını olumlu yönde etkilemediğ i görülmüştür.

Yapılmış olan öznitelik seç me iş lemleri sonucunda ÖK1={2, 3, 4, 6} ve ÖK2c öznitelik kümeleri olarak belirlenmiştir. Normalize edilmiş karş ıtlık değ erini temsil eden 2 numaralı özniteliğ in her iki öznitelik kümesinde de kullanıldığı gözlenmektedir. Yalnızca hızlı öznitelikleri içinde bulunduran ÖK1'i kullanan DVM sınıflandırma tekniğ inin hata oranı 0,0120 iken, yavaş özniteliklerden 8 ve 10 numaralı öznitelikleri de içinde bulunduran ÖK2'yi kullanan DVM sınıflandırma tekniğ inin hata oranı 0,0099 seviyesine düş ebilmiştir. Bundan sonraki bölümlerde İBSM, TBSM1 ve TBSM2 için yapılmakta olan testlerde ÖK1 ve ÖK2 için bu bölümde belirlenmiş olan öznitelik kümeleri kullanılmaktadır.

5.5. Tek Basamaklı ve İki Basamaklı Sınıflandırma Modelleri İçin Çapraz Doğrulama Sonuçları

Bölüm 5.4'te anlatılmakta olan öznitelik seçme işlemi yalnızca hata oranı kriteri dikkate alınarak 5-katlamalı çapraz doğrulama işleminin her bir öznitelik kümesi için 100 defa tekrarlanması ile yapılmıştır. Öznitelik seçme işlemi sonucunda elde edilmiş olan ÖK1 ve ÖK2 kullanılarak tek basamaklı ve iki basamaklı modellerin başarımları hata oranı, duyarlılık ve özgüllük kriterleri üzerinden değerlendirilmiştir. Sınıflandırma modellerinin başarımlarının öngörülebilmesi için 5-katlamalı çapraz doğrulama işlemi 500 tekrarlanarak kullanılmaktadır. Çapraz doğrulama işleminde, Bölüm 5.1'de anlatılmakta olan koşullara uygun olarak oluşturulmuş 170 kıl ve 170 deri örüntüsünden oluşan bir veri seti kullanılmaktadır.

ÖK1 ve ÖK2'yi kullanmakta olan sınıflandırma modelleri İBSM, TBSM1 ve TBSM2 sırasıyla Şekil 4.30, Şekil 4.31 ve Şekil 4.32'de gösterilmektedir. Yukarıda anlatılmakta olan koşullara uyularak TBSM1 ve TBSM2 için yapılmış olan çapraz doğrulama işleminin sonuçları sırasıyla Çizelge 5.6 ve Çizelge 5.7'de gösterilmektedir.

Çizelge 5.6. TBSM1 için performans analiz sonuçları

Hata Oranı		Duyarlılık		Özgüllük	
Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
0,0122	0,0015	0,9891	0,0010	0,9866	0,0028


Çizelge 5.7. TBSM2 için performans analiz sonuçları

Hata Oranı		Duyarlılık		Özgüllük	
Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
0,0101	0,0033	0,9924	0,0055	0,9874	0,0028


Çizelge 5.6 ve Çizelge 5.7’de gösterilmekte olan sonuçlar incelendiğinde, ayırt etme gücü daha yüksek olan öznetelikleri de içinde bulunduran ÖK2’yi kullanmakta olan TBSM2’nin performansının, ÖK1’i kullanmakta olan TBSM1’in performansının üzerine çıktığı gözlenmektedir.

Bu çalışmada önerilmekte olan İBSM’nin duyarlılık değerinin TBSM1’in duyarlılık değerinin üzerine çıkamayacağı EK A’da yapılmakta olan tartışmalar ışığında öngörülebilmektedir. Bu nedenle, İBSM’nin duyarlılık değerinin TBSM1’in duyarlılık değerinin üzerine çıkarılabilmesi için Bölüm 4.7.3’te anlatılmakta olan yöntemin kullanılması önerilmektedir. İBSM’nin duyarlılık değerinin artırılması için, İBSM’nin birinci basamağında kullanılmakta olan sınıflandırıcının taraflı maliyet matrisi ile kıl lehine eğitilmesi, ikinci basamağındaki sınıflandırıcının ise tarafsız bir şekilde eğitilmesini önerilmektedir. Bu amaçla Çizelge 4.3’te gösterilmekte olan maliyet matrisinde $M_{1,1} = 0$, $M_{2,2} = 0$ ve $M_{2,1} = 1$ sabit değerleri kullanılırken, $M_{1,2}$ değeri 1’den başlayarak artırılmakta ve oluşturulan maliyet matrisi İBSM’nin birinci basamağındaki sınıflandırıcının eğitimi sırasında ilgili Matlab fonksiyonunun ‘Cost’ parametresi olarak kullanılmaktadır (EK B).

ÖK1’i ve DVM sınıflandırma tekniğini kullanmakta olan İBSM’nin birinci basamağındaki sınıflandırıcının duyarlılık ve özgüllük değerlerinin $M_{1,2}$ ’e göre değişimi sırasıyla Şekil 5.4 ve Şekil 5.5’te gösterilmektedir. Gösterilmekte olan sonuçlar 5-katlamalı çapraz doğrulama işleminin 500 defa tekrarlanması ve sonuçların ortalamasının alınması ile elde edilmiştir.



Şekil 5.4. Maliyet matrisinin $M_{1,2}$ değerindeki değişim İBSM'nin birinci basamak duyarlılık değeri üzerindeki etkisi



Şekil 5.5. Maliyet matrisinin $M_{1,2}$ değerindeki değişim İBSM'nin birinci basamak özgüllük değeri üzerindeki etkisi

Şekil 5.4 ve Şekil 5.5'te gösterilmekte olan sonuçlar incelendiğinde maliyet matrisinin $M_{1,2}$ değerindeki artışın birinci basamak sınıflandırıcının duyarlılık değerini artırdığı, özgüllük değerini ise azalttığı gözlenmektedir. Ancak $M_{1,2} = 12$ değerinden sonra duyarlılık değerindeki artışın azaldığı ve duyarlılık değerinin bu noktadan sonra neredeyse sabitlendiği görülmektedir. Özgüllük değerinin ise $M_{1,2} = 12$ değerinden sonra da azalmaya devam ettiği görülmektedir. Özgüllük değerindeki bu azalmanın İBSM'nin sınıflandırma hızını olumsuz yönde etkileyeceği EK C'de gösterilmekte olan formüller ışığında öngörülebilmektedir. Birinci basamak özgüllük değerinin daha fazla düşmesinin önüne geçebilmek için 12 değerinin en uygun $M_{1,2}$ değeri olduğuna karar verilmiştir. Bu durumda İBSM'nin birinci basamak ve ikinci basamak sınıflandırıcılarının eğitilmesi sırasında kullanılacak olan maliyet matrisleri aşağıdaki gibi olacaktır:

$$\text{Maliyet Matrisi}_{\text{İBSM birinci basamak}} = \begin{bmatrix} 0 & 12 \\ 1 & 0 \end{bmatrix} \quad (5.2)$$

$$\text{Maliyet Matrisi}_{\text{İBSM ikinci basamak}} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \quad (5.3)$$

Denklem (5.2)'de gösterilmekte olan maliyet matrisinin kullanılması ile eğitilen İBSM birinci basamağında kullanılan DVM sınıflandırma tekniğinin hata oranı, duyarlılık ve özgüllük değerleri Çizelge 5.8'de gösterilmektedir. Gösterilmekte olan sonuçlar 5-katlamalı çapraz doğrulama işleminin 500 defa tekrarlanması ve sonuçların ortalamasının alınması ile elde edilmiştir.

Çizelge 5.8. Taraflı İBSM'nin birinci basamağında kullanılmakta olan sınıflandırıcının performans analiz sonuçları

Hata Oranı		Duyarlılık		Özgüllük	
Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
0,0247	0,0019	0,9945	0,0007	0,9561	0,0038

Çizelge 5.8'de gösterilmekte olan sonuçlar incelendiğinde, Denklem (5.2)'de gösterilmekte olan maliyet matrisi kullanılması ile İBSM'nin birinci basamak sınıflandırıcısının duyarlılık değerinin 0,9945 seviyesine çıkarılabildiği görülmektedir. Ancak birinci basamak sınıflandırıcısının özgüllük değerinin 0,9561 seviyesine düşmesi nedeniyle, İBSM'nin birinci basamak sınıflandırıcısının hata oranı Çizelge 5.6'da gösterilmekte olan TBSM1'in hata oranının iki katı seviyesine çıkmıştır. Birinci basamak sınıflandırıcısının performansı İBSM'nin genel performansını etkileyecektir ancak İBSM'nin performansının birinci ve ikinci basamak sınıflandırıcıların performanslarından bağımsız olarak değerlendirilmesi gerekmektedir.

Yukarıda anlatılmakta olan koşullara uyularak, birinci basamak sınıflandırıcısı Denklem (5.2)'de gösterilmekte olan maliyet matrisi kullanılması ile eğitilmiş olan İBSM için yapılmış olan çapraz doğrulama işleminin sonuçları Çizelge 5.9'da gösterilmektedir.

Çizelge 5.9. Birinci basamak sınıflandırıcısı Denklem (5.2)'de gösterilmekte olan maliyet matrisi kullanılarak eğitilmiş olan İBSM için performans analiz sonuçları

Hata Oranı		Duyarlılık		Özgüllük	
Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
0,0107	0.0029	0.9898	0,0044	0,9886	0,0034

İBSM'nin hata oranı, duyarlılık ve özgüllük değerlerinin, TBSM1 ve TBSM2'nin hata oranı, duyarlılık ve özgüllük değerleri ile karşılaştırılması için Çizelge 5.6, Çizelge 5.7 ve Çizelge 5.9'da gösterilmekte olan sonuçlar Çizelge 5.10'da birlikte gösterilmektedir.

Çizelge 5.10. TBSM1, TBSM2 ve İBSM için performans analiz sonuçları

Sınıflandırma Modeli	Hata Oranı		Duyarlılık		Özgüllük	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
TBSM1	0,0122	0,0015	0,9891	0,0010	0.9866	0,0028
TBSM2	0,0101	0,0033	0,9924	0,0055	0,9874	0,0028
İBSM	0,0107	0.0029	0.9898	0,0044	0,9886	0,0034

Çizelge 5.10'da gösterilmekte olan sonuçlar incelendiğinde, önerilmekte olan taraflı eğitim yöntemi sayesinde İBSM duyarlılık değerinin TBSM1'in duyarlılık değerinin üzerine çıkabildiği görülmektedir. İBSM'nin birinci basamak sınıflandırıcısının taraflı eğitimi sonucunda, birinci basamak sınıflandırıcısının duyarlılık değeri 0,9945 seviyelerine çekilebilmişti (Çizelge 5.8).

İBSM'nin birinci basamak sınıflandırıcısının taraflı eğitimi sonucunda, birinci basamak sınıflandırıcısının özgüllük değeri 0,9561 seviyelerine düşürülmüş olmasına rağmen, İBSM'nin özgüllük değeri ikinci basamak sınıflandırıcısının da etkisiyle hem TBSM1'in hem de TBSM2'nin özgüllük değerlerinin üzerine çıkarılabilmektedir. Bu

durumun temel nedeni, İBSM’de birinci basamak sınıflandırma işleminde yanlış sınıflandırılan deri örüntülerinin ikinci basamakta daha başarılı bir sınıflandırıcı tarafından tekrar sınıflandırılıyor olmasıdır. İBSM’nin özgüllük değerindeki bu artışın, İBSM’nin en önemli avantajlarından birisi olduğu düşünülmektedir.

EK A’da verilmekte olan formüllerle öngörülemediği olan İBSM’nin hata oranının ise TBSM1’in hata oranından daha düşük ve TBSM2’nin hata oranına daha yakın seviyelerde olduğu görülmektedir.

Önerilmekte olan İBSM’nin, TBSM1 ve TBSM2 ile karşılaştırılması için kullanılan bir diğer değerlendirme kriteri olan işlem süresi bir sonraki bölümde incelenmektedir.

5.6. İki Basamaklı ve Tek Basamaklı Sınıflandırma Modellerinin İşlem Süreleri

Belirlenmiş olan iki basamaklı ve tek basamaklı sınıflandırma modellerinin, bir girdi görüntüsünü sınıflandırabilmeleri için ihtiyaç duydukları işlem süresinin uygulama testleri öncesinde öngörülebilmesi için EK C’de yapılmakta olan varsayımlar altında Denklem (C.4), (C.5) ve (C.6)’da verilmekte olan formüller kullanılmaktadır. Bu formüllerde kullanılmakta olan değerlere EK D’de yer verilmektedir. İBSM, TBSM1 ve TBSM2 için Denklem (C.4), (C.5) ve (C.6)’da gösterilmekte olan formüllerin kullanılması ile elde edilmiş olan tahmini işlem süreleri Çizelge 5.11’de gösterilmektedir.

Çizelge 5.11. İBSM, TBSM1 ve TBSM2’nin 630x480 piksellik bir cilt görüntüsünü tahmini sınıflandırma süresi

Sınıflandırma Modeli	630x480 piksellik bir görüntünün 15x15 piksellik örtüşmeyen komşuluk pencereleri ile sınıflandırılma süresi (saniye)
TBSM1	~0,4143
TBSM2	~0,9989
İBSM	~0,6269

Çizelge 5.11’de gösterilmekte olan sonuçlar incelendiğinde, TBSM2’nin toplam işlem süresinin TBSM1’in işlem süresinin iki katından daha fazla olduğu görülmektedir. Bu durum, işlem karmaşıklığı yüksek olan özneliklerin (ÖK2) sınıflandırma modelinde kullanılması sonucunda sınıflandırma işleminde oluşan yavaşlamadan

kaynaklanmaktadır. Bu çalışmada önerilmekte olan İBSM'nin işlem süresinin beklenildiği gibi TBSM1'in işlem süresinden daha fazla ve TBSM2'in işlem süresinden ise daha düşük olduğu gözlenmektedir. Hem ÖK1 hem de ÖK2'yi sınıflandırma işleminde kullanmakta olan İBSM'nin işlem süresinin, yalnızca hızlı öznitelik kümesini (ÖK1) kullanmakta olan TBSM1'in işlem süresine daha yakın olması önerilmekte olan İBSM'nin hız avantajı sağlayabildiğini göstermektedir.

Çizelge 5.11'da EK C'de verilmekte olan formüllerin kullanılması ile tahmini olarak hesaplanmış olan işlem sürelerinin, bu çalışmada kullanılmakta olan görüntü kütüphanesindeki örnek cilt görüntüleri kullanılarak hesaplanması durumunda Çizelge 5.12'de gösterilmekte olan ortalama sonuçlar elde edilmiştir.


Çizelge 5.12. İBSM, TBSM1 ve TBSM2'nin 630x480 piksellik cilt görüntülerini ortalama sınıflandırma süresi (Uygulama sonuçları)

Sınıflandırma Modeli	630x480 piksellik bir görüntünün 15x15 piksellik örtüşmeyen komşuluk pencereleri ile sınıflandırılma süresi (saniye)
TBSM1	~0,4236
TBSM2	~1,0145
İBSM	~0.7215

Görüldüğü gibi uygulama testlerinde elde edilen sonuçlar ile EK C'de verilmekte olan formüllerin kullanılması ile elde edilen sonuçlar tutarlılık göstermektedir. Uygulama testlerinde de, İBSM'nin işlem süresinin TBSM2'nin işlem süresinin altında ve TBSM1'in işlem süresinin üstünde olduğu gözlenmektedir.

5.7. Görsel Değerlendirme

Bu bölümde, Bölüm 5.5 ve Bölüm 5.6'da sayısal olarak değerlendirilmiş olan TBSM1, TBSM2 ve İBSM'nin performansı, görsel bir örnek üzerinde değerlendirilmektedir. Bu amaçla, kullanılmakta olan cilt görüntüsü Şekil 5.6.(a)'da gösterilmektedir. Kullanılmakta olan cilt görüntüsünde yüzeysel yansımaların fazla olması, aydınlatmanın görüntü üzerinde düzgün bir dağılım göstermemesi, cilt çizgilerinin belirgin olması ve bazı kılların yeğnlik değerinin düşük olması nedeniyle sınıflandırma işlemi için zor bir görüntü olduğu düşünülmektedir.




Şekil 5.6. (a) 630x480 piksellik örnek cilt görüntüsü, (b) Doğruluk tablosu (Beyaz pikseller kıl bölgelerini, siyah pikseller deri bölgelerini temsil ediyor)

Şekil 5.6.(a)'da gösterilmekte olan cilt görüntüsündeki kıl bölgeleri 15x15 piksellik pencereler kullanılarak elle işaretlenmiş ve bu görüntü için bir doğruluk tablosu oluşturulmuştur. Elde edilen doğruluk tablosu Şekil 5.6.(b)'de gösterilmektedir. Beyaz pikseller kıl bölgelerini temsil ederken siyah pikseller deri bölgelerini temsil etmektedir. Doğruluk tablosu bu çalışmada kullanılmakta olan örtüşmeyen pencerelerle tarama işlemini uygun olarak oluşturulmuştur.

Şekil 5.6.(a)'da gösterilmekte olan cilt görüntüsün örtüşmeyen pencerelerle taranarak TBSM1, TBSM2 ve İBSM ile sınıflandırılması sonucunda elde edilen kıl bölgeleri, doğruluk tablosundaki kıl bölgeleri ile beraber Şekil 5.7'de gösterilmektedir. Görüntülerdeki siyah bölgeler deri olarak sınıflandırılmış bölgeleri temsil etmektedir.

Şekil 5.7'de gösterilmekte olan görsel sonuçlar incelendiğinde, sonuçların Çizelge 5.10'da gösterilmekte olan çapraz doğrulama işleminin sonuçları ile tutarlılık gösterdiği gözlenmektedir.



Şekil 5.7. (a) Elle işaretlenmiş kıl bölgeleri, (b) TBSM1 tarafından bulunan kıl bölgeleri, (c) TBSM2 tarafından bulunan kıl bölgeleri, (d) İBSM tarafından bulunan kıl bölgeleri

5.8. Sonuç

Bu çalışmada, Şekil 1.1’de çalışma şeması gösterilmekte olan nokta atımlı bilgisayar destekli lazer epilasyon sistemine yönelik olarak iki basamaklı öznitelik tabanlı sınıflandırma yöntemi geliştirilmiştir. Geliştirilen iki basamaklı sınıflandırma yönteminin performansı hız ve başarımlar kriterleri dikkate alınarak, tek basamaklı sınıflandırma modellerinin performansı ile karşılaştırılmıştır. Yapılan testler ve değerlendirmeler sonucunda önerilmekte olan İBSM’nin hızının, yalnızca hızlı öznitelikleri kullanmakta olan TBSM1’in hızına yaklaştığı ve İBSM’nin kıl-deri tespit başarımının ise ayırt etme gücü daha yüksek olan öznitelikleri de kullanmakta olan TBSM2’nin kıl-deri tespit başarımına yaklaştığı görülmüştür. Bu nedenle önerilmekte olan İBSM’nin, yavaş çalışan TBSM2’ye göre daha avantajlı bir yöntem olduğuna karar verilmiştir.

İBSM'nin performansı ile ilgili değerlendirmeler tek bir hızlı-yavaş öznitelik öbeği için yapılmıştır. Farklı hızlı-yavaş öznitelik öbekleri için performans analizlerinin yapılması durumunda daha başarılı olabilecek öznitelik alt kümelerin bulunabileceği düşünülmektedir. Bu amaçla dinamik öznitelik seçme işlemi yapabilecek bir algoritmanın geliştirilmesi planlanmaktadır.

Önerilmekte olan İBSM, lazer epilasyon uygulamasına yönelik olarak cilt görüntülerindeki kıl bölgelerinin tespit edilmesi amacıyla geliştirilmiştir. Ancak, bu modelin büyük veri setlerinde az miktarda bulunan pozitif örneklerin aranması problemlerinde de tespit başarımında ciddi bir düşüş yaşanmadan, hız artışı sağlayabileceği değerlendirilmektedir.

Bu çalışmada, İBSM'nin hız ve sınıflandırma başarımlarının daha rahat değerlendirilebilmesi için örtüşmeyen pencerelerle tarama yöntemi kullanılmıştır. Ancak, bu teknik gerçek zamanlı çalışma koşulları için uygun bir yöntem değildir. Bu nedenle, sınıflandırma işlemi öncesinde anahtar nokta tespit yönteminin kullanılması önerilmektedir. Kıl ve deri bölgelerini ayırt etmek için çıkarılmış olan öznitelikler değerlendirilerek, bölgesel minimum tabanlı anahtar nokta çıkarma yöntemlerinin başarılı olabileceği öngörülebilmektedir.

KAYNAKLAR

- [1] “2013 Cosmetic Surgery National Data Bank Statistics”, American Society of Aesthetic Plastic Surgery, erişim adresi: http://www.surgery.org/sites/default/files/Stats2013_3.pdf, erişim tarihi: 12 Eylül 2014.
- [2] Nanni, C.A., Alster, T.S., Laser-assisted hair removal: side effects of Q-switched Nd:YAG, long-pulsed ruby, and alexandrite lasers, *Journal of American Academy of Dermatology*, 41(2), 165-171, Mart 1999.
- [3] MEGEB Güzellik ve Saç Bakım Hizmetleri: Epilasyon, T.C. Milli Eğitim Bakanlığı, Ankara, 2008.
- [4] Ort, R.J., Anderson, R.R., Optical Hair Removal, *Seminars in Cutaneous Medicine and Surgery*, 18(2), 149-158, Haziran 2009.
- [5] Dierickx, C.C., *Laser Hair Removal: Scientific Principles and Practical Aspects*, Lumenis Inc., Santa Clara, U.S.A., 2002
- [6] Lin, T.Y., Manuskiatti, W., Dierickx, C.C., Hair Growth Cycle Affects Hair Follicle Destruction by Ruby Laser Pulses, *Journal of Investigative Dermatology*, 111(1), 107-113, 1998.
- [7] Marchell, N.L., Alster, T.S., Evaluation of Hair Removal Methods, *Aesthetic Dermatology and Cosmetic Surgery*, 1(1), 3-11, 1999.
- [8] Elise, A.O., Methods of Hair Removal, *Journal of the American Academy of Dermatology*, 40(2), 143-155, Şubat 1999.
- [9] Van Scott, E.J., Ekel, T.M., Auerbach, R., Determinants of Rate and Kinetics of Cell Division in Scalp Hair, *Journal of Investigative Dermatology*, 41, 269-273, Kasım 1963.
- [10] Kligman, A.M., The Human Hair Cycle, *Journal of Investigative Dermatology*, 33, 3007-316, 1959.
- [11] Cotsarelis, G., Sun, T.T., Lavker, R.M., Label-retaining cells reside in the bulge area of pilosebaceous unit: implications for follicular stem cells, hair cycle, and skin carcinogenesis, *Cell*, 61(7), 1329-1337, Haziran 1990.
- [12] Braun-Falco, O., Heilgemeir, G.P., The Trichogram, *Structural and Functional Basis, Performance and Interpretation*, *Seminars in Dermatology*, 4(1), 40-52, 1985.
- [13] “The Fitzpatrick Skin Type Classification Scale”, erişim adresi: <http://www.skininc.com/skinscience/physiology/10764816.html>, erişim tarihi: 12 Eylül 2014.
- [14] Sachdeva, S., Fitzpatrick skin typing: Applications in dermatology, *Indian Journal of Dermatology*, 75(1), 93-96, Ocak 2009.
- [15] Kirsten, H., 2007, The History of American Women and Hair Removal, 1914-1934, *Lisans Tezi, Columbia University American Studies Barnard College*, New York, U.S.A.
- [16] Styczynski, P., Oblong, J., “Ahluwalia, G.S., Removal of Unwanted Facial Hair” in *Cosmetic applications of laser and light-based systems*, chapter 6, 157-179, *William Andrew*, Norwich, New York, U.S.A., 2008.
- [17] Wagner, R.F., Jr., Tomich, J.M., Grande, D.J., Electrolysis and thermolysis for permanent hair removal, *Journal of the American Academy of Dermatology*, 12(3), 441-449, Mart 1985.

- [18] "How Electrolysis Works", erişim adresi: <http://www.electrolysisbyleah.com/>, erişim tarihi: 12 Eylül 2014.
- [19] Richards, R.N., Meharg, G.E., Electrolysis: Observations from 13 years and 140,000 hours of experience, *Journal of the American Academy of Dermatology*, 33(4), 662-666, Ekim 1995.
- [20] Wagner, R.F., Jr., Medical and technical issues in office electrolysis and thermolysis, *The Journal of Dermatologic Surgery and Oncology*, 19(6), 575-57, Haziran 1993.
- [21] Wheeland, R.G., Laser-assisted hair removal, *Dermatologic Clinics*, 15(3), 469-477, Temmuz 1997.
- [22] Hobbs, E.R., Ratz, J.L., James, B., Electrosurgical epilation, *Dermatologic Clinics*, 5(2), 437-444, Nisan 1987.
- [23] Sarkar, P., Hirsch, R.J., Update on laser hair removal, *Cosmetic Dermatology*, 20, 440-444, 2007.
- [24] Dierickx, C.C., Hair removal by lasers and intense pulsed light sources, *Dermatologic Clinics*, 20(1), 135-146, Ocak 2002.
- [25] Goldberg, D.J., Hair removal using lighth-based systems, in *Cosmetic applications of laser and light-based systems*, chapter 5, 145-156, William Andrew, Norwich, New York, U.S.A., 2008.
- [26] Gan, S.D., Graber, E.M., Laser hair removal: A review, *Dermatologic Surgery*, 39(6), 823-838, Haziran 2013.
- [27] Geiges, M.L., History of Lasers in Dermatology, in *Current Problems in Dermatology*, 42, 1-6, Karger, Basel, Switzerland, 2011.
- [28] Aba, G., Lazer epilasyon ile ilgili temel bilgiler, İ.Ü. Cerrahpaşa Tıp Fakültesi Sürekli Tıp Eğitimi Etkinlikleri Adölesan Sağlığı Sempozyum Dizisi No:43, 179-182, İstanbul, Mart 2005.
- [29] Grossman, M.C., Dierickx, C., Farinelli, W., Flotte, T., Damage to hair follicles by normal-mode ruby laser pulses, *Journal of the American Academy of Dermatology*, 35(6), 889-894, Aralık 1996.
- [30] Tanzi, E.L., Lupton, J.R., Alster, T.S., Lasers in dermatology: Four decades of progress, *Journal of the American Academy of Dermatology*, 49(1), 1-34, Temmuz 2003.
- [31] Rangwala, S., Rashid, R.M., Alopecia: a review of laser and light therapies, *Dermatology Online Journal*, 18(2), 3, 2012.
- [32] Anderson, R.R., Parrish, J.A., Selective photothermolysis: precise microsurgery by selective absorption of pulsed radiation, *Science*, 220(4596), 524-527, Nisan 1983.
- [33] Althuler, G.B., Yaroslavsky, I., Absorption Characteristics of Tissues as a Basis for the Optimal Wavelength Choice on Photodermatology, Palomar Medical Technologies, Burlington, Massachusetts, U.S.A., 2004.
- [34] Allemann, I.B., Kaufman, J., Laser Principles, in *Current Problems in Dermatology*, 42, 7-23, Karger, Basel, Switzerland, 2011.
- [35] Stratigos, A.J., Dover, J.S., Overview of lasers and their properties, *Dermatologic Therapy*, 13(1), 2-16, Ocak 2000.
- [36] Bashkatov, A.N., Genina, E.A., Kochubey, V.I., Tuchin, V.V., Optical properties of human skin, subcutaneous and mucous tissues in the wavelength

- range from 400 to 2000 nm, *Journal of Physics D: Applied Physics*, 38(15), 2543-2555, Temmuz 2005.
- [37] Dierickx, C.C., Hair removal by lasers and intense pulsed light sources, *Seminars in Cutaneous Medicine and Surgery*, 19(4), 267-275, Aralık 2000.
- [38] Goldman L., Blaney, D.J., Kindel D.J., Pathology of the effect of the laser beam on the skin, *Nature*, 197, 912-914, Mart 1963.
- [39] Gold, M.G., Lasers and light sources for the removal of unwanted hair, *Clinics in Dermatology*, 25, 443-453, 2007.
- [40] Nanni, C.A., Alster, T.S., A practical review of laser-assisted hair removal using the Q-switched Nd:YAG, long-pulsed ruby, and long-pulsed alexandrite lasers, *Dermatologic Surgery*, 24(12), 1399-1405, Aralık 1998.
- [41] Royo, J., Urdiales, F., Moreno, J., Al-Zarauni, M., Cornejo, P., Trelles, M.A., Six-month follow-up multicenter prospective study of 368 patients, phototypes III to V, on epilation efficacy using an 810-nm diode laser at low fluence, *Lasers in Medical Science*, 26(2), 247-255, Mart 2011.
- [42] Alster, T.S., Bryan, H., Williams, C.M., Long-pulsed Nd:YAG laser-assisted hair removal in pigmented skin: a clinical and histological evaluation, *Archives of Dermatology*, 137(7), 885-889, Temmuz 2001.
- [43] Gan, S.D., Graber, E.M., Laser hair removal: A review, *Dermatologic Surgery*, 39(6), 823-838, Haziran 2013.
- [44] Babilas, P., Schreml, S., Szeimies, R.M., Landthaler, M., Intense pulsed light (IPL): A Review, *Lasers in Surgery and Medicine*, 42, 93-104, 2010.
- [45] Ort, R.J., Dierickx, C., Laser Hair Removal, *Seminars in Cutaneous Medicine and Surgery*, 21(2), 129-144, Haziran 2002.
- [46] Lanigan, S.W., Incidence of side effects after laser hair removal, *Journal of the American Academy of Dermatology*, 49(5), 882-886, 2003.
- [47] AlNomair, N., Nazarian, R., Marmur, E., Complications in lasers, lights, and radiofrequency devices, *Facial Plastic Surgery*, 28(3), 340-346, 2012.
- [48] Lapidoth, M., Shafirstein, G., Amitai, D.B., Hodak, E., Waner, M., David, M., Reticulate erythema following diode laser-assisted hair removal: a new side effect of a common procedure, *Journal of the American Academy of Dermatology*, 55(5), 774-777, 2004.
- [49] Abbas, Q., Celebi, M. E., Garcia, I. F., Hair removal methods: A comparative study for dermoscopy images, *Biomedical Signal Processing and Control* 6, 2011.
- [50] Fiorese, M., Peserico, E., Silletti, A., VirtualShave: automated hair removal from digital dermatoscopic images, 33rd Annual International Conference of the IEEE EMBS, Boston, Massachusetts USA, August 30 - September 3, 2011.
- [51] Zou, Y., Song, E., Li, G., Jin, R., Automatic Detection of Fine Hairs in Skin Aging Analysis, *The 2nd International Conference on Bioinformatics and Biomedical Engineering ICBBE 2008*, 2349-2352, Shanghai, Mayıs, 2008.
- [52] Nguyen, N. H., Lee, T. K., Atkins, M. S., Segmentation of light and dark hair in dermoscopic images: a hybrid approach using a universal kernel, *Medical Imaging 2010: Image Processing*, SPIE, 2010.
- [53] Vincent, L., "Morphological Grayscale Reconstruction in Image Analysis: Applications and Efficient Algorithms," *IEEE Transactions on Image Processing*, 2(2), 176-201, Nisan 1993.

- [54] Gonzalez, R.C., Woods, R.E., Eddins, S.L., Digital Image Processing Using MATLAB, chapter 11, Prentice Hall, New Jersey, 2003.
- [55] Bishop, C.M., Pattern Recognition and Machine Learning, *Springer*, New York, 2006.
- [56] Guyon, I., An Introduction to Variable and Feature Selection, The Journal of Machine Learning Research, 3(3), 1157-1182, 2003.
- [57] Alpaydm, E., Introduction to Machine Learning, Second Edition, *The MIT Press*, Cambridge, Massachusetts, 2010.
- [58] Theodoridis, S., Koutroumbas, K., Pattern Recognition, Second Edition, *Elsevier Academic Press*, Amsterdam, 2003.
- [59] Fisher, R.A., The use of multiple measurements in taxonomic problems, *Annals of Eugenics*, 7(2), 179–188, Eylül 1936.
- [60] Cover, T., Hart, P., Nearest Neighbor Pattern Classification, *IEEE Transactions on Information Theory*, 13(1), 21-27, Ocak 1967.
- [61] Bontempi, G., Birattari, M., Bersini, H., Lazy learning for local modelling and control design, *International Journal of Control*, 72(7/8), 643-658, 1999.
- [62] S.A. Dudani, S.A., The distance-weighted k-nearest-neighbor rule. *Systems*, *IEEE Transactions on Systems Man and Cybernetics*, 6(4), 325-327, 1976.
- [63] Russel, S., Norvig, P., Artificial Intelligence: A Modern Approach, *Pearson*, Prentice Hall, Upper Saddle River, New Jersey, 2003.
- [64] Quinlan, J.R., Induction of Decision Trees, *Machine Learning*, 1(1), 81-106, Mart 1986.
- [65] Quinlan, J.R., C4.5: Programs for Machine Learning, *Machine Learning*, 16(3), 235-240, Eylül 1994.
- [66] Friedman, J.H., Multivariate Adaptive Regression Splines, *The Annals of Statistics*, 19(1), 1-67, Mart 1991.
- [67] Breiman, L., Friedman, J., Olshen, R., Stone, C., Classification and Regression Trees, *Chapman and Hall/CRC Press*, Boca Raton, Fla, USA, Ocak 1984.
- [68] Kass, G.V., An exploratory technique for investigating large quantities of categorical data, *Applied Statistics*, 29(2), 119–127, 1980.
- [69] Loh W.Y., Shih, Y.S., Split selection methods for classification trees, *Statistica Sinica*, 7, 815–840, 1997.
- [70] Wu, X., Kumar, V., CART: Classification and Regression Trees, Top Ten Algorithms in Data Mining, *Chapman and Hall/ CRC Press*, Boca Raton, Fla, USA, 179-203, 2009.
- [71] Vapnik, V., The Nature of Statistical Learning Theory, *Springer-Verlag*, New York, 1995.

EKLER

EK A : İBSM'nin Kıl ve Deri Tespit Başarımının TBSM1 ve TBSM2'nin Kıl ve Deri Tespit Başarımlarına Göre Değişimi

Sınıflandırma işleminde hız artışı sağlayabilmek için bu çalışmada önerilmekte olan iki aşamalı sınıflandırma yönteminde, Bölüm 4.7.1'de belirlenmiş olan performans değerlerinin önceden öngörülebilmesi için birinci basamak ve ikinci basamak sınıflandırıcıların performans analiz sonuçlarının iki basamaklı sınıflandırma yöntemine uyarlanarak yeniden değerlendirilmesi gerekmektedir. Bu amaçla aşağıda açıklanacak olan formülasyonlarda kullanılmak üzere birinci basamak sınıflandırıcı performans ölçütleri *hata oranı*₁, *duyarlılık*₁ ve *özgüllük*₁ olarak isimlendirilirken, ikinci basamak sınıflandırıcı performans ölçütleri ise *hata oranı*₂, *duyarlılık*₂ ve *özgüllük*₂ olarak isimlendirilmektedir. Dikkat edilmesi gereken en önemli konu, birinci basamak sınıflandırıcı performans ölçütleri tüm veri seti kullanılarak hesaplanırken, ikinci basamak sınıflandırıcı performans ölçütleri ise yalnızca birinci aşama sonucunda kıl (pozitif) olarak sınıflandırılmış veri seti kullanılarak hesaplanmış olmak zorundadır.

Önerilmekte olan İBSM'nin kullandığı en önemli kriter birinci basamakta kıl olarak tespit edilebilmiş olan bölgelerin ikinci basamakta tekrar sınıflandırılacak olmasıdır. Bir başka deyişle, birinci basamak sınıflandırma işlemi sonunda doğru pozitif ve yanlış pozitif olarak değerlendirmiş olan bölgeler ikinci basamak sınıflandırıcıda tekrar değerlendirilirken, birinci basamak sınıflandırma işlemi sonucunda doğru negatif ve yanlış negatif olarak değerlendirilmiş bölgeler ikinci aşamada tekrar değerlendirilmeyecektir.

Çizelge A.1. Birinci basamak kıl ve deri sınıfları karışıklık matrisi

		Tahmin Edilen Sınıf	
		Kıl (Pozitif)	Deri (Negatif)
Gerçek Sınıf	Kıl (Pozitif)	DP ₁	YN ₁
	Deri (Negatif)	YP ₁	DN ₁

Çizelge A.1’de gösterilmekte olan birinci basamak kıl ve deri sınıfları karışıklık matrisinde yalnızca yeşil ile işaretlenmiş olan veriler ikinci basamakta tekrar sınıflandırılmaktadır. Yalnızca DP_1 ve YP_1 kümelerinde bulunan verilerin ikinci basamak sınıflandırma işleminden de geçirilmesi durumunda İBSM için oluşan kıl ve deri sınıfları karışıklık matrisi Çizelge A.2’de gösterildiği gibi olmaktadır.

Çizelge A.2. İkinci basamak sınıflandırma işlemi sonucunda oluşan kıl ve deri sınıfları karışıklık matrisi

		Tahmin Edilen Sınıf	
		Kıl (Pozitif)	Deri (Negatif)
Gerçek Sınıf	Kıl (Pozitif)	$DP_1 \times Duyarlilik_2$	$YN_1 + DP_1 \times (1 - Duyarlilik_2)$
	Deri (Negatif)	$YP_1 \times (1 - Özgüllük_2)$	$DN_1 + YP_1 \times Özgüllük_2$

İki basamaklı sınıflandırma işlemleri sonucunda oluşan karışıklık matrisi dikkate alınarak duyarlılık, özgüllük ve hata oranı değerlerini yeniden düzenleyecek olursa,

$$\rightarrow Duyarlilik_{iBSM} = \frac{DP_1 \times Duyarlilik_2}{DP_1 \times Duyarlilik_2 + YN_1 + DP_1 \times (1 - Duyarlilik_2)}$$

$$\rightarrow Duyarlilik_{iBSM} = \frac{DP_1 \times Duyarlilik_2}{YN_1 + DP_1}$$

$$\rightarrow Duyarlilik_{iBSM} = Duyarlilik_1 \times Duyarlilik_2 \quad (A.1a)$$

$$\rightarrow Özgüllük_{iBSM} = \frac{DN_1 + YP_1 \times Özgüllük_2}{DN_1 + YP_1 \times Özgüllük_2 + YP_1 \times (1 - Özgüllük_2)}$$

$$\rightarrow Özgüllük_{iBSM} = \frac{DN_1 + YP_1 \times Özgüllük_2}{DN_1 + YP_1}$$

$$\rightarrow \text{Özgüllük}_{iBSM} = \text{Özgüllük}_1 + \frac{YP_1 \times \text{Özgüllük}_2}{DN_1 + YP_1}$$

$$\rightarrow \text{Özgüllük}_{iBSM} = \text{Özgüllük}_1 + (1 - \text{Özgüllük}_1) \times \text{Özgüllük}_2 \quad (\text{A.1b})$$

$$\rightarrow \text{Hata Oranı}_{iBSM} = \frac{YN_1 + DP_1 \times (1 - \text{Duyarlılık}_2) + YP_1 \times (1 - \text{Özgüllük}_2)}{YN_1 + YP_1 + DP_1 + DN_1}$$

$$\rightarrow \text{Hata Oranı}_{iBSM} = \frac{YN_1 + YP_1 + DP_1 \times (1 - \text{Duyarlılık}_2) - YP_1 \times \text{Özgüllük}_2}{YN_1 + YP_1 + DP_1 + DN_1}$$

$$\rightarrow \text{Hata Oranı}_{iBSM} = \text{Hata Oranı}_1 + \frac{DP_1 \times (1 - \text{Duyarlılık}_2)}{YN_1 + YP_1 + DP_1 + DN_1}$$

$$- \frac{YP_1 \times \text{Özgüllük}_2}{YN_1 + YP_1 + DP_1 + DN_1}$$

Veri setinde başlangıçta eşit sayıda kıl ve deri örneği bulunduğunu varsayarsak,

$$\rightarrow DP_1 + YN_1 = YP_1 + DN_1 \text{ olacaktır.}$$

$$\rightarrow \text{Hata Oranı}_{iBSM} = \text{Hata Oranı}_1 + \frac{DP_1 \times (1 - \text{Duyarlılık}_2)}{2 \times (DP_1 + YN_1)}$$

$$- \frac{YP_1 \times \text{Özgüllük}_2}{2 \times (YP_1 + DN)}$$

$$\rightarrow \text{Hata Oranı}_{iBSM} =$$

$$\text{Hata Oranı}_1 + \frac{\text{Duyarlılık}_1 \times (1 - \text{Duyarlılık}_2)}{2} \quad (\text{A.1c})$$

$$- \frac{(1 - \text{Özgüllük}_1) \times \text{Özgüllük}_2}{2}$$

Denklem (A.1a) ve (A.1b)'de verilen formüllerden de anlaşılacağı gibi İBSM'nin duyarlılık ve özgüllük değerleri, hiçbir koşul olmaksızın birinci ve ikinci basamak

sınıflandırıcıların duyarlılık ve özgülük değerleri kullanılarak hesaplanabilmektedir. İki basamaklı modelin hata oranı ise Denklem (A.1c)'de verilen formül kullanılarak, veri setinde eşit sayıda pozitif ve negatif örnek olması koşulu ile birinci ve ikinci basamak sınıflandırma modellerinin hata oranı, duyarlılık ve özgülük değerleri kullanılarak hesaplanabilmektedir.

Denklem (A.1a)'da gösterilmekte olan İBSM'nin duyarlılık denkleminde anlaşılabilirliği gibi kıl bulma başarımı, birinci basamak ve ikinci basamak sınıflandırıcıların kıl bulma başarımına göre katlanarak düşmektedir. Denklem (A.1b)'de gösterilmekte olan İBSM'nin deri bulma başarımının ise birinci basamak sınıflandırıcıya göre artış gösterdiği gözlenmektedir. Bu durumun temel nedeni sırasıyla,

- Birinci basamak sınıflandırma işleminde yanlış sınıflandırılmış olan pozitif (kıl) örnekler ikinci aşamada tekrar sınıflandırılmayacaktır. Birinci basamak sınıflandırma işleminde yanlış sınıflandırılan pozitif örnekler ikinci basamakta yanlış sınıflandırılan pozitif örneklerin de eklenmesi ile yanlış sınıflandırılan pozitif örneklerin sayısı daha da artacaktır. Bu nedenle İBSM'nin kıl tespit başarımı ($duyarlılık_{İBSM}$) birinci ve ikinci basamak sınıflandırıcıların kıl tespit başarımlarından ($duyarlılık_1$ ve $duyarlılık_2$) daha yüksek olamaz.
- Veri setindeki negatif (deri) örnekler içinden birinci basamak sınıflandırma işleminde yanlış sınıflandırılmış olan örnekler ikinci basamakta yeniden sınıflandırma işleminden geçmektedir. Bu nedenle İBSM'nin deri tespit başarımının ($özgüllük_{İBSM}$) birinci basamak sınıflandırıcısının deri tespit başarımından ($özgüllük_1$) daha düşük olması mümkün değildir.

Önerilmekte olan İBSM'de elde edilen toplam hata oranının artması veya azalması birinci ve ikinci basamak özgülük ve duyarlılık değerlerinin tamamına ve birinci basamak hata oranına bağlıdır. İBSM'nin hata oranının birinci ve ikinci basamak sınıflandırıcıların hata oranına göre artması veya azalması birden fazla faktöre bağlı olduğu için önceden öngörülmesi daha zordur.

İBSM'nin birinci basamağında kullanılan sınıflandırıcının performans ölçütleri olan *hata oranı*₁, *duyarlılık*₁ ve *özgüllük*₁ değerleri daha önce belirtildiği gibi tüm veri seti kullanılarak hesaplanmaktadır. Bu nedenle TBSM1 ile aynı öznelik kümesini (ÖK1) ve sınıflandırma tekniğini kullanan ve performans ölçütleri TBSM1 ile aynı veri seti kullanılarak hesaplanabilecek olan İBSM'nin birinci basamağında kullanılan sınıflandırıcının performans ölçütlerinin (*hata oranı*₁, *duyarlılık*₁ ve *özgüllük*₁) TBSM1'in performans ölçütleri ile aynı olması beklenmektedir.

İBSM'nin ikinci basamağında kullanılan sınıflandırıcının performans ölçütleri olan *hata oranı*₂, *duyarlılık*₂ ve *özgüllük*₂ değerleri ise yalnızca birinci basamak sonucunda kıl (pozitif) olarak sınıflandırılmış olan veri seti kullanılarak hesaplanmış olmak zorundadır. İBSM'nin ikinci basamağında kullanılan sınıflandırıcı, TBSM2 ile aynı öznelik kümesini (ÖK2) ve sınıflandırma tekniğini kullanmaktadır. Buna rağmen İBSM'nin ikinci basamağında kullanılan sınıflandırıcının ve TBSM2'nin performans ölçütleri hesaplanırken kullanılan veri setlerinin farklı olması nedeniyle, yukarıdaki formüllerde kullanılmakta olan *hata oranı*₂, *duyarlılık*₂ ve *özgüllük*₂ değerleri TBSM2'nin performans ölçütleri ile aynı değildir. İBSM'nin ikinci basamağındaki sınıflandırıcının deri tespit başarımının (*özgüllük*₂), TBSM2'nin deri tespit başarımından daha düşük çıkması beklenmektedir. Çünkü İBSM'nin ikinci basamağında kullanılan sınıflandırıcının özgüllük değeri hesaplanırken sınıflandırılması zor olan (birinci basamakta yanlış sınıflandırılmış) deri örüntüleri kullanılacaktır. İBSM'nin ikinci basamağındaki sınıflandırıcının kıl tespit başarımının (*duyarlılık*₂), TBSM2'nin kıl tespit başarımından daha yüksek çıkması beklenmektedir. Çünkü İBSM'nin ikinci basamağında kullanılan sınıflandırıcının duyarlılık değeri hesaplanırken sınıflandırılması kolay olan (birinci basamakta doğru sınıflandırılmış) kıl örüntüleri kullanılacaktır.

Yukarıda İBSM'nin birinci ve ikinci basamağında kullanılan sınıflandırma modellerinin performans ölçütleri sırasıyla TBSM1 ve TBSM2'nin performans ölçütleri ile karşılaştırılmıştır. Bunun sayede İBSM'nin kıl ve deri tespit başarımları TBSM1 ve TBSM2'nin kıl ve deri tespit başarımları temel alınarak önceden öngörülmeye çalışılmaktadır. Yukarıda belirtildiği gibi Denklem (A.1a), (A.1b) ve

(A.1c)'de kullanılmakta olan *hata oranı*₁, *duyarlılık*₁ ve *özgüllük*₁ değerleri TBSM1'in performans ölçütleri ile aynıdır. Denklem (A.1a), (A.1b) ve (A.1c)'de kullanılmakta olan *özgüllük*₂ değeri TBSM2'nin özgüllük değerine eşit veya ondan daha düşükken, *duyarlılık*₂ değeri TBSM2'nin duyarlılık değerine eşit veya ondan daha yüksektir.

Yukarıda yapılmış olan alan açıklamalar ve Denklem (A.1a), (A.1b) ve (A.1c)'de verilmiş olan formüller dikkate alınarak, İBSM'nin kıl ve deri tespit başarımı TBSM1 ve TBSM2'nin kıl ve deri tespit başarımına göre yeniden değerlendirilecek olursa,

- İBSM modelinin kıl tespit başarımı (*duyarlılık*_{İBSM}) TBSM1'in kıl tespit başarımından (*duyarlılık*₁) daha yüksek olamaz.
- İBSM modelinin deri tespit başarımı (*özgüllük*_{İBSM}) TBSM1'in kıl tespit başarımından (*özgüllük*₁) daha düşük olamaz.
- İBSM modelinin kıl ve deri tespit başarımları, doğrudan TBSM1'in kıl ve deri tespit başarımları üzerinden öngörülemez.

EK B : Sınıflandırma İşlemlerinde Kullanılmakta Olan Yerleşik Matlab Fonksiyonları

Çizelge B.1. Bu çalışmada sınıflandırma işlemlerinde kullanılmakta olan Matlab fonksiyonları

Sınıflandırma Teknikleri	Kullanılan Matlab Fonksiyonları
LDA	<code>fitcdiscr(Training, Group, Name, Value)</code>
NB	<code>fitNaiveBayes(Training, Group, Name, Value)</code>
SVM	<code>fitcsvm(Training, Group, Name, Value)</code>
KA	<code>fitctree(Training, Group, Name, Value)</code>
K-NN	<code>knnclassify(Sample, Training, Group, k)</code>

Çizelge B.1’de verilmiş olan fonksiyonlar Matlab yazılımının R2014a versiyonunda “Statistics and Machine Learning” ve “Bioinformatics” kütüphanelerinde bulunmaktadır. Bu fonksiyonların parametrelerinden, “Training” eğitimde kullanılan öznitelik vektörünü, “Group” eğitimde kullanılan öznitelik vektörünün sınıf etiketlerini, “Name” ilgili fonksiyonun parametre ismini ve “Value” ilgili parametrenin girdi değerini temsil etmektedir. Çizelge B.1’de gösterilmekte olan fonksiyonlarla ilgili daha detaylı tartışmalara The MathWorks Inc.’in resmi internet sitesi olan <http://www.mathworks.com/> adresinden ulaşılabilir.

Bu çalışmada, belirtilmediği takdirde ilgili Matlab fonksiyonlarının parametreleri varsayılan değerler olarak kullanılmaktadır.

EK C : İBSM, TBSM1 ve TBSM2'nin İşlem Süreleri

Bu çalışmada önerilmekte olan ve Şekil 4.30'de gösterilen İBSM'nin bir girdi görüntüsündeki kıl ve deri bölgelerini sınıflandırması için ihtiyaç duyduğu toplam sürenin, Denklem (C.1)'de verilmekte olan formül kullanılarak önceden öngörülebileceği değerlendirilmektedir. Denklem (C.1)'de verilmiş olan formül ile ilgili dikkat edilmesi gereken en önemli husus İBSM'nin birinci basamak sınıflandırma işlemi sırasında hesaplanmış olan özneliklerin ikinci basamak sınıflandırma işleminde tekrar hesaplanmasına ihtiyaç duyulmamasıdır. İBSM'nin ikinci basamak sınıflandırma işlemi sırasında birinci basamakta değerlendirilmiş olan örüntüler kullanılmaktadır ve her iki basamakta da kullanılmakta olan ortak özneliklerin yalnızca birinci basamakta hesaplanması yeterlidir. Bu sayede işlem masrafının artması engellenmektedir.

$$t_{İBSM} = \left(\left(t_{\text{öznelik hesaplama}}(\text{ÖK1}) + t_{\text{sınıflandırma}}(\text{model}_1, \text{ÖK1}, x_1) \right. \right. \quad (\text{C.1}) \\ \left. \left. + t_{\text{diğer1}} \right) \times \left(\frac{A_{\text{görüntü}}}{A_{\text{pencere}}} \right) \right) + \left(\left(t_{\text{öznelik hesaplama}}(\text{ÖK2} - \text{ÖK1}) \right. \right. \\ \left. \left. + t_{\text{sınıflandırma}}(\text{model}_2, \text{ÖK2}, x_2) + t_{\text{diğer2}} \right) \times \left(\frac{A_{\text{görüntü}} \times d_{\text{kıl}} \times \text{duyarlılık}_1}{A_{\text{pencere}}} \right. \right. \\ \left. \left. + \frac{A_{\text{görüntü}} \times (1 - d_{\text{kıl}}) \times (1 - \text{özgüllük}_1)}{A_{\text{pencere}}} \right) \right)$$

ÖK1= 1. basamak sınıflandırma işleminde kullanılmakta olan ve hızlı öznelikler arasından seçilmiş olan öznelik kümesi

ÖK2= 2. basamak sınıflandırma işleminde kullanılmakta olan ve tüm öznelikler arasından seçilmiş olan öznelik kümesi

(ÖK2 – ÖK1) = Yalnızca 2. basamak sınıflandırma işlemi sırasında hesaplanması yeterli olan öznelik kümesi

$t_{\text{öznitelik hesaplama}}(\text{ÖK1}) = 1.$ basamak sınıflandırma işleminde kullanılmakta olan özniteliklerin varsayılan pencere boyutundaki bir örüntü için ortalama hesaplama süresi

$t_{\text{öznitelik hesaplama}}(\text{ÖK2} - \text{ÖK1}) =$ Yalnızca 2. Basamak sınıflandırma işleminde hesaplanması yeterli olan özniteliklerin varsayılan pencere boyutundaki bir örüntü için hesaplama süresi

$model_1 = 1.$ basamak sınıflandırma işleminde kullanılan sınıflandırma tekniği (DAA, NB, SVM, KA, K-NN)

$model_2 = 2.$ basamak sınıflandırma işleminde kullanılan sınıflandırma tekniği (DAA, NB, SVM, KA, K-NN)

$t_{\text{sınıflandırma}}(model_1, \text{ÖK1}, x_1) = 1.$ basamakta kullanılan sınıflandırma tekniğinin ÖK1'i kullanılarak eğitilmesi sonucunda oluşan sınıflandırıcının x_1 öznitelik vektörünü ortalama hesaplama süresi. x_1 öznitelik vektörünün uzunluğu ÖK1 öznitelik kümesinin eleman sayısı kadardır.

$t_{\text{sınıflandırma}}(model_2, \text{ÖK2}, x_2) = 2.$ basamakta kullanılan sınıflandırma tekniğinin ÖK2'i kullanılarak eğitilmesi sonucunda oluşan sınıflandırıcının x_2 öznitelik vektörünü ortalama hesaplama süresi. x_2 öznitelik vektörünün uzunluğu ÖK2 öznitelik kümesinin eleman sayısı kadardır.

$t_{\text{diğer1}} = 1.$ basamak sınıflandırma işlemi sırasında öznitelik hesaplama ve öznitelik vektörü sınıflandırma işlemleri dışında yapılan diğer işlemlerin ortalama süresi

$t_{\text{diğer2}} = 2.$ basamak sınıflandırma işlemi sırasında öznitelik hesaplama ve öznitelik vektörü sınıflandırma işlemleri dışında yapılan diğer işlemlerin ortalama süresi

$A_{görüntü}$ = Tarama yapılan cilt görüntüsündeki toplam piksel sayısı
(Varsayılan değer: 630x480 piksel)

$A_{pencere}$ = Komşuluk penceresindeki toplam piksel sayısı (Varsayılan
değer: 15x15 piksel)

$d_{kıl}$ = Tarama yapılan cilt görüntüsündeki pozitif (kıl) bölgelerin
alanının toplam görüntü alanına oranı (Kıl yoğunluğu)

$duyarlılık_1$ = 1. Basamak sınıflandırıcının kıl tespit başarımı

$özgüllük_1$ = 1. Basamak sınıflandırıcının deri tespit başarımı

TBSM1'in bir girdi görüntüsündeki kıl ve deri bölgelerini sınıflandırması için ihtiyaç duyduğu toplam sürenin, aşağıda verilmekte olan formül kullanılarak önceden öngörülebileceği değerlendirilmektedir:

$$t_{TBSM1} = \left((t_{öznitelik\ hesaplama}(ÖK1) + t_{sınıflandırma}(model_1, ÖK1, x_1) + t_{diğerTek1}) \times \left(\frac{A_{görüntü}}{A_{pencere}} \right) \right) \quad (C.2)$$

ÖK1= TBSM1'de kullanılmakta olan ve hızlı öznitelikler arasından seçilmiş olan öznitelik kümesi

$t_{öznitelik\ hesaplama}(ÖK1)$ = TBSM1'de kullanılmakta olan özniteliklerin varsayılan pencere boyutundaki bir örüntü için ortalama hesaplanma süresi

$model_1$ = TBSM1'de kullanılan sınıflandırma tekniği (DAA, NB, SVM, KA, K-NN)

$t_{sınıflandırma}(model_1, ÖK1, x_1)$ = TBSM1'de kullanılan sınıflandırma tekniğinin ÖK1'i kullanılarak eğitilmesi sonucunda oluşan

sınıflandırıcının x_1 öznitelik vektörünü ortalama hesaplama süresi. x_1 öznitelik vektörünün uzunluğu ÖK1 öznitelik kümesinin eleman sayısı kadardır.

$t_{diğerTek1}$ = TBSM1’de sınıflandırma işlemi sırasında öznitelik hesaplama ve öznitelik vektörü sınıflandırma işlemleri dışında yapılan diğer işlemlerin ortalama süresi

$A_{görüntü}$ = Tarama yapılan cilt görüntüsündeki toplam piksel sayısı (Varsayılan değer: 630x480 piksel)

$A_{pencere}$ = Komşuluk penceresindeki toplam piksel sayısı (Varsayılan değer: 15x15 piksel)

TBSM2’nin bir girdi görüntüsündeki kıl ve deri bölgelerini sınıflandırması için ihtiyaç duyduğu toplam sürenin, aşağıda verilmekte olan formül kullanılarak önceden öngörülebileceği değerlendirilmektedir:

$$t_{TBSM2} = \left((t_{öznitelik\ hesaplama}(ÖK2) + t_{sınıflandırma}(model_2, ÖK2, x_2) + t_{diğerTek2}) \times \left(\frac{A_{görüntü}}{A_{pencere}} \right) \right) \quad (C.3)$$

ÖK2= TBSM2’de kullanılmakta olan ve tüm öznitelikler arasından seçilmiş olan öznitelik kümesi

$t_{öznitelik\ hesaplama}(ÖK2)$ = TBSM2’de kullanılmakta olan özniteliklerin varsayılan pencere boyutundaki bir örüntü için ortalama hesaplanma süresi

$model_2$ = TBSM2’de kullanılan sınıflandırma tekniği (DAA, NB, SVM, KA, K-NN)

$t_{sınıflandırma}(model_2, ÖK2, x_2)$ = TBSM2’de kullanılan sınıflandırma tekniğinin ÖK2’i kullanılarak eğitilmesi sonucunda oluşan sınıflandırıcının

x_2 öznitelik vektörünü ortalama hesaplama süresi. x_2 öznitelik vektörünün uzunluğu ÖK2 öznitelik kümesinin eleman sayısı kadardır.

$t_{digerTek2}$ = TBSM2’de sınıflandırma işlemi sırasında öznitelik hesaplama ve öznitelik vektörü sınıflandırma işlemleri dışında yapılan diğer işlemlerin ortalama süresi

$A_{görüntü}$ = Tarama yapılan cilt görüntüsündeki toplam piksel sayısı (Varsayılan değer: 630x480 piksel)

$A_{pencere}$ = Komşuluk penceresindeki toplam piksel sayısı (Varsayılan değer: 15x15 piksel)

Denklem (C.1), (C.2) ve (C.3)’te kullanılmakta olan t_{diger1} , t_{diger2} , $t_{digerTek1}$ ve $t_{digerTek2}$ süreleri bellekten okuma, belleğe yazma, resim kesme gibi sınıflandırma ve öznitelik hesaplama işlemleri dışındaki diğer işlemlerin süreleridir. Bu değerlerinin sonuçları etkilemeyecek kadar düşük olduğu varsayımı yapılırsa, Denklem (C.1), (C.2) ve (C.3)’te verilmiş olan formüller aşağıdaki gibi yeniden düzenlenebilir:

$$\begin{aligned}
 t_{ISBM} = & \left(\left(t_{\text{öznitelik hesaplama}}(\text{ÖK1}) + t_{\text{sınıflandırma}}(\text{model}_1, \text{ÖK1}, x_1) \right) \right. & (C.4) \\
 & \times \left(\frac{A_{\text{görüntü}}}{A_{\text{pencere}}} \right) \left. + \left(\left(t_{\text{öznitelik hesaplama}}(\text{ÖK2} - \text{ÖK1}) \right. \right. \right. \\
 & + t_{\text{sınıflandırma}}(\text{model}_2, \text{ÖK2}, x_2) \left. \left. \left. \times \left(\frac{A_{\text{görüntü}} \times d_{kıl} \times \text{duyarlılık}_1}{A_{\text{pencere}}} \right. \right. \right. \right. \\
 & \left. \left. \left. + \frac{A_{\text{görüntü}} \times (1 - d_{kıl}) \times (1 - \text{özgüllük}_1)}{A_{\text{pencere}}} \right) \right) \right)
 \end{aligned}$$

$$t_{TBSM1} = \left(\left(t_{\text{öznitelik hesaplama}}(\text{ÖK1}) + t_{\text{sınıflandırma}}(\text{model}_1, \text{ÖK1}, x_1) \right) \times \left(\frac{A_{\text{görüntü}}}{A_{\text{pencere}}} \right) \right) \quad (\text{C.5})$$

$$t_{TBSM2} = \left(\left(t_{\text{öznitelik hesaplama}}(\text{ÖK2}) + t_{\text{sınıflandırma}}(\text{model}_2, \text{ÖK2}, x_2) \right) \times \left(\frac{A_{\text{görüntü}}}{A_{\text{pencere}}} \right) \right) \quad (\text{C.6})$$

Denklem (C.4), (C.5) ve (C.6)'da verilmiş olan formüllerde birden fazla varsayım yapılmaktadır. Bu varsayımlardan bazıları,

- Çapraz doğrulama işlemi sonucunda elde edilmiş olan duyarlılık değeri, ilgili sınıflandırma yönteminin herhangi bir cilt görüntüsü üzerindeki kıl bölgelerini tespit edebilme olasılığı ile örtüşmektedir.
- Çapraz doğrulama işlemi sonucunda elde edilmiş olan özgüllük değeri, ilgili sınıflandırma yönteminin herhangi bir cilt görüntüsü üzerindeki deri bölgelerini tespit edebilme olasılığı ile örtüşmektedir.
- Cilt görüntülerindeki kıl bölgelerinin yoğunluğu ortalama sabit bir değer olarak kabul edilebilir.
- Her bir özneliğin hesaplama süresi sabit örüntü penceresi boyutu için farklı cilt görüntülerinde benzerlik göstermektedir.
- Görüntü tarama işlemi sırasında yapılan diğer işlemlerinin süresi, sınıflandırma işlem süresi ve öznelik hesaplama işlem sürelerinden çok kısadır, bu nedenle bu değerler yok sayılabilir.

Yukarıda yapılmış olan varsayımların bir kısmının uygulama testleri sırasında doğruluğunu kaybetmesi beklenmektedir. Ancak uygulama testleri öncesinde İBSM ile TBSM1 ve TBSM2 arasında bir hız karşılaştırması yapılabilmesi için yukarıda verilmiş olan varsayımlar altında, Denklem (C.4), (C.5) ve (C.6)'da gösterilmekte olan formüller kullanılarak yaklaşık bir işlem süresi hesaplanabilmektedir. Uygulama

testlerinde elde edilen sonuçların, Denklem (C.4), (C.5) ve (C.6)'da elde edilen sonuçlarla birebir örtüşmesi beklenmemektedir. Ancak denklemlerden elde edilen sonuçların, uygulama testlerinin sonuçları ile benzerlik göstereceği değerlendirilmektedir.

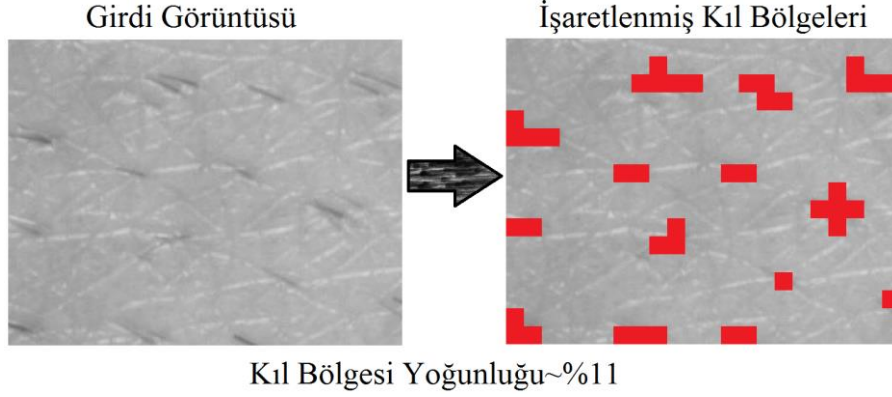
EK D : İBSM, TBSM1 ve TBSM2'nin İşlem Sürelerinin Öngörülebilmesi için Kullanılan Değerler

İBSM, TBSM1 ve TBSM2'nin bir girdi görüntüsünü sınıflandırabilmeleri için ihtiyaç duydukları işlem süresinin uygulama testleri öncesinde öngörülebilmesi için EK C'de yapılmakta olan varsayımlar altında Denklem (C.4), (C.5) ve (C.6)'da verilmekte olan formüller kullanılmaktadır. Bu formüllerde kullanılmakta olan varsayılan girdi görüntüsü boyutu ($A_{görüntü}$) 630×480^3 piksel olarak, varsayılan örüntü penceresi boyutu ($A_{pencere}$) ise 15×15 piksel olarak belirlenmiştir. ÖK1 Çizelge 5.4'de gösterilmekte olan öznitelik kümesi, ÖK2 ise Çizelge 5.5'te gösterilmekte olan öznitelik kümesidir. Formüllerde kullanılan $model_1$ ve $model_2$ sınıflandırma teknikleri ise Bölüm 5.3'te yapılmakta olan değerlendirmeler sonucunda doğrusal çekirdek fonksiyonu kullanan DVM sınıflandırma tekniğidir. İBSM'nin işlem süresinin öngörülebilmesi için kullanılmakta birinci basamak duyarlılık değeri ($duyarlılık_1$) ve birinci basamak özgüllük değeri ($özgüllük_1$) için Çizelge 5.8'de verilmiş olan değerler kullanılmaktadır. İBSM, TBSM1 ve TBSM2'nin işlem sürelerinin öngörülebilmesi için kullanılmakta olan, her bir özniteliğin 15×15 piksellik bir örüntü penceresi için ortalama hesaplanma süreleri için Çizelge 5.1'de verilmekte olan ortalama değerler kullanılmaktadır. Sınıflandırma modellerinin işlem sürelerinin öngörülebilmesi için ihtiyaç duyulan diğer değerler aşağıda yapılmakta olan değerlendirmelerle belirlenmektedir.

İBSM'nin işlem süresinin öngörülebilmesi için kullanılmakta olan bir diğer değer cilt görüntülerindeki ortalama kıl bölgesi yoğunluğudur ($d_{kıl}$). Bu değer sınıflandırma işleminde kullanılmakta olan örnek cilt görüntüleri esas alınarak belirlenmektedir. Cilt görüntülerindeki kıl bölgesi yoğunluğunun belirlenebilmesi için, farklı cilt görüntülerindeki kıl bölgeleri 15×15 piksellik pencerelerle işaretlenmiştir. Daha sonra, örnek görüntüde kıl bölgelerinden oluşan örüntü pencerelerinin sayısı, cilt

³ 630 ve 480 değerleri 15 ile tam bölünebilmektedir. Bu nedenle girdi görüntüsü boyutu olarak 640×480 piksel değeri yerine 630×480 piksel değeri kullanılmaktadır.

görüntüsündeki toplam örüntü penceresi sayısına bölünerek kıl bölgelerinin yoğunluğu tespit edilmiştir. Elde edilen sonuçlardan birisi, örnek bir cilt görüntüsü için Şekil D.1’de gösterilmektedir.



Şekil D.1. Örnek bir cilt görüntüsü için kıl bölgesi yoğunluğu

Yapılan incelemelerde önceden belirlenmiş olan kıl uzunluğu (~1 mm) için kol, bacak gibi bölgelerden alınan görüntülerde kıl bölgesi yoğunluğunun %10 seviyelerinde olduğu görülmüştür. Bu çalışmada kullanılmakta olan görüntü seti için kılların daha yoğun olduğu sakal gibi bölgelerde bu oran %30 seviyelerine kadar çıkmaktadır. Ancak bu seviyelerden daha yüksek kıl yoğunluğuna sahip olan cilt tipleri için önerilen akıllı lazer epilasyon cihazının avantajları ortadan kalkmaktadır. Bu cilt tipleri için geleneksel büyük spot boyutlu lazer cihazlarının kullanımı hız yönünden daha avantajlı olacaktır. Bunun yanı sıra cildin birçok bölümüne lazer atımı yapılması gerektiği için nokta atımlı lazer uygulamasının cilt üzerinde bıraktığı etki, geleneksel cihazların cilt üzerinde bıraktığı etkiden çok farklı olmayacaktır. Bu çalışmada, ortalama kıl bölgesi yoğunluğunun belirlenmesi için kıl bölgesi yoğunluğunun en yüksek olduğu örnek görüntülerle, kıl bölgesi yoğunluğunun en düşük olduğu örnek görüntülerinden elde edilen sonuçların ortalaması alınarak, $d_{kıl}$ değeri 0,2 olarak belirlenmiştir.

Denklem (C.4), (C.5) ve (C.6)'da verilmiş olan $t_{sınıflandırma}(model_1, ÖK1, x_1)$ ÖK1'i kullanmakta olan $model_1$ 'in tek bir öznitelik vektörünü sınıflandırmak için ihtiyaç duyduğu süreyi ve $t_{sınıflandırma}(model_2, ÖK2, x_2)$ ÖK2'yi kullanmakta olan $model_2$ 'in tek bir öznitelik vektörünü sınıflandırmak için ihtiyaç duyduğu süreyi

temsil etmektedir. Bu değerlerin öngörülebilmesi için DVM sınıflandırma tekniği ÖK1 ve ÖK2 kullanılarak 169 kıl ve 169 deri örüntüsüne ait veriler ile eğitilmiş ve oluşturulan sınıflandırıcıların, eğitim setinde kullanılmayan 1 tane kıl ve 1 tane deri örüntüsünü sınıflandırma süresi hesaplanmıştır. Daha sonra bu iki sınıflandırma süresinin ortalaması ilgili sınıflandırıcının tek bir öznelik vektörünü sınıflandırma süresi olarak alınmıştır. Elde edilen sonuçların kesinliğinin artırılabilmesi için yukarıda anlatılmakta olan işlem farklı eğitim ve test kümeleri kullanılarak 100 defa tekrarlanmış ve elde edilen sonuçların ortalaması alınmıştır. Çizelge D.1’de gösterilmekte olan değerler ilgili sınıflandırma yöntemi için tek bir öznelik vektörünün sınıflandırılma süresi olarak belirlenmiştir. Bu çalışmada kullanılan DVM sınıflandırma tekniğinin eğitilmesi için yararlanılan Matlab fonksiyonu EK B’de gösterilmektedir.

Çizelge D.1. Tek bir öznelik vektörünün sınıflandırılma süreleri

	Tek Bir Öznelik Vektörünün Sınıflandırılma Süresi (saniye)
$t_{sınıflandırma}(DVM, ÖK1, x_1)$	1,5596e-05
$t_{sınıflandırma}(DVM, ÖK2, x_2)$	1,5637e-05

Çizelge D.1’de görüldüğü gibi eşit uzunluklardaki öznelik vektörlerini sınıflandırmaya çalışan her iki sınıflandırma yönteminin işlem süreleri çok yakın çıkmıştır.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, Adı : AVŞAR, Murat
Uyruğu : T.C.
Doğum Tarihi ve Yeri : 26.03.1987, Ankara
Medeni hali : Bekâr
Telefon : 0 (506) 460 30 26
e-mail : muratavsar@outlook.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Lisans	Bilkent Üniversitesi Elektrik ve Elektronik Mühendisliği	2013

İş Deneyimi

Yıl	Yer	Görev
2013-Halen	Mavilab Yazılım Bilişim Lazer LTD. ŞTİ.	Mühendis

Yabancı Dil

İngilizce

Yayınlar

- [1] Avşar, M., Yetik, İ.Ş., Automated Feature Based Fine Hair Localization for Laser Hair Removal with Optical Imaging, 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society EMBC14, Chicago, Illinois, U.S.A, Ağustos 2014.
- [2] Avşar, M., Yetik, İ.Ş., Hair Region Localization with Optical Imaging for Guided Laser Hair Removal, 2015 IEEE International Symposium on Biomedical Imaging: From Nano to Macro ISBI15, New York, U.S.A., Nisan 2015.