

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**MİKROSKOBİK İMGELERDE TÜBERKÜLOZ BAKTERİSİNİN RASTGELE
ORMANLAR YÖNTEMİYLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Bilgisayar Müh. Selen AYAS

OCAK 2014
TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

MİKROSKOBİK İMGELERDE TÜBERKÜLOZ BAKTERİSİNİN RASTGELE
ORMANLAR YÖNTEMİYLE SINIFLANDIRILMASI

Bilgisayar Müh. Selen AYAS

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"BİLGİSAYAR YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 13.12.2013
Tezin Savunma Tarihi : 07.01.2014

Tez Danışmanı: Doç. Dr. Murat EKİNCİ

Trabzon 2014

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Selen AYAS tarafından hazırlanan

**MİKROSKOBİK İMGELERDE TÜBERKÜLOZ BAKTERİSİNİN RASTGELE
ORMANLAR YÖNTEMİYLE SINIFLANDIRILMASI**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 17 / 12 / 2013 gün ve 1534 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda**

YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Doç. Dr. Murat EKİNCİ

Üye : Doç. Dr. Cemal KÖSE

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Tüberküloz, 1990'lı yılların ortalarından itibaren ulusal ve uluslararası seviyelerde dikkat ve kontrol edilmesi gereken bir hastalık olmuş ve 1993 yılında Dünya Sağlık Örgütü tarafından genel bir halk sağlığı problemi olarak ilan edilmiştir. Hastalığın teşhisinde mikroskopik görüntüleme en genel kullanılan yöntem olmakla birlikte mikroskopik tanının her aşamasının doğru şekilde yapılması tüberküloz kontrol programının başarısı ve hastalıkla mücadele eden pek çok insanın sağlığı için oldukça önemlidir.

Çalışmada mikroskopik görüntüleme tüberküloz hastalığının teşhisi için bir sistem geliştirilmiştir. Tasarlanan sistemde öğrenmeye dayalı renk ve görünüş tabanlı yaklaşımlar ele alınmış ve literatürdeki çalışmalar incelenmiştir. Teşhis başarısının artırılması için güncel yaklaşımlar ve bu yaklaşımların sisteme olan etkileri araştırılmıştır.

Çalışmalarında danışmanlığımı üstlenen değerli hocam Doç. Dr. Murat EKİNCİ'ye ilgi, destek ve tecrübelerinden dolayı teşekkürlerimi borç bilirim. Yüksek lisans süresince tecrübelerini paylaştığı için Dr. Murat AYKUT'a ve çalışma arkadaşlarıma ayrıca teşekkür ederim. Yüksek lisans eğitimim boyunca sabır, destek ve sevgileriyle yanımda olan eşime ve sevgili aileme çok teşekkür ederim.

Selen AYAS

Trabzon 2014

TEZ BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduđum “Mikroskopik İmgelerde Tüberküloz Bakterisinin Rastgele Ormanlar Yöntemiyle Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Murat EKİNCİ'nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 07/01/2014

Selen AYAS

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ BEYANNAMESİ	IV
İÇİNDEKİLER	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ	XII
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Literatür Araştırması	2
1.3. Tüberküloz Hastalığı	3
1.3.1. Tüberkülozun Tanımı ve Özellikleri	4
1.3.2. Tüberkülozda Bulaşma	5
1.3.3. Tüberkülozda Tanı	5
1.3.4. Mikroskopik İnceleme Süreci	6
1.3.5. Türkiye’ de ve Dünya’ da Tüberküloz	9
1.4. Öznitelik Çıkarımı	10
1.4.1. RGB Renk Modeli	10
1.4.2. Piksel ve Piksel İlişkileri	10
1.4.3. Tek Değişkenli Gauss Olasılık Yoğunluk Fonksiyonu	11
1.4.4. Mahalanobis Uzaklığı	12
1.5. Mikroskopik Görüntülerin Bölütlenmesi	12
1.5.1. Çok Değişkenli Gauss Olasılık Yoğunluk Fonksiyonu	13
1.5.1.1. Gauss Olasılık Yoğunluk Fonksiyonunun Özellikleri	15
1.5.2. Toplu Öğrenme Yöntemleri	16
1.5.2.1. Rastgele Ormanlar	17
1.5.2.1.1. Rastgele Ormanlar Yöntemine Genel Bakış	17
1.5.2.1.2. Önyükleme	18
1.5.2.1.3. Karar Ağaçları	19

1.5.2.1.3.1.	Sınıflandırma ve Regresyon Ağaçları Yöntemi.....	22
1.5.2.1.4.	Out Of Bag Hata Kestirimi	27
1.5.3.	Destek Vektör Makineleri.....	28
1.5.3.1.	Doğrusal Olarak Ayrılabilen Veriler	28
1.5.3.2.	Doğrusal Olarak Ayrılamayan Veriler.....	32
1.5.3.3.	Doğrusal Olmayan Destek Vektör Makineleri.....	34
1.6.	Sınıflandırma Öncesi Ön İşlemler	35
1.6.1.	Matematiksel Morfoloji	35
1.6.1.1.	Aşınma	35
1.6.1.2.	Genleşme.....	36
1.6.2.	Bağlantılı Bileşen Etiketleme.....	36
1.6.3.	Moment Değişmezleri.....	36
1.7.	Bölütlenmiş Verilerin Sınıflandırılması.....	37
1.7.1.	Rastgele Ormanlar	37
1.7.2.	Destek Vektör Makineleri.....	37
1.7.3.	Yapay Sinir Ağları.....	38
1.7.3.1.	Yapay Nöron	38
1.7.3.2.	Yapay Sinir Ağları İçin Nöron Modelleme.....	39
1.7.3.3.	Yapay Sinir Ağları Modelleri.....	41
1.7.3.3.1.	İleri Beslemeli Yapay Sinir Ağları	41
1.7.3.4.	Yapay Sinir Ağlarında Öğrenme	43
1.7.3.4.1.	Hata Geri Yayılımlı Öğrenme Algoritması.....	44
1.8.	Performans Değerlendirmesi.....	46
2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	48
2.1.	Giriş	48
2.2.	Tüberküloz Bakterisinin Otomatik Tanınması	48
2.2.1.	Önişlemler	51
2.2.2.	Öznitelik Çıkartma ve Gürültülü Veri Eliminasyonu	52
2.2.3.	Mikroskobik Görüntülerin Bölütlenmesi	54
2.2.3.1.	Çok Değişkenli Gauss Olasılık Yoğunluk Fonksiyonuna Dayalı Bölütleme ...	55
2.2.3.2.	Rastgele Ormanlar Yöntemine Dayalı Bölütleme	55
2.2.3.3.	Destek Vektör Makineleri Yöntemine Dayalı Bölütleme.....	56
2.2.4.	Sınıflandırma Öncesi Ön İşlemler	58

2.2.4.1.	Morfolojik İşlemler.....	58
2.2.4.2.	Bağlantılı Bileşen Etiketleme.....	59
2.2.4.3.	Moment Değişmezleri ile Yön Bulma.....	60
2.2.5.	Bölütlenmiş Verilerin Sınıflandırılması.....	60
2.2.6.	Deneysel Sonuçlar ve Karşılaştırma.....	61
3.	SONUÇLAR VE TARTIŞMA.....	76
4.	ÖNERİLER.....	78
5.	KAYNAKLAR.....	79
ÖZGEÇMİŞ		

Yüksek Lisans Tezi

ÖZET

MİKROSKOBİK İMGELERDE TÜBERKÜLOZ BAKTERİSİNİN RASTGELE
ORMANLAR YÖNTEMİYLE SINIFLANDIRILMASI

Selen AYAS

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Murat EKİNCİ
2014, 83 Sayfa

Mikroskobik hastalık teşhisi, hastalardan alınan numunelerin mikroskop altında incelenip hastalığın tespit edilmesi sürecidir. Laboratuvar teknisyenlerinin fazla zamanını alan bu görsel inceleme süreci aynı zamanda hataya da oldukça meyillidir. Yorucu iş yükü de buna eklendiğinde tanı süreci çalışanlar açısından oldukça güç ve usandırıcı olmaktadır. Doğru tanının insan sağlığı için önemi düşünüldüğünde birçok bilgisayar destekli örüntü tanıma sistemlerinin geliştirilmesinin nedeni açıkça ortaya çıkmaktadır. Bu amaçla tez çalışmasında, mikroskobik görüntülerdeki tüberküloz bakterisini makine öğrenme algoritmaları ile otomatik teşhis eden görsel arayüzlü bir yazılım Embarcadero Borland C++ platformunda geliştirilmiştir.

Tez çalışması, veritabanının oluşturulması, öznitelik çıkartılması, bölütleme ve sınıflandırmadan oluşmaktadır. Öznitelik çıkartılmasında bölütleme aşaması için yapısal yaklaşımlar, sınıflandırma aşaması için ise görünüşe dayalı yaklaşımlar incelenmiştir. Mikroskobik görüntülerin bölütlenmesinde ve bölütlenmiş görüntülerin sınıflandırılmasında kullanılan Destek Vektör Makineleri, Yapay Sinir Ağları gibi temel yaklaşımların yanında güncel bir yaklaşım olan Rastgele Ormanlar yöntemi de incelenmiştir. Sonuçlara bakıldığında önerilen güncel yöntemin diğer uygulanan yöntemlere oranla oldukça başarılı sonuçlar verdiği görülmektedir.

Anahtar Kelimeler: Tüberküloz Bakterisi, Örüntü Tanıma, Rastgele Ormanlar, Destek Vektör Makineleri, Yapay Sinir Ağları, Mikroskobik Görüntüleme

Master Thesis

SUMMARY

CLASSIFICATION OF TUBERCULOSIS BACTERIA IN MICROSCOPIC
IMAGES USING RANDOM FORESTS ALGORITHM

Selen AYAS

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Assoc. Prof. Dr. Murat EKİNCİ
2014, 83 Pages

Diagnosis of a microscopic disease is a process of determining the disease taken from patients by examining under a microscope. This visual examining process requires much time of laborants and also it is prone to mistakes. Addition of tiring workload, diagnosis process becomes quite difficult and boring for laborants. When the importance of the correct diagnosis for human health considered, the reason of the development of computer-aided pattern recognition systems is understood clearly. For this purpose, in order to automatically diagnose the mycobacterium tuberculosis in microscopic images by means of machine learning algorithms, a software which has visual interface is developed using Embarcadero Borland C++ platform, in this thesis study.

The thesis study covers database construction, feature extraction, segmentation and classification. During the feature extraction, structural based and appearance based approaches are analyzed for segmentation and classification, respectively. In addition to basic approaches such as Support Vector Machines and Artificial Neural Networks, a novel approach called Random Forest is analyzed in the segmentation of microscopic images and classification of segmented images. When the results considered, the proposed novel method is quite successful when compared to the other applied methods.

Key Words: Mycobacterium Tuberculosis, Pattern Recognition, Random Forests, Support Vector Machines, Artificial Neural Networks, Microscopic Imaging

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Mavi zemin üzerinde pembe renginde TB basilleri	4
Şekil 1.2. (a) Ziehl-Neelsen ve (b) Florokrom lekelenme tekniği ile boyanmış yayma örnekleri [23].....	7
Şekil 1.3. Dünyadaki tüberküloz vakalarının kıtalara göre dağılımı [16].....	9
Şekil 1.4. (a) 4 ve (b) 8 bağlantılı komşuluklar	11
Şekil 1.5. Farklı μ ve σ değerlerine bağlı tek değişkenli GOYF'ler	12
Şekil 1.6. Çok değişkenli GOYF	14
Şekil 1.7. RO yönteminin genel şeması	18
Şekil 1.8. Önyüklemeli örneklem oluşturma	18
Şekil 1.9. Karar ağaçları sınıflandırıcıları için oluşturulmuş bir ağaç yapısı	20
Şekil 1.10. CART bölünme algoritmasının basit yapısı.....	23
Şekil 1.11. İki doğrusal ayrılabilen sınıf aracılığıyla hiper düzlemin gösterimi	29
Şekil 1.12. İki doğrusal ayrılamayan sınıf aracılığıyla hiper düzlemin gösterimi.....	33
Şekil 1.13. Bir nöronun McCulloch-Pitts modeli	38
Şekil 1.14. İşleme düğümü ve sinaptik bağlantıdan oluşan nöron yapısı	39
Şekil 1.15. Aktivasyon fonksiyonlarının çeşitleri: (a) eşik (b) parçalı doğrusal (c) sigmoid (d) gauss	41
Şekil 1.16. Tek katmanlı ileri beslemeli ağ ara bağlantı şeması.....	41
Şekil 1.17. Katmanlı ileri beslemeli sinir ağları	45
Şekil 1.18. Hata geri yayımlı eğitim algoritması akış diyagramı	46
Şekil 2.1. Sistemin temel işlem adımları.....	48
Şekil 2.2. Görüntü toplama sistemi.....	49
Şekil 2.3. ZN lekelenme tekniği ile (a) boyanmış görüntüdeki bölgelerin uzman tarafından (b) bölütleme süreci performansını değerlendirmek için boyanması ve (c) sınıflandırma süreci performansını değerlendirmek için bakteri olup olmadığına karar verilmesi (kırmızı-bakteri, siyah-bakteri değil)	50
Şekil 2.4. (a) Orijinal görüntünün imlecin bulunduğu koordinatta (b) 40 piksel yarıçapında 2X büyütme ve (c) 60 piksel yarıçapında 4X büyütme sonuçları ..	52
Şekil 2.5. (0,0) merkez koordinatlara sahip piksel ve komşularının indeks değerleri ve hesaplanan katsayıları	53
Şekil 2.6. Bölütleme performansı için kullanılacak orijinal örnek görüntü	54

Şekil 2.7.	Şekil 2.6.'daki orijinal görüntünün çok değişkenli GOYF yöntemine dayalı bölütlenmiş sonuç görüntüsü (eşik değeri=%99.00)	55
Şekil 2.8.	Şekil 2.6.'daki orijinal görüntünün RO yöntemine dayalı bölütlenmiş sonucu (m=5, N=300).....	56
Şekil 2.9.	Şekil 2.6.'daki orijinal görüntünün DVM yöntemine dayalı bölütlenmiş sonuç görüntüsü (optimum C=2, optimum gamma=0.2479).....	58
Şekil 2.10.	Morfolojik işlemler için kullanılan çarpı biçimli yapısal eleman	58
Şekil 2.11.	Şekil 2.8.'deki RO yöntemine dayalı bölütlenmiş sonuç görüntüsündeki gürültülerin morfolojik işlemlerle kaldırılması	59
Şekil 2.12.	Kullanıcının (a) seçtiği bölge, (b) nesnenin döndürülmesi ve (c) yeniden boyutlandırılmasıyla elde edilen yeni görüntüler	61
Şekil 2.13.	İlk testte kullanılan görüntülere örnekler.....	62
Şekil 2.14.	İkinci testte kullanılan görüntülere bir örnek.....	62
Şekil 2.15.	Üçüncü testte kullanılan görüntülere bir örnek	63
Şekil 2.16.	Dördüncü testte kullanılan görüntülere bir örnek	63
Şekil 2.17.	Beşinci testte kullanılan görüntülere bir örnek	64
Şekil 2.18.	1. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği.....	66
Şekil 2.19.	2. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği.....	67
Şekil 2.20.	3. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği.....	67
Şekil 2.21.	4. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği.....	68
Şekil 2.22.	5. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği.....	68

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Mikroskopik görüntü analizi sonucunda yayma örneklerinin derecelendirilmesi	8
Tablo 1.2. İkili tanı testi	47
Tablo 2.1. Veri kümesi hakkında sayısal bilgiler	50
Tablo 2.2. 1. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri	64
Tablo 2.3. 2. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri	64
Tablo 2.4. 3. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri	65
Tablo 2.5. 4. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri	65
Tablo 2.6. 5. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri	65
Tablo 2.7. 1. lam test görüntüleri için RO yönteminin başarı ölçümleri	69
Tablo 2.8. 2. lam test görüntüleri için RO yönteminin başarı ölçümleri	70
Tablo 2.9. 3. lam test görüntüleri için RO yönteminin başarı ölçümleri	70
Tablo 2.10. 4. lam test görüntüleri için RO yönteminin başarı ölçümleri	71
Tablo 2.11. 5. lam test görüntüleri için RO yönteminin başarı ölçümleri	71
Tablo 2.12. 1. lam test görüntüleri için DVM yönteminin başarı ölçümleri	72
Tablo 2.13. 2. lam test görüntüleri için DVM yönteminin başarı ölçümleri	72
Tablo 2.14. 3. lam test görüntüleri için DVM yönteminin başarı ölçümleri	73
Tablo 2.15. 4. lam test görüntüleri için DVM yönteminin başarı ölçümleri	73
Tablo 2.16. 5. lam test görüntüleri için DVM yönteminin başarı ölçümleri	73
Tablo 2.17. Test görüntüleri için YSA yönteminin başarı ölçümleri	74
Tablo 2.18. Test görüntüleri için RO yönteminin başarı ölçümleri	75
Tablo 2.19. Test görüntüleri için DVM yönteminin başarı ölçümleri	75

SEMBOLLER DİZİNİ

RGB	Kırmızı, Yeşil, Mavi (Red, Green, Blue)
HSV	Renk özü, Doygunluk, Değer (Hue, Saturation, Value)
GOYF	Gauss Olasılık Yoğunluk Fonksiyonu (Gaussian Probability Density Function)
RO	Rastgele Ormanlar (Random Forest)
DVM	Destek Vektör Makineleri (Support Vector Machines)
YSA	Yapay Sinir Ağları (Artificial Neural Network)
TB	Tüberküloz
WHO	Dünya Sağlık Örgütü (World Health Organization)
HIV	İnsan Bağışıklık Yetmezlik Virüsü (Human İmmunodeficiency Virus)
ARB	Aside Dirençli Basil (Acid Resistant Bacillus)
ZN	Ziehl-Neelsen

1. GENEL BİLGİLER

1.1. Giriş

Örüntülerin otomatik tanınması, tanımlanması, sınıflandırılması ve gruplandırılması; tıp, bilgisayarla görü, yapay zekâ ve uzaktan algılama gibi çeşitli mühendislik ve bilimsel alanlarda karşılaşılan önemli problemlerdendir [1]. Örüntü, bir nesnenin ya da varlığın nicel ya da yapısal tanımlaması olarak tanımlanabilir. Örüntü tanıma ise incelenen herhangi bir veri örneğini çoklu sınıflardan ya da kategorilerden biri olarak sınıflandırma sürecidir. Örüntü tanıma insanların en temel özelliği olduğundan uzun zamandan beri üzerinde çalışmalar yapılan bir alan olmuştur [2].

Tıp alanında örüntü tanıma uygulamaları, insanın hareket ve düşünme süreçlerini, çeşitli veri kaynakları yardımıyla hastalıkları teşhis etmesini örnek almaktadır. Röntgen, tomografi, ultrasonografi, mikroskop gibi cihazlar bu veri kaynakları arasında yer alır [3]. Bu cihazlar yardımıyla yapılan tıbbi görüntüleme, hastalıkların erken tanısında, tedavisinde önemli rol oynamaktadır.

Mikroskobik örüntü analizi, mikroskop ile elde edilen örneklerin işlenmesi ve analiz edilmesi için örüntü tanıma tekniklerinin kullanımını gerektirmektedir. Mikroskobik uygulamalar için bu tekniklerin kullanımı, mikroskobik örneklerden daha doğru bilgi elde edilmesini amaçlamaktadır. Patolojik sonuçların insan sağlığı için önemi düşünüldüğünde, birçok bilgisayar destekli örüntü tanıma sistemlerinin geliştirilmesinin nedeni açıkça ortaya çıkmaktadır. Böylece sıkıcı ve zaman alıcı karmaşık teşhis süreci, görüntüden alınan sayısal verilerle iyileştirilmektedir [4].

Bu çalışmada mikroskobik görüntüler üzerinde tüberküloz (TB) bakterisinin otomatik algılanması için bir sistem geliştirilmiştir. Öncelikle balgam örneklerinden alınan mikroskobik görüntüler üzerinde ilgili bölgelerdeki piksellerin ve komşularının renk bilgilerinin çıkartılması için Gauss Olasılık Yoğunluk fonksiyonu (GOYF) incelenmiştir. Özniteliklerin çıkartılması sonunda veriler bölütleme için anlamlı bilgilere sahip olacaktır. İlgili bölgelerin zeminden ayrıştırılması için renk tabanlı bölütleme sürecinde çok boyutlu GOYF, Rastgele Ormanlar (RO) ve Destek Vektör Makineleri (DVM) yöntemleri ele alınmıştır. Elde edilen bölütlenmiş görüntüler üzerinde iyileştirmeler yapılarak görüntüler

sınıflandırma süreci için daha yorumlanabilir hale getirilmiştir. Son olarak şekil tabanlı sınıflandırma süreci için Yapay Sinir Ağları (YSA), RO ve DVM incelenmiştir.

1.2. Literatür Araştırması

TB bakterisinin mikroskopik görüntü analiziyle algılanmasının otomatikleştirilmesi için literatürde çok sayıda yayın olduğu görülmektedir. Konuyla ilgili bütün yayınların burada irdelenmesi olanaksız olduğundan, ancak yakın olan bazılarına değinmek faydalı olacaktır.

Costa (2008) ve arkadaşları adaptif eşikleme dayalı bölütleme yöntemini kullanarak geleneksel ışık mikroskopuyla TB bakterisinin otomatik tanınmasını gerçekleştirmişlerdir [5]. Çalışmada RGB renk uzayındaki görüntülerin R-M görüntülerini elde edip bölütledikten sonra oluşan bazı artefaktların kaldırılması için morfolojik, renk ve boyut filtrelerini kullanmışlardır.

Raof (2008) ve arkadaşları çok seviyeli eşikleme yöntemini, bakterileri zemin veya diğer nesnelere ayırt etmek için bakterilerin RGB renk bilgilerine uygulamışlardır [6]. Tek bir eşik seçmek yerine her bir bileşeni ayrı ayrı eşiklemeye tabi tutup sonuçları birleştirmişlerdir. Çalışmadaki diğer bir yaklaşım ise bakteriler için kırmızı renk tonunun yeşil renk tonuna göre daha yüksek değerde olması gerektiğidir. Bu yaklaşımı da uygulayarak eşikleme yöntemini daha güçlü hale getirmişlerdir. Bir diğer çalışmalarında (2010) [7] ise eşiklemeyi sadece RGB renk uzayında değil HSV uzayında da gerçekleştirmişlerdir. Yine her bir bileşeni ayrı ayrı eşiklemeye tabi tutup sonuçları birleştirmiş ve iki uzay arasında performans karşılaştırması yapmışlardır.

Makkapati (2009) ve arkadaşları renk özü aralığının adaptif seçimle belirlendiği, bakterileri bölütlemek için renk özü renk bileşeni tabanlı yeni bir yaklaşım önermişlerdir [8]. Bölütlenmiş görüntüdeki nesnelere doygunluk değerine göre eşiklemeye tabi tutularak uzun yapıların bakteri olup olmadığına karar vermişlerdir. Bakteri kümelerini ve diğer artefaktları ise alan, uzunluk ve genişlik parametrelerinin değerine göre kaldırmışlardır.

Nayak (2010) ve arkadaşları görüntüleri HSV uzayında Mahalanobis uzaklığını kullanarak bölütlemiş ve bölütlenmiş görüntü üzerinde görüntüleri ortadan kaldırıp birbirine çok yakın olan bölgeleri birleştirmişlerdir [9]. Sabit boyut değeri ile de bölgelerin bakteri olup olmadığına karar vermişlerdir.

Sadaphal (2008) ve arkadaşları bakteri tanınmasının otomatikleştirilmesi için görüntüye renk bölütlemesi ve biçim-boyut analizini sırasıyla uygulamışlardır [10]. Renk bölütlemesinde Bayes bölütlemesi yöntemini kullanmış, görüntüyü iyileştirdikten sonra eksen oranı, dış merkezlilik gibi biçim tanımlayıcıları kullanarak belli bir eşik değeri belirlenip bu değere göre nesnelerin sınıflandırılmasını sağlamışlardır.

Forero ve arkadaşları florokrom lekelenme tekniği ile boyalı preparatlarda TB bakterisinin otomatik tanınması için çeşitli renk uzaylarında çalışmışlardır. Görüntü bölütlemesi için adaptif eşikleme yöntemini kullanmışlar, ardından kenar algılama ve gürültü azaltma yaptıktan sonra nesnelerin özneliklerini çıkarmışlardır. Sınıflandırma aşamasında Sınıflandırma Ağacı [11], Karar Tabanlı Sınıflandırma Ağacı [12] ve Gauss Karışım Modeli [13] yöntemlerini kullanmışlardır.

Siena (2012) ve arkadaşları öncelikle mikroskoptan alınan görüntülere zemin ile bakteriler arasındaki renk ayrımını genişletmek için karşıtlık katmışlardır [14]. Ardından K-Ortalama Kümeleme yöntemi ile bakterileri belirgin şekilde arka zeminden ayırmışlardır. Bölütlenmiş görüntüler üzerindeki gürültüler azaltıldıktan sonra dış merkezlilik ve esneklik biçim tanımlayıcılarını kullanarak Yapay Sinir Ağı ile bakterilerin tanınması sağlanmıştır.

Khutlang (2010) ve arkadaşları görüntülerdeki bakteri aday nesnelere zemin ayırmak için piksel sınıflandırıcıları birleşimini kullanmışlardır [15]. Bölütlenmiş görüntü üzerindeki nesnelerin dış merkezlilik ve esneklik biçim tanımlayıcıları, Fourier öznelikleri, Moment öznelikleri ile nesne içerisindeki ve etrafındaki kırmızı, yeşil ve mavi renk bileşenlerinin ortalama ve standart sapmalarını öznelik olarak seçip öznelik alt kümelerini oluşturmuşlardır. Sınıflandırma aşamasında ise En Yakın Komşuluk, Bayes Sınıflandırıcısı, Lineer ve Karesel Sınıflandırıcıları, Olasılıksal Sinir Ağları ve Destek Vektör Makineleri yöntemlerini kullanmışlardır.

1.3. Tüberküloz Hastalığı


Dünyadaki en büyük sağlık problemlerinden biri olan TB, *Mycobacterium tuberculosis* basilinin neden olduğu bulaşıcı bir hastalıktır. Dünya Sağlık Örgütü (WHO) tarafından 2012 yılında 17. si yayınlanan Küresel Tüberküloz Raporu (Global Tuberculosis Report)'na göre, TB, enfeksiyon hastalıklarına bağlı ölümlerin meydana gelmesinde HIV (Human Immunodeficiency Virus) virüsünden sonra ikinci sırada yer almaktadır [16].

TB hastalığına neden olan *Mycobacterium* mikroorganizmaları hareketsiz ve sporsuz, çubuk şeklindeki yapılardır. Bu mikroorganizma türlerinden biri olan *Mycobacterium tuberculosis*, insanların TB etkenidir ve insanlarda verem hastalığına neden olmaktadır [17]. TB etkeni vücuda girdiği anda hastalığa neden olmamaktadır, zaten insanların yüzde %90'ı hastalık etkenini vücudunda taşımaktadırlar. Vücut direncinin düşmesi, bağışıklık sisteminin zayıflaması gibi durumlarda basiller etkin hale gelerek hastalığa yol açar. TB etkeninin, insan vücudunda ilk olarak etkilediği yer akciğerlerdir. Fakat hastalığın etkinleşmesi durumunda kan ve lenf kanalları vasıtasıyla vücuda yayılarak diğer organları da etkileyebilir. Dolayısıyla, hastalık akciğer tüberkülozundan akciğer dışı organ tüberkülozuna dönüşmektedir [16].

TB etkeni taşıyan bir hasta mutlaka tedavi edilmelidir. Hastalığın tedavisinde önemli olan, hastalığın teşhisinin erken yapılmış olması ve TB basilinin yerleştiği organ, vücuttaki infeksiyon durumu, hastada var olan diğer hastalıkların varlığı göz önüne alınarak uygun ilaçların yeterli doz ve sürede verilmesidir [18].

WHO'nun yayınladığı rapordaki son tahminlerine göre, 2011 yılında yaklaşık 9 milyon yeni TB vakasıyla karşılaşmış olduğu ve hastalığın tedavisinin mümkün olabilmesine karşılık, 1,4 milyon kişinin bu hastalıktan öldüğü bildirilmiştir. WHO, 1993 yılında TB hastalığını küresel halk sağlığı acil vakası olarak ilan etmiş ve bu tarihten sonra da ulusal ve uluslararası seviyelerde TB tedavisini ve kontrolünü geliştirmek için gayretler sarfetmiştir [16].

1.3.1. Tüberkülozun Tanımı ve Özellikleri



Şekil 1.1. Mavi zemin üzerinde pembe renge TB basilleri

TB, 1882 yılında Robert Koch tarafından keşfedilen *Mycobacterium tuberculosis* etkeninin neden olduğu, öncelikle akciğerlere yerleşip kan ve lenf yoluyla tüm vücuda yayılabilen mikrobik, bulaşıcı bir hastalıktır [19]. ‘Koch basili’ olarak da adlandırılmaktadır.

TB basilleri, 1-10 µm uzunluğunda ve 0,2-0,6 µm kalınlığında, aerobik, sporsuz, hareketsiz, kapsülsüz, düz ya da hafifçe kıvrık çubuk şeklindeki yapılardır. Hücre duvar yapıları asit geçirmez özelliktedir. Mikroskopi ile hastalığın teşhisinde uygulanan lekelenendirme yönteminde, boyama sonrası ortama eklenen asit-alkol karışımı ile renkleri giderilemediğinden dolayı aside-dirençli basil (ARB) olarak da adlandırılırlar. Genellikle yüksek oksijen basıncına sahip olan dokularda çoğaldıklarından vücutta ilk yerleştikleri yer akciğerlerdir [17].

1.3.2. Tüberkülozda Bulaşma

TB basilinin iletimi hava aracılığıyla gerçekleşir. Aktif tüberküloza sahip bir kişi öksürdüğünde, hapşırduğunda veya konuştuğunda, basil içeren küçük damlacıklar havaya yayılır ve sağlıklı bir kişinin az miktarda havayı soluması, hastalığın bir kişiden diğerine bulaşmasına neden olur. Basilleri soluyan sağlıklı kişilerin hepsinde hastalık gelişmez; sağlıklı bir kişinin hastalığa yakalanma olasılığı kişinin havayı soluma süresine, solunan basillerin sayısına, kişinin direncine ve bağışıklık sisteminin kuvvetine göre değişir [20]. Hastalık nesnelere, el sıkma, yiyecek ve içecek paylaşma ile bulaşmaz [19] [20].

1.3.3. Tüberkülozda Tanı

TB hastalığında hasta yakınmaları, muayene bulguları ve göğüs röntgeni, hastalığın kesin teşhisi için yeterli değildir. Kesin teşhis için hastadan alınan balgam örneğinde TB basili aranmalıdır [21].

TB hastalığının bazı belirtileri şunlardır [19]:

- 3 hafta ya da daha uzun süren şiddetli öksürük,
- Göğüs ağrısı,
- Öksürükle ya da balgamla akciğerden kan gelmesi,
- Halsizlik ya da aşırı yorgun hissetme,
- İstem dışı kilo kaybı,


- İştah kaybı,
- Üşüme ve ateş,
- Gece terlemeleri.

Hasta bu belirtileri yaşıyorsa, TB hastalığından şüphelenilir. Şüpheli durumlarda, doktor bazı tıbbi testler uygulayarak hastayı değerlendirmelidir. Tıbbi değerlendirme hastalık geçmişi, fiziksel değerlendirme, göğüs röntgeni, tüberkülin deri testi ve mikroskopik inceleme tanı süreçlerini kapsamaktadır. Öncelikle hastanın yaşı, etnik grubu, yaşadığı ülke ve mesleği gibi TB etkenine maruz kalma riskini artırabilecek faktörler sorgulanmalıdır. Fiziksel muayenede, hastanın bedensel durumu ve TB tedavisini etkileyecek HIV enfeksiyonu veya diğer hastalıklara sahip olup olmadığı incelenir. TB deri testi ya da TB kan testi kullanılarak TB enfeksiyonu için test yapılır. Ancak bu yöntem kişinin enfekte olup olmadığı hakkında bilgi verirken, hastalığın aktivitesi hakkında bilgi vermemektedir. Göğüs röntgeni, göğüs anomalilerini saptamak için kullanılır. Röntgende var olan anomaliler, TB hastalığının varlığını düşündürse de başka hastalıklarda da aynı anomalilerin görülebilir olmasından dolayı TB hastalığı kesin teşhis edilemez [22].

Mikroskopik inceleme, akciğer tüberkülozunu doğrulamak için en güvenilir yöntemdir. Tüberkülozdan şüphelenildiği durumlarda, hastadan arka arkaya 2 gün içinde 3 farklı balgam örneği alınır ve mikroskopla incelenir. En az iki pozitif yayma sonucuna sahip hasta, doktor tarafından yayma-pozitif TB vakası olarak teşhis edilir ve hastaya uygun tedavi belirlenir. İncelemede sadece bir pozitif yayma sonucuna sahip hastadan göğüs röntgeni alınır ve göğüs röntgeninde de bulgulara rastlanılırsa hasta yayma pozitif vakası olarak değerlendirilir. Eğer hastanın yayma sonuçlarının 3'ü de negatif ise hastaya 10-15 günlük antibiyotik tedavisi uygulandıktan sonra mikroskopik inceleme yeni balgam örnekleriyle tekrar edilir [21].

1.3.4. Mikroskopik İnceleme Süreci

Hastadan alınan balgam yayması örneklerinin doğru bir şekilde mikroskopik incelenmesinin yapılması için öncelikle örnekler üzerinde lekelenme prosedürünün gerçekleştirilmesi ve ardından klinik çalışanları tarafından, yayma örneklerindeki basillerin varlığının mikroskop altında incelenmesi gerekmektedir.



Şekil 1.2. (a) Ziehl-Neelsen ve (b) Florokrom lekelenme tekniği ile boyanmış yayma örnekleri [23].

Mycobacterium tuberculosis ve benzeri basillerin hücre duvarları, asit-alkol karışımını hücreden geçirmeyen aside dirençli yapıdadır. Bu yüzden basillerin belirlenmesinde aside dirençli lekelenme tekniği kullanılmaktadır. Ziehl-Neelsen (ZN) ve Florokrom lekelenme teknikleri bu teknikler arasında en çok tercih edilenlerdendir. ZN lekelenme tekniğinde yayma örnekleri, karbol fuksin solüsyonu ile kaplandıktan sonra, asit-alkol karışımı ile renk giderilir ve ardından örnekler metilen mavisini solüsyonu ile tekrar boyanır [24]. Sonuç olarak ARB'ler, mavi zemin üzerinde kırmızı-pembe renkte görülürler. Boyanan preparat üzerine immersiyon yağı damlatılarak 100X büyütme objektif ile örneğin ışık mikroskopunda incelemesi yapılır. Florokrom lekelenme tekniğinde ise yayma örnekleri auramine-rhodamine solüsyonu ile kaplandıktan sonra, asit-alkol karışımı ile renk giderilir ve zemin rengini elde etmek için tekrardan potasyum permanganat ile boyanır. Basiller, karanlık zeminde sarı-turuncu, florasan veren parlak renkte görülürler [25]. Elde edilen preparatlar 25X ya da 40X objektif ile florasan mikroskopunda incelenir.

Florokrom lekelenme, ZN lekelenme tekniğinden daha duyarlıdır. Aslında iki yöntem karşılaştırılabilir duyarlılığa sahiptir. Ayrıca florokrom lekelenme tekniği ile boyalı preparatların mikroskop altında hızlı taranabilir olması laboratuvarlarda çok sayıda örnek incelenmesini sağlarken, ZN tekniği ile boyanmış, incelenen preparat sayısı oldukça azdır. Florokrom metodunun dezavantajı ise preparatlardaki basillerin rengi olan florasanın zamanla renginin solmasıdır. Bu yüzden preparatların hazırlandıktan sonra 24 saat içerisinde mikroskopik incelenmesi yapılmalıdır. Ayrıca florasan mikroskopunun maliyetinin ve

sürdürülebilirliğinin yüksek olmasından dolayı, bu yöntem daha çok gelişmiş ülkelerde uygulanmaktadır [17].

Şüpheli durumlarda alınan balgam yayma örneklerinde saptanan basil sayısı, hastanın enfeksiyonunun derecesini ve hastalığın ciddiyetini belirlediğinden çok önemlidir. Bu yüzden, mikroskopik inceleme sonuçlarının sadece nitelendirici değil aynı zamanda sayısal veri de içermesi gereklidir. TB ve Akciğer Hastalıklarına Karşı Uluslararası Birlik, Tablo 1.1.'de verilen sonuç derecelendirmelerini önermektedir [24].

Tablo 1.1. Mikroskopik görüntü analizi sonucunda yayma örneklerinin derecelendirilmesi

ARB Sayısı	Kayıt ve Raporlama
En az 100 alanda hiç basil bulunmaması	0 / negatif
100 alanda 1-9 arası basil bulunması	Gerçek basil sayısı
100 alanda 10-99 arası basil bulunması	+
En az 50 alanda her alan için 1-10 arası basil bulunması	++
En az 20 alanda her alan için 10'dan fazla basil bulunması	+++

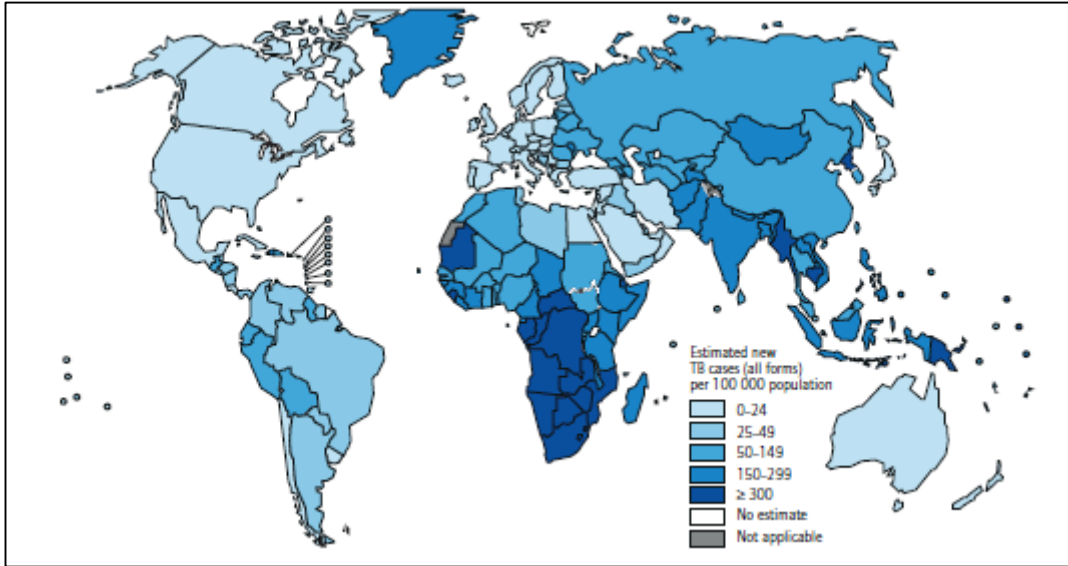
Tablo 1.1.'den de görülebildiği üzere klinik çalışanlarının, tek bir balgam yayması üzerinde en az 100 alanı incelemesi gerekmektedir. Bu da her bir yayma için en az 5 dakika süre gerektirdiğinden, tam gün çalışma durumunda her gün için 25'den fazla yayma incelenemez [24]. Uzman klinik çalışanlarının oldukça zamanını alan görsel inceleme süreci hataya oldukça meyillidir. Ayrıca mikroskopik inceleme sürecinin zihinsel yoğunlaşma gerektirmesi de, incelenecek numune sayısını oldukça sınırlamaktadır. Yorucu iş yükü de buna eklendiğinde tanı süreci çalışanlar açısından oldukça güç ve usandırıcı olmaktadır [26]. Her bir yayma dikkat edilmeden ya da çok kısa süreli incelenirse, yayma örneğindeki ARB'ler gözden kaçırılabilir ve örnek sonucu pozitif olmasına rağmen negatif olarak değerlendirilebilir. Yanlış negatif sonuç tedavinin gecikmesine, hastanın enfeksiyonu etrafa yaymaya devam etmesine; yanlış pozitif sonuç ise hastanın gereksiz tedavi almasına neden olmaktadır. Tedavi süresince alınan yanlış negatif sonuç tedavinin yarıda kesilmesine, yanlış

pozitif sonuç ise gereksiz yere tedavinin uzamasına neden olmaktadır. Yanlış sonuçlar, hastaya ve topluma zarar vermekle birlikte TB kontrol programının başarısını da önemli ölçüde etkileyecektir.

Mikroskopik incelemenin otomatikleştirilmesi, incelenecek yayma sayısını artırarak tanıyı hızlandırırken, laboratuvar çalışanlarının iş yükünü ve infeksiyon kapma riskini azaltacaktır. Ayrıca tanının doğruluğunu ve duyarlılığını geliştirerek hatayı da minimuma indirecektir [3].

1.3.5. Türkiye' de ve Dünya' da Tüberküloz

TB, infeksiyonlu hastalıklara bağlı ölümlerin meydana gelmesinde HIV' den sonra ikinci sırada yer almaktadır. 2011 yılında 8,7 milyon kişi TB hastalığına yakalanmış ve 1,4 milyon kişi ise TB hastalığından dolayı ölmüştür. 2010 yılında ise yaklaşık 10 milyon çocuk, aile içinde TB kaynaklı ölümlerin meydana gelmesinden dolayı ailesiz kalmıştır [16].



Şekil 1.3. Dünyadaki tüberküloz vakalarının kıtalara göre dağılımı [16].

Şekil 1.3.'deki harita incelendiğinde TB vakalarının daha çok düşük ve orta gelirli ülkelerde meydana geldiği görülmektedir. WHO'nun raporuna göre de 2011 yılında TB vakalarının en çoğunun %59 oranla Asya kıtasında meydana geldiği ve bunu %26 'lık oranla Afrika kıtasının izlediği belirtilmektedir. Benzer şekilde düşük vaka oranlarına bakıldığında

ise sırasıyla %7,7, %4,3 ve %3 oranları ile Doğu Akdeniz bölgesi, Avrupa bölgesi ve Amerika bölgesinin, TB vakalarının en az yaşandığı bölgeler olduğu görülür [16].

Türkiye'deki TB vakalarına bakıldığında 2011 yılında 14.417 yeni vakayla karşılaştığı ve her 100.000 kişinin %85'inin ölüm, hastalığın meydana gelmesi gibi çeşitli biçimlerde bu hastalıktan etkilendiği bilinmektedir. TB hastalığına yakalanan kişilerde başarılı tedavi oranı ise yaklaşık %90 civarlarındadır [16]. Tedavi başarısına bakıldığında, özellikle yirminci yüzyılın ortalarında önemli bir hastalık olan tüberkülozun artık insanlar için bir ölüm nedeni olmaktan çıktığı görülmektedir.

1.4. Öznitelik Çıkarımı

Öznitelik çıkartılması, sadece bir sınıfa özgü olan, diğer sınıflarda bulunmayan bilgilerin belirlenme işlemidir. Bir sınıfın diğerlerine göre ayırıcı niteliklerini ortaya koymak, bölütleme ve sınıflandırma aşamalarında performansın artışı yönünde olumlu etki yaratmaktadır.

1.4.1. RGB Renk Modeli


Görüntü işleme, bilgisayar grafikleri ve çoklu ortam sistemlerinde RGB temsili en sık kullanılan renk uzayıdır. Renkli ya da çok bantlı bir görüntü, kırmızı bileşeni f_r , yeşil bileşeni f_g ve mavi bileşeni f_b olan bir f fonksiyonu ile temsil edilebilir. Bu 3 farklı bileşenin farklı yoğunluklarda birleştirilmesi ise doğada kullandığımız diğer tüm renklerin elde edilmesini sağlar. Bu nedenle de diğer renk modellerine göre daha sık tercih edilmektedir.

Kırmızı, yeşil ve mavi bileşenlerden oluşan renkli görüntülerde en küçük değer 0 siyaha, en büyük değer 255 ise kırmızı, yeşil ya da maviye karşılık gelmekte bu da toplamda yaklaşık 16,7 milyon renk gölgesini oluşturmaktadır.

1.4.2. Piksel ve Piksel İlişkileri

Dijital görüntüler, satır ve sütun indekslerinin görüntü üzerinde bir noktayı tanımladığı bir matrisle temsil edilir. Bu matrisin elemanları görüntü elemanı ya da piksel olarak ifade

edilmektedir. Görüntünün sol üst köşesi (0,0) pikselini göstermekte ve bu piksele merkez piksel adı verilmektedir. Görüntü piksel koordinatları resim boyutuyla sınırlı kalmaktadır.



Şekil 1.4. (a) 4 ve (b) 8 bağlantılı komşuluklar

Dijital bir görüntüde her bir pikselin, 3×3 matriste olduğu gibi 8 bitişik komşu pikseli bulunmaktadır. Herhangi bir p pikselinin 4 dikey ve yatay komşulukları ve koordinatları Şekil 1.4(a).’da gösterilmektedir. Burada her bir komşu piksel p pikselinden bir birim uzaklıkta bulunmaktadır. Kalan 4 köşegen komşuluklarda bu kümeye eklendiğinde Şekil 1.4(b).’deki 8-bağlantılı komşuluklar elde edilmiş olur.

1.4.3. Tek Değişkenli Gauss Olasılık Yoğunluk Fonksiyonu


Gauss fonksiyonu adını Carl Friedrich Gauss (1777-1855)’ dan alan çan eğrisi biçimine sahip bir fonksiyondur. Bu karakteristik şeklini $+\infty$ ve $-\infty$ ’a doğru hızla düşmesinden almaktadır.

Ortalaması $E[X] \equiv \mu$ ve varyansı $\text{Var}(X) \equiv \sigma^2$ olan tek değişkenli normal (Gauss) dağılımın olasılık yoğunluk fonksiyonu (1.1) eşitliğindeki gibi verilmektedir.

$$p(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi} \sigma} \exp\left(-\frac{1}{2\sigma^2}(x-\mu)^2\right) \quad (1.1)$$

Burada üstel fonksiyonun argümanı, $-\frac{1}{2\sigma^2}(x-\mu)^2$, x değişkeninin ikinci dereceden fonksiyonudur. Ayrıca ikinci dereceden terim katsayısı negatifken, parabol aşağı yönlüdür.

Önündeki katsayı, $\frac{1}{\sqrt{2\pi} \sigma}$, x ’e bağlı olmayan bir sabittir.



Şekil 1.5. Farklı μ ve σ değerlerine bağlı tek değişkenli GOYF'ler

Şekil 1.15.'deki GOYF'lere bakıldığında μ değişkeninin eğrinin tepe yaptığı yerin merkez konumunu ve σ değişkeninin eğrinin genişliğini belirlediği görülmektedir. Sabit katsayı ise sadece eğrinin tepe noktasının yüksekliğini belirlemektedir. Bu katsayının değeri de σ 'ya bağlı olarak değiştiğinden şekildeki farklı σ değerlerine sahip eğrilerin tepe noktalarının yüksekliği de birbirinden farklı olmaktadır.

1.4.4. Mahalanobis Uzaklığı

Mahalanobis uzaklığı, $x = (x_1, x_2, \dots, x_N)^T$ ve $y = (y_1, y_2, \dots, y_N)^T$ şeklinde verilen iki rassal x ve y vektörleri arasındaki ayrılığın ölçütü olarak tanımlanabilir. S , dağılımın değişinti matrisi olarak verildiğinde Mahalanobis uzaklığı (1.2)'deki gibi hesaplanmaktadır.

$$d_M(x, y) = \sqrt{(x - y)^T S^{-1} (x - y)} \quad (1.2)$$

1.5. Mikroskopik Görüntülerin Bölütlenmesi

Görüntü bölütlemesi, bir görüntüyü belirlenen görüntü öznitelikleri bakımından aynı yapıya sahip olan farklı bölgelere ayırma olarak ifade edilir. Görüntü bölütleme, görüntü

analiz süreçlerinin ilk aşamasıdır. Nesne sınıflandırma gibi bölütleme sonrası yapılacak diğer aşamaların niteliği daha çok yapılan bölütleme işleminin başarısına bağlıdır.

Görüntü bölütleme; çoklu ortam uygulamaları, internet üzerinden renkli görüntü ve video iletimi, bilgisayar tabanlı eğitim ve uzaktan eğitim gibi birçok sayısız uygulamada sıklıkla kullanılmaktadır.

Görüntü bölütleme, insan görsel algısının da önemli bir özelliğidir. İnsanlar çevrelerinde gördüklerini farklı nesnelere ayırmak için görsel algılarını kullanırlar. Bu süreç insanlar için kendiliğinden oluşan doğal bir aktivitedir. Fakat bu süreç resimlerdeki nesnelere için renk, biçim, hareket ve doku analizini gerektirmektedir. Bu yüzden performansının insan görsel sisteminin performansı ile karşılaştırılabildiği algoritma yaratmak çok da kolay değildir. Son yıllarda görüntü bölütlemesi için geliştirilen uygulamalara bakıldığında bu algoritmaları 5 ana kategoriye ayırmak mümkündür: eşikleme, kümeleme, kenar algılama, bölge büyütme ve şablon eşleme. Bu algoritmalar birçok uygulamada başarılı sonuçlar vermektedir, ancak bunların hiçbiri genel olarak tüm görüntülere uygulanamamakta ve farklı algoritmalar da belirli bir uygulama için her zaman başarılı sonuçlar üretememektedir [27]. Bu sebeplerden dolayı, görüntü bölütlemenin hızını ve doğruluğunu artırmak için birçok yaklaşım öne sürülmekte ve yapay zeka gibi diğer alanlardaki bilgilerden de yararlanılmaktadır [28]. Literatüre bakıldığında YSA [29], RO [30] ve DVM [31] algoritmaları gibi akıllı yaklaşımların görüntü bölütlemesinde başarılı bir şekilde kullanıldığı görülmektedir.

1.5.1. Çok Değişkenli Gauss Olasılık Yoğunluk Fonksiyonu

$X = [X_1 \dots X_n]^T$ biçimindeki bir vektör değerli rassal değişkenin, olasılık yoğunluk fonksiyonunun (1.3) eşitliğiyle verilmesi halinde, μ ortalamalı ve Σ ortak değişinti matrisli çok değişkenli normal (Gauss) dağılımına sahip olduğu söylenmektedir.

$$p(\mathbf{x}; \mu, \Sigma) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu)\right) \quad (1.3)$$

Çok değişkenli olasılık yoğunluk fonksiyonunda üstel fonksiyonun argümanı, $-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu)$, \mathbf{x} vektör değişkeninin ikinci dereceden biçimidir. Σ , pozitif


tanımlı olduğundan ve herhangi bir pozitif tanımlı matrisin terside pozitif tanımlı olduğundan, sıfırdan farklı bir z vektörü için (1.4) eşitliği söylenebilir.

$$z^T \Sigma^{-1} z > 0, z \neq \mu \quad (1.4)$$

Buradan da (1.5) ve (1.6) elde edilebilir.

$$(x - \mu)^T \Sigma^{-1} (x - \mu) > 0 \quad (1.5)$$

$$-\frac{1}{2}(x - \mu)^T \Sigma^{-1} (x - \mu) < 0 \quad (1.6)$$



Şekil 1.6. Çok değişkenli GOYF

Tek değişkenli GOYF’de olduğu gibi burada da üstel fonksiyonun argümanı, aşağıya doğru genişleyen n . dereceden bir çanak biçiminde düşünülebilir. Önündeki katsayı, $\frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}}$, tek değişkenli GOYF’deki katsayıdan biraz daha karmaşıktır ve hala x ’e bağlı değildir.

Çok değişkenli gauss olasılık yoğunluğunu anlamak için kovaryans matris kavramını kavramak gereklidir. Rassal X ve Y değişken çifti düşünüldüğünde kovaryansları (1.7) eşitliğindeki gibi ifade edilir.

$$\text{Cov}[X, Y] = E[(X - E[X]) (Y - E[Y])] = E[XY] - E[X] E[Y] \quad (1.7)$$

Çoklu değişkenlerle çalışıldığında kovaryans matris, bütün değişken çiftlerinin kovaryansını özetlemek için kısa bir yol sağlar. Σ sembolü ile ifade edilen kovaryans matris, (i,j) indeksli girişi $Cov[X_i, X_j]$ olan $n \times n$ boyutlu kare bir matristir. Aşağıdaki adımlar takip edildiğinde elde edilen (1.8) eşitliği gibi tanımlanır.

$$\begin{aligned}
\Sigma &= \begin{bmatrix} Cov[X_1, X_1] & \cdots & Cov[X_1, X_n] \\ \vdots & \ddots & \vdots \\ Cov[X_n, X_1] & \cdots & Cov[X_n, X_n] \end{bmatrix} \\
&= \begin{bmatrix} E[(X_1 - \mu_1)^2] & \cdots & E[(X_1 - \mu_1)(X_n - \mu_n)] \\ \vdots & \ddots & \vdots \\ E[(X_n - \mu_n)(X_1 - \mu_1)] & \cdots & E[(X_n - \mu_n)^2] \end{bmatrix} \\
&= E \begin{bmatrix} (X_1 - \mu_1)^2 & \cdots & (X_1 - \mu_1)(X_n - \mu_n) \\ \vdots & \ddots & \vdots \\ (X_n - \mu_n)(X_1 - \mu_1) & \cdots & (X_n - \mu_n)^2 \end{bmatrix} \\
&= E \left[\begin{bmatrix} X_1 - \mu_1 \\ \vdots \\ X_n - \mu_n \end{bmatrix} [X_1 - \mu_1 \dots X_n - \mu_n] \right] \\
\Sigma &= \mathbf{E}[(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^T] \tag{1.8}
\end{aligned}$$

Böylece, Σ hem simetrik pozitif tanımlı hem de köşegen elemanları, her bir farklı x elemanının varyansı olan bir matris olur. Köşegen dışındaki elemanlar ise pozitif veya negatif olabilen kovaryans değerleridir.

1.5.1.1. Gauss Olasılık Yoğunluk Fonksiyonunun Özellikleri

μ ve σ parametrelerine sahip normal bir dağılımın özellikleri aşağıda verilmektedir.

1. Eğri çan şeklindedir. Simetrik olduğu için ortalama, medyan ve mod değerleri birbirlerine eşittir.
2. Eğri x-ksenine asimtotiktir, yani x eksenine sadece $-\infty$ ve $+\infty$ 'da değer.
3. Eğri, $\mu - \sigma$ ve $\mu + \sigma$ 'da bükülme noktalarına sahiptir.
4. Eğrinin altında kalan toplam alan 1'e eşittir.
5. Normal dağılım için olan olasılıklar 3-Sigma Kuralı olarak da bilinen Ampirik Kural ile aşağıdaki gibi ifade edilir.
 - Eğri değerlerinin yaklaşık % 68'i ortalama değerden ± 1 standart sapma uzaklığındaki aralıkta yer alır.

- Eğri değerlerinin yaklaşık % 95'i ortalama değerden ± 2 standart sapma uzaklığındaki aralıkta yer alır.
- Eğri değerlerinin yaklaşık hepsi (yaklaşık % 99,7'i) ortalama değerden ± 3 standart sapma uzaklığındaki aralıkta yer alır.

1.5.2. Toplu Öğrenme Yöntemleri

Toplu öğrenme bir problemi çözmek için tek bir sınıflandırıcı yerine çoklu sınıflandırıcıların eğitildiği bir makine öğrenmesi modelidir. Eğitim verisinden tek bir varsayım yapılan diğer makine öğrenmesi yaklaşımlarına karşılık, toplu öğrenme yöntemleri varsayımlar kümesi yaratır ve bunları birleştirerek kullanır [32].

Çoklu modellerin uygulanma düşüncesi uzun yıllardır süregeldiği için toplu öğrenme yöntemlerinin kullanımının başlangıç noktasını takip etmek zordur. Torbalama (Breiman 1994) [33], toplu öğrenme yöntemlerinin en etkili ve en basit ilk yöntemidir. Yöntem, eğitim setinin yer değiştirmeye örneklenmiş çoklu kombinasyonlarını kullanır. Her bir eğitim seti ise farklı bir modeli eğitmek için kullanılır. Modellerin çıktısı ise tek bir çıktı elde etmek için topluluğun ortalamasının alınması ya da oylama ile belirlenir. Torbalama yöntemi sadece eğitim setindeki küçük değişikliklerin model üzerinde önemli ölçüde değişiklik yarattığı kararsız doğrusal olmayan modellerin kullanımında etkilidir [34]. Hızlandırma (Schapire 1990) [35] ise birçok değişik biçimi olan algoritmalar topluluğudur. Bu algoritmalar arasında en tanınmış olanı ise Adaboost [36] yöntemidir. Bu yöntemde öncelikle, bütün eğitim örneklerine eşit ağırlıklar atanır. Ağırlıkların dağılımı ve eğitim veri setinden temel bir sınıflandırıcı tasarlanır ve test işlemi gerçekleştirildikten sonra yanlış sınıflandırılmış örnekler bir sonraki iterasyonda daha önemli olsun diye bunların ağırlıkları artırılarak ağırlık güncellemesi yapılır. Güncelleme süreci belirlenen bir öğrenme tur sayısı kadar tekrar edilmektedir. Son sınıflandırıcı ise her bir sınıflandırıcının ağırlıklı çoğunluğundan elde edilir [32]. RO [37] yöntemi Torbalama yöntemine rastgelelik özelliğinin eklenmesiyle elde edilmiş bir yöntemdir. Adaboost yöntemiyle karşılaştırıldığında bu yöntem onun kadar iyi hatta bazen daha iyi sonuçlar vermektedir ve gürültüye karşı daha dayanıklıdır. Hızlı olması ve yüksek doğruluk sağlaması yönünden de diğer iki toplu öğrenme yöntemine göre avantaj sağlamaktadır. RO, her bir ağacın, bağımsız örneklenen fakat ormandaki diğer ağaçlarla aynı dağılıma sahip rastgele bir vektörün

değerlerine bağlı olduğu, ağaç tipi sınıflandırıcıların birleşiminden oluşmaktadır. Ormanın genelleştirilmiş hata oranı ormandaki tekil ağaçlarını gücüne ve ağaçlar arasındaki karşılıklı ilişkiye bağlıdır.

1.5.2.1. Rastgele Ormanlar

RO yöntemi Leo Breiman ve Adele Cutler tarafından geliştirilen bir toplu öğrenme yöntemidir. Ormanın eğitimi aşamasında karar ağaçları oluşturulmakta ve tekil ağaçlardan en çok oyu alan sınıf karar sınıfı olarak belirlenmektedir.

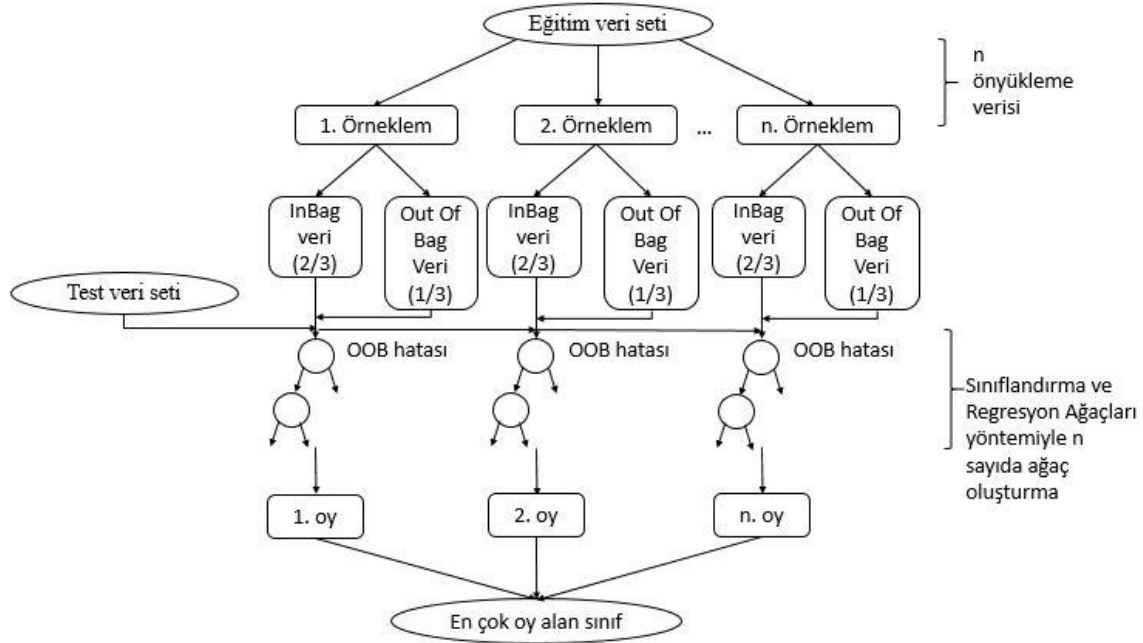
Topluluktaki her bir ağacın oluşturulması için rastgele vektörler oluşturulmaktadır. Bunun ilk örneği, her bir ağacın oluşturulması için eğitim kümesindeki örneklerden rastgele seçim yapılan Torbalama yöntemidir. Bir diğer örnek ise, her bir düğümde K tane en iyi bölünme arasından rastgele bölünme seçimidir [38]. Diğer bir yaklaşım eğitim kümesindeki örnekler üzerindeki rastgele ağırlık kümelerinden eğitim kümesi oluşturmaktır. [39], her bir ağacı oluşturmada kullanılan özniteliklerin rastgele alt kümesinin seçimi olan rastgele alt uzay seçimi yöntemi üzerinde birçok makale yayınlamıştır. Aynı şekilde [40], yazılı karakter sınıflandırma üzerine yazdıkları bir makalede sayısız geometrik öznitelik tanımlayıp her bir düğümde en iyi bölünmeyi sağlamak için rastgele seçim üzerine araştırmalar yapmışlardır. Yapılan bu çalışmalar Breiman tarafından RO yönteminin ortaya çıkarılmasında etkili olmuştur [37].

1.5.2.1.1. Rastgele Ormanlar Yöntemine Genel Bakış

RO, $\{\theta_k\}$ 'nin bağımsız özdeşçe dağılmış rastgele vektörlerden meydana geldiği $\{h(x, \theta_k), k = 1, \dots\}$ biçiminde ağaç yapılı sınıflandırıcı topluluğundan oluşan bir sınıflandırıcıdır. Burada her bir k . ağaç için rastgele oluşturulan θ_k , önceki $\theta_1, \dots, \theta_{k-1}$ rastgele vektörlerden bağımsız fakat onlarla aynı dağılıma sahiptir. Çok sayıda ağaç oluşturulduktan sonra her bir ağaç herhangi bir x girişi için bir sınıfa oy verir. En çok oy alan sınıf ise karar olarak belirlenir. RO yönteminin genel şeması Şekil 1.7.'de verilmektedir.

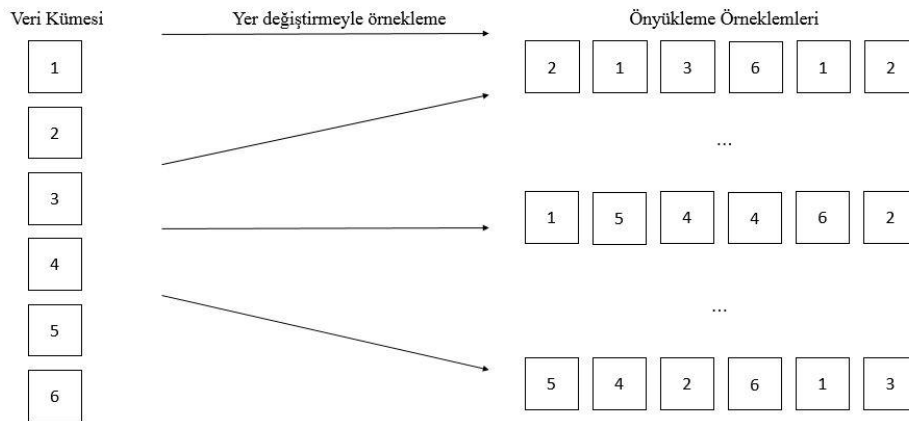
RO algoritmasında, eğitim veri kümesindeki verilerle ormandaki ağaçları oluşturmak için kullanıcı tarafından belirlenmesi gereken iki parametre bulunmaktadır. Bu parametreler

oluşturulacak olan ağaçların sayısı (n) ve en iyi bölünmeyi belirlemek için her bir düğümde kullanılacak olan değişken sayısı (m)'dır.



Şekil 1.7. RO yönteminin genel şeması

1.5.2.1.2. Önyükleme



Şekil 1.8. Önyüklemeli örneklem oluşturma

Önyükleme yöntemi ilk kez 1979 yılında Bradley Efron tarafından ortaya atılmıştır [41]. 1993 yılında ise Efron ve Tibshirani tarafından geliştirilmiştir. Mevcut veri setindeki

verilerden her defasında yerine konarak farklı örnekler seçip yeni bir veri kümesi oluşturmak mümkündür. Bu şekilde yeni veri kümeleri oluşturmaya önyükleme metodu denilmektedir. Önyükleme metodu ile örnek seçimi Şekil 1.8.'de gösterilmektedir.

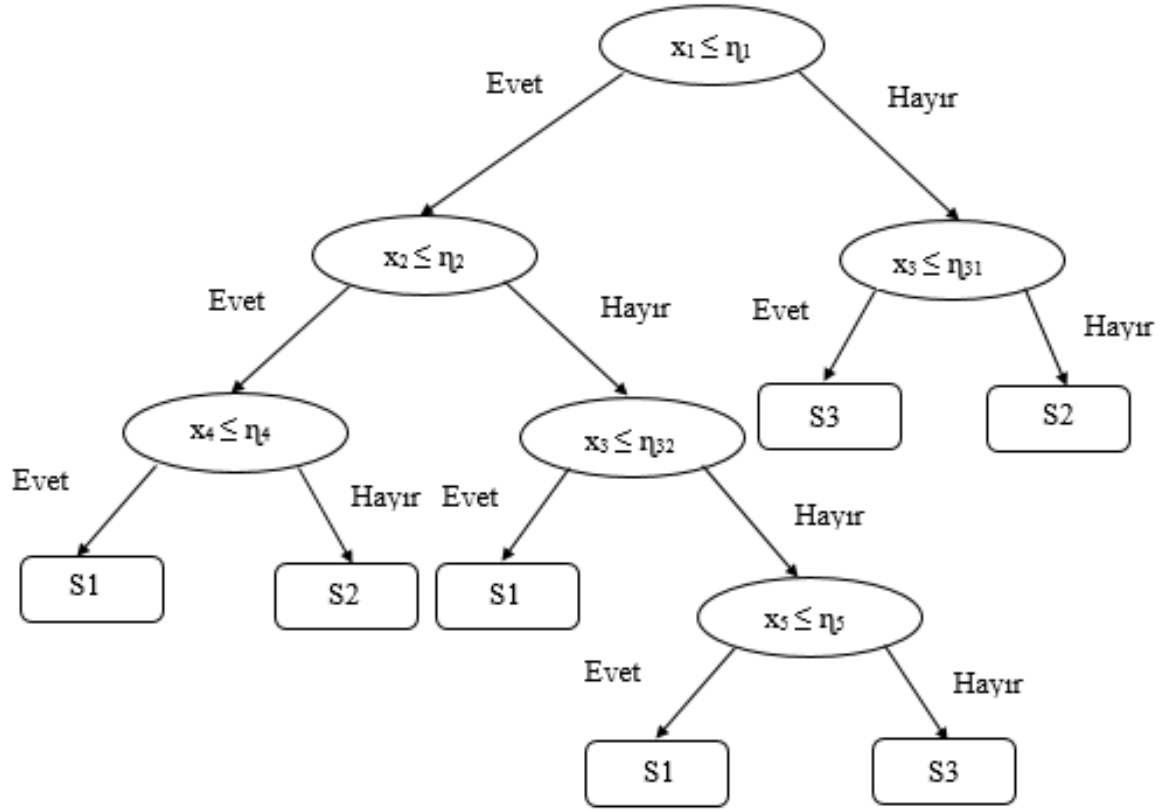
RO algoritmasında da eğitim veri setinden, kullanıcı tarafından belirlenen oluşturulacak ağaç sayısı kadar önyükleme örnekleme yapılmaktadır. Oluşturulan örneklemin 2/3'ü ormandaki ağaçları oluşturmak için InBag verisi olarak, 1/3'ü ise kurulan modelin hata oranını hesaplamak için Out Of Bag verisi olarak ayrılmaktadır. Bu hata oranı modelin kendi kendini test etmesi sonucu oluşmuş bir model içi hata oranıdır.

1.5.2.1.3. Karar Ağaçları

Karar ağaçları sınıflandırıcıları sinyal sınıflandırma, karakter sınıflandırma, uzaktan algılama, tıbbi teşhis, uzman sistemler ve konuşma sınıflandırma gibi birçok geniş alanda başarılı bir şekilde kullanılmaktadır. Karar ağaçları sınıflandırıcılarının en önemli özelliği, karışık karar verme süreçlerini daha basit kararlar topluluğuna dönüştürmektir ve böylece bu yolla alınan sonuç çözümünün istenilen çözüme benzemesi istenir [42].

Sınıflandırma ağaçları olarak da bilinen karar ağaçları, çok aşamalı karar süreçlerinin bir örneğidir. Model aynı zamanda köklü bir ağaç olarak tanımlanmaktadır. Ağaç yapısı kök, iç düğüm, dal ve yaprak olarak adlandırılan dört temel kısımdan oluşmaktadır. Burada gelen uca sahip olmayan düğüm kök olarak isimlendirilmekte ve diğer tüm düğümlerin kesin bir gelen ucu olmaktadır. Gelen uca sahip düğümler arasında çıkış ucu olan düğümlere ise iç düğüm adı verilir, diğer tüm düğümler yaprak olarak isimlendirilir. Karar ağaçlarında her bir iç düğüm, örnek uzayını giriş öznitelik değerlerinin belirli bir ayrık fonksiyonuna göre iki ya da daha fazla alt uzaya böler. En basit ve sık uygulananı, her bir iç düğümün tek bir özniteliği dikkate alması ve örnek uzayının bu öznitelik değerine göre bölünmesidir. Yani burada her bir düğüm bir özniteliğe karşılık düşerken, dallar ise bu özniteliğin değer aralığını ifade eder. Her bir yaprak ise bir sınıfa atanmaktadır.

Örnekler, ağacın kökünden başlayıp yaprağa doğru gezinerek sınıflandırılır. Burada yol ise her bir düğümdeki bölünme şartının sonucuna göre belirlenir. Ağacın kökünden başlanır ve köke karşılık gelen öznitelik ele alınır. Ardından bu özniteliğin gözlenen değerinin hangi çıkış dalına karşılık geldiği bulunur. Yol üzerindeki bir sonraki düğüm seçilmiş olan dalın sonunda olan düğümdür. Aynı işlemler bu düğüm içinde tekrarlanır ve yaprağa ulaşıncaya kadar ağaçta gezinilir [43].



Şekil 1.9. Karar ağaçları sınıflandırıcıları için oluşturulmuş bir ağaç yapısı

Şekil 1.9.'daki yapı kullanılarak gerçekleştirilen sınıflandırma işlemi daha anlaşılır biçimde verilirse, ağaçtaki iç düğümler karar düğümleridir ve farklı öznelikleri temsil ederler. Farklı özneliklerin değerleri olan η eşik değerlerine bağlı olarak sınıflandırılacak örneğin özneliklere ait olan x değerleri kökten yapraklara doğru ilerlerler. Gezinme esnasında iç düğümlerdeki şart koşullarına göre bir alt düğüme geçiş sağlanır. Yaprak düğüme gelindiğinde ise o örneğe ait sınıf belirlenmiş olur.

Literatürde daha anlaşılabilir olduklarından karmaşıklığı az olan karar ağaçları önerilmektedir. Bunun yanında Breiman ve arkadaşlarına göre (1984) [44] ağaç karmaşıklığının performans doğruluğu üzerinde çok önemli etkisi vardır. Genellikle geniş karar ağaçları verilere aşırı uyum sağlama ile elde edilir ve bu yüzden zayıf genelleştirme yeteneği sergilerler. Buna rağmen geniş bir karar ağacı eğer verilere aşırı uyum sağlama ile başlatılmamışsa yeni örnekleri kolayca genelleştirebilir. Oluşturulmuş bir ağacın

karmaşıklığını ise toplam düğüm sayısı, toplam yaprak sayısı, ağacın derinliği ve kullanılan özelliklerin sayısı belirler [43].

Karar ağacı oluşturma algoritmaları verilen bir veri kümesinden karar ağacı oluşturmaktadır. Genel olarak amaç, genelleştirilmiş hata oranını minimum yapacak olan en uygun karar ağacını bulmaktır. Bununla birlikte ağacın ortalama derinliğini minimum yapmak ya da oluşturulacak düğüm sayısını minimum yapmak gibi hedefler de belirlenebilir.

Verilen bir veri kümesinden en uygun karar ağacının oluşturulması zor bir iş olarak düşünülmektedir. Hancock ve arkadaşları (1996) [45] , verilen bir eğitim kümesi için minimum karar ağacının oluşturulmasını ‘belirsiz polinomsal zamanda çözülebilen’ (NP) problemlerin ‘Zor’ sınıfına atamaktadır. Diğer taraftan Hyafil ve Rivest (1976) [46] ise yeni bir örneğin sınıflandırılması için gerekli olan test sayısı ile ilişkili olarak minimum ikili ağacın oluşturulmasını NP-Tam sınıfına atamaktadır. Oluşturulmuş bir karar ağacının minimum eşdeğer karar ağacını bulmak [47] ya da karar tablosundan en uygun karar ağacını oluşturmak NP-Zor sınıflı problem olarak bilinmekte ve NP-Tam ise hem NP hem de NP-Zor olan problemlerin sınıfına denilmektedir [43].

Karar ağacı oluşturma problemlerinin çözümü için sezgisel yöntemler kullanılmaktadır. Bu yöntemler iki gruba ayrılabilir: yukarıdan-aşağıya yaklaşımı ya da aşağıdan-yukarıya yaklaşımı. Literatüre bakıldığında ilk grubun daha çok tercih edildiği görülmektedir [48]. Burada karar ağacı, ağacın kökü yukarıda, yaprakları ise aşağıda olarak oluşturulur. Ağacın oluşturulması aşağıdaki adımlardan oluşmaktadır:

1. Her bir iç düğüm için bölünme kuralının seçimi. Yani, her bir düğümde veri kümesini ayırmak için özelliklerin bir eşik değeri ile birlikte belirlenmesidir.
2. Hangi düğümlerin yaprak düğüm olacağına karar verilmesi. Bu adım her bir düğüm için bölünmeye devam edilip edilmeyeceğine ya da düğümü yaprak düğüm yapıp ona bir sınıf etiketi atanıp atanmayacağına karar vermektir.
3. Yaprak düğümlere sınıf etiketi atanması. Bu oldukça basittir, tahmini yanlış sınıflandırma oranını minimum yaparak etiketlerin atanması yapılır.

ID3 [49], C4.5 [50], Sınıflandırma ve Regresyon Ağaçları (CART) [44] gibi çeşitli yukarıdan-aşağıya karar ağacı oluşturma yöntemleri bulunmaktadır. C4.5 ve CART gibi bazı yöntemler büyütme ve budama olmak üzere iki safhadan oluşmaktadır. Diğer yöntemler ise sadece büyütme safhasından meydana gelmektedir.

1.5.2.1.3.1. Sınıflandırma ve Regresyon Ağaçları Yöntemi

CART yöntemi 1984 yılında Breiman, Freidman, Olshen ve Stone tarafından geliştirilmiştir [44]. Karar ağaçlarını oluşturmak için CART, sınıfları önceden belirlenmiş veri kümesi olan öğrenme örnekleri olarak adlandırılan verileri kullanır. Karar ağaçları öğrenme örneklerini soru kümeleriyle birlikte çok küçük parçalara ayırır. Burada CART yöntemi sadece evet/hayır sorularını sorar. Yani bu yöntem en iyi bölünmeyi –maksimum homojenlik ile veriyi iki parçaya ayıracak soruyu- bulmak için mümkün olan bütün değişkenleri ve değerleri arayacaktır. Bu süreç her bir veri parçası için tekrarlanır.

Literatürde yüzlerce değişken ve seviyeden oluşan oldukça karmaşık karar ağaçları mevcuttur. CART yöntemi kolayca sayısal ve kategorik verileri işleyebilmektedir. CART yönteminin bir diğer avantajı ise aykırı durumlara karşı sağlam oluşudur. Genellikle bölünme algoritmaları aykırı durumları tekil düğümlerde diğerlerinden ayırır. CART yönteminin önemli bir özelliği ise sınıflandırma ve regresyon ağaçları yapısının, bağımsız değişkenlerin monoton dönüşümleri bakımından değişmez olmasıdır.

CART yöntemi 3 aşamadan oluşmaktadır [51]:

1. Maksimum ağacın oluşturulması.
2. Doğru ağaç boyutunun seçimi.
3. Oluşturulan ağacın kullanılarak yeni verilerin sınıflandırılması.

1. Maksimum Ağacın Oluşturulması


Maksimum ağacın oluşturulması, öğrenme örneklerini sınıf bilgisini içeren son yapraklara kadar bölmek anlamına gelmektedir. Sınıflandırma ve regresyon için kullanılan bölünme algoritmaları birbirinden farklıdır. Sınıflandırma ağaçları, öğrenme örnekleri kümesinin her birinin sınıfının önceden bilindiği verilerde kullanılırken, regresyon ağaçları ise sınıfların bilinmediği verilerde kullanılır.

a) Sınıflandırma Ağacı:

Sınıflandırma ağaçlarında öğrenme örneklerindeki sınıflar önceden kullanıcı tarafından belirlenmiştir. t_p 'nin üst düğüm, t_l ve t_r 'nin ise sırasıyla üst düğüme ait sol ve sağ alt düğüm ve benzer şekilde M tane x_j değişkenli ve N tane örnekleli X değişken matrisli

öğrenme örneği kümesinin $-[N \times M]$ boyutlu- ve K tane sınıfa sahip N örnekli Y sınıf vektörünün $-[N \times 1]$ boyutlu- olduğunu kabul edelim.

Sınıflandırma ağaçları, öğrenme örneklerini küçük parçalara bölen kural olarak bilinen bölünme kuralına göre oluşturulur. Her defasınada veri maksimum homojenliğe sahip iki parçaya ayrılır.



Şekil 1.10. CART bölünme algoritmasının basit yapısı

Şekil 1.10'daki yapıya göre t_p , t_l , t_r sırasıyla üst, sol alt ve sağ alt düğüme, x_j , j . değişkene ve x_j^R , x_j değişkeninin en iyi bölünme değerine karşılık gelmektedir.

Alt düğümlerin maksimum homojenliği, $i(t)$ saflık fonksiyonuyla tanımlanır. t_p üst düğümün saflığı, $x_j \leq x_j^R, j=1, \dots, M$, herhangi bir mümkün bölünmesi için sabit olduğundan, sol ve sağ alt düğüm için maksimum homojenlik, saflık fonksiyonunun değişiminin, $\Delta i(t)$, maksimizasyonuna eşit olacaktır:

$$\Delta i(t) = i(t_p) - E[i(t_c)] \quad (1.9)$$

Burada t_c , t_p üst düğümünün sol ve sağ alt düğümünü ifade etmektedir. P_l ve P_r 'nin sırasıyla sol ve sağ alt düğümün olasılıklarını ifade ettiğini varsayarsak (1.10) eşitliğini elde ederiz.

$$\Delta i(t) = i(t_p) - P_l i(t_l) - P_r i(t_r) \quad (1.10)$$

Bu yüzden, her bir düğüme CART aşağıdaki maksimizasyon problemini çözer.

$$\arg \max_{x_j \leq x_j^R, j=1, \dots, M} [i(t_p) - P_l i(t_l) - P_r i(t_r)] \quad (1.11)$$

(1.11), CART yönteminin, $\Delta i(t)$ saflık ölçütünün değişimini maksimum yapacak olan $x_j \leq x_j^R$ en iyi bölünme sorusu için, X matrisindeki bütün değişkenlerin mümkün olan bütün değerlerini arayacağını göstermektedir. Burada diğer önemli soru, $i(t)$ saflık fonksiyonunun nasıl tanımlanacağıdır. Teoride birçok saflık fonksiyonu bulunmaktadır, fakat bunlar arasından sadece ikisi pratikte daha sık kullanılmaktadır: Gini bölünme kuralı ve Twoing bölünme kuralıdır.

Gini Bölünme Kuralı: Gini indeksi olarak da bilinen Gini bölünme kuralı en sık kullanılan kuraldır. (1.12) eşitliğindeki saflık fonksiyonunu kullanmaktadır.

$$i(t) = \sum_{k \neq l} p(k|t)p(l|t) \quad (1.12)$$

(1.12)'de k ve $l = 1, \dots, K$ - sınıfların indeksi, $p(k/t)$ t düğümüne ait k sınıfının koşullu olasılığıdır. Gini saflık fonksiyonunu (1.11)'deki maksimizasyon problemine uygularsak, $\Delta i(t)$ saflık ölçütünün değişimini (1.13)'deki gibi elde ederiz.

$$\Delta i(t) = - \sum_{k=1}^K p^2(k|t_p) + P_l \sum_{k=1}^K p^2(k|t_l) + P_r \sum_{k=1}^K p^2(k|t_r) \quad (1.13)$$

Bundan dolayı Gini algoritması (1.14)'deki problemi çözecektir.

$$\arg \max_{x_j \leq x_j^R, j=1, \dots, M} \left[- \sum_{k=1}^K p^2(k|t_p) + P_l \sum_{k=1}^K p^2(k|t_l) + P_r \sum_{k=1}^K p^2(k|t_r) \right] \quad (1.14)$$

Böylece Gini algoritması öğrenme örneklerindeki en geniş sınıfı arayacaktır ve onu verilerin geri kalanından ayıracaktır. Bu algoritma gürültülü veriler içinde çok iyi çalışmaktadır.

Twoing Bölünme Kuralı: Gini kuralından farklı olarak Twoing, toplamda verinin %50'sini oluşturacak iki sınıf arar. Twoing bölünme kuralı, (1.15)'de verilen saflık ölçütünün değişimini maksimum yapacaktır.

$$\Delta i(t) = \frac{P_l P_r}{4} \left[\sum_{k=1}^K |p(k|t_l) - p(k|t_r)| \right]^2 \quad (1.15)$$

Dolayısıyla Twoing algoritması (1.16) eşitliğindeki maksimizasyon problemini çözecektir.

$$\arg \max_{x_j \leq x_j^R, j=1, \dots, M} \left(\frac{P_l P_r}{4} \left[\sum_{k=1}^K |p(k|t_l) - p(k|t_r)| \right]^2 \right) \quad (1.16)$$

Twoing bölünme kuralı, daha dengeli ağaçlar oluşturmayı sağlasada, Gini bölünme kuralından daha yavaş çalışır. Yani örneğin, toplam sınıf sayısı K 'ya eşit olduğu durumda Twoing bölünme kuralı ile 2^{K-1} mümkün bölünme elde ederiz.

b) Regresyon Ağacı:

Regresyon ağaçlarında, sınıflar bulunmamaktadır. Bunun yerine X değişken matrisindeki her bir örneğin tepki değerlerini gösteren Y tepki vektörü vardır. Regresyon ağaçları önceden belirlenmiş sınıflara sahip olmadığından, Gini ve Twoing gibi sınıflandırma bölünme kuralları regresyon ağaçlarına uygulanamaz.

Regresyon ağaçlarında bölünme 'artanların karelerini minimize etme algoritması'na göre yapılır. (1.17)'de verilen bu algoritma, iki sonuç düğümün beklenen toplam varyanslarını minimize eder.

$$\arg \min_{x_j \leq x_j^R, j=1, \dots, M} [P_l \text{Var}(Y_l) + P_r \text{Var}(Y_r)] \quad (1.17)$$

Burada $\text{Var}(Y_l)$ ve $\text{Var}(Y_r)$, sol ve sağ alt düğümün tepki vektörlerinin varyansını gösterirken, $x_j \leq x_j^R, j=1, \dots, M$, uygun bölünme sorusunu göstermektedir.

Artanların karelerini minimize etme algoritması, Gini bölünme kuralına benzerdir. Bu yüzden Gini saflık fonksiyonunu varyans gösterimiyle yorumlayabiliriz. K sınıfına sahip nesnelere 1 ve diğer sınıflara sahip nesnelere 0 değerini atarsak, bu değerlerin örnek varyansı $p(k/t)[1 - p(k/t)]$ denkleminde eşit olacaktır. Bu denklemi K sınıf sayısı ile özetlersek, (1.18)'deki saflık ölçütünü elde ederiz.

$$i(t) = 1 - \sum_{k=1}^K p^2(k|t) \quad (1.18)$$

Bölünme kuralları kullanılarak maksimum ağaç oluşturulur. Maksimum ağaç özellikle regresyon ağaçlarında her bir tepki değerinin ayrı bir düğümle sonlandığı durumlarda oldukça büyük oluşturulabilir. Bu durumlarda önemsiz düğümleri kesen budama yöntemleri kullanılır.

2. Doğru Ağaç Boyutunun Seçimi

Maksimum ağaçlar yüksek karmaşıklığa sahip olabilir ve çok sayıda seviyeden oluşmaktadırlar. Bu yüzden yeni gelen verilerin sınıflandırılmasından önce ağaçlar optimize edilebilir. Ağaç optimizasyonu önemsiz düğümleri ve hatta alt ağaçları keserek doğru ağaç boyutunu seçmek demektir. Pratikte iki budama algoritması kullanılmaktadır: yaprak sayısı ile yapılan optimizasyon ve çapraz geçerlilik.

Yaprak sayısı ile yapılan optimizasyon tekniğinde bölünme, yaprak düğüm sayısının önceden belirlenen gerekli olan N_{min} minimum yaprak düğüm sayısından az olması durumunda sonlandırılır. Buradan da N_{min} parametresinin büyük olması durumunda oluşturulan ağacın küçük olacağı açıkça görülmektedir. Önemli olan N_{min} parametresinin seçimidir; bu değerde genellikle öğrenme örneklerinin %10'u olarak belirlenir.

Çapraz geçerlilik yöntemi ise ağacın karmaşıklığı ile yanlış sınıflandırma hatası arasındaki oranın hesaplanmasına dayalı bir yöntemdir. Ağaç boyutunun artmasıyla yanlış sınıflandırma hatası azalır ve maksimum ağaç oluşturulduğunda bu hata 0'a eşit olur. Fakat diğer taraftan karmaşık karar ağaçları, bağımsız veriler üzerinde kötü bir performans sergilemektedir. Bu yüzden ağaç karmaşıklığı ve yanlış sınıflandırma hatası arasındaki uygun oranın bulunması gerekmektedir. Bu da (1.19) eşitliğindeki maliyet – karmaşıklık fonksiyonunun kullanımıyla gerçekleştirilir.

$$R_{\alpha}(T) = R(T) + \alpha(\tilde{T}) \rightarrow \min_T \quad (1.19)$$

Burada $R(T)$, T ağacının yanlış sınıflandırma hatasını, $\alpha(\tilde{T})$, ağaçtaki yaprak düğümlerinin toplam sayısını veren \tilde{T} 'ye bağlı karmaşıklık ölçütünü göstermektedir. α

parametresi ise test örnek dizisine göre hesaplanmaktadır. Bu süreç rastgele seçilen eğitim ve test örnekleri için birçok kez tekrarlanır.

3. Yeni Verilerin Sınıflandırılması

Sınıflandırma veya regresyon ağacı oluşturulduktan sonra ağaç yeni verilerin sınıflandırılması için kullanılır. Ağaca yerleştirilmiş soru kümeleri kullanılarak her bir örnek ağaçtaki yaprak düğümlerin gösterdiği sınıflardan birine sahip olur.

1.5.2.1.4. Out Of Bag Hata Kestirimi

RO yönteminde, test kümesi hatasının yansız kestirimini elde etmek için çapraz geçerlilik yöntemine ya da ayrı bir test veri kümesine ihtiyaç duyulmamaktadır. Bu işlem koşma esnasında iç hata olarak kestirilmektedir.

$T = \{(y_n, x_n), n=1, \dots, N\}$ biçiminde eğitim veri kümesinin olduğunu ve verilen eğitim veri kümesini kullanarak $Q(x, T)$ kestiricisinin oluşturulduğunu düşünelim. Burada y bir sınıf etiketidir. T eğitim veri kümesinden önyüklemeli, T ile aynı boyutta $T_{B,1}, \dots, T_{B,K}$ eğitim kümeleri ve ardından k . önyüklemeli eğitim veri kümesi için $Q(x, T_{k,B})$ kestiricileri oluşturulur. T eğitim kümesinden T_B eğitim kümeleri oluşturulurken örneklerin yaklaşık olarak %37'lik parçası, T_B eğitim kümesi içinde yer almaz. Bu ayrılan örneklerin kestirimi out-of-bag hatasını vermektedir [52]. Out-of-bag verisi, oluşturulan ağaçlar yani kestiriciler üzerinde yukarıdan aşağıya doğru yerleştirilir. Her bir karar ağacı için verilen sonuç sınıf kararı alınarak doğru sınıf ile karşılaştırılır. İki sınıfın birbirine eşit olmama durumunun sayısının oranı OOB hatasını vermektedir. Tüm karar ağaçları için yapılan OOB hata oranlarının ortalaması alınarak karar ormanının OOB hata kestirimi yapılır.

Literatüre bakıldığında out-of-bag hata kestirimini kullanan pek çok çalışma ile karşılaşılmaktadır. Tibshirani (1996) [53] ve Wolpert ve Macready (1999) [54], OOB hata kestirimini genelleştirilmiş hata kestiriminin bir bileşeni olarak kullanmayı önermişlerdir. Wolpert ve Macready regresyon tipi problemler üzerinde çalışmış ve torbalama kestiricilerinin genelleştirilmiş hatasını kestirmek için pek çok yöntem önermişlerdir. Tibshirani rastgele bir sınıflandırıcı için genelleştirilmiş hata kestirimini hesaplamak için varyansın out-of-bag kestirimini kullanmıştır. Breiman (1996) [52] ise out-of-bag kestiriminin, eğitim veri kümesiyle aynı boyutta test veri kümesi kullanmak kadar doğru

sonuç verdiğini deneysel olarak kanıtlayan sonuçlar vermiştir. Bu yüzden, out-of-bag hata kestirimi, test veri kümesinden farklı bir küme kullanma ihtiyacını ortadan kaldırmıştır.

Yeteri kadar ağaç oluşturulduğunda OOB hata oranının oldukça doğru kestirildiği, oluşturulmadığında ise OOB hata oranının olduğundan büyük kestirildiği belirtilmiştir. OOB hata oranı, modelin düzgün kurulmasını ve oluşturulan her ağaca bir ağırlık değeri verilmesini sağlar. En düşük hata oranına sahip ağaca en yüksek, en yüksek hata oranına sahip ağaca en düşük ağırlık verilir. Bu şekilde ormanda kurulan tüm ağaçlara göreceli olarak bir ağırlık verilmiş olur.

1.5.3. Destek Vektör Makineleri

DVM, 1995 yılında Vapnik [55] tarafından ortaya atılan sınıflandırma ve regresyon analizi için kullanılan bir danışmanlı öğrenme yöntemidir. Genelleştirilmiş doğrusal sınıflandırıcıları topluluğunun bir üyesidir. Bir başka deyişle, verilerin aşırı öğrenmesinden kaçınırken tahmin doğruluğunu maksimum yapmak için makine öğrenmesi teorisini kullanan sınıflandırma ve regresyon tahmin aracıdır [56].

DVM'nin amacı, örüntü vektörlerinin en iyi ayırma hiper düzlemini oluşturacak çok boyutlu öznitelik uzayına eşlenmesi ve sınıflandırılmasıdır. DVM daha çok ikili sınıflandırma üzerinde durmaktadır. Çok sınıflı sınıflandırıcılar ise ikili sınıflandırıcıların birleşimiyle oluşmaktadır.

1.5.3.1. Doğrusal Olarak Ayrılabilen Veriler

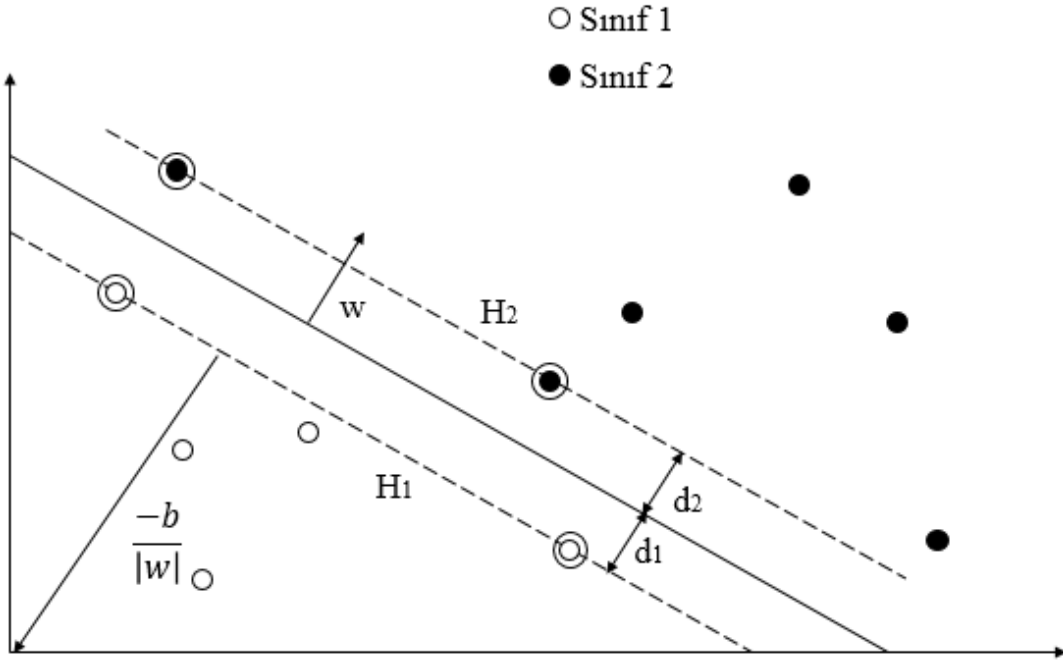
Her bir x_i verisinin D özelliğe sahip olduğu bir eğitim örnek kümesinin, $y_i = \pm 1$ etiketleriyle w_1 ve w_2 sınıflarından birine dahil olduğu ikili bir sınıflandırma işlemini ele alalım. Eğitim kümesi aşağıdaki biçimde ifade edilir.

$$\{x_i, y_i\}, i = 1, \dots, L, y_i \in \{-1, +1\}, x \in R^D$$

Doğrusal olarak ayrılabilen veri, $D=2$ olduğunda iki sınıfı ayırabilen bir çizgi ve $D > 2$ olduğunda ise bir hiper düzlem çizilebilir demektir. Hiper düzlem $wx + b = 0$ denklemi

ile ifade edilebilir. Burada w hiper düzleme diktir, $|b|/\|w\|$ hiper düzlemden merkeze olan dikey uzaklık ve $\|w\|$, w 'nin Öklid formudur.

Destek vektörleri ayırma hiper düzlemine en yakın olan örneklerdir ve DVM'nin amacı hiper düzlemi iki sınıfın en yakın örneklerinden olabildiğince uzağa getirecek biçimde yönlendirmektir. Yani en geniş marjinli hiper düzlemi aramaktır.



Şekil 1.11. İki doğrusal ayrılabilen sınıf aracılığıyla hiper düzlemin gösterimi

Şekil 1.11.'de görüldüğü gibi DVM'nin uygulanması, w ve b değişkenlerinin seçimi anlamına gelmektedir. Böylece eğitim verileri (1.20) ve (1.21) eşitliklerindeki gibi ifade edilebilir.

$$x_i \cdot w + b \geq +1, y_i = +1 \quad (1.20)$$

$$x_i \cdot w + b \leq -1, y_i = -1 \quad (1.21)$$

(1.20) ve (1.21), (1.22)'deki koşul biçiminde birleştirilebilir.

$$y_i (x_i \cdot w + b) - 1 \geq 0 \forall_i \quad (1.22)$$

Ayrırma hiper düzleminin en yakınında bulunan noktaları yani Şekil 1.11.'de daire içerisinde gösterilen destek vektörleri göz önüne alırsak, bu noktaların üzerlerinde bulunduğu H_1 ve H_2 düzlemleri (1.23) ve (1.24)'deki gibi ifade edilebilir.

$$H_1 : x_i \cdot w + b = +1 \quad (1.23)$$

$$H_2 : x_i \cdot w + b = -1 \quad (1.24)$$

Şekil 1.11'de d_1 , H_1 'den hiper düzleme olan uzaklık ve d_2 , H_2 'den hiper düzleme olan uzaklık olarak tanımlanmıştır. Hiper düzlemin H_1 ve H_2 'den eş uzaklığı, d_1 'in d_2 'ye eşit olduğunu gösterir ki bu da marjın olarak bilinmektedir. Hiper düzlemi, destek vektörlerden olabildiğince uzakta yönlendirmek için marjın maksimum yapılmalıdır.

Basit vektör geometrisi marjının $\frac{1}{\|w\|}$ 'ya eşit olduğunu gösterir ve marjını maksimum yapmak, w 'yu (1.22) koşuluna göre minimum yapmak demektir.

$$\min \|w\|, \text{ öyle ki, } y_i(x_i \cdot w + b) - 1 \geq 0 \forall_i \quad (1.25)$$

$\|w\|$ ' yu minimum yapmak $\frac{1}{2} \|w\|^2$ 'ni minimum yapmaya eşittir ve bu terimin kullanılması karesel programlama optimizasyonunun uygulanmasını mümkün kılar. Bu yüzden (1.26) eşitliğini çözmeye ihtiyaç vardır:

$$\min \frac{1}{2} \|w\|^2, \text{ öyle ki, } y_i(x_i \cdot w + b) - 1 \geq 0 \forall_i \quad (1.26)$$

Minimizasyondaki sınırlamalara sahip optimizasyon problemlerine getirilen standart bir yaklaşım Lagrange biçimciliğidir. Bu yüzden (1.26)'daki sınırlamalara, α Lagrange çarpanlarını dağıtmak gerekmektedir.

$$L_p \equiv \frac{1}{2} \|w\|^2 - \alpha [y_i(x_i \cdot w + b) - 1 \forall_i] \quad (1.27)$$

$$\equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^L \alpha_i [y_i(x_i \cdot w + b) - 1] \quad (1.28)$$

$$\equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^L \alpha_i y_i(x_i \cdot w + b) + \sum_{i=1}^L \alpha_i \quad (1.29)$$

(1.29) eşitliğini minimum yapacak w ve b değerleri ile maksimum yapacak α değerini bulmak için L_p 'nin w ve b 'ye göre türevleri alınır ve türevleri 0'a eşitlenir. Burada hala $\alpha_i \geq 0 \forall_i$ şartı sağlanmalıdır.

$$\frac{\partial L_p}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^L \alpha_i y_i x_i \quad (1.30)$$

$$\frac{\partial L_p}{\partial b} = 0 \Rightarrow w = \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.31)$$

(1.30) ve (1.31) eşitliklerini, (1.29) eşitliğinde yerine koyarsak maksimize edilmesi gereken, α 'ya bağlı yeni bir eşitlik elde ederiz.

$$L_D \equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j, \quad \text{öyle ki, } \alpha_i \geq 0 \forall_i, \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.32)$$

$$\equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i H_{i,j} \alpha_j, \quad H_{i,j} \equiv y_i y_j x_i \cdot x_j \quad (1.33)$$

$$\equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha, \quad \text{öyle ki, } \alpha_i \geq 0 \forall_i, \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.34)$$

Elde edilen yeni formül L_D , birincil problem olan L_p 'nin ikili biçimi olarak ifade edilir. Dikkat edilmelidir ki ikili biçim, hesaplanacak olan x_i giriş vektörlerinin her birinin iç çarpımına eşittir. L_D 'yi maksimize etmek için (1.35) hesaplanmalıdır.

$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right], \quad \text{öyle ki, } \alpha_i \geq 0 \forall_i, \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.35)$$

Bu bir konveks optimizasyon problemidir ve problemin çözümü α ' yı verir. (1.30) eşitliği ise bize w 'yu verir. Geriye b 'nin hesaplanması kalır. (1.31)'i sağlayan x_s destek vektörü olan herhangi bir veri (1.36)'daki biçime sahiptir.

$$y_s (x_s \cdot w + b) = 1 \quad (1.36)$$

(1.30) eşitliği, (1.36) eşitliğinde yerine koyulursa (1.37) elde edilir.

$$y_s \left(\sum_{m \in S} \alpha_m y_m x_m \cdot x_s + b \right) = 1 \quad (1.37)$$

Burada S , destek vektörlerin indis kümesini göstermektedir. S , $\alpha_i > 0$ olduğu durumlarda, i indislerinin bulunmasıyla elde edilir. (1.37) eşitliğinin her iki tarafının y_s ile çarpılıp (1.20) ve (1.21)'deki $y_s^2=1$ ifadesi kullanılırsa b , (1.38) ve (1.39) eşitlikleri ile elde edilir.

$$y_s^2 \left(\sum_{m \in S} \alpha_m y_m x_m \cdot x_s + b \right) = y_s \quad (1.38)$$

$$b = y_s - \sum_{m \in S} \alpha_m y_m x_m \cdot x_s \quad (1.39)$$

Keyfi bir x_s destek vektörü kullanmak yerine, S kümesindeki destek vektörlerin tümünün ortalamasını almak daha uygundur.

$$b = \frac{1}{N_s} \sum_{s \in S} \left(y_s - \sum_{m \in S} \alpha_m y_m x_m \cdot x_s \right) \quad (1.40)$$

Böylece bu denklemler yardımıyla ayırma hiper düzleminin en uygun yönlendirmesini tanımlayan w ve b değişkenleri belirlenmiş olur.

1.5.3.2. Doğrusal Olarak Ayrılamayan Veriler

DVM yöntemini, doğrusal olarak tamamen ayrılamayan verileri de ele alarak geliştirmek için, (1.20) ve (1.21) eşitliklerindeki sınırlamaları yanlış sınıflandırılmış noktalar için gevşetmek gerekmektedir. Bu, bir pozitif yapay değişkenin ($\xi_i, i = 1, \dots, L$) eşitliklere uygulanmasıyla gerçekleştirilir.


$$x_i \cdot w + b \geq +1 - \xi_i, \quad y_i = +1 \quad (1.41)$$

$$x_i \cdot w + b \leq -1 + \xi_i, \quad y_i = -1 \quad (1.42)$$

$$\xi_i \geq 0 \forall_i \quad (1.43)$$

(1.41), (1.42) ve (1.43) eşitlikleri, (1.44) koşulu biçiminde birleştirilebilir.

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0, \xi_i \geq 0 \forall_i \quad (1.44)$$



Şekil 1.12. İki doğrusal ayrılamayan sınıf aracılığıyla hiper düzlemin gösterimi

Yumuşak marjlinli DVM'de, marjin sınırının yanlış tarafında bulunan veri noktaları, uzaklıkla artan bir cezaya sahiptir. Yanlış sınıflandırma sayısını azaltmak için (1.26) eşitliğindeki hedef fonksiyonumuza uygulanabilecek makul bir yaklaşım, (1.45) eşitliğini bulmaktır.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i, \text{ öyle ki, } y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \forall_i \quad (1.45)$$

Burada C parametresi, pozitif yapay değişken ve marjin ölçüsü arasındaki ödünleşmeyi kontrol eder. Doğrusal olarak ayrılabilen verilerde olduğu gibi denklemi w , b ve ξ_i 'ye göre minimum ve α 'ya göre maksimum yapmak gerekmektedir. Bunun için denklem Lagrange olarak yeniden formüle edilirse (1.46) elde edilir.

$$L_p \equiv \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i - \sum_{i=1}^L \alpha_i [y_i(x_i \cdot w + b) - 1 + \xi_i] - \sum_{i=1}^L \mu_i \xi_i \quad (1.46)$$

Burada $\alpha_i \geq 0$ ve $\mu_i \geq 0 \forall_i$ şartı sağlanmalıdır. w , b ve ξ_i 'ye göre türev alınır ve türevler 0'a eşitlenirse (1.47), (1.48) ve (1.49) elde edilir.

$$\frac{\partial L_p}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^L \alpha_i y_i x_i \quad (1.47)$$

$$\frac{\partial L_p}{\partial b} = 0 \Rightarrow \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.48)$$

$$\frac{\partial L_p}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \mu_i \quad (1.49)$$

Denklemleri yerine koyarsak, L_D (1.34)'deki aynı biçime sahip olur. Bununla birlikte $\mu_i \geq 0 \forall_i$ şartını sağlayan (1.49) eşitliği, $\alpha \leq C$ şartını sağladığını da gösterir. Bu nedenle (1.50) bulunmalıdır.

$$\max_a \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right], \text{ öyle ki, } 0 \leq \alpha_i \leq C \forall_i \text{ ve } \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.50)$$

b , (1.40)'daki ifadeyle aynı biçimde hesaplanır. Yalnız bu durumda, b 'yi hesaplamak için kullanılan destek vektörlerin kümesi, $0 < \alpha_i \leq C$ olduğu durumda i indisini bulunmasıyla belirlenir.

1.5.3.3. Doğrusal Olmayan Destek Vektör Makineleri

Doğrusal olarak ayrılabilen verilere DVM uygulandığında, uygulamaya bütün giriş değişkenlerinin iç çarpımlarından H matrisi elde edilerek başlanır.

$$H_{ij} = y_i y_j k(x_i, x_j) = x_i \cdot x_j = x_i^T x_j \quad (1.51)$$

$k(x_i, x_j)$, çekirdek fonksiyon denilen fonksiyon topluluğunun bir örneğidir. Çekirdek fonksiyonların tümü iki vektörün iç çarpımlarının hesaplanması esasına dayanmaktadır. Bu demektir ki, eğer fonksiyonlar, doğrusal olmayan özellik eşleme fonksiyonuyla ($x \rightarrow \varphi(x)$)

yüksek boyutlu uzaya taşınabilirse, özellik uzayındaki eşlenen girişlerin sadece iç çarpımlarının, φ değişkenin açıkça hesaplanmasına ihtiyaç duyulmadan belirlenmesi gerekir.

Çekirdek fonksiyonlarının yararlı olmasının sebebi, x girişlerinin uzayında doğrusal olarak ayrılamayan/bağlanamayan birçok sınıflandırma/regresyon probleminin uygun bir eşleme fonksiyonuyla yüksek boyutlu özellik uzayına taşınabilmesidir.

En sık kullanılan çekirdek fonksiyonları aşağıdaki gibidir.

$$\text{Radyal Tabanlı fonksiyon: } k(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2} \quad (1.52)$$

$$\text{Polinomial fonksiyon: } k(x_i, x_j) = (x_i \cdot x_j + a)^b \quad (1.53)$$

$$\text{Sigmoid fonksiyon: } k(x_i, x_j) = \tanh(\alpha x_i \cdot x_j - b) \quad (1.54)$$

Fonksiyonlardaki a ve b parametreleri çekirdeğin davranışına göre belirlenmektedir.

1.6. Sınıflandırma Öncesi Ön İşlemler

1.6.1. Matematiksel Morfoloji

Matematiksel morfoloji, görüntü üzerinde sınırlar, iskelet gibi yapıların tanımlanması ve çıkarılması, gürültü giderilmesi gibi amaçlar için kullanılmaktadır. Görüntüdeki piksel yoğunlukları ile değil şekiller ile ilgilenir. Bütün matematiksel morfoloji işlemleri aşınma ve genleşme tabanlıdır [57].

1.6.1.1. Aşınma

İkili bir f görüntüsünün, s yapısal elemanı tarafından gerçekleştirilen aşınma işlemi, yapısal elemanın görüntü üzerinde gezdirilmesi ve yapısal elemandaki 1'lerin görüntüdeki 1'ler ile eşleşmesi esasına dayanmaktadır. Eşleştiği durumlarda görüntüdeki merkez piksel 1, diğer durumlarda ise 0 yapılıdır.

1.6.1.2. Genleşme

İkili bir f görüntüsünün, s yapısal elemanı tarafından gerçekleştirilen genleşme işlemi, yapısal elemanın görüntü üzerinde gezdirilmesi ve yapısal elemanın merkezindeki 1 ile görüntünün (x,y) koordinatındaki 1 eşleşirse, yapısal eleman ile görüntü parçası lojik or'lama işlemine tabi tutulur.

1.6.2. Bağlantılı Bileşen Etiketleme

Bağlantılı bileşen etiketleme, var olan bir görüntüyü tarayarak görüntünün piksellerini, piksel bağlantılarına dayanarak parçalar şeklinde gruplayan bir algoritmadır. Nesne tabanlı modellerin kurulmasında nesnelerin tekil olarak görüntüden çıkarılması önemli olduğundan sık kullanılan bir algoritmadır.

1.6.3. Moment Değişmezleri

Moment değişmezleri bir nesnenin biçimini karakterize etmek için kullanılır. Hem şeklin sınırları hem de iç bölgesindeki bilgiler kullanılarak hesaplanır. Sayısal şekil tabanlı bir görüntü için merkezi momentlerin ayrık formu (1.55)'deki gibi ifade edilir.

$$\mu_{pq} = \sum_{(x,y \in S)} (x - \bar{x})^p (y - \bar{y})^q \quad (1.55)$$

Burada \bar{x} ve \bar{y} , merkezi momentleri göstermektedir ve (1.56) ile (1.57) eşitlikleri kullanılarak hesaplanır.

$$\bar{x} = \frac{M_{10}}{M_{00}}, \bar{y} = \frac{M_{01}}{M_{00}} \quad (1.56)$$

$$M_{pq} = \sum_x \sum_y x^p y^q f(x, y) \quad (1.57)$$

1.7. Bölütlenmiş Verilerin Sınıflandırılması

Sınıflandırma, görüntü analizi alanında kullanılan gerekli tamamlayıcı fonksiyonlardır. Görüntüde var olan nesnelerin farklı yoğunluklarını ayırmak ve tanımlamak için kullanılan bir ölçütü ilgilidir. Bu ölçüt, her bir sınıfı temsil eden örnek görüntülerden ölçüm için kullanılan sayısal parametrelere ya da temel özelliklerin tanımlamalarına kadar farklı karmaşıklık ve biçimde çeşitlilik göstermektedir.

Genellikle sınıflandırmada, bilgisayarlar insanlardan daha iyi olma eğilimi gösterirler. Çünkü grupları birbirinden ayırmak için yararlı bilgileri nesnelere çıkartabilirler. Bunun yanında kritik olmayan parametrelerdeki rastgele değişimlerden etkilenmezler ve istatistiksel yöntemler geliştirebildiklerinden sınıflandırmada daha iyidirler.

1.7.1. Rastgele Ormanlar

RO yöntemi Leo Breiman ve Adele Cutler tarafından geliştirilen bir toplu öğrenme yöntemidir. Ormanın eğitimi aşamasında karar ağaçları oluşturulmakta ve tekil ağaçlardan en çok oyu alan sınıf karar sınıfı olarak belirlenmektedir. RO algoritmasında, eğitim veri kümesindeki verilerle ormandaki ağaçları oluşturmak için kullanıcı tarafından belirlenmesi gereken iki parametre bulunmaktadır. Bu parametreler oluşturulacak olan ağaçların sayısı (n) ve en iyi bölünmeyi belirlemek için her bir düğümde kullanılacak olan değişken sayısı (m)'dir. RO yaklaşımı hakkında detaylı bilgi 1.5.2. bölümünde verilmiştir.

1.7.2. Destek Vektör Makineleri

DVM, 1995 yılında Vapnik [55] tarafından ortaya atılan sınıflandırma ve regresyon analizi için kullanılan bir danışmanlı öğrenme yöntemidir. DVM'nin amacı, görüntü vektörlerinin en iyi ayırma hiper düzlemini oluşturacak çok boyutlu öznelik uzayına eşlenmesi ve sınıflandırılmasıdır. DVM yaklaşımı hakkında detaylı bilgi 1.5.3. bölümünde verilmiştir.


1.7.3. Yapay Sinir Ağları

YSA, insanın düşünsel yeteneklerini, biyolojik olarak makul mühendislik tasarımlarıyla matematiksel olarak modelleme fikrinden ortaya çıkmıştır. Gerçek bir beyni andıran çok büyük ölçekte paralel hesaplama şeması anlamına gelen YSA, örüntü tanıma teori ve pratiğinde önemli etkilere sahip bir sınıflandırma aracı olmak için gittikçe gelişmektedir [58].

1943 yılı, YSA'nın gelişiminde başlangıç yılı olarak sayılabilir. McCulloch ve Pitts (1943) [59], temel hesaplama nöronunun ilk modelini ortaya çıkarmışlardır. Ardından Donald Hebb (1949) [60], nöronların bağlantılarını güncelleme için ilk öğrenme şemasını önermiştir. Bu öğrenme kuralı, sinir ağları teorisine temel katkılarda bulunmuştur. Rosenblatt'ın (1958) [61] perseptron teorisini önermesi bu alan üzerine yapılan diğer çalışmalardandır. Bernard Widrow ve Marcian Hoff (1959), yeni ve güçlü bir öğrenme kuralı olan Widrow-Hoff öğrenme kuralını geliştirmişlerdir. Marvin Minsky ve Seymour Papert (1969) [62], makine öğrenmesi araştırmalarıyla ilgili kitap yayınladıklarında, katmanlı öğrenme ağları gelişme gösterememiştir. Bu kitapta perseptron modelinin sınırlandırmaları üzerine yapılmış çalışmalar vardır. Ardından bazı bilim adamları hala YSA modelini geliştirmeye devam etmişlerdir. Werbos (1975) [63], ilk perseptron modelini geliştirmeye çalışmış ve geri yayılım ağını ortaya çıkarmıştır. Diğer araştırmacılar olan Steve Grossberg, Teuvo Kohonen ve Henry Klopff yeni modeller geliştirmişlerdir.

1.7.3.1. Yapay Nöron

McCulloch ve Pitts, yapay bir nöron için hesaplama modeli olarak ikili eşik birimi önermişlerdir (Şekil 1.13).



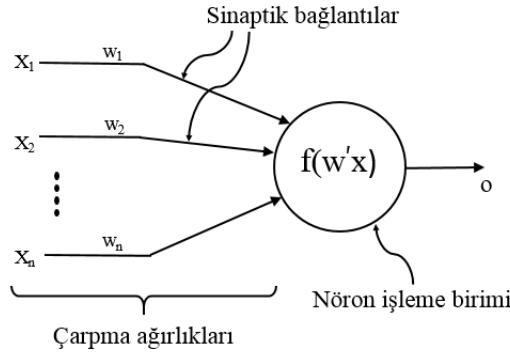
Şekil 1.13. Bir nöronun McCulloch-Pitts modeli

Bu matematiksel nöron, n tane giriş sinyalinin ($x_j, j=1, \dots, n$) ağırlıklı toplamlarını hesaplar ve toplam, belli bir u eşik değerinin üzerindeyse 1 çıkışını, diğer durumlarda ise 0 çıkışını üretir. Matematiksel olarak:

$$y = \theta \left(\sum_{j=1}^n w_j x_j - u \right) \quad (1.58)$$

(1.58)'de $\theta(\cdot)$, 0'da birim basamak fonksiyonu ve w_j, j . girişle ilgili sinaps ağırlığıdır. Gösterimin basitliği için u eşik değeri, nörona bağlı olan, $x_0=1$ sabit girişli $w_0=-u$ ağırlığı olarak hesaba katılır. Pozitif ağırlıklar uyarıcı sinapslara karşılık gelirken, negatif ağırlıklar engelleyici sinapslara karşılık gelir. McCulloch ve Pitts, uygun seçilen ağırlıkların, genel hesaplama yapan nöronların senkron dizilmelerine yol açar. Burada biyolojik nörona basit bir benzerlik vardır: teller ve ara bağlantılar, sırasıyla akson ve dentriti modellerken bağlantı ağırlıkları sinapsları temsil eder ve eşik fonksiyonu, somadaki işleme benzemektedir. Fakat McCulloch ve Pitts modeli, biyolojik nöronların gerçek davranışlarını yansıtmayan birkaç basit varsayım da içermektedir.

1.7.3.2. Yapay Sinir Ağları İçin Nöron Modelleme



Şekil 1.14. İşleme düğümü ve sinaptik bağlantıdan oluşan nöron yapısı

Her bir nöron modeli, sinaptik giriş bağlantısı ve tek bir çıkışa sahip olan işleme elemanından meydana gelir. Nöron girişlerinin (x_i) sinyal akışı, nöron çıkış sinyali akışında olduğu gibi oklarla belirtilen şekilde tek yönlü düşünülebilir. Genel bir nöron yapısı Şekil

1.14.'de verilmektedir. Sembolik gösterim nöronun, ağırlıklar kümesinden ve nöron işlem elemanı ya da düğüm denilen yapıdan oluştuğunu göstermektedir. Nöron çıkış sinyali (1.59) ve (1.60) eşitliklerindeki ilişkiyle verilebilir.

$$o = f(w^t x) \quad \text{ya da} \quad (1.59)$$

$$o = f\left(\sum_{i=1}^n w_i x_i\right) \quad (1.60)$$

Burada w ağırlık vektörü ve x giriş vektörü olarak (1.61) ve (1.62) eşitliklerindeki gibi tanımlanır.


$$w \triangleq [w_1 \ w_2 \ \dots \ w_n]^t \quad (1.61)$$

$$x \triangleq [x_1 \ x_2 \ \dots \ x_n]^t \quad (1.62)$$

$f(w^t x)$ aktivasyon fonksiyonu olarak adlandırılır. Literatürde kullanılan bazı aktivasyon fonksiyonları Şekil 1.15.'de gösterilmiştir. Bunların içerisinde en sık kullanılanı sigmoid fonksiyondur. Aktivasyon fonksiyonunun alanı, *net* olarak bilinen nöron modelin aktivasyon değerlerinin kümesidir. Bu yüzden fonksiyon genelde $f(\text{net})$ olarak kullanılır. *Net* değişkeni ağırlık ve giriş vektörünün skaler çarpımları olarak tanımlanır.

$$\text{net} \triangleq w^t x \quad (1.63)$$

Burada dikkat edilmelidir ki, eşik değeri (1.59), (1.60) ve (1.63) eşitliklerinde açıkça kullanılmamıştır, fakat bu sadece sembolik gösterim içindir. Modellenmiş nöronun gerçekte x_1, x_2, \dots, x_{n-1} giriş değerlerinden gelen $n-1$ bağlantıya sahip olduğu farzedilir. Ayrıca $x_n=1$ ve $w_n=T$ olduğu düşünülür. Eşik değeri bazı modeller için önemli rol oynadığından, bazen eşik değeri ayrı nöron model parametresi olarak ayrıca elde edilir.



Şekil 1.15. Aktivasyon fonksiyonlarının çeşitleri: (a) eşik (b) parçalı doğrusal (c) sigmoid (d) gauss


1.7.3.3. Yapay Sinir Ağları Modelleri

YSA, yapay nöronların düğüm ve ağırlıklı yönlü kenarların nöron girişleri ve nöron çıkışları arasındaki bağlantı olduğu ağırlıklı yönlü graf olarak da düşünülebilir. Bağlantı mimarilerine bağlı olarak YSA iki kategoriye ayrılabilir:

- İleri beslemeli YSA: döngü olmayan graflardır.
- Geri beslemeli YSA: geri besleme bağlantılarından dolayı döngülerin meydana geldiği graflardır.

Tez çalışmasında ileri beslemeli yapay sinir ağları modeli kullanıldığından bu bölümde ileri beslemeli ağ yapısına değinilecektir.

1.7.3.3.1. İleri Beslemeli Yapay Sinir Ağları



Şekil 1.16. Tek katmanlı ileri beslemeli ağ ara bağlantı şeması

N girişe sahip m nörondan oluşan temel bir ileri beslemeli mimari Şekil 1.16.'da gösterilmektedir. Nöronların çıkışları ve giriş vektörleri sırasıyla (1.64) ve (1.65) eşitliklerinde verilmiştir.

$$o = [o_1 \ o_2 \ \cdots \ o_m]^t \quad (1.64)$$

$$x = [x_1 \ x_2 \ \cdots \ x_n]^t \quad (1.65)$$

w_{ij} ağırlığı i. nöronu, j. giriş ile bağlar. i. nöron için aktivasyon değeri (1.66)'daki gibi yazılabilir.

$$net_i = \sum_{j=1}^n w_{ij} x_j, \quad i = 1, 2, \dots, m \quad (1.66)$$

(1.67)'de verilen doğrusal olmayan dönüşüm, x 'in işlenmesini tamamlayan $f(net_i)$ ($i=1, 2, \dots, m$) aktivasyon fonksiyonunu içermektedir. Dönüşüm ağıdaki m nöronun her biri için uygulanmakta ve (1.67) eşitliğindeki gibi ifade edilmektedir.

$$o_i = f(w_i' x), \quad i = 1, 2, \dots, m \quad (1.67)$$

Burada w_i ağırlık vektörü, i. çıkış düğümüne karşılık gelen ağırlıkları içerir ve (1.68)'deki gibi tanımlanır.

$$w_i \triangleq [w_{i1} \ w_{i2} \ \cdots \ w_{in}]^t \quad (1.68)$$

Doğrusal olmayan matris işleci Γ sembolü ile gösterildiğinde, ağ tarafından x giriş uzayının o çıkış uzayına eşlenmesi (1.69)'daki gibi ifade edilebilir.

$$o = \Gamma[Wx] \quad (1.69)$$

Burada W , ilişki matrisi de denilen ağırlık matrisidir.

$$W \triangleq \begin{bmatrix} w_{11} & \cdots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{m1} & \cdots & w_{mn} \end{bmatrix} \quad (1.70)$$

$$\Gamma[\cdot] \triangleq \begin{bmatrix} f(\cdot) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & f(\cdot) \end{bmatrix} \quad (1.71)$$

Dikkat edilmelidir ki, Γ matris işlecinin köşegenlerindeki doğrusal olmayan aktivasyon fonksiyonları ($f(\cdot)$), her bir nörondaki *net* aktivasyon değerlerini işler. Her bir aktivasyon değeri sırasıyla bir girişin ve ona karşılık düşen ağırlık vektörünün skaler çarpımına eşittir. Giriş örneğinin çıkış örneğine eşlenmesi ileri beslemeli ve anlık tipte olduğundan, x girişi ile o çıkışı arasında zaman gecikmesi olmamaktadır. Bu yüzden (1.69) eşitliğini t zamanını da içeren açık biçimde (1.72) eşitliğindeki gibi yeniden yazabiliriz.

$$o(t) = \Gamma[Wx(t)] \quad (1.72)$$

İleri beslemeli ağların açıkça bir geri besleme bağlantısı olmamasına rağmen, $x(t)$, $o(t)$ 'ye eşlendiğinde çıkış değerleri, beklenen çıkış değerlerini sağlayan bir öğreticinin bilgisiyle karşılaştırılır ve ağırlıklarına uyarlamak için hata sinyali kullanılır.

1.7.3.4. Yapay Sinir Ağlarında Öğrenme

Öğrenmenin kesin tanımının formüle edilmesi zor olmasına rağmen, YSA'de öğrenme süreci, ağ mimarisini ve bağlantı ağırlıklarını güncelleme problemi olarak görülebilir. Böylece ağ belirli bir görevi verimli bir şekilde gerçekleştirebilir. Ağ bağlantı ağırlıklarını, mevcut eğitim örneklerinden öğrenir. Yani öğrenmeyi verilen örneklerin giriş-çıkış ilişkilerinden yapar. Performans, iteratif bir şekilde ağdaki ağırlıkların güncellenmesiyle zamanla gelişir. YSA'nın örneklerden otomatik öğrenme yeteneği, yöntemi çekici ve ilginç yapmaktadır.


Öğrenme sürecini tasarlamak ya da anlamak için ilk olarak sinir ağının modelini oluşturmak, ağdaki mevcut bilgilerin ne olduğunu bilmek gerekir. Buna öğrenme paradigması adı verilir. İkinci olarak ise ağ ağırlıklarının nasıl güncellendiğini anlamak yani hangi öğrenme kurallarının güncelleme sürecini yönettiğini anlamak gerekir. Öğrenme algoritması, öğrenme kurallarının ağırlıkları ayarlamak için kullanıldığı yöntemle ilgilidir.

Üç ana öğrenme paradigması vardır: danışmanlı, danışmansız ve hibrid. Danışmanlı öğrenmede, ağa her bir giriş örneği için doğru bir çıkış (cevap) sağlanır. Ağırlıklar bilinen doğru cevaba olabildiğince yakın cevap üretmek için ağa olanak sağlayarak belirlenir. Danışmansız öğrenmede, eğitim veri kümesindeki her bir giriş örneği ile ilgili doğru bir cevaba gerek duyulmaz. Verilerin temelinde yatan yapı ya da verilerdeki örnekler arasındaki karşılıklı ilişki araştırılır ve karşılıklı ilişkilerden yararlanılarak örnekler kategorilere ayrılır. Hibrid öğrenme ise danışmanlı ve danışmansız öğrenmeyi birleştirir. Ağırlık kısmı danışmanlı öğrenme aracılığıyla belirlenirken, diğerleri ise danışmansız öğrenme aracılığıyla elde edilir.

Literatürde birçok öğrenme kuralı bulunmaktadır. Bu kurallar danışmanlı ve danışmansız öğrenme ile alakalıdır. Sıkça kullanılan perseptron, delta ve Widrow-Hoff danışmanlı öğrenme kuralları sınıfına girerken; Hebbian, Winner-take-all danışmansız öğrenme kuralları sınıfına girmektedir.

1.7.3.4.1. . Hata Geri Yayımlı Öğrenme Algoritması

Genelleştirilmiş Delta Algoritması olarak da bilinen Hata Geri Yayımlı Öğrenme Algoritması uygulamada en çok kullanılan öğrenme algoritmasıdır. Bu öğrenme algoritmasında giriş örnekleri, geri yayımlı eğitim boyunca sıralı olarak ağa sunulur. Eğer bir örnek ağa sunulduğunda, onun sınıflandırma sonucu hatalı belirlenirse, sinaptik ağırlıklar güncellenir ve böylece en küçük ortalama kare sınıflandırma hatası azalır. Giriş çıkış eşlemesi, beklenen ve gerçek değerlerin karşılaştırılması ve ağırlıkların güncellenmesi, eğitim kümesindeki bütün örneklerin kabul edilebilir toplam hata ile öğrenmesine kadar devam eder. Burada kullanılan hata kümülatiftir ve bütün eğitim kümesi için hesaplanır. Sınıflandırma süreci boyunca, eğitilmiş sinir ağı ileri yönlü işlemektedir.

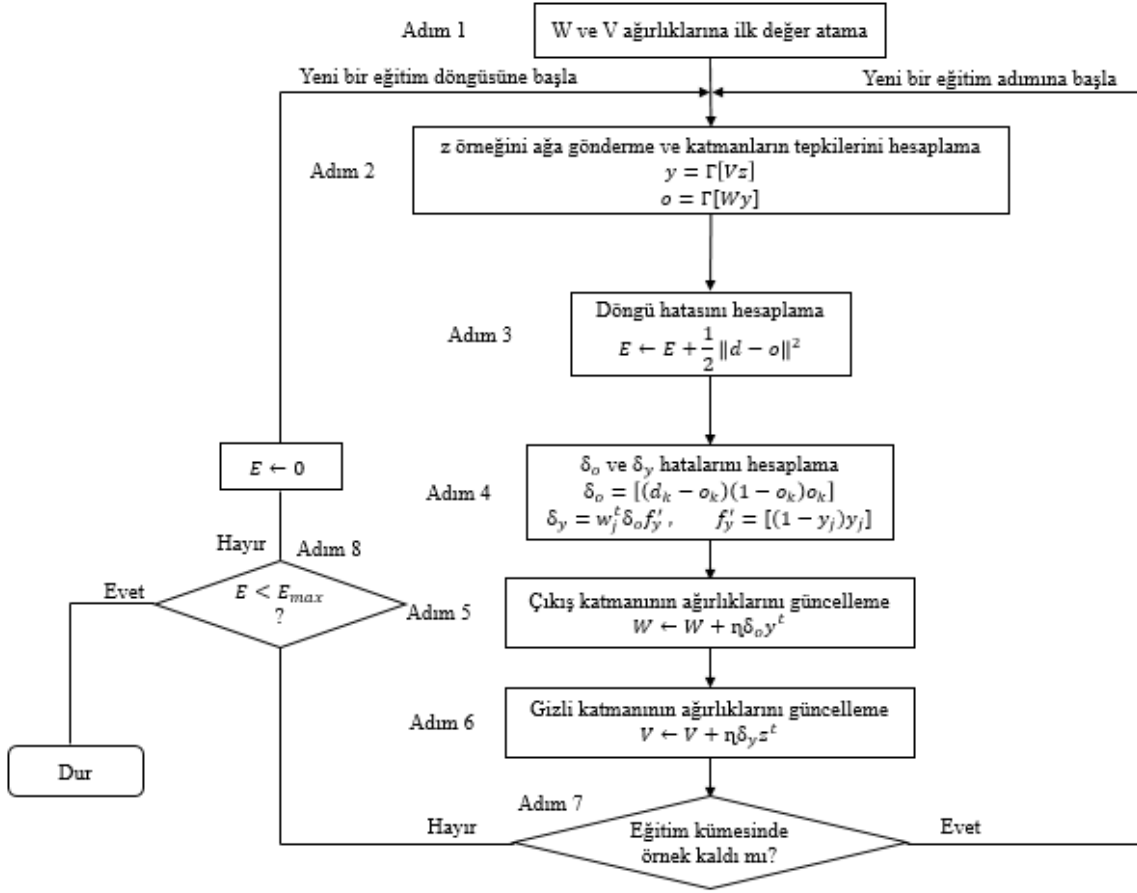


Şekil 1.17. Katmanlı ileri beslemeli sinir ağı

Şekil 1.18., Şekil 1.17.'de verilen temel iki katmanlı ağ için hata geri yayımlı öğrenme algoritmasının akış diyagramını göstermektedir. Burada z ve o sırasıyla giriş ve çıkış, y ise gizli katman çıkış vektörlerini göstermektedir. d tepki vektörü, z giriş vektörlerine karşılık gelen, öğretici tarafından sağlanan vektördür.

Öğrenme Adım 2'deki ileri besleme evresi ile başlamaktadır. z örnek vektörü girişte sunulduğunda, katmanların cevabı olan y ve o , bu evrede hesaplanır. Ardından hata sinyali hesaplama evresi (Adım4) takip eder. Burada dikkat edilmelidir ki önce çıkış katmanındaki hata sinyal vektörü hesaplanır, ardından bu hata giriş düğümlerine doğru yayılır. Adım 5 'de $K \times J$ ağırlıkları, W matrisi içinde sırasıyla güncellenir. Son olarak ise $J \times I$ ağırlıkları, Adım 6'da V matrisi içinde güncellenir.

Giriş - çıkış eşleşmesinin kümülatif döngü hatası, bütün eğitim kümesindeki çıkış hatalarının toplamı olarak Adım 3'de hesaplanır. Bütün eğitim döngüsü için sonuç hata değeri, eğitim kümesindeki örneklerin ($\{z_1, z_2, \dots, z_p\}$) her biri tamamlandıktan sonra hesaplanır. Öğrenme işlemi, Adım 8'de gösterildiği gibi sonuç hata değeri E_{max} üst sınırının altında olduğu zaman durdurulur.



Şekil 1.18. Hata geri yayımlı eğitim algoritması akış diyagramı

1.8. Performans Değerlendirmesi

Gerçek hayattaki danışmanlı öğrenme uygulamalarında, sınıf etiketlerine sahip eğitim veri kümesinden yararlanılarak etiketleri bilinmeyen test veri kümesi hakkında tahmin yapılmaktadır. Ardından öğrenme algoritması tarafından elde edilen performans ölçülmelidir. Bu nedenle sınıflandırıcı eğitim veri kümesiyle test edilir ve test veri kümesine uygulandığında tahmin edilen sınıf etiketleriyle doğru sınıf etiketleri karşılaştırılarak performans ölçümü gerçekleştirilir [64]. Bir sınıflandırıcı değerlendirildiğinde, performansın ölçümü için birçok farklı yol mevcuttur.

İki mümkün sınıflı danışmanlı öğrenmede iki tane ikili değişken tanımlanmalıdır. Bunlar pozitif veya negatif gerçek sonuçlar ile pozitif veya negatif üretilen test sonuçlarıdır. İki tane ikili değişken 2*2'lik bir tabloya yerleştirildiğinde dört durum oluşmaktadır (Tablo 1.2). Bu dört durum gerçekte pozitif kümeye dahil olup test sonucuna göre de pozitif çıkan durum Doğru Pozitif (TP), gerçekte negatif kümeye dahil olup test sonucunun hatalı olarak

pozitif çıktığı durum Yanlış Pozitif (FP), gerçekte pozitif kümeye dahil olup test sonucunun hatalı olarak negatif çıktığı durum Yanlış Negatif (FN) ve gerçekte negatif kümeye dahil olup test sonucuna göre de negatif çıkan durum Doğru Negatif (TN) durumlarıdır.

Tablo 1.2. İkili tanı testi

Gerçek Sonuç	Test Sonuçları		
	Pozitif	Negatif	
Pozitif	A(Doğru Pozitif)	C(Yanlış Negatif)	A+C
Negatif	B(Yanlış Pozitif)	D(Doğru Negatif)	B+D
Toplam	A+B	C+D	A+B+C+D

Tablo 1.2.'deki değerler kullanılarak çeşitli oranlar hesaplanmaktadır.

Duyarlılık (Sensitivity): Gerçekte pozitif olan kümenin test sonuçlarının ne kadar doğrulukta bulunabildiğini gösterir.

$$\text{Duyarlılık} = A / (A+C) = TP / (TP + FN) \quad (1.73)$$

Özgüllük (Specificity): Gerçekte negatif olan kümenin test sonuçlarının ne kadar doğrulukta bulunabildiğini gösterir.

$$\text{Özgüllük} = D / (B+D) = TN / (TN + FP) \quad (1.74)$$

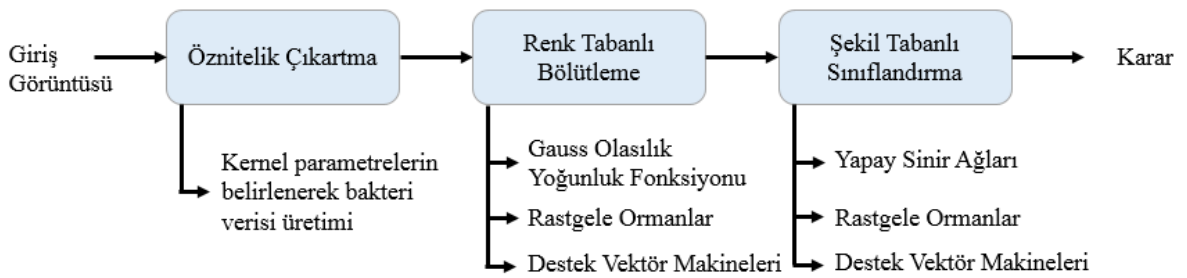
Doğruluk (Accuracy): Gerçekte pozitif ve negatif olan kümenin doğru tanınmasının tüm tanınma sonuçlarına oranını gösterir.

$$\text{Doğruluk} = (A + D) / (A + B + C + D) = (TP + TN) / (TP + FP + TN + FN) \quad (1.75)$$

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1. Giriş

Bu tez çalışmasında, mikroskopik görüntüler üzerinde TB bakterisinin otomatik tanınmasına dayalı bir sistem gerçekleştirilmiştir. Sisteme giriş olarak mikroskopik görüntüler verilmektedir. Görüntülerin eğitim aşamasının kolaylaştırılması için görüntü üzerinde imleç ile gezinilen yerlerde belirli çap ve oranda büyütme yapılmış ve bakteriye ait olma olasılığı olan bölgelerin piksel tabanlı eğitimi gerçekleştirilmiştir. Öznitelik çıkarma yöntemi olarak piksellere, piksel ve sekiz komşuluğunda GOYF uygulanmıştır. Eğitilen örneklerin Mahalanobis uzaklıkları dikkate alınarak yanlış eğitilen verilerin eğitim kümesinden kaldırılması yani gürültülü veri eliminasyonu sağlanmıştır. Bölütleme aşamasında elde edilen öznitelikler kullanılarak, eğitim görüntülerinin bölütleme işleminin gerçekleştirilmesi için GOYF, RO ve DVM yöntemleri üzerinde durulmuştur. Bu yöntemlerde, verilen eğitim örnekleri yardımıyla bakteriye ait olma olasılığı olan bölgelerin diğer bölgelerden ayrılması sağlanmıştır. Son aşamada da eğitim örneklerindeki bakteri ve bakteri olmayan şekilsel bölgelerin YSA, RO ve DVM yöntemleriyle şekil tabanlı eğitilmesi sağlanmış ve bölütlenmiş görüntüler üzerindeki nesnelere bu yöntemler aracılığıyla sınıflandırılmıştır. Şekil 2.1.'de sistemin temel işlem adımları verilmiştir.




Şekil 2.1. Sistemin temel işlem adımları

2.2. Tüberküloz Bakterisinin Otomatik Tanınması

Mikroskopik görüntülerde TB bakterisinin tanınması son yıllarda araştırmacıların etkin biçimde ilgilendiği konulardan biridir. Bu konu ile ilgili olarak sadece bölütleme

yöntemlerinin uygulandığı çalışmalar [5][6][7] olduğu gibi bölütleme ve sınıflandırma yöntemlerinin sırasıyla uygulandığı çalışmalar da [10][11] bulunmaktadır. Bu çalışmalarda sınıflandırma sürecinde yapısal yaklaşımlar ileri sürülmüştür. Yapısal yaklaşımlar görüntülerdeki nesnelerin özniteliklerinin çıkartılıp nesneye ait ayırt edici özelliklerin belirlenmesini hedef alır. Buna karşın görünüşe dayalı yaklaşımlar öznitelik çıkarmanın aksine görüntüdeki nesnelerin bütünü ele almaktadır. Gerçekleştirdiğimiz sistemde görünüşe dayalı yaklaşımlar uygulanmakta ve bunlar yapısal yaklaşımlara göre sınıflandırmada daha iyi sonuç vermektedirler.

Bu çalışmada sunulan sistemin performansı, TB bakterisinin mikroskopik görüntülerinden oluşan veritabanı üzerinde değerlendirilmektedir. ZN lekeliendirme tekniği ile boyanmış balgam yayma örnekleri, Karadeniz Teknik Üniversitesi Tıp Fakültesi, Tıbbi Mikrobiyoloji Anabilim Dalı Mikobakteriyoloji Laboratuvarında hazırlanmıştır. Alınan yaymalar, 5 farklı hastadan 5 yayma-pozitif örnekleri içermektedir. Her bir hastanın balgam yayma örneklerinden 9 ila 40 arasında renkli görüntü alınmıştır.




Şekil 2.2. Görüntü toplama sistemi

Şekil 2.2.'de verilen görüntü toplama sistemi, Karadeniz Teknik Üniversitesi Bilgisayarla Görü Laboratuvarında kurulmuştur. Sistem, standart bir kişisel masaüstü bilgisayar, bir mikroskop ve bir dijital kameradan oluşmaktadır. Yayma örnekleri 100X büyütme objektif altında Nikon Eclipse 80i ışık mikroskopunda taranmaktadır. Görüntü toplama için Premiere Digital Microscope Eyepiece MA88-300 dijital kamerası mikroskopun okülerine takılmıştır. Alınan görüntüler 24 bit derinliğinde bitmap dosya formatında saklanmaktadır ve piksel çözünürlüğü 640*480'dir.

Veri kümesinin toplamı 116 pozitif görüntüden oluşmaktadır. Veri kümesi hakkındaki sayısal bilgiler Tablo 2.1.'de verilmiştir. Bölütleme ve sınıflandırma sürecinin gerçekleştirilmesi için görüntülerin yaklaşık üçte biri eğitim, geri kalanı ise sistemi test etmek için kullanılmıştır. Bütün görüntüler uzman tarafından incelenip bakteri ve bakteri olmayan bölgelere karar verilmiştir. Bölütleme aşamasının performansını belirlemek için renk bakımından benzer olan bakteri ve bakteri olmayan bölgeler uzman tarafında kırmızı ile boyanmıştır (Şekil 2.3a). Sınıflandırma aşamasının performansı için ise yine uzman tarafından şüpheli bölgelerin bakteri olup olmadığına karar verilmiştir (Şekil 2.3b).

Tablo 2.1. Veri kümesi hakkında sayısal bilgiler


<i>Veri Kümesi</i>	<i>#Hasta</i>	<i>#Görüntü</i>	<i>1.Hasta</i>	<i>2.Hasta</i>	<i>3.Hasta</i>	<i>4.Hasta</i>	<i>5.Hasta</i>
<i>Eğitim</i>	5	40	7	3	7	13	10
<i>Test</i>	5	76	10	6	13	27	20
<i>Toplam</i>	5	116	17	9	20	40	30



(a)

Şekil 2.3. ZN lekelenme tekniği ile (a) boyanmış görüntüdeki bölgelerin uzman tarafından (b) bölütleme süreci performansını değerlendirmek için boyanması ve (c) sınıflandırma süreci performansını değerlendirmek için bakteri olup olmadığına karar verilmesi (kırmızı-bakteri, siyah-bakteri değil)

Şekil 2.3.' ün devamı



TB bakterisinin otomatik tanınması için gerçekleştirilen sistemde öncelikle eğitim veri kümesinin oluşturulması için eğitim görüntülerindeki ilgilenilen alanların belirlenmesi gerçekleştirilir. Ardından öznitelik çıkartma ve gürültülü veri eliminasyonu sağlandıktan sonra renk tabanlı bölütleme ve şekil tabanlı sınıflandırma işlemleri ile sınıflandırma tamamlanmış olur.


2.2.1. Önışlemler

TB mikroorganizmaları mikroskopla alınan görüntülerde orijinal görüntü boyutuna nazaran oldukça küçük görünen yapılardır. Kullanıcı, piksel tabanlı eğitim aşamasında bakteri olmayan bölgelerden yanlışlıkla eğitim örneği alabilir. Bu durum ilerki safhalarda bölütleme ve sınıflandırma sürecini zorlaştırmakta ve sistemin başarı oranını düşürmektedir. Bu nedenle görüntü üzerinde imleç ile gezinilen yerlerde belirli yarıçap ve oranlarda büyütme yapılmıştır.


Büyütme işlemi için gerçekleştirilen işlem adımları şu şekildedir:

- Kullanıcı tarafından istenilen yarıçap değeri piksel türünden ve büyütme oranı X türünden belirlenir.
- Oluşturulacak olan büyütme gösteren daire belirlenen yarıçap değerine göre oluşturulur.
- Yarıçap değerinin büyütme değerine olan oranı kullanılarak ham görüntü üzerindeki imlecin bulunduğu koordinatlardan \pm oran değeri çıkarılarak elde


edilen koordinatlar arasında kalan görüntü daire üzerine kopyalanır ve kopyalanmış görüntü, ham görüntü üzerinde imlecin bulunduğu koordinatlar merkez olmak üzere gösterilir.



(a)



(b)




(c)

Şekil 2.4. (a) Orijinal görüntünün imlecin bulunduğu koordinatta (b) 40 piksel yarıçapında 2X büyütme ve (c) 60 piksel yarıçapında 4X büyütme sonuçları

2.2.2. Öznitelik Çıkartma ve Gürültülü Veri Eliminasyonu

Mikroskobik görüntülerden öznitelik çıkartmak için piksellerin renk bilgilerinden yararlanılmıştır. Bunun için imleç konumundaki piksel ve merkez pikselin sekiz komşuluğundaki piksellerin kırmızı, yeşil ve mavi bileşenleri, hesaplanan katsayı oranında kullanılmıştır. Katsayılar, iki değişkenli GOYF'nin piksel ve sekiz komşuluğuna

uydurulmasıyla elde edilmiştir. Şekil 2.5.'de x,y koordinatlarına sahip olan piksellerin merkez piksel indeksi (0,0) olmak üzere tüm indeksleri verilmiştir.



Şekil 2.5. (0,0) merkez koordinatlara sahip piksel ve komşularının indeks değerleri ve hesaplanan katsayıları

Bağımlı olmayan değişkenler için iki değişkenli GOYF (2.1)'deki gibi verilmektedir.

$$f_{X,Y}(x,y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}} \quad (2.1)$$

Burada üstel ifadenin önündeki katsayı sabit olduğundan hesaplanmamakta ve σ_x ve σ_y değişkenlerinin 1'e eşit olduğu durumda katsayılar aşağıdaki gibi belirlenmektedir (Şekil 2.5.).

$$x = -1, y = +1 \rightarrow f_{X,Y}(x,y) = e^{-\frac{(-1)^2}{2 \cdot 1} - \frac{1^2}{2 \cdot 1}} \cong 0.3679$$

$$x = 0, y = +1 \rightarrow f_{X,Y}(x,y) = e^{-\frac{0^2}{2 \cdot 1} - \frac{1^2}{2 \cdot 1}} \cong 0.6065$$

$$x = +1, y = +1 \rightarrow f_{X,Y}(x,y) = e^{-\frac{1^2}{2 \cdot 1} - \frac{1^2}{2 \cdot 1}} \cong 0.3679$$

$$x = -1, y = 0 \rightarrow f_{X,Y}(x,y) = e^{-\frac{(-1)^2}{2 \cdot 1} - \frac{0^2}{2 \cdot 1}} \cong 0.6065$$

$$x = 0, y = 0 \rightarrow f_{X,Y}(x,y) = e^{-\frac{0^2}{2 \cdot 1} - \frac{0^2}{2 \cdot 1}} \cong 1$$

$$x = +1, y = 0 \rightarrow f_{X,Y}(x,y) = e^{-\frac{1^2}{2 \cdot 1} - \frac{0^2}{2 \cdot 1}} \cong 0.6065$$

$$x = -1, y = -1 \rightarrow f_{X,Y}(x,y) = e^{-\frac{(-1)^2}{2 \cdot 1} - \frac{(-1)^2}{2 \cdot 1}} \cong 0.3679$$

$$x = 0, y = -1 \rightarrow f_{x,y}(x, y) = e^{-\frac{0^2}{2*1} - \frac{(-1)^2}{2*1}} \cong 0.6065$$


$$x = +1, y = -1 \rightarrow f_{x,y}(x, y) = e^{-\frac{1^2}{2*1} - \frac{(-1)^2}{2*1}} \cong 0.3679$$

Katsayılarından yararlanılarak eğitilen her bir piksel ve komşularının kırmızı, yeşil ve mavi bileşenleri konumlarındaki ilgili katsayılarla çarpılarak 27 boyutlu özellik vektörü elde edilir.

Eğitim kümesindeki bütün görüntülerin piksel tabanlı eğitimi sırasında önışlem olarak görüntü üzerinde belirli çap ve oranda büyütme yapılmasına rağmen kullanıcı hala bakteri olmayan bölgeden eğitim örneği alabilir. Bu nedenle eğitim yapılan örnekler arası Mahalanobis uzaklığı hesaplanarak gürültülü veri eliminasyonu sağlanmıştır. Mahalanobis uzaklığı diğer uzaklık ölçütlerinden farklı olarak veriden hesaplanan değışinti matrisini yani verinin dağılımını da hesaba katıp sınıflar arası farklılığı artırırken sınıf içi farklılığı bastırmasından dolayı problem için uygun uzaklık metriği olarak seçilmiştir.

2.2.3. Mikroskobik Görüntülerin Bölütlenmesi


Gerçekleştirilen sistemin test sürecinin ilk aşaması, test kümesindeki görüntülerde bakteri olmaya aday bölgelerin renk bilgileri kullanılarak zeminden ayrıştırılmasıdır. Bunun için 3 çeşit yöntem kullanılmıştır. Her bir yöntemle ait sonuç görüntüleri, Şekil 2.6'da verilen görüntüye ait bölütlenmiş sonuç görüntüsüdür.



Şekil 2.6. Bölütleme performansı için kullanılacak orijinal örnek görüntü

2.2.3.1. Çok Değişkenli Gauss Olasılık Yoğunluk Fonksiyonuna Dayalı Bölütleme

Eğitilen veri kümesine çok değişkenli bir GOYF'nin uydurulmasını temel alan basit bir yaklaşımdır. Eğitim verilerinden yararlanılarak verileri temsil eden 27 boyutlu bir gauss eğrisi oluşturulmuştur. 3-sigma kuralı olarak da bilinen, eğri değerlerinin yaklaşık %95'inin ortalama değerden ± 2 , %99,7'sinin ise ortalama değerden ± 3 standart sapma uzaklığındaki aralıkta yer aldığını ifade eden yaklaşımdan yararlanılmıştır. Test kümesindeki her bir test verisinin, kullanıcının yaklaşık olarak 3 sigma kuralındaki %95-%99,7 aralığında belirlediği bir yüzdelik değere göre bölütlenmesi sağlanmıştır.



Şekil 2.7. Şekil 2.6.'daki orijinal görüntünün çok değişkenli GOYF yöntemine dayalı bölütlenmiş sonuç görüntüsü (eşik değeri=%99.00)

2.2.3.2. Rastgele Ormanlar Yöntemine Dayalı Bölütleme

Karar ağaçları tabanlı bir yöntem olan RO yönteminde kullanıcı tarafından iki parametre belirlenmesi istenmiştir. Bu parametreler oluşturulacak olan ağaç sayısı (n) ve en iyi bölünmeyi belirlemek için her bir düğümde kullanılacak olan değişken sayısı (m)'dir. Kullanıcının belirlediği ağaç sayısı kadar önyükleme örneklem oluşturulmuştur. Bu örneklemin 2/3'ü ağacı oluşturmak için kullanılırken 1/3'ü oluşturulan modelin iç hata oranını kestirmek için kullanılmıştır. Oluşturulan tüm ağaçların OOB hata kestirimlerinin ortalaması ise kurulan modelin OOB hata oranını göstermektedir. OOB hata oranı, modelin düzgün kurulmasını ve oluşturulan her bir ağaca bir ağırlık verilmesini sağlamaktadır.

Burada önemli olan en iyi ağaç sayısı ve değişken sayısının belirlenebilmesidir. Bunun için $m=4,5,\dots,10$ ve $N=100,150,\dots,500$ arasında değer seçilerek modelin kurulması sağlanmıştır. Modelin kurulmasında kullanılan karar ağaçlarını oluşturmak için bir sınıflandırma ağaçları oluşturma yöntemi olan budamasız CART algoritması ve ağaçları oluşturmada her bir dalda kullanılacak olan m değişken arasından en iyi bölünmeyi seçmek için Gini bölünme kuralı kullanılmıştır.

Ağaçların oluşturulmasından sonra test verileri ağaçların kökünden itibaren yerleştirilmeye başlanmıştır. Bunun için görüntünün her bir piksel ve sekiz komşuluğu kullanılarak çıkartılan öznelikler test verisi olarak kullanılmıştır. Her bir veri son yaprak düğümünde bir sınıfa atanmış ve sınıfların aldıkları ağırlıklı oylar toplanmıştır. Sınıf tahmini ise en çok oyu almış olan sınıf seçilerek yapılmıştır.



Şekil 2.8. Şekil 2.6.'daki orijinal görüntünün RO yöntemine dayalı bölütlenmiş sonucu ($m=5$, $N=300$)

2.2.3.3. Destek Vektör Makineleri Yöntemine Dayalı Bölütleme

Renkli görüntülerin bölütlemesinde sıkça kullanılan DVM'nin mikroskobik görüntülerden elde edilen verilere uygulanmasında aşağıdaki adımlar gerçekleştirilmiştir.


- Eğitim verileri üzerinde basit bir ölçekleme işlemi yapılmıştır. Bunun için 27 boyutlu uzayda her bir özneliğin en küçük ve en büyük değerleri bulunarak tüm verilere (-1,+1) aralığında (2.2)'deki ölçekleme formülü uygulanmıştır.
-

$$yeniDeger = minOlcek + (maxOlcek - minOlcek) * \frac{eskiDeger - minDeger}{maxDeger - minDeger} \quad (2.2)$$

Burada $\min\text{Olcek}=-1$ iken $\max\text{Olcek}=+1$ değerini göstermektedir. eskiDeger ; verinin o özneliğe ait değerini, $\min\text{Deger}$; bütün veri kümesi içindeki verilerin o özneliğe ait değerleri arasındaki en küçük değeri, $\max\text{Deger}$ ise en büyük değeri göstermektedir. Bulun yeniDeger de o verinin ölçeklenmiş sonuç verisidir.

Ölçekleme burada büyük sayısal aralıkta olan verilerin küçük sayısal aralıklara düşürülmesini sağlar, aynı zamanda hesaplama karmaşıklığını da ortadan kaldırmış olur.

- Çekirdek fonksiyonu olarak radyal tabanlı fonksiyon seçilmiştir. Bu çekirdek fonksiyonunun seçilmesinin nedeni, fonksiyonun öznelikler ile sınıf etiketleri arasındaki ilişkinin doğrusal olmadığı durumları ele almaktadır ve verileri doğrusal olmayan bir şekilde yüksek boyutlu uzaya eşlemektedir. Diğer bir neden ise modelin karmaşıklığını etkileyen hiper parametrelerin sayısının radyal tabanlı fonksiyonda az olmasıdır.
- En iyi C ve γ parametrelerinin belirlenebilmesi için k katlamalı çapraz geçerlilik tekniği kullanılmıştır. Bu teknikte eğitim kümesi eşit sayıda k tane alt kümeye ayrılmaktadır. Sıralı olarak $k-1$ tane alt küme ile sınıflandırıcı eğitilirken 1 alt küme ile de sınıflandırıcının test edilmesi sağlanmaktadır. Böylece tüm eğitim kümesindeki her bir örnek bir kere tahmin edilmiş olur. Çapraz geçerlilik doğruluğu ise doğru sınıflandırılan verilerin yüzdesi olarak hesaplanmaktadır. Çapraz geçerlilik tekniği kullanılarak en iyi C ve γ parametrelerinin belirlenmesinde ızgara taraması yaklaşımı kullanılmıştır. Çeşitli (C, γ) çift değerleri denenmiş ve en iyi çapraz geçerlilik doğruluğu veren çift seçilmiştir. Parametrelerin üssel biçimde artan dizileri, parametrelerin belirlenmesinde en pratik yaklaşımdır. Bu nedenle C parametresi için 2^{15} ile 2^{-5} aralığında 2^{-2} adımlarıyla, γ parametresi için ise 2^{-6} ile 2^{-1} aralığında $2^{1/2}$ adımlarıyla ilerlenmiştir.
- Belirlenen C ve γ parametreleri kullanılarak tüm eğitim kümesinin eğitilmesi sağlanmıştır. Yeni gelen test görüntüsünün öznelikleri çıkartılarak kurulan model ile test edilmesi sağlanmıştır.



Şekil 2.9. Şekil 2.6.'daki orijinal görüntünün DVM yöntemine dayalı bölütlenmiş sonuç görüntüsü (optimum $C=2$, optimum $\gamma=0.2479$)

2.2.4. Sınıflandırma Öncesi Ön İşlemler

2.2.4.1. Morfolojik İşlemler

Çalışmada bölütleme yapılmış görüntüler üzerinde var olan küçük gürültüleri ortadan kaldırmak için görüntüye morfolojik işlemler uygulanmıştır. Bunun için aşınma ve genişleme işlemleri peşpeşe uygulanarak açma işlemi gerçekleştirilmiştir. Böylece görüntüdeki gürültülerin kaldırılıp nesnel üzerindeki küçük deliklerin kapanması sağlanmıştır. Bu işlemler için kullanılan yapısal eleman Şekil 2.10.'daki 3x3 boyutunda çarpı biçimli yapısal elemandır.

0	1	0
1	1	1
0	1	0

Şekil 2.10. Morfolojik işlemler için kullanılan çarpı biçimli yapısal eleman

Çeşitli yöntemlerle bölütlenmiş sonuç görüntülerine Şekil 2.10.'daki yapısal eleman uygulandığında elde edilen örnek bir sonuç görüntüsü Şekil 2.11.'de verilmektedir.



Şekil 2.11. Şekil 2.8.'deki RO yöntemine dayalı bölütlenmiş sonuç görüntüsündeki gürültülerin morfolojik işlemlerle kaldırılması

2.2.4.2. Bağlantılı Bileşen Etiketleme

Bölütlenmiş görüntülerde birden fazla nesnenin olduğu durumlarda birbirleriyle piksel bağlantısı olan bölgeler aynı etikete atanıp görüntülerdeki nesnelere belirlenmiştir. Etiketleme algoritması aşağıdaki adımlardan oluşmaktadır:

- Görüntüdeki pikselleri (0,0) koordinatından başlayarak tara.
- Taranan ilgili pikselin değeri 1 ise pikselin sol ve üst komşusuna bak.
 - a. Eğer komşuları etiket almamışsa piksele yeni etiket ver.
 - b. Eğer komşularından biri etiketlenmiş ya da ikisinin de etiketi aynı ise piksele aynı etiketi ver.
 - c. Eğer komşularından ikisi de farklı etiketlenmiş ise üst komşusunun etiketini piksele vererek sol komşusunun etiketine sahip olanların etiketlerini de kendi etiketiyle değiştir.
- Görüntünün tüm pikselleri taranıncaya kadar 2. adımı tekrarla.

Bağlantılı bileşen etiketleme algoritması ile aynı zamanda nesnelere tam çevreleyen en küçük dikdörtgensel bölge, bölgenin başlangıç ve bitiş sınır koordinatları yardımıyla belirlenmiştir.

2.2.4.3. Moment Değişmezleri ile Yön Bulma


Bölütlenmiş görüntülerde bulunan nesnelere her zaman aynı doğrultuda bulunmazlar. Çalışmada tanıma aşamasında görünüş tabanlı bir yaklaşım önerildiğinden şekil tabanlı eğitilecek ve test edilecek nesnelere aynı doğrultuda olması istenmektedir. Bu amaçla bağlantılı bileşen etiketleme yöntemiyle nesnelere sınırları çizilip yapısı çıkarıldıktan sonra moment değişmezleri yöntemi ile yönleri bulunmuş ve nesnelere döndürülüp aynı doğrultuya getirilmeleri sağlanmıştır. Moment değişmezleri ile yön bulma formülü (2.3)'de verilmektedir.

$$Yön = \frac{\text{atan}\left(\frac{2 * \mu_{11}}{\mu_{20} - \mu_{02}}\right)}{2} \quad (2.3)$$

2.2.5. Bölütlenmiş Verilerin Sınıflandırılması

Gerçekleştirilen sistemin test sürecinin ikinci aşaması bölütlenmiş görüntü üzerindeki bakteri olmaya aday bölgelerin bakteri olup olmadığına karar verilmesidir. Bunun için sınıflandırma aşamasında, bölütleme aşamasında kullanılan RO ve DVM yöntemlerine ek olarak YSA yöntemi de kullanılmıştır.

Sınıflandırma işlemi öncesinde eğitim görüntülerindeki bakteri ve bakteri olmayan şekilsel bölgelerin kullanıcı tarafından seçilmesi sağlanmıştır. Bu bölgelerin bağlantılı bileşen etiketleme yöntemi ile buldukları koordinatlar ve nesnelere çevreleyen en küçük dikdörtgensel bölgeler belirlendikten sonra moment değişmezleri ile yönleri bulunup hepsinin aynı doğrultuya getirilmeleri sağlanmıştır. Seçilen bölgelerin genişlik ve uzunlukları birbirinden farklı olabileceğinden bu bölgeler yeniden boyutlandırılıp 30x30 piksel boyutuna getirilmişlerdir (Şekil 2.12.)



Şekil 2.12. Kullanıcının (a) seçtiği bölge, (b) nesnenin döndürülmesi ve (c) yeniden boyutlandırılmasıyla elde edilen yeni görüntüler


Sınıflandırma aşamasında görünüş tabanlı bir yaklaşım önerildiğinden oluşturulan eğitim görüntülerinin her bir pikseli önemli bilgi taşımaktadır. Bu yüzden 30x30 piksel boyutundaki piksellerin tümünün RGB bileşenleri kullanılarak sınıflandırma aşamasında 2700 özellikli vektörler oluşturulmuştur. Bu vektörler kullanılarak YSA, RO ve DVM yöntemleri ile test işlemi gerçekleştirilmiştir.

YSA yöntemi için hata geri yayımlı öğrenme algoritması kullanılmıştır. RO ve DVM yöntemlerinin kullanımı bölütleme aşamasında uygulandığı gibidir. RO yöntemi için $m=2000$, 2250 ve 2500 değişken sayısı ile $N=250$, 500, 750 ve 1000 ağaç sayısı kullanılarak model oluşturulmuştur. DVM yöntemi için ise yine bölütleme aşamasında anlatılan işlem adımları uygulanıp en iyi parametreler belirlenmiş ve kurulan model ile test görüntüsünün test edilmesi sağlanmıştır.


2.2.6. Deneysel Sonuçlar ve Karşılaştırma

TB bakterisinin mikroskopik görüntülerinin bölütlenmesi üzerine yapılan testlerde, GOYF, RO ve DVM yöntemleri karşılaştırılmıştır. Her bir yöntem için özgü çeşitli parametrelerin değişkenliğine göre de bölütlemedeki duyarlılık, özgüllük ve doğruluk değerleri hesaplanmıştır.

Uygulanan ilk test, 1.hastanın balgam yayma örneğinden alınan 17 farklı görüntü üzerinde gerçekleştirilmiştir. Bu görüntülerin 7 tanesi eğitim, 10 tanesi ise test işlemi için kullanılmıştır. Eğitim ve test görüntülerinin sayılarının yaklaşık olarak birbirine eşit olması görüntülerdeki arka planın çeşitliliğinden kaynaklanmaktadır (Şekil 2.13). Veritabanındaki görüntüler, sadece bu lama özgü olarak, yayma örneğinin boyanmasından kaynaklı 4 sınıfa ayrılmaktadır. Bunlar zemin renginin mavi, açık mavi, soluk ve koyu olduğu durumlardır. Bu yüzden eğitim aşamasında hepsinden 1 ila 2 arasında eğitim örneği alınmıştır.




Şekil 2.13. İlk testte kullanılan görüntülere örnekler




Şekil 2.14. İkinci testte kullanılan görüntülere bir örnek

İkinci yapılan test, 2.hastanın balgam yayma örneğinden alınan 9 farklı görüntü üzerinde uygulanmıştır. Bu görüntüler ilk testte kullanılan görüntülere nazaran arka plan çeşitliliğinin çok fazla olmadığı daha sağlıklı görüntülerden oluşmaktadır (Şekil 2.14.). Eğitimde 3, testte ise 6 görüntü kullanılmıştır.




Şekil 2.15. Üçüncü testte kullanılan görüntülere bir örnek

Diğer bir test 3. hastanın balgam yayma örneğinden alınan 20 görüntü üzerinde uygulanmıştır. Alınan görüntülerin belli bölgelerinde bulanıklık meydana geldiğinden, görüntüler tam olarak net değildir. Aynı zamanda lamın aşırı boyanmasından ve yayılan balgamın kalın olmasından dolayı görüntüler üzerinde pembe-mor renkli bakteri olmayan dokular meydana gelmiştir (Şekil 2.15). 20 görüntünün 7 tanesi eğitimde, 13 tanesi ise testte kullanılmıştır.



Şekil 2.16. Dördüncü testte kullanılan görüntülere bir örnek

Dördüncü test, 4. hastanın balgam yayma örneğinden alınan 40 farklı görüntü üzerinde uygulanmıştır. Bu görüntülerde 3. test görüntülerinde olduğu gibi bulanıklığın ve renkli dokuların meydana geldiği, arka planın çeşitliliğinin fazla olduğu görüntülerdir (Şekil 2.16). Görüntülerin 13 tanesi eğitim, 27 tanesi ise test işlemi için kullanılmıştır.



Şekil 2.17. Beşinci testte kullanılan görüntülere bir örnek

Diğer bir test, 5. hastanın balgam yayma örneğinden alınan 30 farklı görüntü üzerinde uygulanmıştır. Bu görüntüler 2. testte kullanılan görüntüler gibi sağlıklı görüntülerden oluşmaktadır. Sadece zemin üzerindeki bakterilerin rengi, burada biraz daha farklı olarak daha açık pembe renge ve görüntülerde doku oluşumları görülmektedir (Şekil 2.17).

GOYF yöntemine dayalı bölütleme işleminin 5 farklı test kümesine uygulanmasıyla elde edilen sonuç tabloları aşağıda verilmektedir.

Tablo 2.2. 1. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri

Eşik Değer Başarı Ölçümleri	%98.40	%98.30	%98.20	%98.10	%98.00	%97.90
Duyarlılık	%48.97	%51.52	%54.94	%57.54	%60.12	%63.43
Özgüllük	%99.01	%98.80	%98.54	%98.01	%97.74	%94.86
Doğruluk	%98.98	%98.76	%98.51	%97.98	%97.71	%94.80

Tablo 2.3. 2. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri

Eşik Değer Başarı Ölçümleri	%99.00	%98.90	%98.80
Duyarlılık	%71.28	%75.05	%78.83
Özgüllük	%98.53	%96.58	%90.88
Doğruluk	%98.45	%96.53	%90.85

Tablo 2.4. 3. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri

Eşik Değer Başarı Ölçümleri	%99.80	%99.70	%99.60
Duyarlılık	%22.33	%34.50	%45.84
Özgüllük	%99.74	%99.19	%97.70
Doğruluk	%99.36	%98.87	%97.44

Tablo 2.5. 4. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri

Eşik Değer Başarı Ölçümleri	%99.70	%99.60	%99.50	%99.40
Duyarlılık	%22.53	%31.54	%40.72	%48.90
Özgüllük	%99.60	%98.20	%98.35	%96.71
Doğruluk	%99.02	%98.68	%97.90	%96.32

Tablo 2.6. 5. lam test görüntüleri için GOYF'nin eşik değerlerine göre başarı ölçümleri

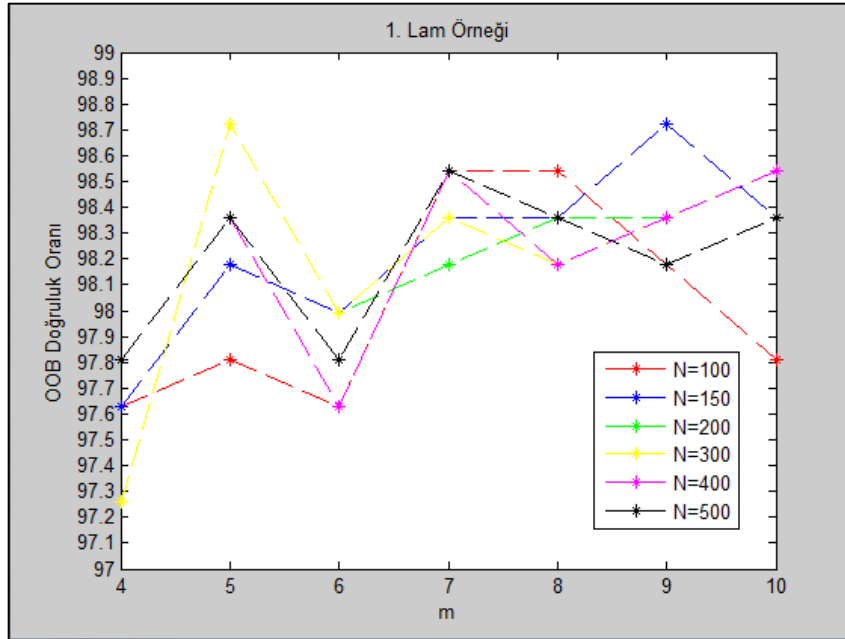
Eşik Değer Başarı Ölçümleri	%99.90	%99.80	%99.70
Duyarlılık	%24.04	%55.94	%76.83
Özgüllük	%99.91	%98.61	%72.09
Doğruluk	%99.62	%98.44	%72.08

Tablolar incelendiğinde eşik değerinin değişmesiyle birlikte duyarlılık değerinin artarken özgüllük değerinin azaldığı görülmektedir. Tablolarda genel olarak belirli bir eşik değerinden sonra başarı ölçümlerinin yapılmamasının nedeni, değerlerin hızlı adımlarla azalması ve sonucunda istenmeyen bir biçimde duyarlılık değerinin %100'e yaklaşırken özgüllük değerinin %0'a düşmesindedir. Aynı zamanda sonuç görüntüleri incelendiğinde de eşik değerinin azalmasıyla birlikte çok fazla bakteri olmayan bölgelerinde bakteri olarak belirlendiği görülmektedir. Sonuç olarak bu yöntemde eşik değerinin belirlenmesi kullanıcıya bağlı olmakla beraber duyarlılık ve özgüllük arasındaki ödünleşimde çok fazladır. Yani tanı sistemlerinde hem duyarlılık değerinin hem de özgüllük değerinin yüksek olması beklenirken bu yöntemle birlikte duyarlılık değerinde yüksek artış sağlanırken özgüllük değerinde ise yüksek azalış meydana gelmektedir. Bu da test görüntülerinin bölütlenme

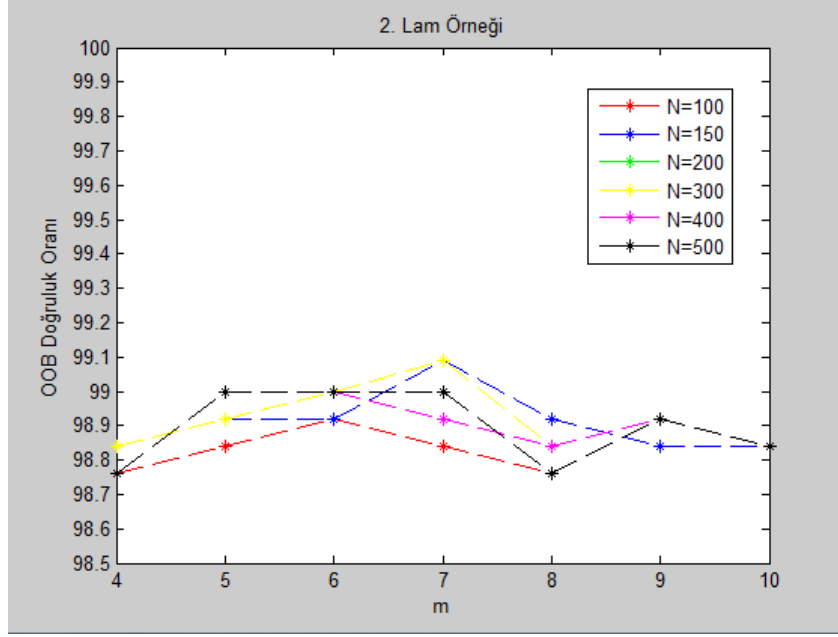
başarısını düşürdüğünden bölütlemeye çok başarı sağlamayıp verimli bir algoritma olmamıştır.

Testlerde kullanılan görüntü örneklerine bakıldığında en sağlıklı görüntülerin 2. ve 5. kümelerde olduğu görülmektedir. Tabloların sonuçları incelendiğinde de görüntülerin başarı ölçümleri üzerindeki etkileri de açıkça görülmektedir. Özgüllük değerinin tüm tablolarda ortak olarak %97 civarlarında olduğu durumları göz önüne alırsak duyarlılık değerleri 1. küme için %60, 2. küme için %70, 3. küme için %45, 4. küme için %40 ve 5. küme için %60 civarlarında olduğu görülmektedir.


RO yöntemine dayalı bölütleme işleminin başarı sonuçlarına bakmadan önce her bir test için oluşturulan m değişkene bağlı N adet ağaçtan oluşan modelin iç hata oranına bakmak gerekmektedir. Bu iç hata oranı oluşturulan modelin ne kadar düzgün kurulduğunu ve kararlılığını göstermektedir. Aşağıdaki grafiklerde her bir test kümesi için oluşturulan ağaçların m ve N değişkenlerine bağlı OOB doğruluk oranları verilmektedir.



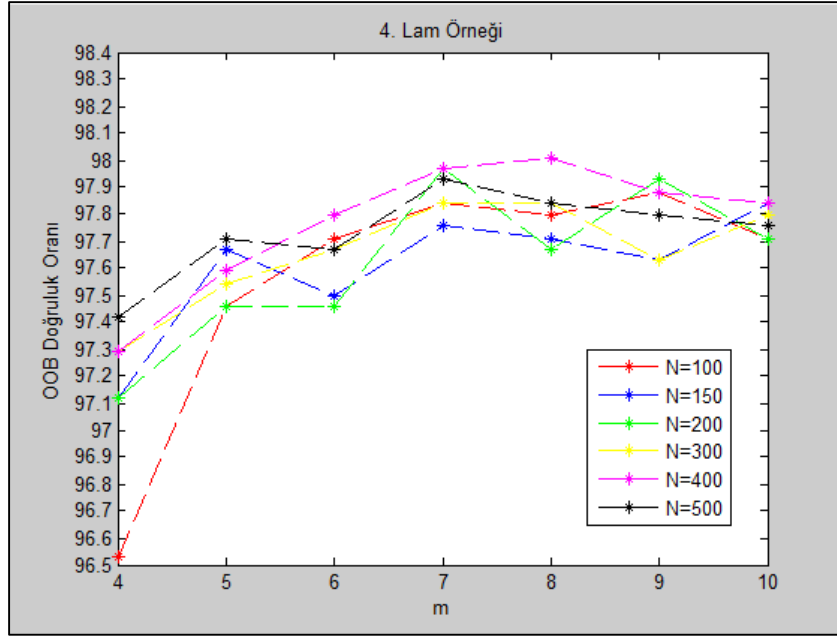
Şekil 2.18. 1. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği




Şekil 2.19. 2. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği



Şekil 2.20. 3. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği



Şekil 2.21. 4. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği



Şekil 2.22. 5. lam eğitim görüntüleri için oluşturulan RO modelinin OOB hata kestirim grafiği

Oluşturulan grafiklerden 1. test için olanı incelendiğinde OOB hata kestiriminin %1.28 minimum ve %2.74 maksimum seviyesinde olduğu görülmektedir. İkinci test için

oluşturulan OOB grafiğinde hata kestirimi %0.91 minimum ve %1.24 maksimum seviyesinde, üçüncü test için %1.52 minimum ve %2.00 maksimum seviyesinde, dördüncü test için %1.99 minimum ve %3.47 maksimum seviyesinde ve son test olan beşinci test için %0.73 minimum ve %1.44 maksimum seviyesinde olduğu görülmektedir. Buradan her bir test kümesi için oluşturulan modellerin maksimum %3.47 hata oranı ile oluşturulduğu görülmektedir ve bu da oldukça başarılı bir sonuçtur. Bu sonuçtan yola çıkılarak modelin düzgün kurulduğu ve kararlı bir model tasarlandığı görülmektedir. Yine test kümelerinde kullanılan görüntülerin farklılığı, kurulan modellerin OOB hata oranlarında kendini göstermektedir.

Test kümelerindeki bölütleme için ayrılmış olan test verileri üzerinde RO yönteminin çalıştırılması sonucunda sırasıyla aşağıdaki duyarlılık, özgüllük ve doğruluk bölütleme başarı ölçümleri elde edilmiştir.

Tablo 2.7. 1. lam test görüntüleri için RO yönteminin başarı ölçümleri

Ağaç Sayısı (N) Değişken Sayısı (m)	N=100	N=150	N=200	N=300	N=400	N=500
m=4	%81.54	%81.12	%81.18	%80.50	%80.38	%80.84
	%98.13	%97.28	%97.29	%98.15	%98.20	%98.19
	%98.11	%97.27	%97.28	%98.14	%98.18	%98.17
m=5	%82.31	%81.89	%80.86	%81.52	%81.76	%81.80
	%97.64	%98.49	%98.57	%98.54	%98.50	%98.54
	%97.62	%98.47	%98.55	%98.52	%98.49	%98.52
m=6	%81.15	%81.52	%81.61	%81.29	%81.52	%81.64
	%98.40	%98.55	%98.56	%98.56	%98.54	%98.56
	%98.39	%98.54	%98.54	%98.55	%98.52	%98.55
m=7	%81.21	%80.83	%80.59	%80.29	%80.77	%80.87
	%98.54	%98.58	%98.56	%98.56	%98.54	%98.55
	%98.53	%98.56	%98.55	%98.55	%98.53	%98.53
m=8	%79.36	%79.52	%79.90	%80.21	%80.14	%80.03
	%97.83	%98.61	%98.62	%98.69	%98.68	%98.66
	%97.81	%98.59	%98.60	%98.67	%98.66	%98.64
m=9	%76.77	%76.85	%77.60	%77.25	%77.58	%77.56
	%97.47	%97.65	%97.65	%97.66	%97.65	%97.64
	%97.46	%97.63	%97.63	%97.64	%97.64	%97.62
m=10	%79.60	%80.03	%80.57	%80.19	%80.48	%80.54
	%98.72	%98.71	%98.75	%98.68	%98.72	%98.72
	%98.70	%98.70	%98.74	%98.66	%98.70	%98.70

Tablo 2.8. 2. lam test görüntüleri için RO yönteminin başarı ölçümleri

Ağaç Sayısı (N) Değişken Sayısı (m)	N=100	N=150	N=200	N=300	N=400	N=500
m=4	%91.67	%93.97	%93.05	%93.56	%93.42	%93.46
	%98.12	%97.96	%98.06	%98.06	%98.02	%98.02
	%98.10	%97.95	%98.05	%98.05	%98.00	%98.01
m=5	%94.06	%93.94	%93.82	%94.41	%94.32	%94.26
	%98.18	%98.86	%98.92	%98.90	%98.18	%98.91
	%98.17	%98.85	%98.91	%98.89	%98.17	%98.89
m=6	%93.54	%93.14	%93.77	%93.57	%93.82	%93.53
	%98.98	%99.00	%98.98	%98.99	%98.98	%98.98
	%98.97	%98.99	%98.96	%98.97	%98.97	%98.97
m=7	%91.16	%92.83	%92.53	%92.41	%92.59	%92.61
	%98.99	%98.08	%98.23	%98.23	%98.23	%98.22
	%98.97	%98.07	%98.22	%98.21	%98.22	%98.21
m=8	%91.84	%91.52	%91.81	%91.77	%91.66	%91.78
	%99.02	%99.02	%99.00	%99.02	%99.01	%99.01
	%99.00	%99.00	%98.98	%99.00	%98.99	%98.99
m=9	%88.22	%88.54	%88.06	%88.50	%88.83	%88.49
	%98.90	%98.03	%98.80	%98.76	%98.80	%98.78
	%98.97	%98.00	%98.77	%98.74	%98.77	%98.75
m=10	%90.39	%90.60	%90.35	%90.67	%90.57	%90.60
	%99.07	%99.03	%99.05	%99.03	%99.04	%99.04
	%99.04	%99.01	%99.02	%99.01	%99.01	%99.02

Tablo 2.9. 3. lam test görüntüleri için RO yönteminin başarı ölçümleri

Ağaç Sayısı (N) Değişken Sayısı (m)	N=100	N=150	N=200	N=300	N=400	N=500
m=4	%88.33	%89.42	%90.17	%89.19	%89.63	%89.73
	%96.49	%96.34	%96.05	%96.36	%96.27	%96.27
	%96.46	%96.31	%96.03	%96.33	%96.24	%96.24
m=5	%90.23	%90.18	%90.63	%90.46	%90.49	%90.38
	%97.24	%97.08	%96.97	%97.19	%97.14	%97.15
	%97.21	%97.05	%96.94	%97.16	%97.11	%97.12
m=6	%89.48	%89.62	%90.12	%90.02	%90.03	%90.23
	%97.21	%97.30	%97.21	%97.26	%97.21	%97.21
	%97.18	%97.27	%97.17	%97.23	%97.18	%97.18
m=7	%89.96	%89.44	%90.00	%89.98	%89.82	%90.10
	%97.05	%97.29	%97.17	%97.12	%97.20	%97.17
	%97.02	%97.25	%97.14	%97.08	%97.17	%97.14
m=8	%88.02	%89.03	%89.13	%88.80	%88.92	%88.90
	%97.69	%97.50	%97.61	%97.62	%97.55	%97.60
	%97.64	%97.47	%97.57	%97.58	%97.51	%97.56
m=9	%87.81	%87.45	%87.35	%87.68	%87.88	%87.77
	%97.36	%97.47	%97.39	%97.40	%97.41	%97.39
	%97.32	%97.43	%97.34	%97.36	%97.37	%97.35
m=10	%88.92	%89.22	%89.21	%89.14	%89.24	%89.36
	%97.83	%97.64	%97.61	%97.69	%97.70	%97.71
	%97.79	%97.60	%97.57	%97.65	%97.67	%97.67

Tablo 2.10. 4. lam test görüntüleri için RO yönteminin başarı ölçümleri

Ağaç Sayısı (N) Değişken Sayısı (m)	N=100	N=150	N=200	N=300	N=400	N=500
m=4	%67.06	%66.61	%67.18	%69.09	%69.88	%68.48
	%98.69	%98.72	%98.74	%98.65	%98.59	%98.69
	%98.46	%98.49	%98.51	%98.44	%98.39	%98.47
m=5	%72.66	%74.53	%74.67	%72.87	%73.34	%74.95
	%98.46	%98.51	%98.39	%98.41	%98.44	%98.43
	%98.27	%98.33	%98.22	%98.23	%98.26	%98.26
m=6	%73.46	%72.64	%74.58	%74.45	%74.77	%74.80
	%98.23	%98.30	%98.36	%98.27	%98.28	%98.28
	%98.05	%98.11	%98.19	%98.10	%98.12	%98.11
m=7	%73.84	%73.35	%74.13	%74.15	%74.24	%73.93
	%98.42	%98.36	%98.46	%98.39	%98.41	%98.41
	%98.25	%98.17	%98.29	%98.22	%98.23	%98.23
m=8	%73.60	%73.00	%73.49	%73.49	%73.69	%73.93
	%98.50	%98.42	%98.38	%98.46	%98.43	%98.41
	%98.32	%98.23	%98.20	%98.28	%98.25	%98.23
m=9	%71.10	%70.63	%72.32	%71.30	%71.73	%72.01
	%98.36	%98.31	%98.25	%98.27	%98.27	%98.31
	%98.16	%98.11	%98.07	%98.08	%98.08	%98.13
m=10	%75.12	%75.77	%75.17	%74.76	%75.15	%75.07
	%98.25	%98.37	%98.22	%98.18	%98.21	%98.23
	%98.08	%98.20	%98.05	%98.01	%98.04	%98.06

Tablo 2.11. 5. lam test görüntüleri için RO yönteminin başarı ölçümleri

Ağaç Sayısı (N) Değişken Sayısı (m)	N=100	N=150	N=200	N=300	N=400	N=500
m=4	%89.53	%89.64	%89.06	%89.70	%89.66	%89.56
	%98.61	%98.61	%98.65	%98.62	%98.68	%98.61
	%98.58	%98.58	%98.61	%98.59	%98.64	%98.58
m=5	%91.86	%91.90	%92.66	%92.73	%92.76	%92.73
	%98.90	%98.85	%98.91	%98.88	%98.91	%98.89
	%98.87	%98.83	%98.89	%98.86	%98.89	%98.87
m=6	%92.75	%92.69	%93.05	%92.57	%92.72	%92.80
	%98.94	%98.94	%98.96	%98.97	%98.95	%98.95
	%98.92	%98.92	%98.94	%98.94	%98.93	%98.93
m=7	%92.37	%92.39	%92.76	%92.58	%92.61	%92.52
	%98.99	%99.03	%98.99	%99.01	%98.98	%99.01
	%98.97	%99.00	%98.97	%98.99	%98.96	%98.99
m=8	%92.29	%92.33	%92.64	%92.40	%92.45	%92.40
	%98.96	%99.10	%99.05	%99.05	%99.03	%99.05
	%98.93	%99.08	%99.03	%99.02	%99.01	%99.03
m=9	%90.86	%90.38	%90.86	%90.61	%91.02	%90.65
	%99.09	%99.10	%99.09	%99.09	%99.09	%99.09
	%99.06	%99.07	%99.06	%99.06	%99.06	%99.06
m=10	%92.24	%92.74	%92.89	%92.74	%92.82	%92.74
	%99.12	%99.16	%99.11	%99.13	%99.13	%99.15
	%99.09	%99.14	%99.09	%99.11	%99.11	%99.13

Farklı test kümeleri için elde edilen bölütleme başarı ölçümlerine bakıldığında ilk test kümesi için $m=5$ değişken ile $N=100$ ağaç kullanıldığında %82.31 değeriyle en başarılı sonuç alınmıştır. Özgüllük değeri ise bu ikili için %97.64 olarak hesaplanmıştır. Tüm tablo incelendiğinde ise özgüllük değerinin daha yüksek olduğu – en yüksek %98.75- sonuçlar ile de karşılaşılmaktadır. Fakat tanı testleri için duyarlılık değeri hastalığın tüm olası pozitif durumlarını göstermesinden dolayı özgüllük değerinden daha çok önemlidir. İkinci test kümesi için sonuçlar incelendiğinde $m=5$ değişken için $N=300$ ağaç kullanıldığında duyarlılık değeri %94.41, üçüncü test için $m=5$ değişkeni için $N=200$ ağaç kullanıldığında duyarlılık değeri %90.63, dördüncü test için $m=10$ değişken için $N=150$ ağaç kullanıldığında duyarlılık değeri %75.77 ve son test için ise $m=6$ değişken için $N=200$ ağaç kullanıldığında duyarlılık değeri %93.05 değeri ile en iyi duyarlılık performansları elde edilmiştir. RO yönteminin sonuçlarına bakıldığında lamın boyanma kalitesinin de burada önemli olduğu görülmektedir.

DVM yönteminde 5-katlamalı çapraz geçerlilik yöntemi kullanılarak C parametresi 2^{15} ile 2^{-5} aralığında 2^{-2} adımlarıyla, γ parametresi 2^{-6} ile 2^{-1} aralığında $2^{1/2}$ adımlarıyla değiştirilerek en iyi parametreler belirlenmiştir ve elde edilen sonuçlar tablolarda verilmiştir.

Tablo 2.12. 1. lam test görüntüleri için DVM yönteminin başarı ölçümleri

Parametreler		Başarı Ölçümleri	
En iyi C	2048	Duyarlılık	%21.25
En iyi γ	0.012	Özgüllük	%99.79
Çapraz geçerlilik doğruluğu	%99.82	Doğruluk	%99.74

Tablo 2.13. 2. lam test görüntüleri için DVM yönteminin başarı ölçümleri

Parametreler		Başarı Ölçümleri	
En iyi C	2	Duyarlılık	%98.09
En iyi gamma	0.2479	Özgüllük	%94.88
Çapraz geçerlilik doğruluğu	%99.90	Doğruluk	%98.10

Tablo 2.14. 3. lam test görüntüleri için DVM yönteminin başarı ölçümleri

Parametreler		Başarı Ölçümleri	
En iyi C	512	Duyarlılık	%47.21
En iyi gamma	0.012	Özgüllük	%99.74
Çapraz geçerlilik doğruluğu	%98.74	Doğruluk	%99.48

Tablo 2.15. 4. lam test görüntüleri için DVM yönteminin başarı ölçümleri

Parametreler		Başarı Ölçümleri	
En iyi C	512	Duyarlılık	%41.09
En iyi gamma	0.064	Özgüllük	%99.68
Çapraz geçerlilik doğruluğu	%98.18	Doğruluk	%99.25

Tablo 2.16. 5. lam test görüntüleri için DVM yönteminin başarı ölçümleri

Parametreler		Başarı Ölçümleri	
En iyi C	2048	Duyarlılık	%87.02
En iyi gamma	0.02352	Özgüllük	%99.59
Çapraz geçerlilik doğruluğu	%99.46	Doğruluk	%99.55

DVM yönteminin ilk test kümesi için başarı sonuçları incelendiğinde en iyi parametrelerin belirlenmesine karşın %21.25 oranında bir duyarlılık elde edilmiştir. Bu sonuç RO yönteminin çok gerisinde kalmaktadır. GOYF yöntemiyle karşılaştırıldığında ise duyarlılık olarak bu yöntemden kötü sonuçlar vermekte fakat özgüllük oranı olarak bu yöntemi geçmektedir. İkinci test kümesi için DVM yönteminin duyarlılığı %98.09, RO yönteminin duyarlılığı ise %94.41 olarak hesaplanmıştır. Fakat özgüllük değerleri incelendiğinde RO, DVM yöntemini geçmektedir. Burada da bir ödünleşme söz konusudur. Bu yüzden doğruluk değerine bakılırsa RO yönteminin DVM yöntemine göre daha başarılı sonuç ürettiği görülür. Diğer test sonuçlarının tümünde DVM yöntemi GOYF yöntemini

geçmekte fakat en iyi parametrelerin belirlenmesine karşın RO yönteminin oldukça gerisinde kalmaktadır.

Bölütlenmiş 2. hastadan alınan görüntüler üzerinde sınıflandırma işleminin gerçekleştirilmesi için eğitim görüntülerinden 40 bakteri ve 18 bakteri olmayan nesne olmak üzere toplam 58 nesne seçilmiştir. Bu nesnelerin doğrultuları bulunmuş ve nesnelere döndürülüp yeniden boyutlandırılarak eğitim görüntüleri hazırlanmıştır. Test görüntülerindeki TB'lerin tanınmaları üzerine yapılan testlerde YSA, RO ve DVM yöntemleri karşılaştırılmıştır.

YSA yöntemi için ara katmandaki nöron sayısı 100, 200, ..., 500 arasında 100 sayı artırılarak beş farklı durum incelenmiştir. Her bir durum için kabul edilebilir hata değeri, 10^{-3} olarak seçilmiştir. Elde edilen sonuçlar Tablo 2.17'de verilmiştir.

Tablo 2.17. Test görüntüleri için YSA yönteminin başarı ölçümleri

Ara Katman Nöron Sayısı Başarı Ölçümleri	100	200	300	400	500
Duyarlılık	%64.77	%72.75	%76.82	%75.04	%72.85
Özgüllük	%67.07	%63.61	%63.78	%63.44	%64.07
Doğruluk	%66.61	%65.36	%66.28	%65.66	%65.73

Tablo incelendiğinde ara katmandaki nöron sayısı 100 seçildiğinde duyarlılık değerinin %64.77 olarak hesaplandığı görülmektedir. Nöron sayısı arttıkça duyarlılık değeri artmıştır. Nöron sayısı 300 seçildiğinde ise değer en yüksek değerine ulaşmış ve düşmeye başlamıştır. Bu yüzden test verileri için en yüksek duyarlılık değeri veren 300 sayısı en iyi nöron sayısı olarak belirlenmiştir.

RO yöntemi için değişken ve ağaç sayısı ikililerine bağlı olarak 12 farklı durum incelenmiştir. Tablo 2.18'de elde edilen başarı ölçümleri verilmiştir.

Tablo 2.18. Test görüntüleri için RO yönteminin başarı ölçümleri

Ağaç Sayısı (N) Değişken Sayısı (m)	N=250	N=500	N=750	N=1000
m=2000	%86.44	%87.84	%75.07	%73.80
	%62.50	%64.84	%77.17	%77.50
	%67.08	%69.23	%76.69	%76.39
m=2250	%89.34	%85.52	%75.71	%73.81
	%62.89	%64.67	%77.33	%77.50
	%67.98	%68.65	%76.95	%76.71
m=2500	%88.01	%85.52	%75.71	%73.81
	%63.70	%64.84	%77.33	%77.50
	%68.38	%68.78	%76.95	%76.71

Tablo incelendiğinde N=250 ağaç ve m=2250 değişken sayıları seçildiğinde en yüksek duyarlılık değerinin %89.34 olarak hesaplandığı görülmektedir. En yüksek değeri, N=250 ve m=2500 ikilisi ile %88.01 duyarlılık değerinin ve N=500 ve m=2000 ikilisi ile %87.84 duyarlılık değerinin izlediği görülmektedir. Her bir ikilinin başarı ölçümleri arasındaki azalış ve artışların büyük olmasının nedeni, her bir nesnenin 2700 öznitelikle temsil edilmesinden dolayı ağaç ve değişken sayısının aralarında büyük fark oluşturacak şekilde seçilmesidir. Yine de seçilen parametrelerle elde edilen duyarlılık değeri, YSA yöntemiyle elde edilen en yüksek duyarlılık değeriyle karşılaştırıldığında RO yönteminin YSA yönteminden yaklaşık %13 oranında bir yüzdelle daha iyi sonuç verdiği görülmektedir.

Tablo 2.19. Test görüntüleri için DVM yönteminin başarı ölçümleri

Parametreler		Başarı Ölçümleri	
En iyi C	8192	Duyarlılık	%86.71
En iyi γ	0.012	Özgüllük	%60.15
Çapraz geçerlilik doğruluğu	%72.41	Doğruluk	%66.13

Tablo incelendiğinde en iyi parametrelerin belirlenmesine karşılık duyarlılık değerinin %86.71 olarak hesaplandığı görülmektedir. Bölütleme de olduğu gibi sınıflandırma aşamasında da yöntemin RO yönteminin oldukça gerisinde kaldığı görülmektedir.

3. SONUÇLAR VE TARTIŞMA

Çalışmamızda, mikroskopik görüntülerden tüberküloz bakterisinin otomatik teşhisini yapan bir sistem gerçekleştirilmiştir. Geliştirilen bilgisayar destekli sistem ile, hastalığın insan etkileşimini en aza indirerek teşhis edilmesi hedeflenmektedir.

Çalışma eğitim ve test veri tabanlarının oluşturulması, öznitelik çıkartımı, bölütleme ve sınıflandırma olmak üzere dört kısımda incelenmiştir. Eğitim ve test veritabanında kullanılmak üzere 5 farklı hastadan alınan yayma örneklerinin mikroskopik görüntüleri elde edilmiştir. Eğitim ve test veritabanları toplamda 116 görüntüden oluşmakta ve görüntülerin 40 tanesi sistemi eğitmek, geri kalan 76 görüntü ise sistemi test etmek için kullanılmıştır.

Ön işlem olarak bakteri verisi üretimi gerçekleştirilirken bir büyüteç tasarlanıp sistem kullanıcısının yanlış eğitim örneği alma etkisi azaltılmıştır. Buna ek olarak çıkartılan özniteliklerin Mahalanobis uzaklıkları da dikkate alınarak gürültülü veri eliminasyonu sağlanmıştır. Bölütleme aşaması için öznitelik çıkartılmasında eğitim görüntülerinden danışmanlı bakteri verisi üretimi yapılmıştır. Bunun için iki boyutlu Gauss Olasılık Yoğunluk Fonksiyonuna dayalı kernel parametrelerin belirlenmesi işlemi gerçekleştirilmiştir. Sınıflandırma aşamasında ise öznitelik çıkartılması için görünüşe dayalı yaklaşım ileri sürülmüştür. Kullanıcıdan bakteri ve bakteriyeye benzer bakteri olmayan bölgelerin seçilmesi istenmiş ve bölgelerin döndürülüp yeniden boyutlandırılmasıyla aynı forma getirilmeleri sağlanmıştır.

Bölütleme aşamasında Gauss Olasılık Yoğunluk Fonksiyonu, Destek Vektör Makineleri ve Rastgele Ormanlar yaklaşımı incelenmiş ve başarı sonuçları kıyaslandığında güncel bir yaklaşım olan Rastgele Ormanların diğer yöntemlere oranla daha yüksek performans sağladığı görülmüştür. Her bir yaklaşımın gerçekleştirilmesinde karşılaşılan sorun ilgili parametrelerin belirlenmesi olmuştur. Uygun parametre seçimi, çapraz geçerlilik yöntemi ile otomatik belirlendiği gibi çapraz geçerlilik yöntemine ihtiyaç duyulmadığı durumlarda ise elle belirlenmiştir. Her iki durumda da seçimin her zaman iyi sonuç vermemesi ve veritabanının çok büyük olmasının getirdiği fazla işlem yükü de bu aşamada karşılaşılan sorunlardandır. Bu sorunlara yöntemlerin karmaşıklığının getirdiği yükün de eklenmesi çalışmanın zorluğunu ortaya koymaktadır.

Son olarak gerçekleştirilen sınıflandırma aşamasında Yapay Sinir Ağları, Destek Vektör Makineleri ve Rastgele Ormanlar yöntemleri üzerinde durulmuştur. Yapısal

yaklaşımlarda olduğu gibi görünüşe dayalı yaklaşımlarda da Rastgele Ormanlar yönteminin diğer yöntemlerden daha iyi sonuç verdiği görülmüştür. Karmaşıklık ve iş yükü problemi burada da karşımıza çıkan sorunlar arasındadır.

Tüm çalışma incelendiğinde hastalardan alınan yayma örneklerinin farklı kalınlıkta yayılmış olması, uzun süre boyama işlemine tabi tutulması, yaymayı oluşturan hastadan alınan balgamın yoğunluğu gibi yayma örneklerinin çeşitliliğini gösteren bir çok etken bölütleme ve sınıflandırma aşamasının başarısını etkilemektedir. Bunun yanında görüntü alınan kameranın çözünürlüğü, mikroskobun makrovida ve mikrovida ile görüntü ve netlik ayarının yapılması, ışığın şiddeti de başarıyı etkileyen görüntü toplanması ile ilgili karşılaşılan problemlerdendir.

Sonuç olarak önerilen yöntem güncel bir yaklaşım olup mikroskobik görüntülerin analizinde kullanılmayan bir yaklaşım olduğundan ve diğer yöntemlerle kıyaslandığında performans açısından başarılı sonuçlar verdiği için değişik alanlardaki birçok probleme de genelleştirilebilir.

Çalışma sırasında geliştirilen yaklaşımın bir bölümünün mikroskobik görüntülere uygulanmasına dayanan 1 adet bildiri 2013 Sinyal İşleme ve İletişim Uygulamaları Kurultayına sunulmuş ve bildiri kitapçığında basılmıştır [26].

4. ÖNERİLER

Donanımsal olarak görüntü toplamada kullanılan kameranın rezolasyonu artırılabilir. Böylece mikroskoptan alınan görüntülerin daha net olması sağlanacaktır. Bunun yanında yayma örneklerinin mikroskopla incelenmesinde katmanlı bir yapı söz konusu olduğundan, aynı alan içerisinde tek katmana dayalı görüntü alma yerine birçok katmandan alınan görüntüler uygun bir algoritma ile birleştirilip en net görüntü elde edilebilir.

Öznitelik çıkartılmasında, farklı renk uzaylarının da performans üzerindeki etkisi incelenebilir. Görünüme dayalı yaklaşımlarda ise yeniden boyutlandırılmış görüntü boyutu değiştirilerek performans karşılaştırılması yapılabilir. Ayrıca görüntünün zamansal domenden frekans domenine aktarılıp farklı özniteliklerin elde edilmesi de sağlanabilir. Kullanılan yöntemlerden Rastgele Ormanlar yaklaşımı, Torbalama ve Hızlandırma yönteminin birleşimi ve gelişimi olduğundan bu yöntem de uygulanarak başarı sonuçları incelenebilir.

5. KAYNAKLAR

1. Jain, K. A., Duin, P. W. R. ve Mao, J., Statistical Pattern Recognition: A Review, IEEE Transaction on Pattern Analysis and Machine Intelligence, 22, 1 (2000) 4-37.
2. Bow, S., Pattern Recognition and Image Preprocessing, Second Edition, Marcel Dekker Inc., New York, 1992.
3. Veropoulos, K., Machine Learning Approaches to Medical Decision Making, Doktora tezi, University of Bristol, Faculty of Engineering, Department of Engineering Mathematics, Bristol, 2001.
4. Smochina, C., Herghelegiu, P. ve Manta, V., Image Processing Techniques Used in Microscopic Image Segmentation, BULETINUL INSTITUTULUI POLITEHNIC DIN IAȘI, LVII, LXI (2011) 83-98.
5. Costa, G. F. M., Filho, F. F. C., Sena, J. F., Salem, J. ve Lima, M. O., Automatic Identification of Mycobacterium Tuberculosis with Conventional Light Microscopy, 30th Annual International IEEE EMBS Conference, August 2008, Vancouver, British Columbia, 382-385.
6. Raof, R. A. A., Salleh, Z., Sahidan, S. I., Mashor, M. Y., Md Noor, S. S., Idris, F. M. ve Hasan, H., Color Thresholding Method for Image Segmentation Algorithm of Ziehl-Neelsen Sputum Slide Images, 5th International Conference on Electrical Engineering, Computing Science and Automatic Control, November 2008, Mexico, 212-217.
7. Raof, R. A. A., Mashor, M. Y., Ahmad, R. B., Noor, S. S. M. ve Osman, M. K., Comparison of Colour Thresholding Method Using RGB and HSI Information for Ziehl-Neelsen Sputum Slide Images, 10th International Conference on Information Science, Signal Processing and their Applications, May 2010, Malaysia, 724-727.
8. Makkapati, V., Agrawal, R. ve Acharya, R., Segmentation and Classification of Tuberculosis Bacilli from ZN-Stained Sputum Smear Images, 5th Annual IEEE Conference on Automation Science and Engineering, August 2009, India, 217-220.
9. Nayak, R., Shenoy, V. P. ve Galigekere, R. R., A New Algorithm for Automatic Assessment of the Degree of TB_infection Using Images of ZN-stained Sputum Smear, International Conference on Systems in Medicine and Biology, December 2010, India, 294-299.
10. Sadaphal, P., Rao, J., Comstock, G. W. ve Beg, M. F., Image Processing Techniques for Identifying Mycobacterium Tuberculosis in Ziehl-Neelsen Stains, Int J Tuberc Lung Dis, 12, 5 (2008) 579-582.
11. Forero, M. G., Cristobal, G. ve Alvarez-Borrego, J., Automatic Identification Techniques of Tuberculosis Bacteria, Applications of Digital Image Processing XXVI, 5203 (2003) 71-81.

12. Forero, M. G., Sroubek, F. ve Cristobal, G., Identification of Tuberculosis Bacteria Based on Shape and Color, Real-Time Imaging, 10 (2004) 251-262.
13. Forero, M. G., Cristobal, G. ve Desco, M., Automatic Identification of Mycobacterium Tuberculosis by Gaussian Mixture Models, Journal of Microscopy, 223 (2006) 120-132.
14. Siena, I., Adi, K., Gernowo, R. ve Mirnasari, N., Development of Algorithm Tuberculosis Bacteria Identification Using Color Segmentation and Neural Networks, International Journal of Video & Image Processing and Network Security, 12, 04 (2012) 9-13.
15. Khutlang, R., Krishnan, S. Dendere, R., Whitelaw, A., Veropoulos, K., Learmonth, G. ve Douglas, T. S., Classification of Mycobacterium Tuberculosis in Images of ZN-Stained Sputum Smears, IEEE Transactions on Information Technology in Biomedicine, 14, 4 (2010) 949-957.
16. WHO, Global Tuberculosis Report, France, 2012.
17. Palomino, J. C., Leao, S. C. ve Ritacco, V., Tuberculosis 2007-From Basic Science to Patient Care, First Edition, BourcillierKamps.com, 2007.
18. Küçükusta, A. R., Tüberküloz Tedavisi, <http://www.ahmetrasimkucukusta.com/2010/01/20/yazilar/tip-yazilari/tuberkuloz/tuberkuloz-tedavisi/>, 20 Ocak 2010.
19. Centers for Disease Control and Prevention, Get the Facts About TB Disease, 2005.
20. International Union Against Tuberculosis and Lung Disease, A Tuberculosis Guide for Specialist Physicians, France, 2003.
21. Central TB Division, Module for Laboratory Technicians, New Delhi, 2005.
22. National Center for HIV/AIDS, Viral Hepatitis, STD, and TB Prevention, TB Elimination-Diagnosis of Tuberculosis Disease, 2011.
23. Shrihari, N. ve Bact, K., A Comparison of Three Different Staining Methods for the Detection of Acid Fast Bacilli (Mycobacterium Tuberculosis) in Sputum Samples, Journal of Pharmaceutical and Biomedical Sciences, 14, 14 (2012) 1-2.
24. International Union Against Tuberculosis and Lung Disease, Sputum Examination for Tuberculosis by Direct Microscopy in Low Income Countries, France, 2000.
25. <http://www-medlib.med.utah.edu/WebPath/webpath.html>, Auramine-Rhodamine Fluorescence -Acid Fast Bacteria.
26. Guven, S. ve Ekinci, M., Tüberküloz Bakterisinin Mikroskopik Görüntü Analiziyle Algılanması, 21. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2013, Girne, Kıbrıs.

27. Wang, X., Wang, T. ve Bu, J., Color Image Segmentation Using Pixel Wise Support Vector Machine Classification, Pattern Recognition, 44 (2011) 777-787.
28. Estrada, F. J. ve Jepson, A. D., Benchmarking Image Segmentation Algorithms, Int J Comput Vis, 85 (2009) 167-181.
29. Quan, J., Wen, X. ve Xu, X., Multiscale Probabilistic Neural Network Method for SAR Image Segmentation, Applied Mathematics and Computation, 205 (2008) 578-583.
30. Schroff, F., Criminisi, A. ve Zisserman, A., Object Class Segmentation Using Random Forests, British Machine Vision Conference, Leeds, UK, 54.1-54.10.
31. Wang, X., Zhang, X., Yang, H. ve Bu, J., A Pixel-Based Color Image Segmentation Using Support Vector Machine and Fuzz C-Means, Neural Networks, 33 (2012) 148-159.
32. Zhou, Z., Ensemble Learning, Encyclopedia of Biometrics, (2009).
33. Breiman, L., Bagging Predictors, Machine Learning, 24 (1996) 123-140.
34. Sewell, M., Ensemble Learning, <http://machine-learning.martinsewell.com/ensembles/ensemble-learning.pdf>, Nisan 2007.
35. Schapire, R. E., The Strength of Weak Learnability, Machine Learning, 5 (1990) 197-227.
36. Freund, Y. ve Schapire, R. E., A Short Introduction to Boosting, Journal of Japanese Society for Artificial Intelligence, 14, 5 (1999) 771-780.
37. Breiman, L., Random Forests, Machine Learning, 45 (2001) 5-32.
38. Dietterich, T., An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting and Randomization, Machine Learning, 40 (1998) 139-157.
39. Ho, T. K., The Random Subspace Method for Constructing Decision Forests, IEEE Transaction on Pattern Analysis and Machine Intelligence, 20, 8 (1998) 832-844.
40. Amit, Y. ve Geman, D., Shape Quantization and Recognition with Randomized Trees, Neural Computation, 9 (1997) 1545-1588.
41. Singh, K. ve Xie, M., Bootstrap: A Statistical Method, www.stat.rutgers.edu/~mxie/rcpapers/bootstrap.pdf, 2008.
42. Safavin, S. R. ve Landgrebe, D., A Survey of Decision Tree Classifier Methodology, IEEE Transaction on Systems, Man and Cybernetics, 21, 3 (1991) 660-674.
43. Rokach, L., Pattern Classification Using Ensemble Methods, Vol. 75, World Scientific Publishing Co. Pte. Ltd., Singapore, 2010.

44. Breiman, L., Friedman, J., Stone, C. J. ve Olshen, R. A., Classification and Regression Trees, Chapman & Hall, 1984
45. Hancock, T., Jiang, T., Li, M. ve Tromp, J., Lower Bounds on Learning Decision Lists and Trees, Information and Computation, 126, 2 (1996) 114-122.
46. Hyafil, L. ve Rivest, R. L., Constructing Optimal Binary Decision Trees is NP-Complete, Information Processing Letters, 5, 1 (1976) 15-17.
47. Zantema, H. ve Bodlaender, H. L., Finding Small Equivalent Decision Trees is Hard, International Journal of Foundations of Computer Science, 11, 2 (2000) 343-354.
48. Webb, A., Statistical Pattern Recognition, Second Edition, John Wiley & Sons Ltd, Malvern, UK, 2002.
49. Quinlan, J. R., Induction of Decision Trees, Machine Learning, 1 (1986) 81-106.
50. Quinlan, J. R., C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers Inc, San Francisco, CA, USA, 1993.
51. Timofeev, R., Classification and Regression Trees (CART) Theory and Applications, Yüksek Lisans Tezi, Humboldt University, Berlin, 2004.
52. Breiman, L., Out-of-bag Estimation, <http://www.stat.berkeley.edu/~breiman/OOBEstimation.pdf>, 1996.
53. Tibshirani, R., Bias, Variance and Prediction Error for Classification Rules, Technical Report, 9602 (1996).
54. Wolpert, D. H. ve Macready, W. G., An Efficient Method to Estimate Bagging's Generalization Error, Machine Learning, 35, 1 (1999) 41-55.
55. Vapnik, V. N., The Nature of Statistical Learning Theory, Springer-Verlag, New York, USA, 1995.
56. Jakkula, V., Tutorial on Support Vector Machine (SVM), School of EECS, Washington State University, Pullman 99164.
57. Shih F. Y., Image Processing and Pattern Recognition Fundamentals and Techniques, John Wiley & Sons, Inc., New Jersey, 2010.
58. Kuncheva, L. I., Combining Pattern Classifiers Methods and Algorithms, John Wiley & Sons, Inc., New Jersey, 2004.
59. McCulloch, W. S. ve Pitts, W. H., A Logical Calculus of The Ideas Immanent in Nervous Activity, Bulletin of Mathematical Biophysics, 5 (1943) 115-133.

60. Hebb, D. O., *The Organization of Behavior: A Neuropsychological Theory*, New Edition, Psychology Press, 2002.
61. Rosenblatt, F., *The Perceptron: A Probabilistic Model for Information Storage & Organization in the Brain*, Psychological Review, 65 (1958) 386-408.
62. Minsky, M. ve Papert, S. A., *Perceptrons: An Introduction to Computational Geometry*, Expanded Edition, The MIT Press, 1987.
63. Werbos, P. J., *The Roots of Backpropagation: From Ordered Derivatives to Neural Networks and Political Forecasting*, First Edition, Wiley-Interscience, 1994.
64. Elkan, C., *Evaluating Classifiers*, <http://cseweb.ucsd.edu/~elkan/250B/classifiereval.pdf>, 2011.

ÖZGEÇMİŞ

Selen AYAS, 1988 İstanbul doğumludur. İlkokulu ve ortaokulu Bahçelievler İlköğretim Okulu' nda ve liseyi Ataköy Lisesinin Yabancı Dil Ağırlıklı bölümünde tamamlamıştır. Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü' nden 2011 yılında ikincilikle mezun olmuştur. Aynı yıl güz döneminde Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans programına, bahar döneminde de aynı bölümde araştırma görevlisi olarak çalışmaya başlamıştır. Halen Bilgisayar Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır. İyi derecede İngilizce bilmektedir.