

**KARADENİZ TEKNİKÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**PERİAPİKAL KİST VE KERATOKİSTİK ODONTOJENİK TÜMÖR LEZYONLARININ
YARI OTOMATİK BÖLÜTLENMESİ VE SINIFLANDIRILMASI**

DOKTORA TEZİ

Ercüment YILMAZ

**HAZİRAN 2018
TRABZON**

KARADENİZ TEKNİKÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**PERİAPİKAL KİST VE KERATOKİSTİK ODONTOJENİK TÜMÖR
LEZYONLARININ YARI OTOMATİK BÖLÜTLENMESİ VE
SINIFLANDIRILMASI**

Ercüment YILMAZ

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 29.05.2018
Tezin Savunma Tarihi : 27.06.2018

Tez Danışmanı : Prof. Dr. Temel KAYIKÇIOĞLU

Trabzon 2018

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Ana Bilim Dalında
Ercüment YILMAZ Tarafından Hazırlanan

**PERİAPİKAL KİST VE KERATOKİSTİK ODONTOJENİK TÜMÖR
LEZYONLARININ YARI OTOMATİK BÖLÜTLENMESİ VE
SINIFLANDIRILMASI**

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 29 / 05 / 2018 gün ve 1755 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda

DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Prof. Dr. Cemal KÖSE

Üye : Prof. Dr. Ali GANGAL

Üye : Prof. Dr. Kürşat ER

Üye : Doç. Dr. İsa YILDIRIM

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Bu tez kapsamında konik ışınli bilgisayarlı tomografi cihazları ile elde edilen üç boyutlu medikal görüntülerde gözlemlenen periapikal kist ve keratokistik odontojenik tümör türlerindeki dental lezyonların yarı otomatik bölütlenmesi ve bölütlenen bölgedeki lezyonun teşhisine yardımcı olacak bir karar destek sisteminin geliştirilmesi konusu işlenmiştir.

Bu doktora tezi, Karadeniz Teknik Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurul Başkanlığı'nın 08.10.2013 tarih ve 567 sayı numaralı etik kurul kararına uygun olarak hazırlanmıştır.

Tez çalışması süresince değerli katkılarını, görüş ve önerilerini benden esirgemeyen, her aşamada yanımda olan tez danışmanım Sayın Prof. Dr. Temel KAYIKÇIOĞLU'na ve çalışmam süresince sundukları değerli katkılardan dolayı Sayın Prof. Dr. Cemal KÖSE ve Sayın Prof. Dr. Ali GANGAL'a teşekkürlerimi sunarım.

Tez konusunun belirlenmesinde değerli öneri ve katkılarını sunan, tez çalışması kapsamındaki tüm tıbbi görüntüleri temin eden, KTÜ Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Başkanı Sayın Doç. Dr. Saadettin KAYIPMAZ'a teşekkürlerimi ve şükranlarımı sunarım.

Bu çalışmaya sundukları katkılardan dolayı KTÜ Diş Hekimliği Fakültesi öğretim üyesi arkadaşlarıma ve KTÜ Tıp Fakültesi Patoloji Anabilim Dalı Başkanı Sayın Prof. Dr. Ümit ÇOBANOĞLU'na şükranlarımı sunarım.

Çalışmalarım sırasında görüş ve desteklerini benden esirgemeyen değerli öğretim üyesi arkadaşlarım Dr. Öğr. Üyesi Önder AYDEMİR'e, Doç. Dr. Tamer TÜZÜNER'e, Doç. Dr. Behçet Uğur TÖREYİN'e ve Dr. Öğr. Üyesi Tolga BERBER'e teşekkürü borç bilirim.

Tez çalışmam süresince yanımda olan, desteklerini esirgemeyen bütün değerli hocalarıma ve kıymetli arkadaşlarıma teşekkür ederim.

Yaşamım ve öğrenim hayatım boyunca hep yanımda olan, bugünlere gelmemi sağlayan, sevgili annem Mürvet YILMAZ ve babam Kemal YILMAZ'a maddi-manevi destekleri için minnet ve şükranlarımı sunarım.

Ercüment YILMAZ

Trabzon 2018

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Periapikal Kist ve Keratokistik Odontojenik Tumor Lezyonlarının Yarı Otomatik Bölütlenmesi ve Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Temel KAYIKÇIOĐLU’nun sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 27/06/2018

Ercüment YILMAZ

İÇİNDEKİLER DİZİNİ

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER DİZİNİ.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Dental Radyolojinin Tarihçesi.....	2
1.3. Konik Işınlı Bilgisayarlı Tomografi (KİBT)	3
1.4. Diş Hekimliğinde Konik Işınlı Bilgisayarlı Tomografi.....	5
1.4.1. Dental Lezyonlar	7
1.4.2. Dental Lezyonların Radyografik Analizi	8
1.4.2.1. Radyolusent Lezyonlar	8
1.4.2.2. Radyopak Lezyonlar:.....	8
1.4.3. Dental Lezyon Türleri	9
1.4.3.1. Odontojenik Kistler	9
1.4.3.1.1. Periapikal Kist (Radiküler Kist)	10
1.4.3.1.2. Rezidüel Kist	11
1.4.3.1.3. Dentigeröz Kist.....	11
1.4.3.1.4. Lateral Periodontal Kist.....	12
1.4.3.2. Odontojenik Olmayan Kistler.....	13
1.4.3.2.1. Basit Kemik Kisti	13
1.4.3.2.2. İnsiziv Kanal Kisti.....	13
1.4.3.3. Odontojenik Tümörler	14
1.4.3.3.1. Ameloblastoma.....	14
1.4.3.3.2. Keratokistik Odontojenik Tümör	14

1.4.3.3.3. Odontoma	15
1.5. Medikal Görüntü ve İşaret İşleme	16
1.6. Literatür Araştırması.....	17
1.7. Tezin Özgünlüğü	22
1.8. Tezin Kapsamı	24
2. YAPILAN ÇALIŞMALAR.....	28
2.1. Materyal.....	28
2.1.1. Kullanılan KIBT Cihazı ve Oluşturulan Görüntü Veritabanı.....	28
2.2. Yöntem	29
2.2.1. KIBT Görüntülerinde İyileştirme İşlemleri.....	29
2.2.1.1. Gürültü Seviyesi Kestirimi	30
2.2.1.2. Bulanıklık Seviyesi Kestirimi.....	31
2.2.1.3. Anizotropik Yayılma (AY).....	34
2.2.1.4. AY Denkleminde Yinelemenin Durdurulması	35
2.2.2. İlgilenilen Hacimsel Bölgenin (İHB) Tespiti ve Bölütlenmesi	37
2.2.3. Görüntü Bölütleme Yöntemleri	40
2.2.3.1. Adaptif K-Ortalama Kümeleme	40
2.2.3.2. Rasgele Yürüyüş Algoritması.....	41
2.2.3.3. Bölge Tabanlı Aktif Kontur Modeli	45
2.2.3.3.1. Mumford-Shah Modeli	45
2.2.3.3.2. Yerel Gauss Dağılımına Enerji Sağlayan Aktif Konturlar	45
2.2.3.4. Lezyonlu Bölgelerin Yarı Otomatik Bölütlenmesi.....	46
2.2.3.5. Bölütleme Performansının Karşılaştırılması	50
2.2.4. Özniteliklerin Çıkartılması	51
2.2.4.1. Düzey İstatistikleri.....	51
2.2.4.2. 3B Haralick Doku Öznitelikleri.....	52
2.2.4.3. Öznitelik Vektörü	54
2.2.5. Sınıflandırma Yöntemleri.....	55
2.2.5.1. k-En Yakın Komşuluk	55
2.2.5.1.1. Ağırlıklı k-En Yakın Komşuluk	57
2.2.5.2. Naive Bayes	58
2.2.5.3. Karar Ağaçları	60
2.2.5.4. Rastgele Orman	62

2.2.5.5.	Yapay Sinir Ağları.....	62
2.2.5.6.	Destek Vektör Makineleri	64
2.2.5.6.1.	Destek Vektör Makinelerinin Özü.....	65
2.2.5.6.2.	Ayırıcı Hiperdüzlem.....	65
2.2.5.6.3.	Maksimum Marjlı Hiperdüzlem	66
2.2.5.6.4.	Yumuşak Marj	67
2.2.5.6.5.	Çekirdek Fonksiyonu.....	68
2.2.5.6.6.	Doğrusal Destek Vektör Makineleri.....	69
2.2.5.6.7.	Yumuşak Marjlı Doğrusal Destek Vektör Makineleri	73
2.2.5.6.8.	Doğrusal Olmayan Destek Vektör Makineleri	74
2.2.6.	Veri Sınıflandırmada Doğrulama Teknikleri.....	76
2.2.6.1.	10-Kat Çapraz Doğrulama.....	76
2.2.6.2.	2-Kat Çapraz Doğrulama.....	77
2.2.6.3.	Birini Dışarıda Bırak Çapraz Doğrulama	77
2.2.6.4.	Bölünmüş Örnek Doğrulama.....	78
2.2.7.	İleriye Doğru Seçim Algoritması	79
2.2.8.	Temel Bileşenler Analizi.....	79
3.	BULGULAR VE İRDELEME.....	81
3.1.	Görüntülerde Ön İşleme Çalışmaları.....	81
3.1.1.	Gürültü Seviyesi Kestirim Deneyleri	81
3.1.2.	Gürültü Temizleme Deneyleri	84
3.2.	Manuel Bölütleme	85
3.3.	Yarı Otomatik Bölütleme Deneyleri.....	87
3.4.	Sınıflandırma Deneyleri	89
3.5.	Eğitim ve Test.....	89
3.6.	Sınıflandırma Sonuçları.....	90
3.7.	Yarı Otomatik Bölütleme ve Sınıflandırma Deneyleri.....	107
4.	SONUÇLAR VE KARŞILAŞTIRMA.....	109
5.	ÖNERİLER	113
6.	KAYNAKLAR.....	117
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

PERİAPİKAL KİST VE KERATOKİSTİK ODONTOJENİK TÜMÖR
LEZYONLARININ YARI OTOMATİK BÖLÜTLENMESİ VE SINIFLANDIRILMASI

Ercüment YILMAZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Temel KAYIKÇIOĞLU
2018, 124 Sayfa

Konik ışınli bilgisayarlı tomografi (KIBT) görüntüleme, diş hekimliđi alanında radyolojik incelemelerde son yıllarda sıklıkla kullanılmaktadır. Bu tezde, üç boyutlu (3B) KIBT görüntülerinde periapikal kist (PK) ve keratokistik odontojenik tümör (KOT) lezyonlarının bölütlenmesi ve doğru sınıflara ayrılması çalışmaları yapılmış ve yöntemler önerilmiştir. 50 adet 3B KIBT görüntüsü içeren veri dosyaları çalışmanın veri kümesi olarak belirlenmiştir. Uzmanlar tarafından verilerin yarısı PK ve diđer yarısı ise KOT olarak teşhis edilmiştir. Teşhis edilen lezyonlar bu çalışma özelinde geliştirilen yazılım aracılığı ile çeşitli deneylerde kullanılmışlardır. Lezyonlu hacimsel bölgeler geliştirilen yazılımın araçları ile manuel bölütlenmiş ve mutlak doğruluk kümesi elde edilmiştir. Ön işlem adımı için KIBT görüntülerinde tespit edilen gürültülerin temizlenmesine yönelik gürültü temizleme yaklaşımı önerilmiştir. Lezyonların anatomik ve iç yapılarındaki çeşitliliğe uyum sağlayacak yarı otomatik bölütleme yaklaşımı önerilmiştir. Bölütlenmiş lezyonlardan temel istatistikler ve 3B Gri Seviye Birlikte Görülme Matrisi (GSBGM) bilgileri hesaplanmış ve 636 adet öznelik bilgisi içeren öznelik vektörü elde edilmiştir. Sınıflandırma deneyleri için altı farklı sınıflandırıcı kullanılmıştır. Sınıflandırma deneyleri sonucunda PK ve KOT lezyonları büyük bir doğruluk oranı ile tespit edilebilmekte ve sınıflandırılabilir.

Anahtar Kelimeler: Bilgisayar destekli tanı; Dental lezyon; Konik ışınli bilgisayarlı tomografi; Periapikal kist; Keratokistik odontojenik tümör; Hacimsel dokusal özellikler; Gürültü temizleme; Yarı otomatik bölütleme; Sınıflandırıcı; Dental görüntü veritabanı

PhD. Thesis

SUMMARY

SEMI AUTOMATIC SEGMENTATION AND CLASSIFICATION OF PERIAPICAL CSYT AND KERATOCYSTIC ODONTOGENIC TUMOR LESIONS

Ercüment YILMAZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Temel KAYIKÇIOĞLU
2018, 124 Pages

In recent years Cone-beam Computed Tomography (CBCT) imaging is frequently used for radiological examinations in the field of dentistry. In this thesis, studies on segmentation and classification of lesions of periapical cyst (PC) and keratocystic odontogenic tumor (KOT) in three dimensional (3D) CBCT images have been carried out and methods have been proposed. 50 CBCT 3D image dataset files have been employed as the dataset of the study. Experts have identified half of the data as periapical cyst (PC) and the other half as keratocystic odontogenic tumor (KCOT). The diagnosed lesions were used in experiments with specially developed software for this study. The lesional volumetric regions were manually segmented with the developed software tools to obtain a ground truth set. A noise removal approach has been proposed for the preprocessing step for removing noise detected in the CBCT images. A semi-automated segmentation approach has been proposed to accommodate the anatomical and internal variations of the lesions. Basic statistics and 3D Gray Level Co-Occurrence Matrix (GLCM) information were calculated from the segmented lesions and feature vector containing 636 feature information was obtained. Six different classifiers were used for classification experiments. As a result of classification experiments, PC and KCOT lesions can be detected and classified with great accuracy.

Key Words: Computer aided diagnosis; Dental lesion; Cone beam computed tomography; Periapical cyst; Keratocystic odontogenic tumor; Volumetric textural features; Noise removal; Semi-automatic segmentation; Classifier; Dental image database

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. KIBT çalışma prensibi ve görüntünün elde ediliş adımları [17].....	5
Şekil 2. Örnek bir KIBT görüntüsü	6
Şekil 3. Diş ve diş kökü bölgelerinin x-ışını soğurma farklılıkları [6].....	9
Şekil 4. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen radiküler kist	10
Şekil 5. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen rezidüel kist.....	11
Şekil 6. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen dentigeröz kist.....	12
Şekil 7. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen BKK	13
Şekil 8. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen KOT	15
Şekil 9. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen odontoma.....	16
Şekil 10. KDS için model geliştirme adımlarını gösteren akış diyagramı	26
Şekil 11. KDS çalışma prensibini gösteren akış diyagramı.....	27
Şekil 12. KODAK 9500 KIBT sistemi (a) KIBT cihazının genel görünümü (b) KIBT cihazının kontrol paneli.....	28
Şekil 13. KIBT cihazı ile elde edilen veriler (a) KIBT cihazından elde edilen 3B görüntü bilgilerinin DICOM standartlı iki boyutlu görüntü kesit dosyalarında saklanmış hali (b) DICOM verilerinden elde edilen anonimize edilmiş ve bölütlenmiş kist ve tümör lezyonlarından oluşturulan veritabanı	29
Şekil 14. Gürültü seviyesi kestirim metodunun akış şeması	31
Şekil 15. Bulanıklık seviyesi kestirim metodunun akış şeması.....	33
Şekil 16. Gürültü bilgisi içeren KIBT görüntü kesitlerine uygulanan AY filtreleme yönteminde bulanıklık seviyesi değerinin yinelemenin durdurulması için kullanımını gösteren akış şeması [73].....	37
Şekil 17. Geliştirilen görüntüleme yazılımının ekran görüntüsü.....	38
Şekil 18. (a) KIBT görüntüsünde 2B kesitte işaretlenmiş lezyon bölgesi (b) 2B düzlemler üzerindeki işaretlemeler sonucunda lezyonlu bölgeye karşılık gelen kesitlerin 3B gösterimi [75].....	39
Şekil 19. Rasgele yürüyüş bölütleme adımlarının gösterimi (a) <i>L1, L2, L3</i> etiketleri ile gösterilen başlangıç tohumlarının yerleştirildiği düzen (b) her bir düğüm için hesaplanan <i>L1</i> etiketli düğüme ulaşma olasılıkları (c) her bir düğüm için hesaplanan <i>L2</i> etiketli düğüme ulaşma olasılıkları (d) her bir düğüm için hesaplanan <i>L3</i> etiketli düğüme ulaşma olasılıkları (e) RY yöntemi ile elde edilen bölütleme sonucu.....	42
Şekil 20. Farklı algoritmaların sıralı bir düzende kullanılması ile elde edilen yarı otomatik bölütleme yöntemi işlem adımları [76].....	47

Şekil 21. Yarı otomatik lezyon bölütlemenin bir kesitte uygulanış adımları [76].	49
Şekil 22. KIBT görüntüsünde tespit edilen lezyon için mutlak doğru referans olarak kabul edilen manuel bölütleme sonucu (solda) ve yarı otomatik bölütleme yöntemi ile elde edilen 3B sonuç görsellerin karşılaştırması [76].	51
Şekil 23. 3B GSBGM'nin hesaplanmasında kullanılan 13 farklı yön vektörü [75].	54
Şekil 24. k-EYK yönteminde örnek bir veri noktasına en yakın komşuluk tespiti	56
Şekil 25. KA yöntemi ile örnek bir sınıflandırma	60
Şekil 26. Bir YSA örneği	63
Şekil 27. Örnek veri kümesi için DVM sınıflandırıcı ile elde edilebilecek olası ayırıcı hiperdüzlemler	66
Şekil 28. DVM'de maksimum marjlı hiperdüzlem örneği	67
Şekil 29. DVM'de yumuşak marj gösterimi	68
Şekil 30. DVM doğrusal ayrılamayan veriler (solda), çekirdek fonksiyonu uygulanan DVM sınıflandırma sonucunda elde edilen ayırıcı hiperdüzlem (sağda)	69
Şekil 31. 10-kat çapraz doğrulama yöntemi uygulaması	77
Şekil 32. Homojen, tek gri seviye (128) değerli 512x512 boyutundaki sentetik görüntü (solda), sentetik görüntüye $\sigma_g=5$ değerli gauss gürültüsü uygulaması sonucunda elde edilen çıktı ve tahmin edilen gürültü seviyesi $\sigma_n=4.9289$ (sağda)	81
Şekil 33. 512x512 boyutunda 0-256 aralığında 16 farklı gri seviye değerli sentetik dama tahtası görüntüsü (solda), sentetik görüntüye $\sigma_g=5$ değerli gauss gürültüsü uygulaması sonucunda elde edilen çıktı ve tahmin edilen gürültü seviyesi $\sigma_n=4.9458$ (sağda)	82
Şekil 34. KIBT ile elde edilen örnek bir görüntü kesiti (solda), $\sigma_g=10$ değerli gauss gürültüsü uygulaması sonucunda elde edilen çıktı ve tahmin edilen gürültü seviyesi $\sigma_n=10.0151$ (sağda)	83
Şekil 35. Manuel bölütleme aşaması görselleri. 2B kesitte işaretlenmemiş lezyonlu bölge (solda), işaretleme sonrası 2B görüntü kesiti (sağda) [76].	86
Şekil 36. Kullanılan veri kümesinde manuel bölütleme işlemleri sonucunda elde edilen lezyonlu bölgelerin 3B gösterimleri	87
Şekil 37. 10KÇD metodu ile 636 özniteliğin kullanıldığı ilk deney grubuna ait sonuçların gösterimi [75].	91
Şekil 38. 10KÇD metodu ile İDS yöntemi uygulanan ikinci deney grubuna ait sonuçların gösterimi [75].	92
Şekil 39. 2KÇD metodu ile 636 özniteliğin kullanıldığı üçüncü deney grubuna ait sonuçların gösterimi [75].	93
Şekil 40. 2KÇD metodu ile İDS yöntemi uygulanan dördüncü deney grubuna ait sonuçların gösterimi [75].	94
Şekil 41. BDBÇD metodu ile 636 özniteliğin kullanıldığı beşinci deney grubuna ait sonuçların gösterimi [75].	95

Şekil 42. BDBÇD metodu İDS yöntemi uygulanan altıncı deney grubuna ait sonuçların gösterimi [75].	96
Şekil 43. İDS yönteminin kullanıldığı deneylerde her bir sınıflandırıcı için seçilen özniteliklerin sayısı [75].	97
Şekil 44. KA sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznitelikleri gösteren saçılım grafikleri	98
Şekil 45. k-EYK sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznitelikleri gösteren saçılım grafikleri	98
Şekil 46. RO sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznitelikleri gösteren saçılım grafikleri	99
Şekil 47. NB sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznitelikleri gösteren saçılım grafikleri	99
Şekil 48. DVM sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznitelikleri gösteren saçılım grafikleri	100
Şekil 49. YSA sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznitelikleri gösteren saçılım grafikleri	100
Şekil 50. KIBT ile elde edilen öznitelik kümesinde Anova çekirdek fonksiyonlu TBA uygulama sonucu.	101
Şekil 51. TBA ile elde edilen öznitelik vektörünün kullanıldığı, bölünmüş örnek doğrulama sonuçları gösterimi	102
Şekil 52. TBA ile elde edilen öznitelik vektörünün kullanıldığı, bölünmüş örnek doğrulama sonuçları gösterimi	103
Şekil 53. KA sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özniteliklere ait saçılım grafiği	104
Şekil 54. k-EYK sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özniteliklere ait saçılım grafiği	104
Şekil 55. RO sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özniteliklere ait saçılım grafiği	105
Şekil 56. NB sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özniteliklere ait saçılım grafiği	105
Şekil 57. DVM sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özniteliklere ait saçılım grafiği	106
Şekil 58. YSA sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özniteliklere ait saçılım grafiği	106
Şekil 59. KDS sisteminde manuel ve yarı otomatik bölütleme ve sınıflandırma sonuçları gösterimi	107
Şekil 60. KDS sisteminde gürültülü KIBT verisi için manuel, yarı otomatik (gürültülü), yarı otomatik (gürültüsüz) bölütleme ve sınıflandırma sonuçları gösterimi	108

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Dental radyoloji ile ilgili gelişmeleri gösteren kronolojik olaylar listesi [6].....	2
Tablo 2. İnsan dokusunun 100keV X-ray ışınlarını soğurma katsayısı [16].....	4
Tablo 3. 512x512 ebatlı tek gri seviyeli görüntülere uygulanan gürültüler ve gürültü seviyesi kestirim sonuçları	82
Tablo 4. 512x512 ebatlı, 0-256 aralığında 16 gri seviye değerli sentetik dama tahtasına uygulanan gürültüler ve gürültü seviyesi kestirimi sonuçları	83
Tablo 5. KIBT ile elde edilen 10 farklı görüntü kesitlerine uygulana gürültü değerleri ve gürültü seviyesi kestirim yöntemi ile tahmin edilen gürültü seviyeleri	84
Tablo 6. 1200 KIBT görüntü kesitinde Gauss gürültüsü temizleme ile ilgili deneylerin sonuçları [72].	85
Tablo 7. 1200 KIBT görüntü kesitinde Poisson gürültüsü temizleme ile ilgili deneylerinin sonuçları [72].	85
Tablo 8. 50 KIBT görüntüsünde yarı otomatik lezyon bölütleme benzerlik karşılaştırmaları sonuçlarına ait ortalama performans değerleri	89
Tablo 9. İkili sınıflandırma için oluşturulan karışıklık matrisi.....	90
Tablo 10.Literatürde KIBT görüntülerinde lezyon bölütleme çalışmaları sonuçları ile tez çalışması sonuçları karşılaştırması	111
Tablo 11.Literatürde KIBT görüntülerinde lezyon sınıflandırma çalışmaları sonuçları ile tez çalışması sonuçları karşılaştırması	111

SEMBOLLER DİZİNİ

- 10KÇD :10-Kat Çapraz Doğrulama
2B : İki Boyutlu
2KÇD : 2-Kat Çapraz Doğrulama
3B : Üç Boyutlu
AA : Ayrıştırma Analizi
Ak-EYK: Ağırlıklı k-En Yakın Komşuluk
Ak-OK : Adaptif k-ortalama Kümeleme
AY : Anizotropik Yayılma
BBA : Beyin Bilgisayar Arayüzü
BDBÇD: Birini Dışarıda Bırak Çapraz Doğrulama
BKK : Basit Kemik Kisti
BÖD : Bölünmüş Örnek Doğrulama
BT : Bilgisayarlı Tomografi
CAD : Bilgisayar Destekli Tanı
ÇF : Çekirdek Fonksiyonu
DAA : Doğrusal Ayrıştırma Analizi
DSGO : Doruk Sinyal Gürültü Oranı
DVM : Destek Vektör Makinesi
FN : Yanlış Negatif
FP : Yanlış Pozitif
GSBGM: Gri Seviye Birlikte Görülme Matrisinin
İDS : İleri Doğru Seçim
KA : Karar Ağaçları
k-EYK : K-En Yakın Komşuluk
KDS : Karar Destek Sistemi
KHT : Kenar Histogram Tanımlayıcı
KKT : Karush-Kuhn-Tucker
KIBT : Konik Işınlı Bilgisayarlı Tomografi
KOT : Keratokistik Odontojenik Tümör
LDA : Lineer Diskriminant Analizi

LS	: Level Set
MHO	: Mutlak Hatalar Ortalaması
MRI	: Manyetik Rezonans Görüntüleme
NB	: Naive Bayes
OHK	: Ortalama Hataların Karesi
OMKH	: Optimal Marjlı Kanonik Hiperdüzlem
PET	: Pozitron-Emisyon Tomografisi
PK	: Periapikal Kist
PSD	: Spektral Güç Yoğunluğu
RO	: Rastgele Orman
ROI	: İlgilenilen Alan
RY	: Rasgele Yürüyüş
SD	: Sınıflandırma Doğruluğu
SPECT	: Tek Foton-Emisyon Tomografisi
TBA	: Temel Bileşen Analizi
TME	: Temporomandibular Eklem
TN	: Doğru Negatif
TP	: Doğru Pozitif
VC	: Vapnik-Chervonenkis
İHB	: İlgilenilen Hacimsel Bölge
WHO	: Dünya Sağlık Örgütü
YGAK	: Yerel Gauss Dağılımına Enerji Sağlayan Aktif Kontur
YSA	: Yapay Sinir Ağları

1. GENEL BİLGİLER

1.1. Giriş

Klinik diş hekimliğinde diş hastalıklarının tespit edilmesi ve tedavi edilmesi süreçlerinin ilk ve en önemli basamağı teşhis ve planlamadır. Dişler, çene kemikleri ve çevre dokulardaki hastalıkların tanımlanmasında radyolojik incelemelerin önemli bir payı bulunmaktadır. Diş hekimliğinin alt dallarından birisi olan Ağız, Diş ve Çene Radyolojisi ana bilim dalı, diş hastalıklarının teşhisi ve tedavilerinin planlanması ile ilgilidir. Oral Diagnoz ABD New York Columbia Üniversitesi'nde Dr. Daniel Ziskin tarafından 1930 yılında bir birim olarak kurulmuştur ve bu birim adı altında bilimsel çalışmalar yürütülmüştür [1].

Diş hastalıklarının teşhis edilmesi için oral muayenenin yanı sıra gözle görülemeyen bölgelerin incelenmesi için radyolojik tetkiklerin yapılması da çoğu zaman gerekli olmaktadır. Periapikal, panoramik (pantomografi) ve konik ışıklı bilgisayarlı tomografi (KIBT) görüntüleme yöntemlerinden faydalanılarak gözle görülemeyen bölgelerin görüntülerini elde etmek mümkündür [2]. Periapikal radyografiler bir veya birden çok diş kökünün olduğu bölgeyi konvansiyonel x-ışınları yardımı ile görüntüleyebilirken, pantomografi sayesinde bütün çene bölgesinin panoramik iki boyutlu (2B) görüntüsü oluşturulabilmektedir. Bu yöntemlerle elde edilen 2B görüntüler diş hekimine hastaya ait gözle göremedikleri alanları inceleme imkanı vermektedir.

Bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRI), pozitron-emisyon tomografisi (PET), tek foton-emisyon tomografisi (SPECT) vb. üç boyutlu (3B) görüntüleme yöntemleri ile elde edilen 3B veriler bilgisayar yardımı ile işlenerek 2B görüntülerden elde edilemeyecek derecede önemli ve hayati bilgilere ulaşmak mümkün olmuştur.

1990'lı yılların sonlarına doğru diş hekimliği alanında kullanılmaya başlanan KIBT teknolojisi ise boyun ve çene bölgesini 3B olarak görüntüleme imkanını sağlamaktadır [3]. KIBT görüntülerinden elde edilen derinlik ve hacim bilgileri lezyon vb. patolojilerin 3B olarak elde edilmesi, yüz ve çene bölgeleri travmalarının tespiti ve implant planlaması gibi uygulamalarda faydalı olmaktadır.

1.2. Dental Radyolojinin Tarihçesi

Wurzburg Üniversitesi fizik profesörü Wilhelm Conrad Roentgen, 8 Kasım 1895 tarihinde karartılmış bir odada x-ışınlarını keşfederek tıp tarihindeki önemli gelişmelerden birine imza atmış ve 1895’de yazdığı makalede [4] yeni radyasyonun özelliklerini anlatmıştır. Bu keşiften 15 gün sonra Alman diş hekimi Otto Walkhoff ilk dental görüntüleri almayı başarmış ve diş hekimliğinde radyolojinin temelini atmıştır. Diş hekimi Dr. Edmund Kells, Roentgen’in x-ışını buluşunun üzerinden 4 ay geçmeden x-ışınlarının diş ve çene radyografilerinde kullanımı üzerine araştırmaya yapmaya başlamış ve 1899 Ağustos ayında Dental Cosmos Dergisinde yayınladığı makalesinde [5] bu çalışmalarının sonuçlarını sunmuştur.

Tablo 1. Dental radyoloji ile ilgili gelişmeleri gösteren kronolojik olaylar listesi [6].

Yıl	Gelişme	Öncü / Üretici
1895	X-ışınlarının keşfi	W.C. Roentgen
1896	İlk dental radyograf	O. Walkhoff
1896	Amerika Birleşik Devletlerinde ilk dental radyograf (kafatası)	W.J. Morton
1896	Amerika Birleşik Devletlerinde ilk dental radyograf (canlı hasta)	C.E. Kells
1901	X-radyasyonu tehlikeleri ile ilgili ilk makale	W.H. Rollins
1904	İki eşit parçaya böler tekniğinin tanıtımı	W.A. Price
1913	İlk dental metin	H.R. Raper
1913	İlk ön sarılmış dental filmler	Eastman Kodak Company
1913	İlk x-ışını tüpü	W.D. Coolidge
1920	İlk makine yapımı film paketleri	Eastman Kodak Company
1923	İlk dental x-ışını makinesi	Victor X-Ray Corp, Chicago
1925	Isırma radyografisi tekniğinin tanıtımı	H.R. Raper
1933	Rotasyonlu panoramik konsepti önerildi	
1947	Uzun konik paralelleştirme tekniği tanıtımı	F.G. Fitzgerald
1948	Panoramik radyografinin kullanılmaya başlanması	
1955	D-speed filmin kullanıma sunulması	
1957	İlk değişken-kilovoltaj dental x-ray cihazı	General Electric
1978	Dental xeroradiography tanıtımı	
1981	E-speed filmin kullanıma sunulması	
1987	Ağız içi dijital radyografi tanıtımı	
1998	Konik ışınlı bilgisayarlı tomografi (KIBT) dental görüntüleme için kullanılmaya başlandı	
1999	Ağız ve maksillofasial radyoloji diş hekimliğinde bir uzmanlık haline geldi	
2000	F-speed filmin kullanıma sunulması	

1913’de Kodak firması ilk diş hekimliği röntgen filmini geliştirmiş ve 1920’de bunu geliştirerek makine üretimi ve paketlemesine geçmiştir. 1947’de Dr. Gordon Fitzgerald, x-ışını makinesi için uzun koniyi dizayn etmiş, 1960 yılında ise Panorex adı verilen ilk panoramik x-ışını makinesi piyasaya sürülmüştür [7]. Bu cihazlar aracılığı ile üst, alt çenenin ve tüm dişlerin tek film üzerinde gösterilebilmesi mümkün olmuştur.

Diş hekimliğinde kullanılan ağız içi ve ağız dışı radyografik projeksiyonların 2B olması nedeniyle büyütme, bozulma ve çakışma gibi problemler oluşmaktadır. 2B görüntülerde derinlik ve hacim kavramlarının da bulunmaması nedeniyle bu yöntemler ile tam verim elde etmek mümkün değildir. Radyolojik incelemelerden daha sağlıklı sonuçlar çıkartabilmek için 3B görüntüleme tekniklerinin kullanılması kaçınılmazdır. 3B KIBT’nin 1990’lı yıllarda geliştirilmesi ile diş hekimleri iki boyuttan üçüncü boyuta geçme şansı elde etmişlerdir [8,9].

1.3. Konik Işınlı Bilgisayarlı Tomografi

Konik ışın sistemleri, tek rotasyonda 3B veri elde etme olanağı sağlamaktadır [7]. KIBT kullanımını esnasında hastalar BT kullanımına göre 15 kat daha düşük radyasyon dozuna maruz kalmaktadırlar. KIBT’nin radyasyon dozu aynı zamanda panoramik radyografi kullanımındaki radyasyon dozu ile de eşittir. [10–12]. KIBT kullanımındaki bir diğer avantajı ise kısa bir zamanda (10-70 sn.) tarama işleminin tamamlanabilmesidir [13]. KIBT ile elde edilen görüntülerin yüksek çözünürlüklü olması sayesinde tanı kalitesi de artmaktadır [3].

KIBT kullanılarak gerçekleştirilen görüntüleme işlemlerinde hasta cihazın merkezinde konumlanarak bu kısımdaki çene ve baş tutucu ile sabitlenmektedir. Sistem sabitlenen hastanın etrafında 360° dönüş yapan x-ışını kaynağı ile aynı yönde hareket eden ters istikametteki dedektörden oluşmaktadır. Gerçekleştirilen dönüş esnasında x-ışınları kaynaktan konik ışın prensibi ile çıkararak hastaya ulaşmakta ve diğer taraftaki dedektör tarafından yakalanmaktadır.

Tomografi görüntüleme tekniğinde kaynaktan çıkan x-ışını homojen olmayan nesnelere geçerken zayıflayarak dedektöre ulaşmaktadır.

$$I = I_0 e^{-\mu x} \quad (1)$$

Yukarıdaki denklemde I nesnenin arkasındaki x-ışını parlaklık değeri, I_0 ise nesne olmadan dedektörde yakalanacak x-ışını parlaklık değeridir. Buradaki x , objeden geçerken x-ışınının kat ettiği mesafe, a ise kullanılan x-ışını enerjisi için malzemenin doğrusal zayıflama katsayısıdır.

İnsan bedeni gibi homojen olmayan nesnelere için x-ışını zayıflaması aşağıdaki denklemde gösterildiği şekilde ifade edilebilir [14].

$$I = I_0 e^{-\int a(x) dx} \quad (2)$$

Tıbbi uygulamalar için normal ve hastalıklı dokuların farklı emilim katsayıları olması çok önemlidir. Bununla birlikte, farklı yumuşak dokuların soğurma katsayıları çok küçük bir aralıkta yerleşmektedir. Homojen olmayan nesnelere x-ışını soğurma katsayıları Hounsfield skalasında [15] belirli değerler ile temsil edilirler.

Tablo 2. İnsan dokusunun 100keV x-ışınlarını soğurma katsayısı [16].


Materyal	Hounsfield biriminde soğurma katsayısı
su	0
hava	-1000
kemik	1086
kan	53
yağ	-61
beyin beyaz/gri	-4
göğüs dokusu	9
kas	41
yumuşak doku	51

Hounsfield skalasındaki zayıflama katsayıları aşağıdaki denklemde gösterildiği üzere su referans alınarak hesaplanır.

$$H_{doku} = \frac{\mu_{doku} - \mu_{su}}{\mu_{su}} \times 1000 \quad (3)$$

3B hacimli veri grubu oluşturmak için ileri teknoloji algoritmaları içeren yazılım programları kullanılmaktadır. KIBT prensibi hemen hemen 25 yıldır kullanımda olmasına

rağmen, sadece son zamanlarda ucuz x-ışını tüpü, yüksek kalitede dedektör sistemleri ve güçlü bilgisayarların gelişmesi ile kazanç sağlayıcı ve verimli sistemler haline gelmiştir.




Şekil 1. KIBT çalışma prensibi ve görüntünün elde edilış adımları [17].

1.4. Diş Hekimliğinde KIBT

KIBT'nin diş hekimliğinde kullanımı son yıllarda daha da yaygınlaşmıştır [18]. KIBT diş hekimliğinde çeşitli patolojilerin sınırlarının ve içeriklerinin tespitinde [13], çene ve yüz bölgesindeki travmaların ve kırıkların görüntülenmesinde, implant planlamalarında, sinüs incelemelerinde [19] vb. hastalıkların ve problemlerin tanımlanması ve tedavilerin planlanmasında etkin bir şekilde kullanılmaktadır. KIBT cihazları endodontide tedavi sonuçlarının değerlendirilmesinde [20], ortodontide kraniyofasiyal (baş ve yüz bölgesi) görüntüler üzerinde belirli kategorilerde bilgi sağlanmasında [21] veya verilerin bir veya

daha fazlasının bağımsız çözümünde [22,23] fayda sağlamaktadır. Bunlara ek olarak KIBT, çene-yüz cerrahisinde teşhis sırasında ve ameliyat öncesinde edinilmesi gereken görüntü bilgisinin sağlanmasında, ameliyat riski ve ameliyat sonrası komplikasyon oranı azaltılmasında [24], 3B kemik yapısı hakkında bire bir bilgi edinilmesi ve uygun bir yazılım kullanılarak implant planlamasının ideal olarak yapılabilmesi [25,26] vb. hususlarda önemli avantajlar sunmaktadır.

Hacimsel görüntüler sayesinde diş ve diş kökü çevresindeki anormalliklerin konumları ve boyutlarının tespiti kolaylaşmıştır. Görüntülerde gözlemlenen bir anormallik mevcutsa bu anormalliğin türüne hekim tarafından karar verilir. Bulgular bazen patolojik lezyon varlığına işaret ederken bazen de rastlanılan bölgede normal bir anatomik bulgu da mevcut olabilir. KIBT görüntüsünden elde edilen aksiyal, sagittal ve koronal düzlemler boyunca farklı açılardan yapılan incelemelerle hekimler bulgular hakkında daha kolay karar verebilmektedirler.



Şekil 2. Örnek bir KIBT görüntüsü

Tespit edilen anormallikler genellikle endodontik veya periapikal lezyonlar olarak ifade edilebilir. Endodontik lezyonlar çene kemiğinde enfeksiyona bağlı olarak gelişen patolojilerdir. Radyolojik incelemeler sonucunda gözlemlenen lezyonların özelliklerinin zamanında ve doğru anlaşılması durumunda verilecek tedavi kararlarına bağlı olarak ortaya

çıkan yıkımları tersine çevirmek mümkündür. Bu husus KIBT ve diğer radyolojik inceleme metodlarının önemini ortaya koymaktadır [7].

Tarama sonucunda elde edilen lezyonlar konumları, yayılımları, içerikleri ve çevre bölgelerdeki yapılara etkileri gibi özellikleri dikkate alınarak değerlendirilir [3]. Kimi lezyonların (ör. malignant tümör lezyonları) kansere dönüşme potansiyeli bulunmaktadır. Bu tür lezyonların erken teşhis edilmeleri hastalığın ilerlemesinin önüne geçilebilmesi ve ölüme varan sonuçların bertaraf edilebilmesi bakımından oldukça önemlidir [2].

1.4.1. Dental Lezyonlar

Dental lezyonlar diş ve dişleri çevreleyen anatomik yapılarda rastlanan patolojik anormallikler olarak ifade edilmektedir [7]. Lezyonlar dişlerdeki iltihaplardan, diş kökü ve çene bölgesinde oluşan travmalardan veya çene ve dişlerin gelişimleri esnasında oluşan deformasyonlar sebebiyle oluşabilmektedir. Dental lezyonların oluşumunda farklı sebepler aktif rol oynar. Bu sebeplerin arasında en çok rastlanılanı diş kök kanalı yolu ile gelişen iltihaba bağlı lezyonlardır. Lezyon oluşumunda ayrıca dişeti dokusundan yayılan veya dolaşım sistemi aracılığı ile yayılan iltihaplar da etkin olabilmektedir.

En sık görülen ve diş kök kanalı aracılığı ile yayılan lezyonların oluşumları diş çürümeleri ile başlamaktadır. Dişler dıştan içe doğru mine tabakası, dentin tabakası ve pulpa odası olarak adlandırılan bölümlerden oluşmaktadır. Mine tabakası dişin dışını çevreleyen sert bir tabakadır, bir alttaki dentin tabakası ise oldukça zayıf bir yapıdadır. Pulpa odası ise dişleri besleyen damar ve sinirlerin bulunduğu bir kanal olarak ifade edilebilir.

Diş çürümeleri sert mine tabakasında başlar ve çürümenin başlangıcında gerekli tedavinin uygulanması yaşanabilecek potansiyel sorunları önleyebilir. Tedavi edilmeyen diş çürükleri zayıf dentin tabakasını kolaylıkla geçerek pulpa odasına, yani sinir ve damarların yer aldığı kanala ulaşır. Bu kanalda yer alan damarlar ve sinirler çene kemiği ile bağlantılı olduklarından diş çürüğü sebebiyle oluşan yıkımdan geçecek her türlü bakteri ve mikroorganizma çene kemiğine kadar ilerleyerek nüfuz edebilir. Dişin kökü ve çene kemiğine yayılan mikroorganizmalar çoğalarak bu bölgelere yerleşir, kemik ve diş kökünde yıkıma sebep olurlar. Bu aşamada gerekli tedaviler uygulanmazsa hastalık komşu bölgelere ve dişlere doğru ilerler. Kimi zaman bu ilerleme kistik oluşumlara, kimi zaman alt çenede bulunan sinir kanalındaki sinirlerde tahribata, kimi zaman da üst çenede sinüs boşluklarına ve burun mukozasında yayılmaya kadar varabilir.

Bazı durumlarda ağız bakımının iyi yapılmaması sonucunda diş eti plakları oluşup ilerleyen durumlarda bu plaklar diş taşlarına dönüşebilmektedir. Bakterilerin diş taşlarına yerleşmeleri sonucu da diş eti enfeksiyonları gelişebilir ve tedavi edilmemeleri halinde kemiğe kadar ilerleyen enfeksiyon iltihaplarına, kemik yıkımına ve dolayısıyla da lezyon oluşumuna sebep olurlar.

Travmalar ve dişlere uygulanan orantısız kuvvetlerin yarattığı yıkımlar sonucunda da lezyonlar oluşabilmektedir. Diş kayıpları, çeneye ve dişlere alınan darbeler, diş sıkma ve dişlerle sert yabancı cisimleri çiğneme alışkanlıkları vb. sebeplerle oluşan kuvvetlerin meydana getirdiği yıkımlar lezyon gelişimine sebep olabilir.

Bazı lezyonların oluşma sebepleri de 20 yaş dişleridir. Süren dişlere ait gömük yapıların kemik içinde kalmaları sebebiyle oluşan lezyonlar kemiği eriterek kistlere dönüşebilme potansiyeline sahip olurlar.

1.4.2. Dental Lezyonların Radyografik Analizi

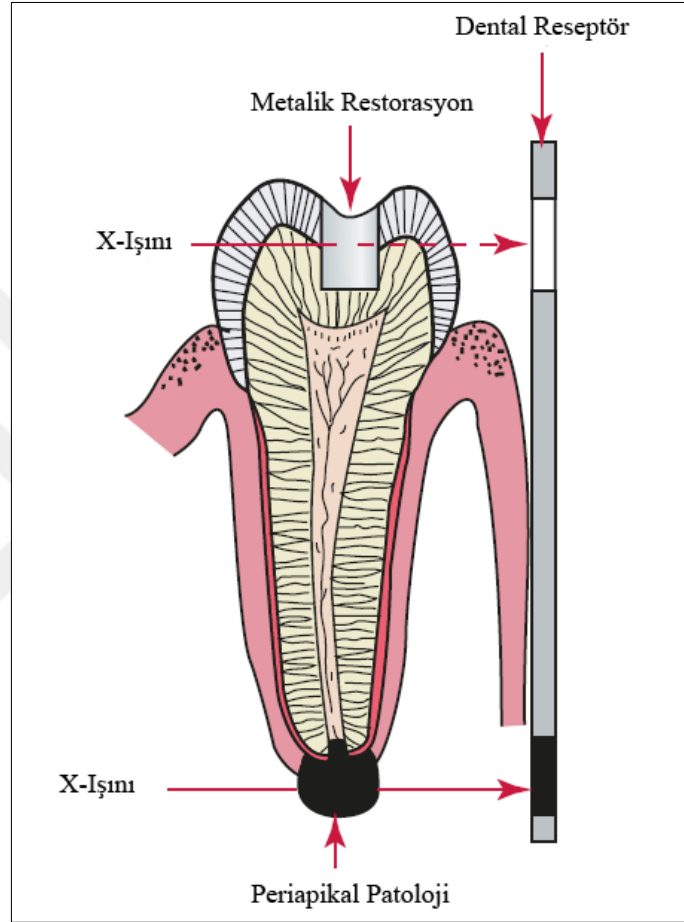
1.4.2.1. Radyolusent Lezyonlar

Radyolusent yapılar radyografi yöntemleri ile elde edilen diş görüntülerinde koyu veya siyah renk ile temsil edilen bölgeyi ifade etmektedir. Radyolusent bölgeler x-ışınının geçmesine izin veren, yoğunlukları olmayan veya çok az olan yapıları içerirler. Örneğin, diş çürükleri diş alanını çevreleyen yapılara göre daha az yoğundur ve kolayca x-ışını (Şekil 3) geçişine izin verirler. Bu nedenle diş çürüğü radyolusent görünür. Diğer radyolusent yapılar olarak hava boşlukları, yumuşak dokular, diş pulpası ve periodontal ligament alanı ifade edilebilir.

1.4.2.2. Radyopak Lezyonlar

Radyopak yapılar radyografi yöntemleri ile elde edilen diş görüntülerinde parlak veya beyaz renk ile temsil edilen bölgeyi ifade etmektedir. Radyopak bölgeler x-ışınının geçmesine izin vermeyen yüksek yoğunluklu yapıları içermektedir. Dişlere müdahale sonucu uygulanmış metalik bileşenler radyopak görünür. Mine, dentin ve kemikler de diğer radyopak yapılar arasında sayılabilir.

Radyolojik görüntüleme esnasında x-ışınları yoğun bölgeden geçerken tamamen soğurulur ve reseptör yüzeyde beyaz veya radyopak sonuç elde edilir. X-ışınları hacimsel olarak yıkılmış patolojik bölgelerden soğurulmadan geçer ve reseptörde karanlık ya da radyolusent sonuç elde edilir.



Şekil 3. Diş ve diş kökü bölgelerinin x-ışını soğurma farklılıkları [6].

1.4.3. Dental Lezyon Türleri


1.4.3.1. Odontojenik Kistler

Odontojenik kistler [27], içeriğinde sıvı bulunan, epitel ile kaplı, çevresi de bir bağ dokusu ile çevrili olan dental lezyon türleridir. Kist içindeki sıvı, astar hücreleri tarafından salgılanır veya lezyonu çevreleyen dokular tarafından üretilir. Bu tarz kistler Odontojenik tümör olarak adlandırılan kistlere göre 2,25 kat daha sıklıkla gözlemlenir [28]. Radyografik

olarak yıkıcı özelliğe sahip, iyi tanımlanmış kortikal (kabuksal) kenarlara sahip, yuvarlak veya hidrolik şekilli lezyonlar olarak görünürler.

1.4.3.1.1. Periapikal Kist (Radiküler Kist)

Periapikal kistler (PK) canlı olmayan bir dişin kökünde bulunan en yaygın odontojenik kist türü olup çene bölgesindeki kistlerinin yarısından fazlasını (yüzde 65-70) oluşturmaktadır [29]. Bu tarz kistler dişlerdeki çürükler veya travmaya bağlı olarak ikincil periapikal dokuların iltihaplanması sonucu gelişirler. Bu tarz lezyonlar radyolüsent görüntüye sahiptirler.



Şekil 4. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen radiküler kist


Büyük periapikal kistler kök rezorpsiyonuna (erime ve doku kaybı), çevre dokuların ve özellikle çene kemiklerinin bölgesel yer değiştirmesine ve genişlemesine sebep olabilir. PK lezyonların saptanması ve ortaya çıkan hasarın anlaşılmasında KIBT görüntüleri periapikal radyografi görüntülerine nazaran daha üstün olabilir. Literatürden elde edilen

sonuçlara göre, ağız içi periapikal radyografilere göre KIBT ile tespit edilebilen periapikal lezyon sayısı yüzde 25-60 daha fazladır [30,31]. Periapikal kistler çoğunlukla asemptomatik, yani belirti vermeyen lezyonlardır ve rutin radyografik muayeneler sonucunda tespit edilirler.

Periapikal kistler çoğu vakada kök kanal tedavisi uygulanarak, lezyonun çok büyük olduğu ve ilerlemiş vakalarda ise cerrahi müdahaleler ile tedavi edilebilirler.

1.4.3.1.2. Rezidüel Kist

Diş çıkarıldıktan sonra kalan radiküler kistler, “artık kist” olarak da ifade edilen rezidüel kist olarak adlandırılırlar.



Şekil 5. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen rezidüel kist

1.4.3.1.3. Dentigeröz Kist

Dentigeröz kistler, sürmemiş veya gömülü dişlerde rastlanan, kimi araştırmalara göre [32,33] çene kistlerinin yüzde 18-24’ünü oluşturan ikinci en yaygın odontojenik kist türüdür.

Bu kistler, diř kronu (diř tacı) ve epitel bileřenler arasındaki sıvı birikimi sonucunda diř köklerinin geniřlemesinden kaynaklanır. Dentigeröz kistlerin iliřkili olduđu diřlerin önemli ölçüde yer deęiřtirmesine neden olduđu bilinmektedir. Periapikal kistlere benzer olarak belirti vermeyen ve radyolojik incelemeler sonucunda genellikle maksiller kanin ve mandibular üçüncü molarlarda tespit edilen lezyonlardır.

Dentigeröz kist tedavisinde genellikle iliřkili diř cerrahi müdahale sonucu çıkarılır. Bu iřlem sonrası bu tür lezyonlar nadiren nüksederler.



řekil 6. KIBT'de aksiyal, sagittal ve koronal kesitlerde gözlemlenen dentigeröz kist


1.4.3.1.4. Lateral Periodontal Kist

Lateral periodontal kistler, diřlerin kökleri arasında kemik içerisinde meydana gelen nadir gelişen (<%1) kistlerdir. Kistlerin çođu gibi belirti vermez, rutin radyolojik muayenelerde gözlemlenen yuvarlak veya oval řekilli, sınırları net belli olan bir görüntü ile kendini belli eder. Bu türdeki kistler cerrahi müdahaleler ile çıkartılarak tedavi edilirler.

1.4.3.2. Odontojenik Olmayan Kistler

1.4.3.2.1. Basit Kemik Kisti

Basit kemik kisti (BKK) gerçek bir kist olmayıp, çenelerde gözlemlenen, bağ dokusu ile kaplanmış bir oyuktur. Çoğunlukla mandibular arka bölgede, genellikle yaşamın ikinci on yılında görülen bu lezyonlar, dişlerin kökleri arasında çok bağlı bir görünüm veren tarak şeklindeki oyuklar olarak görülür.



Şekil 7. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen BKK

1.4.3.2.2. İnsiziv Kanal Kisti

İnsiziv kanal kisti çoğunlukla diş kökünden daha yukarıdaki pulpaya giden kanalda veya anterior maksilladaki kanalda gözlemlenen, odontojenik olmayan kistlerin en yaygın

türlerindedir. Bu tür kistler, maksiller ön dişlerle ilişkili olarak periapikal bir radyolusens olarak görünebilirler. KIBT taramalarında bu kistlerin ortalama çapının erkeklerde daha büyük olma eğilimi ile yaklaşık 14 mm olduğu bildirilmiştir [34].

1.4.3.3. Odontojenik Tümörler


Odontojenik tümörler yavaş büyüyen, pürüzsüz ve iyi tanımlanmış görüntü sunan, bazen kortikal (kabuksal) sınırları olan dental lezyon türleridir. Kistlerden farklı olarak, bu lezyonlar menşe dokusuna bağlı olarak radyolus, karışık yoğunluk veya radyopak olabilir. Çevreleyen dokular üzerinde baskı uygularlar ve yer değiştirme, genişleme ve kök yıkımına neden olabilirler.

1.4.3.3.1. Ameloblastoma

Ameloblastomlar en sık karşılaşılan odontojenik neoplazmlar (anormal bir şekilde hızlı çoğalan hücreler) olup tipik olarak üçüncü molar bölgede posterior mandibulada, ilişkili foliküler kistler veya gömülü dişler ile ortaya çıkarlar. Karakteristik histopatolojik özellikleri ve sıklıkla lokal agresif davranışları ile iyi bilinmektedirler. Bu tarz genişlemiş olan ve radyolusent görüntü veren tümörler, bir “sabun köpüğü benzeri” görünümde, tek cepli veya çok cepli olabilirler. Bu tür lezyonlar, korteks boyunca çevredeki oral yumuşak dokulara uzanarak aşınmalara sebep olabilirler. Ameloblastomlar, bitişik dişlerin köklerinin önemli ölçüde erimesine neden olabilirler.

1.4.3.3.2. Keratokistik Odontojenik Tümör


Keratokistik odontojenik tümör (KOT) eskiden odontojenik kist olarak bilinen iyi huylu bir tümördür. Bu lezyon türü Dünya Sağlık Örgütü (WHO) tarafından epitel dokunun tümör benzeri karakteristik göstermesi sebebiyle çoklu kistik odontojenik tümör olarak sınıflandırılmıştır [35]. KOT içindeki epitel iyi huylu bir tümör ile uyumlu, doğal bir büyüme potansiyeline sahiptir. Büyüme mekanizmasındaki bu fark nedeniyle KOT kistleri farklı bir radyografik görünüm vermektedirler. KOT kistlerinin görülme sıklığı yüzde 5-17 arasında değişir. Bu türler en çok erkek hastalarda gözlemlenirler.



Şekil 8. KIBT’de aksiyal, sagital ve koronal kesitlerde gözlemlenen KOT

1.4.3.3.3. Odontoma

Odontoma, mandibulada en sık görülen odontojenik tümördür. Bu lezyonlar, dentin ve mine dahil olmak üzere çeşitli diş bileşenlerinden oluşmakta olup diş dokuları ile büyük benzerlik gösterirler ve anormal bir şekilde gelişirler. Bileşik bir odontoma, dişlere benzeyen küçük yapıların bir araya toplandığı bir kütle oluşturur. Karmaşık bir odontoma ise, düzensiz bir şekilde gelişen, kendine özgü bir biçimi olmayan bir kütle oluşturur.



Şekil 9. KIBT’de aksiyal, sagittal ve koronal kesitlerde gözlemlenen odontoma

1.5. Medikal Görüntü ve İşaret İşleme

Medikal görüntüleme ve işaret işleme alanında gerçekleştirilmekte olan çalışmaların sayısı gün be gün artmaktadır. Farklı disiplinlerde çeşitli hastalıklar ile ilgili yapılan bu çalışmalarda her geçen gün daha iyi sonuçlar elde edilmektedir. Çalışmaların önemli bir kısmı medikal bilgilerin sınıflandırılmaları hakkındadır ve üzerinde çalışılan hastalığın karakteristiğine bağlı olarak her çalışmada farklı bir yöntem tercih edilmektedir. İlgilenilen konuda bir sınıflandırıcı mekanizmasının oluşturulması için ilk adım elde edilen verilerden anlamlı öznitelikler çıkartılmasıdır. İncelenmekte olan medikal bilginin içeriğine bağlı olarak elde edilebilecek öznitelikler değişiklik gösterebilir. Örneğin beyin bilgisayar arayüzü (BBA) ile ilgili yapılmış bir çalışmada elde edilen sinyal verilerinde spektral güç yoğunluğu (PSD) tekniği ile elde edilen öznitelikler kullanışlı olabilir [36]. Retina görüntü bilgileri içeren bir veritabanında yapılan çalışmada görüntünün kalitesinin belirlenmesi için şekil, doku ve parlaklık bilgileri iyi bir sınıflandırıcı kurulabilmesi adına yeterli olabilir [37].

Lezyonların tespiti ve sınıflandırılması bilgisayarla görme alanında çözülmesi zor bir problem olarak karşımıza çıkmaktadır. Diğer anatomik yapılarda rastlanan lezyonların

tespiti ile ilgili çalışmalardan farklı olarak, dental bölgedeki anatomik yapıların çeşitlilik gösteriyor olması diş hekimliği alanında bilgisayarla görme uygulamalarını daha da zorlu hale getirmektedir.

1.6. Literatür Araştırması

Farklı türlerdeki medikal görüntüler ile yapılan çalışmalara kıyasla, çene ve diş görüntülerinde gerçekleştirilen çalışmaların sayısı oldukça sınırlıdır. Bu nedenle dental lezyonların bilgisayar destekli teşhisi ve sınıflandırılması ile ilgili literatürdeki çalışmaların sayısı da görece azdır [20,38–43].

KIBT'nin kullanımının yaygınlaşması ile beraber, son yıllarda bu cihazlar ile elde edilen görüntüler üzerinde indeksleme, veritabanı oluşturma, görüntü işleme, bölütleme, sınıflandırma vb. alanlara yönelik akademik çalışmalar gerçekleştirilmeye başlanmıştır.

Literatürde radyolojik yöntemlerle elde edilen görüntülerde periapikal lezyonların sınıflandırılması ile ilgili çalışmaların bir kısmı panoramik radyografi görüntüleri üzerinde uygulanmıştır. Bu alanda, KIBT görüntüleri ile yürütülen çalışmalar ile ilgili literatür henüz oluşum aşamasındadır.

Orthopantomogram görüntülerinde çene kemiği kisti ve Necrosis sınıflandırılması hakkında gerçekleştirilen çalışmada [39] karar ağaçları (KA), Naive Bayes (NB), yapay sinir ağı (YSA), k-En yakın komşuluk (k-NN), destek vektör makineleri (DVM) ve doğrusal diskriminant analizi (DDA) [44] gibi sınıflandırıcıların performansları ölçülmüştür. Bu çalışmada, 13 farklı görüntü içeren bir veritabanı kullanılmış olup KA, NB ve YSA sınıflandırıcıları ile gerçekleştirilen deneylerde en iyi performans değeri olarak ortalama %85'lik bir sınıflandırma doğruluğu elde edilmiştir.

Dental panoramik görüntülerde gerçekleştirilen bir çalışmada [45] ise tespit edilen lezyonların DVM kullanılarak kist veya tümör sınıflarına ayrılması ile ilgili deneyler gerçekleştirilmiştir. Çalışmada 133 farklı panoramik görüntüyü içeren veri kümesi kullanılmış olup verilerin 53'ü kist, 80'i ise tümör lezyonu olarak teşhis edilmiştir. Birinci seviye istatistikler, gri seviye birlikte görülme matrisi (GSBGM) ve Gray Level Run Length (GLRM) matrisinden elde edilen bilgiler kullanılarak lezyonlu bölgelere ait öznelik vektörü oluşturulmuştur. Çalışmanın sonucunda, en yüksek sınıflandırma doğruluğu %87.18 olarak elde edilmiş olup, eğri altındaki alan (AUC) değeri olarak da en yüksek 0.9444 performansına ulaşılmıştır.

2008 yılında yayınlanan bir makalede [46] 596 hastadan elde edilen 1014 görüntüde tespit edilen periapikal lezyonların ebatları ile ilgili bir indeksleme çalışmasından bahsedilmektedir. Görüntüler hem periapikal radyografi hem de KIBT cihazları ile ayrı ayrı elde edilmiştir. Hastalardan elde edilen lezyonlu bölgelerin çapları bir yazılımda yer alan ölçüm araçları kullanılarak ölçülmüş ve bulunan değerlere göre lezyonlar 0-6 değer aralığında puanlandırılmıştır. Gerçekleştirilen testler sonucunda, periapikal radyografi ile elde edilen görüntülerde lezyon tespit oranı %39 olurken, KIBT ile elde edilen görüntülerde lezyon tespit oranı %60.9 olarak bulunmuştur. Bu çalışmaya göre dental lezyonlar, 2B periapikal radyografiye kıyasla KIBT görüntülerinde daha etkili ve daha kolay bir şekilde tespit edilebilmektedir.

2009 yılında yürütülen başka bir çalışma [47] insan kadavrasına ait 6 çene kemiğinde oluşturulan yapay lezyonlar üzerinde gerçekleştirilmiştir. Bu lezyonların ağız içi radyolojisi (periapikal radyografi) ve KIBT görüntüleme yöntemleri ile tespiti ve elde edilen sonuçların hassasiyetinin belirlenmesi ana hedefi olarak belirlenmiştir. Çalışmanın sonucunda, KIBT ile elde edilen görüntülerin hassasiyeti %100 olarak tespit edilmiş olup bu hassasiyet periapikal radyografi görüntülerinde %24.8 olarak hesaplanmıştır.

2013 yılında KIBT görüntüleri ile elde edilen verilerin ne ölçüde doğru olduklarını belirlemeyi hedefleyen bir başka çalışma gerçekleştirilmiştir [48]. Bu çalışmada kadavralardan elde edilen 15 adet insan çene kemiği üzerinde birtakım işlem adımları sonucunda gözle görülebilir ve ölçülebilir ebatlarda periapikal lezyonlar, diş kökü kırıkları, kemik yıkımları, değişik çaplarda kemik lezyonları vb. problemliler yapılar yapay olarak üretilmiştir. Çene kemikleri düzgün parçalar halinde KIBT ile taranarak bu bölgelere ait 3B görüntü bilgisi, tıpta sayısal görüntüleme ve haberleşme (DICOM) formatındaki veri dosyalarına aktarılmıştır. Veriler Amira 5.4.3 yazılımında lokal eşik değeri belirleme algoritması kullanılarak ilgili konuda uzman bir doktor tarafından işaretlenmiş ve aynı yazılım aracılığı ile lezyonlu bölgelerin hacimsel verileri elde edilmiştir. Aynı bölgeler fiziksel olarak silikon benzeri bir materyalle doldurularak fiziksel şekli elde edilmiştir. Daha sonra ilgili bölgeden ayrılan bu materyalin hacminin su ölçüğü aracılığı ile hesaplanması ile yapay lezyonun hacim bilgisi elde edilmiştir. Ki kare testi uygulanarak yapılan analizlerde KIBT kullanılarak elde edilen hacimsel veri ile gerçek hacimsel ölçüm arasında $R^2=0.969$ 'luk bir regresyon katsayısı ortaya çıkmıştır. Bu çalışmaya göre KIBT ile elde edilen görüntü bilgilerinin yüksek oranda güvenilir olduğu ortaya çıkmıştır.

2006 yılında yürütülen benzer bir çalışmanın [49] sonucunda da KIBT ile elde edilen görüntülerden elde edilen veriler ile gerçek hacimsel veriler arasında yine %96'lık bir regresyon ortaya çıkmıştı.

Benzer bir çalışmada [50], diş çürüklerinin konvansiyonel radyografi, fosfor plak tarayıcı (fosfor plakalara çekilen görüntüyü lazerle okuyup bilgisayar ekranına aktaran cihaz) ve KIBT kullanılarak tespit edilmesi ve bu yöntemler aracılığı ile elde edilen sonuçların doğruluklarının karşılaştırılması hedeflenmiştir. Bu amaçla hastalardan elde edilen 72 adet çürük diş bahsi geçen görüntüleme sistemleri kullanılarak taranmıştır. Elde edilen sonuçlara göre azı dişlerindeki çürüklerin tespitinde her üç yöntem arasında istatistiksel farklılıklar bulunmaktadır. Buna karşı kesici dişlerdeki çürüklerin tespitinde her üç yöntem arasında belirgin istatistiksel farklılıklar söz konusu değildir. Çalışmadan elde edilen verilere göre KIBT'nin diş çürüklerinin tespitinde yardımcı bir yöntem olarak kullanılabilceğini, ancak tek başına çürük tespiti için daha hızlı uygulanıp sonuç alınabilen konvansiyonel radyografi tekniklerinin yeterli olacağı ifade edilmiştir.

Yapay lezyonlar üzerinde gerçekleştirilen benzer iki çalışmada [51,52] koyun çene kemiklerinde yapay olarak üretilen lezyonlu bölgelerin KIBT aracılığı ile görüntülenmesi ve Cavalieri yöntemi ile bu görüntülerdeki hastalıklı bölgelerin elde edilmesi hedeflenmiştir. Çalışmada ortaya çıkan 3B veriler değerlendirilmiş ve çıkan sonuçlara göre KIBT ile elde edilen hacim bilgisinin lezyonlu bölgelere ait gerçek hacimsel değerleri büyük doğrulukla karşıladığı ifade edilmiştir.

Bahsi geçen çalışmalar [47–52] bir arada değerlendirildiği takdirde, KIBT'nin diş yüzeyinde veya dişin sınırları içerisinde yer alan çürüklerin tespitinde kullanımının zaruri olmadığı, ancak; diş kökünden başlayarak çene kemiği üzerinde seyreden patolojilerin tespitinde kullanımının daha verimli sonuçlar doğuracağı bulgusu ortaya çıkmaktadır.

KIBT ile elde edilen görüntülerin doğruluk oranının yüksek olması sebebiyle özellikle son yıllarda hekimlerin bu görüntü bilgilerine dayanarak yürüttükleri teşhis ve tedavi planlamalarında bir artış gözlemlenmektedir. KIBT ile elde edilen görüntülerin mevcut yazılımların sunduğu imkanlar aracılığı ile hekimler tarafından işaretlenmesi ve hastalıklı bölgelerin tespit edilmesi oldukça zaman alıcıdır. Günümüzde medikal görüntüler üzerinde ilgilenilen bölgenin (ROI) otomatik veya yarı otomatik yöntemlerle daha kısa sürede işaretlenmesini hedefleyen yöntemler geliştirilmiştir. Bu yöntemlerin çoğunluğu sınırları büyük ölçüde belirli olan patolojik yapıların (lezyon, damar, diş, kemik vb.) tespit edilmesinde faydalı olmaktadır. Ancak; sınırları net olmayan patolojik yapıların tespitinde

probleme özel olarak farklı yöntemlerin birleşiminden elde edilen hibrit bölütleme yöntemleri daha iyi sonuçlar vermektedir.

2008 yılında 17 farklı KIBT görüntüsünde gözlemlenen apikal lezyonların bölütlenmesi hedefiyle farklı yöntemlerin performanslarının test edildiği bir çalışma gerçekleştirilmiştir [53]. Bu çalışmada Normalized Cut, Garph Cut, rastgele yürüyüş (RY) bölütleme yöntemleri kullanılmıştır. Deneyler sonucunda RY algoritması kenar algılamada diğer iki yöntem kadar başarı sağlayamamış ve bazı durumlarda bölütleme alanının dışına taşmalar gerçekleşmiştir. Buna rağmen RY, lezyon sınırını tamamını kapsayan, tümüyle kapalı bir lezyonun hacmini tutarlı bir şekilde bulabilirken, diğer iki yöntem tutarlı bir hacimsel bölge bulmakta başarısız olmuşlardır. Bu nedenle, eksiklerine rağmen RY yöntemi KIBT görüntülerindeki lezyonlu bölgeleri bölütleme deneylerinde en iyi performansı göstermiştir.

2009 yılında gerçekleştirilen bir diğer çalışma ise [38], 17 farklı hastaya ait KIBT görüntü kümesinde tespit edilen kist ve granülöm türündeki lezyonların bölütlenmesi ve sınıflandırılması deneyleri hakkındadır. Gerçekleştirilen çalışma iki aşamalı olup, ilk aşamada görüntülerde tespit edilen lezyonlar RY yöntemi ile otomatik bölütlenmişlerdir. Ardından bölütlenen hacimsel bölgelerden ortalama, entropi, minimum değer, medyan, maksimum değer, standart sapma, çarpıklık ve basıklık istatistikleri elde edilmiş ve bu değerler ile öznelik vektörleri oluşturulmuştur. Elde edilen öznelik vektörleri doğrusal DDA ve ADABOOST [54] sınıflandırıcıları ile test edilmiştir. Sınıflandırıcı performanslarının doğrulanması için birini dışarıda bırak çapraz doğrulama (BDBÇD) [55] yöntemi uygulanmıştır ve çalışmanın sonucunda %94.1'lik sınıflandırma doğruluğu değeri elde edilmiştir.

2016 yılında gerçekleştirilen bir çalışmada, KIBT görüntülerinde tespit edilen kist ve tümörlerin, otomatik bir yöntemle bölütlenmesi hedeflenmiştir. Yöntemin çalışma prensibine göre, ilk aşamada difüzyon filtreleme kullanılarak bir ön işlem adımı uygulanmaktadır. Bu işlemin ardından görüntüde simetrik eksen belirlenir ve her görüntü bu eksene göre iki parçaya ayrılır. İkinci aşamada, görüntünün sol parçasına ve sağ bölüme yansıyan kopyasına karşılık gelen piksellerin yer değişimini düzeltmek için serbest biçimli bir deformasyon uygulanır. Son aşamada ise yoğunluk farklılıkları analiz edilerek yanlış pozitif bölgeleri kaldırmak için bir dizi kısıtlama uygulanmıştır. Bu amaçla geliştirilen yöntemin performansı 97 farklı KIBT veri kümesi üzerinde gerçekleştirilen deneylerle test

edilmiştir. Deneylein sonucunda radiküler, dentigeröz ve KOT lezyonları için DICE katsayısı doğruluk değeri sırasıyla ortalama 0.83, 0.87 ve 0.80 olarak edilmiştir.

2017 yılında gerçekleştirilen bir diğeri çalışmada [42] çene bölgesinde tespit edilen lezyonların doğru sınıflara ayrılmasına yönelik bir yöntem önerilmiştir. Bu çalışmada yüzey ve doku bilgisine dayanan hibrit bir metodolojiden bahsedilmektedir. Üç aşamalı olan yöntemin ilk aşamasında her lezyon bir önceki çalışmada [41] önerilen yöntem ile bölütlenmiştir. İkinci aşamada Contourlet ve SPHARM katsayıları hesaplanmış, ve bu bilgiler doku ve şekil özelliklerini elde etmek için kullanılmıştır. Üçüncü adımda ise 96 hastaya ait, odontojenik kist ve KOT türlerinde lezyon tespit edilmiş KIBT görüntülerinden oluşan mutlak doğruluk (ground truth) veri kümesi sınıflandırma deneylerinde kullanılmıştır. Deneyler DVM ve sparse diskriminant analizi ile gerçekleştirilmiştir. Ortogonalize SPHARM öznelikleri kullanılarak elde edilen sınıflandırma doğruluğu %96.48 olarak elde edilmiştir.

Yakın geçmişte KOT kategorisine giren lezyonların, kistlerden ayrılmasına yönelik olarak bir başka çalışma [43] daha gerçekleştirilmiştir. Bu çalışmada KOT türündeki lezyonlara hatalı tanı koyulabildiğine vurgu yapılmıştır. Bu problemin gerekçesi olarak bazı durumlarda oluşan doku iltihabı sebebiyle lezyona ait tanımlayıcı kriterlerde gerçekleşen bilgi kayıpları gösterilmiştir. Bu tanısal ikileme karşı karşıya kalındığında, KOT lezyonlarının patofizyolojik karakterizasyonu için hacimsel analizin olası yararlarını belirlemek amacıyla deneyler gerçekleştirilmiştir. Deneylerde histopatolojik olarak doğrulanmış, toplam 114 hastadan elde edilen, 27 adet KOT ve 87 adet odontojenik kist türündeki lezyon bilgilerini içeren KIBT görüntüleri kullanılmıştır. Çalışmada ITK-SNAP uygulaması kullanılarak yarı otomatik bölütleme işlemleri gerçekleştirilmiş ve elde edilen sonuçlar değerlendirilmiştir. Hacimsel analizler sonucunda, KOT lezyonların neoplastik olmayan odontojenik çene kistlerinin ortalama büyüklüğünü önemli ölçüde aştığını ve bu sonuçların KOT'ların neoplastik doğası lehine bir farklılık ortaya koyduğu ifade edilmiştir.

Gerçekleştirilen bu çalışmalar ve kullanılan veriler ilgili problemlere özgü olup KIBT görüntülerinde dental lezyonların tespiti ve sınıflandırılması ile ilgili literatüre olumlu katkılar sağlamışlardır. Mevcut çalışmalarda kullanılan bölütleme yöntemleri ve sınıflandırma performansları kullanılan verilere özgü olarak değerlendirilmiştir. Medikal görüntüler üzerinde ilgilenilen bölgenin tespit edilmesi oldukça zorlu bir problemdir. İlgilenilen bölgenin elde edilmesi her görüntü ve her problemde farklı bir çözüm yöntemi kullanılmasını zorunlu kılmaktadır.

Her ne kadar önerilen yöntemler çalışmaya özgü veriler ile belirli oranda başarı sağlamış olsalar da farklı veriler ile elde edilecek sonuçların başarısı henüz test edilmemiştir. Örneğin, görüntüyü simetrik iki parçaya ayırarak üst üste yansıyan bu parçalara ait kopyaların karşılaştırılmasına dayalı olarak önerilen yöntemin [41] çene bölgesinin her iki tarafında da oluşabilecek lezyonların belirlenmesinde ortaya koyacağı performans ölçülmemiştir. Çene bölgesine ait anatomik yapının gösterdiği çeşitlilik ve patolojilerin gösterdiği varyasyonlar nedeniyle çözüme katkı sağlayan yöntemlerin eksik kaldıkları durumlar ortaya çıkabilir. Sonuç olarak, medikal cihazlar aracılığı ile elde edilen görüntüler üzerinde ilgilenilen bir bölgenin tespit edilmesine yönelik kullanılan her bir algoritmanın kendisine has özellikleri, avantajları ve dezavantajları bulunmaktadır [56–59].

1.7. Tezin Özgünlüğü

Bu tez kapsamında KIBT aracılığı ile elde edilen görüntülerde tespit edilen dental lezyonların bölütlenmesi ve sınıflandırılması problemlerinin çözümüne yönelik çalışmalar gerçekleştirilmiştir. Bu doğrultuda literatürdeki mevcut yöntemlerden farklı yaklaşımlar belirlenmiş ve uygulanmıştır. Literatür taramasında ifade edildiği üzere bu alanda sınırlı sayıda gerçekleştirilmiş çalışmaların her birinde o çalışmaya özgü bir veri kümesi kullanılmıştır. Bu tezde kullanılan veri kümesi Bölüm 2’de Materyal başlığında anlatıldığı şekilde bu çalışmaya özgü olarak elde edilmiş ve kullanılmıştır.

Literatürdeki diğer çalışmalardan farklı olarak tezde kullanılan veri kümesinden elde edilen 50 farklı KIBT görüntüsüne ait lezyonlu hacim bölgeleri ve öznitelik vektörleri anonimize edilmiş olarak <http://www.dentalimagedataset.com/database/dentalcbct001> adresinde sunulmuştur. Böylelikle bu çalışmaya ait veriler diğer araştırmacılar tarafından da kullanılacak şekilde erişime açılmış ve literatüre katkı olarak sunulmuştur.

Geçmiş bazı çalışmalarda [41] görüntülerdeki lezyonlu bölgelerin bölütlenmesi ve sınıflandırılması için gerçekleştirilecek işlemler öncesinde bir ön işlem adımının uygulanması tercih edilmiştir. Bu çalışmalarda ön işlem için tercih edilen difüzyon filtreleme yöntemi sonraki adımlarda işlenecek görüntüyü iyileştirmektedir. Difüzyon filtreleme gereğinden az uygulandığında görüntüde yeterli iyileştirme gerçekleşmemektedir. Difüzyon filtreleme gereğinden fazla uygulandığında ise görüntüde bulanıklık meydana gelmektedir. Bu etkiye bağlı olarak sonraki işlem adımlarındaki başarı düşmektedir.

Bu tez kapsamında gerçekleştirilen çalışmalarda difüzyon filtreleme yöntemi ile görüntüdeki gürültüleri en etkin şekilde temizleyecek bir yaklaşım önerilmiştir. Önerilen yaklaşım difüzyon filtrelemenin uygun bir ölçüm metriğine bağlı olarak yinelemeli olarak görüntüye uygulanmasını sağlamaktadır. Literatürdeki diğer uygulamalar ile karşılaştırıldığında önerilen yaklaşım en iyi performansı göstermektedir. Bu bağlamda bu tez çalışması kapsamında önerilen ön işleme yaklaşımı literatüre özgün bir katkı olarak sunulmuştur.

KIBT görüntülerinde gözlemlenen dental lezyonların bölütlenmesi için gerçekleştirilmiş olan çalışmalarda, ilgili çalışmaya özgü veriler üzerinde belirli oranlarda başarı sağlanmıştır. Bu tez kapsamında yürütülen çalışmalar ve gerçekleştirilen deneyler sonucunda KIBT görüntülerindeki lezyonları etkin bir şekilde bölütleyebilen yarı otomatik bir bölütleme yöntemi önerilmiş ve literatüre özgün bir katkı olarak sunulmuştur. Bu bölütleme yaklaşımı, literatürde mevcut bulunan bölütleme yöntemlerinin özelliklerinden faydalanan hibrit bir yöntem olarak önerilmiştir.

Bu tez kapsamında gerçekleştirilen çalışmaların en önemli hedefi, PK ve KOT lezyonlarının etkili bir şekilde sınıflandırılmasını sağlayacak doğru sınıflandırma modelinin belirlenmesine yöneliktir. Literatürde mevcut bulunan önceki çalışmalarda lezyonlu bölgelere ait bazı temel istatistikler hesaplanarak sınıflandırma modelleri için kullanılacak öznitelikler elde edilmiştir. Bu tezde kullanılan öznitelikler 3B lezyonlu bölgelere ait temel istatistik değerlerini kapsadığı gibi, 3B dokusal özniteliklerden oluşan, 624 farklı istatistik değerini de içermektedir. Toplamda 636 öznitelik değerinin yer aldığı çalışma kapsamındaki deneylerde öznitelik seçim yöntemlerinden faydalanılarak bu veriler içerisinde en uygun alt öznitelik kümeleri belirlenmiştir. Doğru sınıflandırma modelinin kurulabilmesi için 6 farklı sınıflandırıcı kullanılmış ve her bir sınıflandırıcı için farklı parametreler ve farklı doğrulama teknikleri denenerek olabilecek bütün varyasyonların uygulanması amaçlanmıştır. Gerçekleştirilen 8 farklı deney grubunda elde edilen modeller bu çalışmaya özgü verilerde yüksek başarı göstermiştir.

Tezin diğer özgün tarafı, çalışma özelinde geliştirilen görüntüleme yazılımı ve bu yazılıma ait bileşenlerdir. Nihai çıktı olarak elde edilen bu yazılım, KIBT görüntülerini inceleme, varsa mevcut gürültüleri temizleme, lezyonlu bölgeleri yarı otomatik bölütlenmesi, 3B lezyonlu bölgelere ait öznitelik çıkartma ve sınıflandırma yetenekleri ile donatılmıştır. Bahsi geçen özelliklerin tamamı tez çalışması kapsamında önerilen veya

uygulanan, çalışmaya özgün yöntemlerdir. Geliştirilen yazılım pratikte kullanıma hazır bir karar destek sistemi olarak özgün bir katkıya dönüşmüştür.

1.8. Tezin Kapsamı

Bu tez kapsamında KIBT ile elde edilen 3B görüntülerde tespit edilen dental lezyonların bölütlenmesi ve elde edilen çıktılara ait patolojilerin sınıflandırılması ile ilgili çalışmalar gerçekleştirilmiştir. Kullanılan veriler Karadeniz Teknik Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi kliniğine rutin kontroller için gelen 50 farklı hastadan alınan KIBT görüntü bilgilerini kapsamaktadır. İlgili veri kümesi hakkındaki detaylı bilgiler çalışmanın ikinci bölümünde Materyal başlığında sunulmuştur. İkinci bölümde Yöntem başlığının ilk kısmında, çalışmada kullanılan gürültü temizleme yöntemleri tanıtılmış (gürültü seviyesi kestirimi, bulanıklık seviyesi kestirimi, anizotropik yayılma) ve bu yöntemlerin parametrelerinden faydalanılarak kurgulanan gürültü temizleme yaklaşımı önerilmiştir. Yöntem başlığının diğer bir konusu olan ilgili hacimsel bölgenin (İHB) tespiti ve bölütlenmesi kısmında, kullanılan bölütleme algoritmaları (adaptif k-ortalama kümeleme, rasgele yürüyüş ve bölge tabanlı aktif kontur modeli) açıklanmış ve bu yöntemlerin birlikte uygulanması sonucu elde edilen hibrit yarı otomatik bölütleme yaklaşımı önerilmiştir. Yöntem başlığının son kısmında ise çalışmada kullanılan sınıflandırıcılar tanıtılmış ve sınıflandırma yaklaşımları, öznitelik çıkartma yöntemleri (düzey istatistikleri, 3B GSBGM), sınıflandırma yöntemleri, veri sınıflandırmada doğrulama teknikleri ve öznitelik seçim algoritmalarından detaylı olarak bahsedilmiştir.

Tezin üçüncü bölümünde, bu çalışma kapsamında kullanılan veri kümesi ile gerçekleştirilen deneylerden bahsedilmiştir. Üçüncü bölümün ilk kısmında KIBT görüntülerinde gürültü temizleme deneylerinden bahsedilmiş ve önerilen gürültü temizleme yaklaşımının performansı irdelenmiştir.

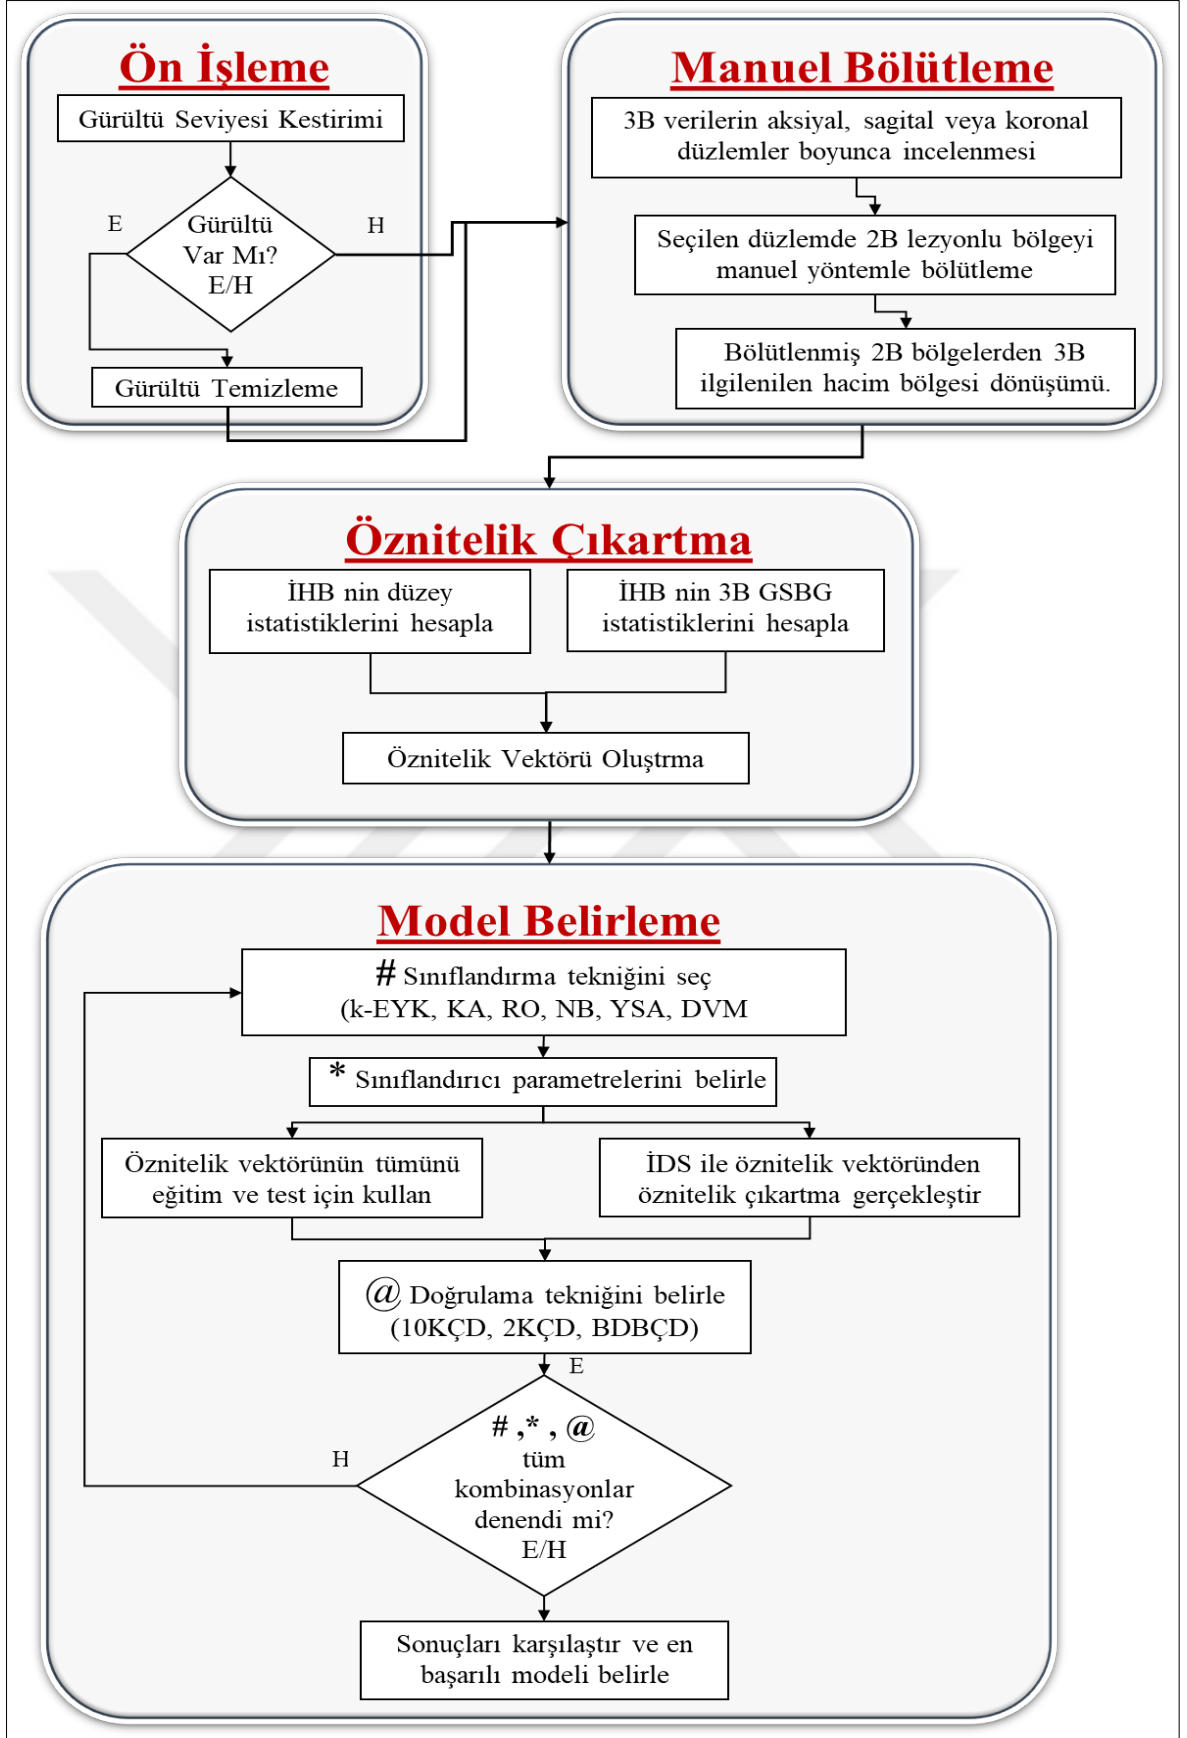
KIBT ile elde edilen görüntülerde tespit edilen dental lezyonları yüksek doğruluk oranı ile bölütleyebilecek uygun bir yöntemin belirlenmesi çalışmanın ana hedeflerinin arasındadır. Üçüncü bölümde lezyonlu bölgelerin manuel bölütlenmesi ile ilgili çalışmalardan bahsedilmiştir. Ardından, ikinci bölümde önerilen yarı otomatik bölütleme yöntemi kullanılarak veri kümesindeki lezyonlu bölgelerin tespit edilmesi hakkındaki deneyler ve deney çıktılarına ait performans sonuçları anlatılmıştır.

Çalışmanın ana hedefi olan, PK ve KOT türlerindeki lezyonlu görüntülerin sınıflandırılması ile ilgili deneyler de üçüncü bölümde anlatılmıştır. Farklı hastalara ait 25 adet PK ve 25 adet KOT türündeki dental lezyonların manuel bölütlenmeleri, elde edilen hacimsel bölgelerden çıkartılan 636 farklı öznitelik bilgisi ve 6 farklı sınıflandırıcı ile gerçekleştirilen deneyler bu kısımda anlatılmıştır. Deneylerin sonuçları ve en iyi performans gösteren DVM sınıflandırıcısı ile ilgili veriler bu bilgilerin devamında açıklanmıştır.

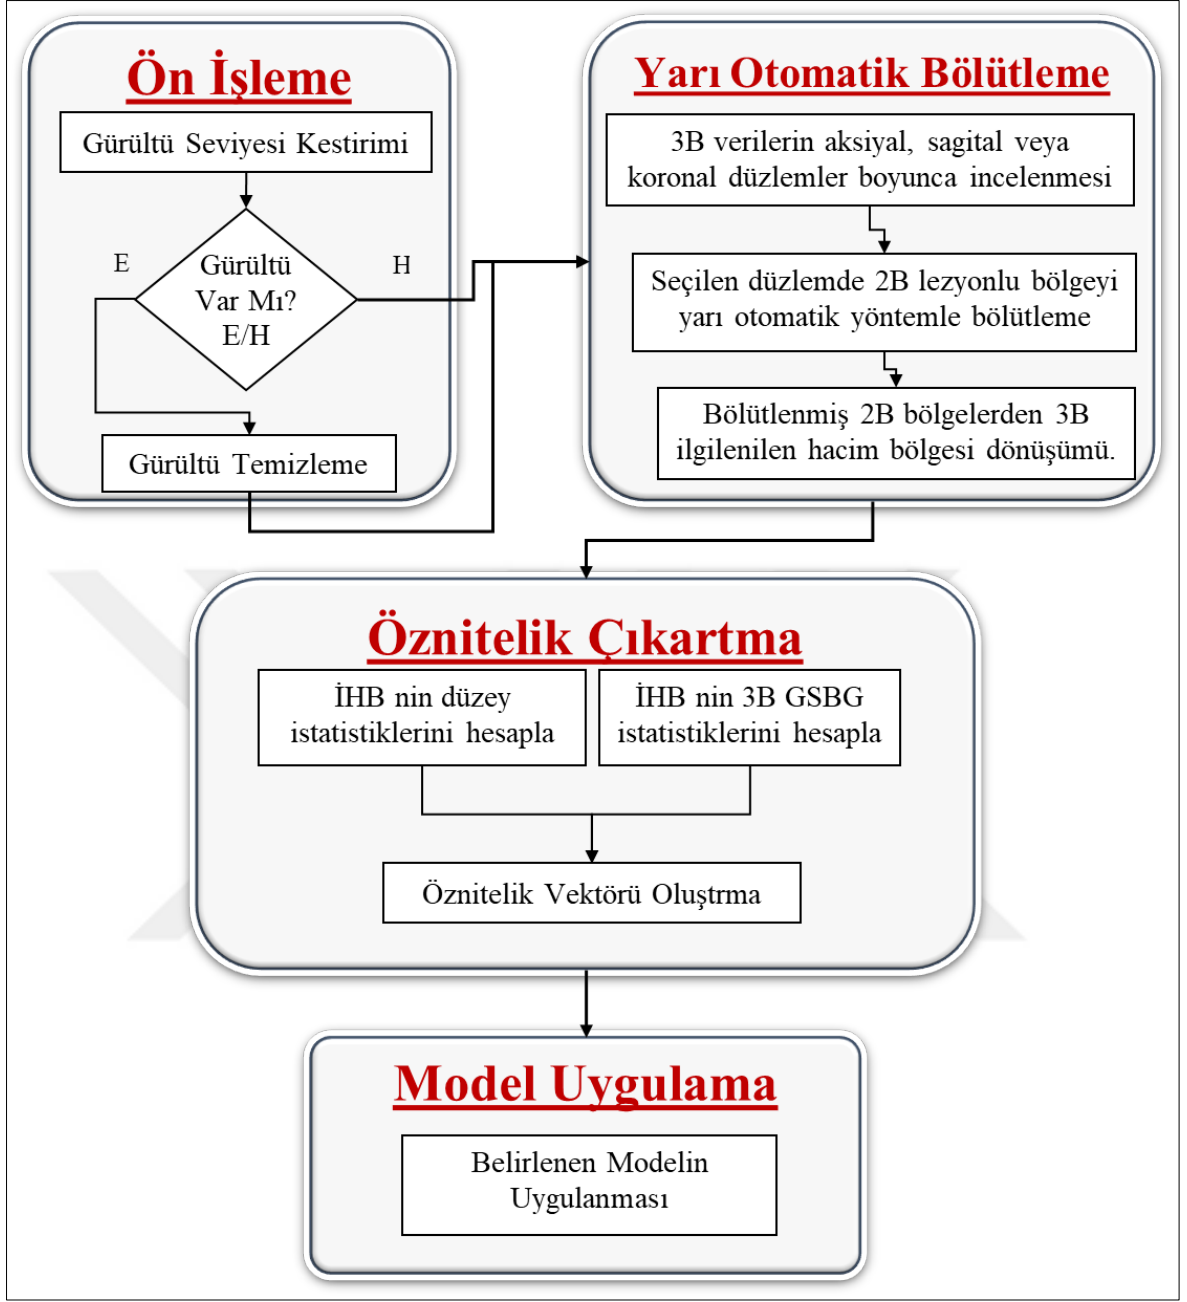
Üçüncü bölümün son kısmında ise önerilen sistemin bir bütün halinde çalışması sonucunda elde edilecek performans sonuçları irdelenmiştir. Geliştirilen yazılım aracılığı ile işlenen veriler yarı otomatik yöntemle bölütlenmiş, bu aşamada varsa mevcut gürültüler temizlenmiştir. Elde edilen bölütleme sonuçlarına ait her bir İHB'den öznitelikler çıkartılarak daha önceki deneylere göre en başarılı sonucu veren DVM ile sınıflandırılmıştır.

Tezin dördüncü bölümünde deneylere ait sonuçlardan bahsedilmekte olup beşinci bölümde ise öneriler ve tartışma başlığına yer verilmiştir.

KIBT görüntülerinde PK ve KOT türlerindeki dental lezyonların bilgisayar destekli tespiti ve analizi ile ilgili gerçekleştirilen bu çalışmanın model geliştirme aşamaları Şekil 10'da karar destek sistemine yönelik geliştirilen modelin uygulama aşamaları ise Şekil 11'de gösterilmiştir.



Şekil 10. KDS için model geliştirme adımlarını gösteren akış diyagramı




Şekil 11. KDS çalışma prensibini gösteren akış diyagramı

2. YAPILAN ÇALIŞMALAR

2.1. Materyal

2.1.1. Kullanılan KIBT Cihazı ve Oluşturulan Görüntü Veritabanı

Karadeniz Teknik Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Kliniği'ne rutin kontroller için gelen 50 farklı hastadan elde edilen KIBT görüntüleri çalışmanın veritabanını oluşturmaktadır. Görüntülerin tamamı KODAK 9500 KIBT cihazı ile elde edilmiştir.



Şekil 12. KODAK 9500 KIBT sistemi (a) KIBT cihazının genel görünümü (b) KIBT cihazının kontrol paneli

Veriler 3B veri kümeleri halinde DICOM standardında kayıt edilmiştir. 3B veri kümesini oluşturan her bir dosyadaki medikal görüntü bilgileri Hounsfield skalasında uygun veri aralıklarına dönüştürülerek çalışmada kullanılmıştır. Kullanılan veriler <http://www.dentalimagedataset.com/database/dentalcbct001> adresinde anonimize edilmiş haliyle erişime açılmıştır.

Ad	Değiştirme tarihi	Tür	Boyut
Analyses	20.12.2014 14:50	Dosya klasörü	
Captures	20.12.2014 14:50	Dosya klasörü	
3DSlice1.dcm	14.5.2014 09:53	DCM Dosyası	328 KB
3DSlice2.dcm	14.5.2014 09:53	DCM Dosyası	328 KB
3DSlice3.dcm	14.5.2014 09:53	DCM Dosyası	329 KB
3DSlice4.dcm	14.5.2014 09:53	DCM Dosyası	329 KB
3DSlice5.dcm	14.5.2014 09:53	DCM Dosyası	330 KB
3DSlice6.dcm	14.5.2014 09:53	DCM Dosyası	330 KB
3DSlice7.dcm	14.5.2014 09:53	DCM Dosyası	331 KB
3DSlice8.dcm	14.5.2014 09:53	DCM Dosyası	332 KB
3DSlice9.dcm	14.5.2014 09:53	DCM Dosyası	332 KB

(a)

Ad	Değiştirme tarihi	Tür	Boyut
Lesion01_cyst	9.12.2015 00:23	MATLAB Data	165 KB
Lesion02_cyst	9.12.2015 00:23	MATLAB Data	239 KB
Lesion03_cyst	9.12.2015 00:23	MATLAB Data	721 KB
Lesion04_tumor	9.12.2015 00:25	MATLAB Data	19.684 KB
Lesion05_cyst	9.12.2015 00:23	MATLAB Data	901 KB
Lesion06_cyst	9.12.2015 00:24	MATLAB Data	1.221 KB
Lesion07_tumor	9.12.2015 00:25	MATLAB Data	127 KB
Lesion08_cyst	9.12.2015 00:24	MATLAB Data	836 KB
Lesion09_cyst	9.12.2015 00:24	MATLAB Data	634 KB
Lesion10_cyst	9.12.2015 00:24	MATLAB Data	853 KB
Lesion11_tumor	9.12.2015 00:25	MATLAB Data	919 KB

(b)

Şekil 13. KIBT cihazı ile elde edilen veriler (a) KIBT cihazından elde edilen 3B görüntü bilgilerinin DICOM standartlı iki boyutlu görüntü kesit dosyalarında saklanmış hali (b) DICOM verilerinden elde edilen anonimize edilmiş ve bölütlenmiş kist ve tümör lezyonlarından oluşturulan veritabanı

2.2. Yöntem

2.2.1. KIBT Görüntülerinde İyileştirme İşlemleri

Radyolojik incelemelerden anlamlı sonuçlar çıkartabilmek için değerlendirilecek olan medikal görüntülerin net gözlemlenebilir ve gürültüden arındırılmış olması gereklidir. KIBT cihazları ile görüntü elde edilmesi işlemleri esnasında oluşan anormalliklerin ortadan kaldırılması sonucunda görüntüler iyileştirilecek ve böylece radyoloji uzmanlarının teşhis aşamasındaki incelemeleri kolaylaşacaktır.

KIBT taramaları sırasında yuvarlama hatalarından dolayı oluşan gürültüler, elektronik gürültüler veya foton kaybı ile ortaya çıkan gürültüler oluşabilmektedir [60]. BT görüntülerinden farklı olarak düşük doz kullanımı sebebiyle KIBT cihazı ile elde edilen görüntülerde gürültü oluşması olasılığı daha da yüksektir [2,60]. KIBT görüntülerinde doruk sinyal gürültü oranı (DSGO) BT görüntülerine göre çok daha düşüktür.

Literatürde KIBT cihazları kullanılarak edilen görüntülerde gürültü temizlenmesi ile ilgili gerçekleştirilmiş sınırlı sayıda çalışma bulunmaktadır [61–63].

Çeşitli gürültü temizleme algoritmaları ile KIBT veya farklı türdeki medikal görüntülerde oluşan istenmeyen anormalliklerin ortadan kaldırılması mümkündür. Seçilecek yöntem kullanılarak gerçekleştirilecek gürültü temizleme işleminin sonucunda orijinal görüntüdeki bilgilerin olabildiğince muhafaza edilmesi beklenmektedir. Bilgi kaybını engellemek için en uygun filtreleme yöntemi tercih edilmelidir. Böylece, tanı işlemleri

esnasında radyoloji uzmanları ön işlemden geçirilmiş görüntülerde en uygun yöntemi kullanarak ilgilenen bölgeyi daha net bir şekilde tespit edebilirler.

2.2.1.1. Gürültü Seviyesi Kestirimi

KIBT görüntülerinde gürültü temizleme yöntemlerini test etmeden önce mevcut verilerde gürültü olup olmadığını belirlemek gerekecektir. Bu nedenle KIBT görüntülerinde gürültü seviyesini ölçmek amacıyla parça tabanlı bir gürültü seviyesi kestirim metodu kullanılacaktır [64].

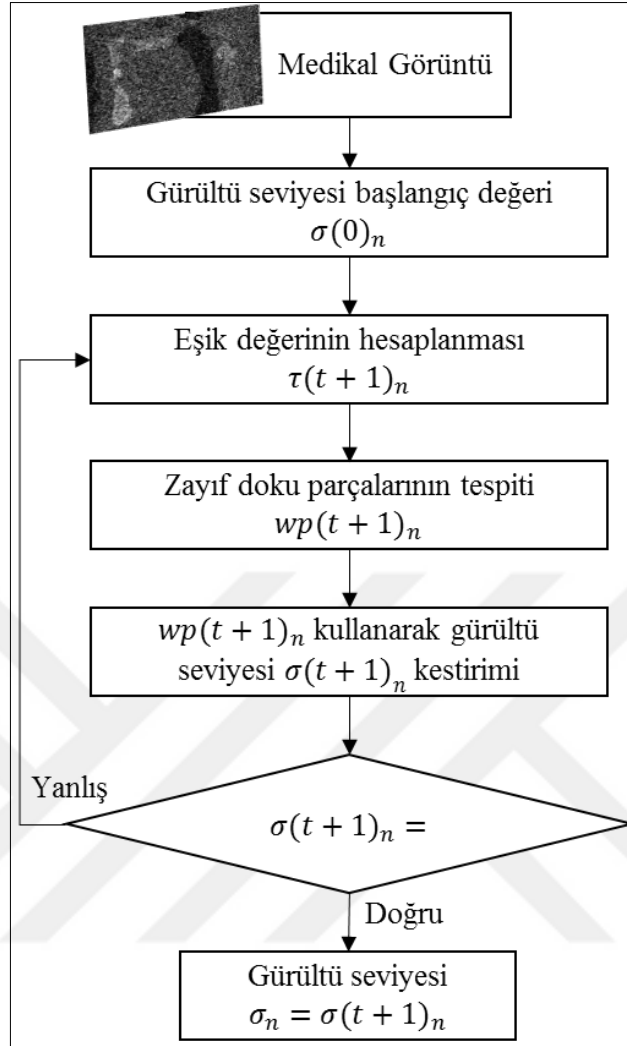
Görüntüdeki zayıf doku parçalarının seçilmesi işlemi oldukça zordur. Literatürde yer alan bu yöntem ile görüntülerdeki zayıf doku parçaları, bu parçalara ait gradyan değerleri ve bu parçalara ait istatistiklerden yararlanılarak tespit edilebilmektedir. Görüntünün sadece zayıf doku parçaları içermesi durumunda, bu parçalara ait bilgilerin temel bileşenler analizi (TBA) kullanılarak işlenmesi sonucunda gürültü seviyesinin kestirilmesi mümkündür.

Gürültü seviyesi kestirim metodu yinelemeli bir düzende çalışmaktadır. Zayıf doku parçaları her tekrarlama da belirlenen bir eşik değere bağlı olarak tespit edilmektedir. Bunun için başlangıçta test edilen doku bölgesinin beyaz Gauss gürültüsüne sahip olduğu varsayılır. Bu varsayım doku gölgesinin gradyan kovaryans matrisinin maksimum özdeğerinin belirlenen bir eşik değerden daha küçük olması durumunda kabul edilecektir. Kabul edilen parça otomatik olarak seçilecektir. Eşik değeri olan τ değeri aşağıdaki denklemde gösterildiği gibi hesaplanmaktadır.

$$\tau = \sigma_n^2 F^{-1} \left(\delta, \frac{N}{2}, \frac{2}{N} \text{tr}(\mathbf{D}_h^T \mathbf{D}_h) \right) \quad (4)$$

Denklemden, δ verilen anlamlılık düzeyini, σ_n n inci yinelemede hesaplanan gürültü seviyesini, $F^{-1}(\delta, \alpha, \beta)$ ters gama kümülatif dağılım fonksiyonunu, α şekil parametresi ve β ise ölçeklendirme parametresini temsil etmektedir.

Gürültü seviyesi kestirim metodunun akış diyagramı Şekil 14'de gösterilmiştir.



Şekil 14. Gürültü seviyesi kestirim metodunun akış şeması

2.2.1.2. Bulanıklık Seviyesi Kestirimi

Tıbbi görüntülerde önemli detayları (kenarları, farklı bölgeler, vs.) korumak için oluşabilecek bulanıklardan kaçınmak gerekmektedir. Bulanıklık düzeyi tahmini yöntemi ile tıbbi görüntüde gerçekleştirilecek filtreleme işlemleri sonucunda elde edilen çıktının bulanıklık düzeyi hesaplanabilir.

Tercih edilen bulanıklık düzeyi tahmini yöntemi [65] bulanıklık düzeyinin hesaplanacağı referans görüntüyü girdi olarak kullanarak işlem adımlarını başlatır. Yöntemin ilk aşamasında referans görüntüye bulanıklık efekti uygulanır. Ardından referans görüntü ile bu görüntünün bulanık versiyonuna alçak geçiren filtreleme işlemleri ayrı ayrı uygulanır. Bir sonraki adımda elde edilen çıktılarda her iki görüntünün komşu piksellerdeki

parlaklık deęişimleri hesaplanır. Bu iki farklı parlaklık deęişimlerinin karşılaştırılması sonucunda başvuru görüntünün bulanıklık seviyesi belirlenir.

Bulanıklık düzeyi tahmini yönteminde I olarak tanımlanan bir görüntü girdi olarak kullanılır. İlk olarak giriş görüntüsünün B olarak ifade edilen bulanık versiyonu üretilir. Denklem (5) ve Denklem (6)'da belirtildięi gibi dikey ve yatay alçak geçiren filtreler kullanarak B_{Ver} ve B_{Hor} deęerleri hesaplanır.

$$h_v = \frac{1}{9} [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] \quad B_{Ver} = h_v \times I \quad (5)$$

$$h_h = h_v^T \quad B_{Hor} = h_h \times I \quad (6)$$

Bir sonraki adımda I ve B olarak temsil edilen her iki görüntüdeki mutlak farklar hesaplanır. Bu amaçla $D_{R_{Ver}}$, $D_{I_{Ver}}$, $D_{B_{Ver}}$, $D_{I_{Hor}}$, ve $D_{B_{Hor}}$ deęerleri Denklem 7 ve Denklem 8' de gösterildięi şekilde hesaplanır. Her iki denklemde R ifadesi yerine I ve B koyularak görüntü ve bulanık versiyonu için gerekli hesaplamalar gerçekleştirilebilir.

$$D_{R_{Ver}}(i, j) = Abs(R(i, j) - R(i-1, j)) \quad i = 1:m-1, \quad j = 0:n-1 \quad (7)$$

$$D_{R_{Hor}}(i, j) = Abs(R(i, j) - R(i, j-1)) \quad j = 1:n-1, \quad i = 0:m-1 \quad (8)$$

Komşu pikseller arasındaki yoğunluk deęişimleri Denklem 9 ve Denklem 10 ile hesaplanır.

$$V_{Ver} = Max(0, D_{I_{Ver}}(i, j) - D_{B_{Ver}}(i, j)) \quad i = 1:m-1, \quad j = 1:n-1 \quad (9)$$

$$V_{Hor} = Max(0, D_{I_{Hor}}(i, j) - D_{B_{Hor}}(i, j)) \quad i = 1:m-1, \quad j = 1:n-1 \quad (10)$$

Görüntülerin varyasyonlarını karşılaştırmak için katsayılar toplamı Denklem 11'de gösterildięi şekilde hesaplanır. Denklemde $s_{I_{Ver}}$, $s_{I_{Hor}}$, $s_{B_{Ver}}$, ve $s_{B_{Hor}}$ ifadelerinin yerine s_R ifadesi kullanılmıştır. Ayrıca, $D_{R_{Ver}}$, $D_{I_{Ver}}$, $D_{B_{Ver}}$, $D_{I_{Hor}}$, ve $D_{B_{Hor}}$ ifadelerinin yerine de D_R ifadesi kullanılmıştır.

$$s_{-}R = \sum_{i,j=1}^{m-1,n-1} D_{-}R(i, j) \quad (11)$$


Bir sonraki adımda, Denklem 12 ve Denklem 13 uyarınca, yatay ve dikey bulanıklık seviyeleri 0 ile 1 aralığına normalize edilerek hesaplanır.

$$bI_{Ver} = \frac{s_{-}I_{Ver} - s_{-}V_{Ver}}{s_{-}I_{Ver}} \quad (12)$$

$$bI_{Hor} = \frac{s_{-}I_{Hor} - s_{-}V_{Hor}}{s_{-}I_{Hor}} \quad (13)$$

Son adımda bulanıklık seviyesi, Denklem 14'e göre daha önceki adımda hesaplanmış olan dikey veya yatay bulanıklık düzeylerinin en büyük değeri olarak bulunur.

$$blevel_I = Max(bI_{Ver}, bI_{Hor}) \quad (14)$$



Şekil 15. Bulanıklık seviyesi kestirim metodunun akış şeması

2.2.1.3. Anizotropik Yayılma

Anizotropik yayılma (AY) [66] Perona ve Malik tarafından önerilmiş olup, gürültü bilgisi içeren görüntünün yayılma denkleminin başlangıç değeri olarak verilerek ısı denkleminin yinelemeli olarak çözülmesi prensibine dayalıdır. Denklemin çözümü sonucunda çıkış görüntüsü üretilmektedir [67]. Yöntemi ifade eden temel gösterim aşağıdaki denklemde ifade edilmiştir.

$$\frac{\partial}{\partial t} nI(x, y, t) = \text{div} \left[g(\|\nabla nI(x, y, t)\|) \nabla nI(x, y, t) \right] \quad (15)$$

Denklemde t zaman parametresi, $I(x, y, 0)$ orijinal görüntü, $\nabla I(x, y, t)$ görüntünün t zamanındaki gradyan versiyonu, $g(\cdot)$ ise sözde iletkenlik fonksiyonudur. Bu fonksiyon $\lim_{x \rightarrow \infty} g(x) = 1$ eşitliğini sağlayacak şekilde seçilmektedir. Bu sebepten ötürü yayılma tek düze bölgeler arasında maksimum olurken, kenar bölgelere gelindiğinde $\lim_{x \rightarrow \infty} g(x) = 0$ olur ve yayılma durur.

Perona ve Malik tarafından bu eşitlikte $g(x)$ ifadesinin yerine kullanılmak üzere iki fonksiyon tanımlanmıştır. Bahsi geçen fonksiyonlar Denklem 16 ve Denklem 17’de verilmiştir.

$$g_1(x) = \exp \left[- \left(\frac{x}{K} \right)^2 \right] \quad (16)$$

$$g_2(x) = \frac{1}{1 + \left(\frac{x}{K} \right)^2} \quad (17)$$

Her iki denklemde K yayılma oranını kontrol eden yayılma parametresi olup gürültülü veya kenar atfedilen görüntü gradyanları arasında yumuşak bir eşik işlevi görmektedir.

Perona ve Malik AY algoritmasını Denklem 18’ deki gibi ayrıklaştırmışlardır.

$$I_{t+1}(s) = nI_t(s) + \frac{\lambda}{|n_s|} \sum_{p \in \eta_s} g_k \left(\left| \nabla nI_{s,p} \right| \right) \nabla nI_{s,p} \quad (18)$$

2.2.1.4. AY Denkleminde Yinelemenin Durdurulması

Bir önceki çalışmamızda [68], KIBT görüntülerinde meydana gelebilecek gürültüleri temizlemek için belirlenen dört farklı yöntem arasında deneysel bir karşılaştırma gerçekleştirilmiştir. Deneysel bu tez kapsamında kullanılan KIBT cihazı ile 30 farklı hastadan elde edilen 300 farklı görüntü kesitlerine değişik seviyelerde gürültü bilgisi eklenmiştir. Çalışmanın sonucuna göre AY metodunun [66] gürültü bilgisi içeren KIBT görüntülerinin iyileştirilmesinde daha başarılı olduğu ifade edilmiştir [69–71].

Geleneksel AY filtreleme kullanılarak gürültü temizleme işlemi uygulanırken yineleme durdurma problemi ile karşılaşılmaktadır. Yineleme uygulanarak gerçekleştirilen AY işleminin gürültülü KIBT görüntülerine uygulanması sırasında yinelemeyi durdurmak için bulanıklık metriğinden [65] faydalanılabilir.

Bu doğrultuda yinelemeyi durduracak uygun parametreyi tespit etmek amacıyla KIBT görüntülerinde ön deneyler gerçekleştirilmiştir. Deneyin ilk aşamasında KIBT ile 30 farklı hastadan elde edilen 30 farklı 2B görüntü kesitine değişik seviyelerde Gauss, benek, tuz ve biber gürültüleri eklenmiştir. Daha sonra bu görüntü kesitlerine yinelemeli olarak AY filtresi uygulanmıştır. Her yineleme adımında elde edilen çıktının doruk sinyal gürültü oranı (DSGO) [72], mutlak hatalar ortalaması (MHO) ve bulanıklık seviyesi ($blevel_1$) ölçülmüştür.

DSGO ve MHO değerlerine ait hesaplamalar Denklem 19 ve Denklem 20'de gösterilmiştir.

$$OHK = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - dI(i, j)]^2 \quad (19)$$

$$DSGO = 10 \log_{10} \left(\frac{MAX_I^2}{OHK} \right) \quad (20)$$

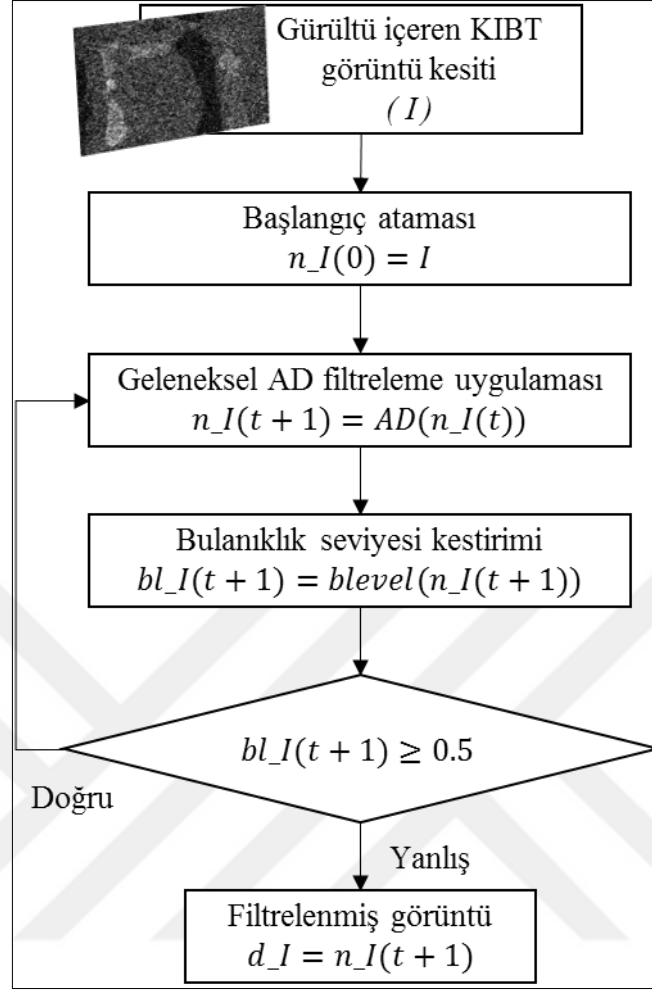
Ortalama hataların karesi (OHK) değerinin hesaplandığı Denklem 19'da, I gürültü içermeyen orijinal görüntü kesitini, dI aynı görüntünün gürültü eklenmiş versiyonunu ifade etmektedir. DSGO değeri, gürültü içermeyen görüntü kesitlerinin maksimum değeri olan MAX_I ve bir önceki hesaplamada bulunan MHO değeri kullanılarak Denklem 20'de gösterildiği şekilde hesaplanır.

MHO değerinin hesaplandığı Denklem 21’de, Iv ile dIv değerleri I ve dI görüntü matrislerinin vektörleştirilmiş versiyonlarını ifade etmektedir. Denklemde n değişkeni bu vektörlerden herhangi birinde bulunan eleman sayısını belirtmektedir.

$$MHO = \frac{1}{n} \sum_{i=1}^n |Iv_i - dIv_i| \quad (21)$$

Gürültü eklenmiş görüntülere AY fitresinin uygulanmasının ardından her yinelemede elde edilen çıktılar gürültü bilgisi içermeyen orijinal görüntüler ile karşılaştırılmıştır. Bu karşılaştırmalar sonucunda, DSGO değerinin en büyük olduğu veya MHO değerinin en küçük olduğu durumlarda filtreleme işleminin sonlandırılması gerektiği iddia edilmektedir. Ayrıca, her yineleme sonucunda hesaplanacak olan bulanıklık seviyesi ile DSGO ve MHO değerleri arasında bir korelasyon kurulması amaçlanmıştır. Gerçekleştirilen ön deneylerin çıktılarının karşılaştırılması sonucunda, en büyük DSGO değerleri ortalamasının deneylerden elde edilen tüm bulanıklık seviyesi puanlarının ortalaması olan 0.512 değeri ile korelasyona sahip olduğu tespit edilmiştir. Benzer şekilde, en küçük MHO değerlerinin ortalaması ile 0.499 bulanıklık seviyesi ortalama değerinin bir korelasyona sahip olduğu da belirlenmiştir. Bu sonuçlara uygun olarak, AY filtreleme işlemlerinde yinelemenin durdurulması için kullanılacak en uygun bulanıklık seviyesi değeri 0.5 olarak belirlenmiştir.

Gerçekleştirilen ön çalışmalara göre [73] AY filtreleme yönteminin gürültü bilgisi içeren görüntülerde uygulanışını gösteren akış diyagramı Şekil 16’de verilmiştir.



Şekil 16. Gürültü bilgisi içeren KIBT görüntü kesitlerine uygulanan AY filtreleme yönteminde bulanıklık seviyesi değerinin yinelenen durdurulması için kullanımını gösteren akış şeması [73].


2.2.2. İlgilenilen Hacimsel Bölgenin Tespiti ve Bölütlenmesi

KIBT'nin kullanımı yaygınlaştıkça, bu cihaz ile elde edilen görüntülerde teşhis ve planlama işlemlerinin gerçekleştirilebilmesi için uygun bilgisayar yazılımlarının kullanımına ihtiyaç duyulmaya başlanmıştır. Bu tür yazılımlar çoğunlukla ilgili cihazı üreten firma tarafından geliştirilerek hekimlerin ve uzmanların kullanımına sunulmaktadır. Hekimler ve uzmanlar ilgili yazılımlar sayesinde KIBT ile elde edilmiş olan 3B görüntülerde aksiyal, sagittal, koronal veya istenilen başka bir düzlemdeki kesitler arasında geçişler yaparak incelemelerini gerçekleştirebilmektedirler. Ayrıca, bu tür yazılımların sundukları özellikler sayesinde 3B çene ve yüz görüntü bilgisi bilgisayar ekranında rahatça izlenebilmektedir. Yazılımların sundukları araçlar kullanılarak "dental ark" [2] tespiti, ilgili

görüntü bölgesinde mesafe ve alan ölçümleri, implant planlama işlemleri veya görüntüdeki herhangi bir bölgenin Hounsfield değerleri hesaplanarak kemik yoğunluk verilerinin elde edilebilmesi mümkün olmaktadır [74]. Sundukları bu imkanlara rağmen yazılımların hastalıklı bölgelerin (lezyon, odontoma vb.) gerçek zamanlı olarak tespit edilmesi, bu bölgelerin sınıflandırılması veya hekime teşhiste yardımcı olacak bilgilerin önerilmesi gibi özellikleri oldukça kısıtlıdır veya ilgili yazılımlarda bu özellikler hiç bulunmamaktadır.

Görüntüleri elde ettiğimiz KODAK 9500 KIBT cihazına ait yazılım, 3B veri kümelerini görselleştirmek ve bu görüntüleri incelemek amacıyla halihazırda kullanılmaktadır. Ancak; mevcut yazılım çalışmamızda da yer alan görüntülerde ilgilenilen bölgelerin işaretlenmesi için gerekli araçlara sahip değildir. Piyasada bulunan diğer görüntüleme uygulamalarında ise DICOM formatındaki veriler üzerinde ilgilenilen bölgeler işaretlenebilirken, bu verilere ait özniteliklerin çıkartılmasını sağlayacak bir araç bulunmamaktadır.


Bu eksikleri giderebilmek ve çalışmalarını kolaylıkla yürütmek amacı ile bu tez çalışmasına özel olarak MATLAB R2016b platformu ile bir görüntüleme yazılımı geliştirilmiştir (Şekil 17). Bu yazılıma eklenen öznitelik çıkartma modülü sayesinde başka araçlara ihtiyaç duymadan 3B DICOM veri kümelerinde inceleme, işaretleme ve verilerden öznitelik çıkartma işlemleri bir arada gerçekleştirilebilmektedir. Ayrıca bu yazılım, gelecek çalışmalarda ihtiyaç duyulabilecek yeni özellikler eklenerek, daha da geliştirilebilecektir.



Şekil 17. Geliştirilen görüntüleme yazılımının ekran görüntüsü

Görüntülerde ilgilenilen bölgelerin işaretlenmesi için farklı bölütleme yöntemlerinden faydalanmak mümkündür. Bu yöntemlerin dental görüntülerde uygulanması ve lezyonların bölütlenmesi hedefli çalışmalar hali hazırda yürütülmektedir. Çalışmamızda mutlak doğru referans olarak kabul edilecek olan, ilgilenilen bölgelerin işaretlenmesi için manuel bölütleme yöntemi tercih edilmiştir. Radyoloji uzmanı seçtiği eksendeki bir kesitten itibaren lezyonlu bölgeyi içeren bütün kesitleri manuel işaretleyerek bölütleme işlemini gerçekleştirebilmektedir.

Bölütleme işlemleri sonucunda işaretlenen her bir voksele ait Hounsfield değerleri 3B veri matrisinde saklanmaktadır. Ortaya çıkan matrisin boyutları 3B uzayda lezyon bilgilerini çevreleyecek bir dikdörtgenler prizmasının boyutları ile eşdeğerdir. Elde edilen bu 3B matrisin ihtiva ettiği bilgilerden tespit edilen lezyona ait özniteliklerin çıkartılması adımlarında faydalanılacaktır. Bu çalışmada bölütleme sonucunda elde edilen 3B matriste lezyonlu bölgeye karşılık gelen vokseller elde edildikleri orijinal Hounsfield değerleri ile temsil edilecektirler. Lezyonlu bölgenin dışında kalan ve lezyonu çevreleyen voksellerdeki veriler ise hava ile eşdeğer olarak görülen -1000 değeri ile değiştirilecektir (Şekil 18).



Şekil 18. (a) KIBT görüntüsünde 2B kesitte işaretlenmiş lezyon bölgesi (b) 2B düzlemler üzerindeki işaretlemeler sonucunda lezyonlu bölgeye karşılık gelen kesitlerin 3B gösterimi [75].

2.2.3. Görüntü Bölütleme Yöntemleri

2.2.3.1. Adaptif K-Ortalama Kümeleme

K-ortalama çoğunlukla görüntü bölütlemeye faydalanılan, görüntülerdeki piksellerin parlaklık derecelerine göre, bu piksellerin kendi aralarında k adet alt kümede gruplandırılmalarını sağlayan, bir yöntemdir. Gruplandırılan pikseller aynı parlaklık seviyesi ile temsil edilirler ve görüntü bilgisi sadece belli piksel değerlerine indirgenmiş olur. Kümeleme, yinelemeli olarak uygulanan işlem adımları sonucunda gerçekleştirilirken, elde edilen sonuçlar her adımda seçilen küme merkezine göre farklılık göstermektedir [76].

$D = \{d^{(j)} | j = 1, \dots, n\}$, K kümeli bir veri seti, $C = \{c_i | i = 1, \dots, n\}$ K merkezli bir küme ve $S_j = \{d^{(j)} | d^{(j)} \in k\}$ ise j inci kümeye ait örneklerin kümesi olsun. Geleneksel k-ortalama algoritması, amaç fonksiyonu olarak tanımlanan aşağıdaki fonksiyonu minimize etmeyi hedefler.

$$Cost(D, C) = \sum_{j=1}^n dist(d^{(j)}, c_k) \quad (22)$$

Burada $dist(d^{(j)}, c_k)$ ifadesi, $d^{(j)}$ noktası ile c_k küme merkezi arasındaki Öklid mesafesini belirtmektedir. Bu algorithmada c_k küme merkezleri rastgele örnekleme ile belirlenmekte ve böylece küme merkezlerinden minimum mesafeye göre noktaların hangi kümeye ait olduğuna karar verilmektedir. Bu yinelemeli yöntemde yeni c_k küme merkezleri aşağıdaki formülle belirlenir.

$$c_k = \frac{\sum_{d^{(j)} \in S_k} d^{(j)}}{|S_k|} \quad (23)$$

Burada $|S_k|$, k inci kümedeki eleman sayısını ifade etmektedir. Küme merkezleri sabit kalana değin seçilen merkeze göre üyeliklerin belirlenmesi ve yeni küme merkezlerinin hesaplanması adımları tekrar edilir.

Her yineleme adımında seçilecek küme merkezinin adaptif olarak belirlenmesini sağlayan adaptif k-ortalama kümeleme (Ak-OK) [77] yöntemi sayesinde hedeflenen

optimum küme merkezlerinin belirlenmesi kolaylaşmıştır. Bu algoritmada, küme merkezleri optimizasyon formülasyonu ve yeni bir yineleme yöntemine dayalı olarak belirlenmektedir.

Ak-OK algoritmasında, ilk önce veriler $D = \cup_{k=1}^K S_k, S_{k_1} \cap S_{k_2} = \emptyset, k_1 \neq k_2$ ifadesindeki gibi K alt kümeye ayrılır ve ilk küme merkezleri aşağıdaki formül ile belirlenir.

$$x_{(k)}^{(0)} = \sum_{d^{(j)} \in S_k} d^{(j)} / |S_k|, k = 1, \dots, K \quad (24)$$

Minimum mesafeye göre K -kümelerinin her biri için diğer piksellerin aidiyetine karar verilir. Ardından yeni küme merkezleri;

$$x_i^{(k+1)} = \sum_{d^{(j)} \in S_k} \frac{d_i^{(j)}}{q_j^k} / \sum_{j=1}^n \frac{1}{q_j^k} \quad (25)$$

formülü ile belirlenir. Burada $q_j^k = \|x^{(k)} - d^{(j)}\|$ olarak hesaplanmaktadır.


Orijinal algoritmada olduğu gibi Ak-OK algoritmasında da küme merkezleri sabit kalana değin, seçilen merkezlere göre diğer piksellerin aidiyetlerinin belirlenmesi ve yeni küme merkezlerinin hesaplanması adımları tekrar edilir.

2.2.3.2. Rasgele Yürüyüş Algoritması

Rasgele yürüyüş (RY) [78] kullanıcı tarafından verilen başlangıç girişlerine göre bölütleme işlemlerini gerçekleştiren, olasılık ve graf teorisine dayalı olarak çalışan bir algoritmadır. Bu algoritma 2B görüntülerde kullanıcı etkileşimi ile veya otomatik olarak yerleştirilen tohumlardan başlayarak bölütleme işleminin gerçekleştirilmesi prensibi ile çalışmaktadır.

Görüntüde bölütlenecek bölge sayısına göre kullanılacak tohumlar ve bu tohumlara karşılık gelen sınıf etiketi sayısı değişkenlik gösterir. Sadece belirli bir bölgenin bölütlenmek istenildiği durumda iki farklı sınıf etiketi kullanılacaktır. Bu durumda tohumlardan bir grup bölütlenecek bölgedeki piksellere, diğer grup ise bölütleme dışında kalacak bölgedeki piksellere yerleştirilirler. Eğer birden fazla bölge ayrı ayrı bölütlenecek ise, bölütlenmesi istenilen her bölge için farklı sınıfta etiketlenmiş tohumlar, bölütleme dışında kalacak bölgeye de diğerlerinden ayrı bir sınıfta etiketlenmiş tohumlar yerleştirilir.

Bölütleme işlemlerini ve hesaplamaları kolaylaştırmak amacıyla görüntüdeki her bir pikselin ve bu piksellere ait parlaklık değerlerinin karşılık geldiği bir Laplace matrisi oluşturulur. Laplace matrisinde tohumların yerleştirildiği pikseller başlangıç düğümleri olarak seçilirler. Başlangıç düğümlerinden, tohum yerleştirilmemiş diğer düğümlere doğru bir rasgele yürüyüş modeli oluşturur ve her bir düğüm için ulaşım olasılıkları hesaplanır. Bu hesaplamaların sonucunda etiketli olmayan bir düğüm başlangıç düğümlerinden hangisine daha büyük bir olasılık ile ulaşıyorsa o düğüme ait etiket ile işaretlenir. Bütün düğümler ve bu düğümlere karşılık gelen pikseller için etiketleme işlemi tamamlandıca bölütleme tamamlanmış olur.



Şekil 19. Rasgele yürüyüş bölütleme adımlarının gösterimi (a) L_1, L_2, L_3 etiketleri ile gösterilen başlangıç tohumlarının yerleştirildiği düzen (b) her bir düğüm için hesaplanan L_1 etiketli düğüme ulaşım olasılıkları (c) her bir düğüm için hesaplanan L_2 etiketli düğüme ulaşım olasılıkları (d) her bir düğüm için hesaplanan L_3 etiketli düğüme ulaşım olasılıkları (e) RY yöntemi ile elde edilen bölütleme sonucu

Bölütlenmek istenen bir I görüntüsünün $G = (V, E)$ gösteriminde olduğu gibi, ağırlıklı ve yönsüz bir graf yapısı ile temsil edildiği varsayalım. Burada V düğümler kümesini, $v \in V$ bu kümede yer alan bir düğümü, E kenarlar kümesini, $e \in E$ ise bu kümede yer alan bir kenarı belirtmektedir. Her v_i görüntüdeki bir x_i pikselini, her e_{ij} ise v_i ve v_j düğümlerini birbirine bağlayan kenarı ifade etmektedir. Görüntüyü temsil eden graf yapısında bu e_{ij} kenarı için w_{ij} ile ifade edilen bir ağırlık değeri atanır. Görüntüdeki parlaklık değerlerine karşılık graf yapısındaki ağırlık değerleri Gauss ağırlık fonksiyonu ile aşağıdaki şekilde hesaplanır:

$$w_{ij} = \exp\left(-\beta(g_i - g_j)^2\right) \quad (26)$$

Burada g_i , v_i düğümüne karşılık gelen i 'inci pikseldeki görüntü parlaklık değerini, β dışarıdan verilen serbest parametreyi temsil etmektedir. RY olasılıklarının çözümü bir kombinatoryal Dirichlet problemini minimize etmekle aynıdır.

Dirichlet integrali, bir u alanı ve Ω bölgesi için, aşağıdaki gibi tanımlanabilir:

$$D[u] = \frac{1}{2} \int_{\Omega} |\nabla u|^2 d\Omega \quad (27)$$

Sınır değerlerine bağlı bir harmonik fonksiyon bulma problemi olan Dirichlet problemi, bir Laplace denklemi çözülerek analitik olarak hesaplanabilir. Dirichlet integralini ayırtırmak için, kombinatoryal Laplace matrisi aşağıda gösterildiği gibi oluşturulur.

$$L_{ij} = \begin{cases} d_i & i = j \\ -w_{ij} & v_i \text{ ile } v_j \text{ komşu düğümler} \\ 0 & \text{diğer durum} \end{cases} \quad (28)$$

Bu gösterimdeki d_i ifadesi v_i düğümünün derecesini belirtmekte olup $d_i = \sum_j w_{ij}$ formülünün hesaplanması sonucunda elde edilmektedir.

Laplace matrisinin elde edilmesinin ardından kombinatoryal Dirichlet integrali aşağıdaki ifade ile yeniden formülize edilir.

$$D[x] = \frac{1}{2} x^T L x \quad (29)$$

Buradaki x denklemini minimize eden bir harmonik fonksiyon ve graftaki tüm düğümlerden oluşan bir vektördür.

V vektörünü oluşturan düğümler iki gruba ayrılır. V_m ile ifade edilenler etiketlenmiş tohum düğümleri, V_u ile ifade edilen düğümler ise etiketlenmemiş düğümlerdir. Enerji fonksiyonu yeniden formüle edildiğinde:

$$\begin{aligned} D[x_U] &= \frac{1}{2} x^T \begin{bmatrix} x_M^T & x_U^T \end{bmatrix} \begin{bmatrix} L_M & B \\ B & L_U \end{bmatrix} \begin{bmatrix} x_M \\ x_U \end{bmatrix} \\ &= \frac{1}{2} (x_M^T L_M x_M + 2x_U^T B^T x_M + x_U^T L_U x_U) \end{aligned} \quad (30)$$

Bu formülde x_M ve x_U sırasıyla etiketli ve etiketsiz düğümlere ait olasılıkları, L_M ve L_U her iki türdeki düğümlerin iç bağılıklarını, B ve B^T ise düğümler arası bağılıkları göstermektedir. $D[x_U]$ 'nun x_U 'ya göre diferansiyeli alınıp kritik noktalar bulunduğu:

$$L_U x_U = -B^T x_M \quad (31)$$

olarak elde edilir.

Elde edilen bu eşitlikten yola çıkarak sonuncu etiket dışındaki her bir s etiketi için kombinatoryal Dirichlet problemi:

$$L_U x^s = -B^T m^s \quad (32)$$

denkleminde veya bütün etiketler için:

$$L_U X = -B^T M \quad (33)$$

denkleminde çözülür. Her bir v_i düğümü için, $\max_s(x_i^s)$ 'e karşılık gelen etiket atanarak nihai bölütleme elde edilir.

2.2.3.3. Bölge Tabanlı Aktif Kontur Modeli

Aktif kontur modelleri [79] bölütlenecek bilginin yer aldığı bölgeye kullanıcı tarafından yerleştirilen bir başlangıç konturunun yinelemeli işlemler sonucunda şeklini güncellemesi prensibi ile çalışırlar. Verilen başlangıç konturu, bir enerji minimizasyonu denkleminin yinelemeli çözümü yoluyla bu güncelleme işlemini gerçekleştirir. Başlangıçta belirlenen işlem adımı sayısınca çözülen enerji minimizasyonu denklemi sonucunda başlangıç konturu bölütlenecek bölgenin kenarlarına yaslanır ve elde edilmek istenilen nesnenin şeklini alarak bölütlemeyi tamamlar.

Bu prensip ile çalışan çeşitli aktif kontur modelleri mevcuttur. Bu modellerin önemli bir kısmı bölütleme işlemlerinde karşılaşılan bazı problemlerin üstesinden gelememektedirler. Literatürde önerilen her model, daha sonra o modeldeki sorunlara çözüm getiren başka bir model sayesinde güncellenmiştir. Bu modellerin arasında, çalışmamızda da kullandığımız, yerel Gauss dağılımına enerji sağlayan aktif kontur (YGAK) modelinin bölütleme başarısı diğerlerine nazaran daha yüksektir.

2.2.3.3.1. Mumford-Shah Modeli

$\Omega \subset \mathbb{R}^2$ 2B görüntü uzayı ve $I: \Omega \rightarrow \mathfrak{R}$ verilen bir gri seviyeli görüntü olsun. Mumford-Shah görüntü bölütlemeyi, bir I görüntüsü verildiğinde, görüntüyü farklı nesnelere temsil eden ve örtüşmeyen bölgelere bölen bir C konturunun belirlenmesi şeklinde ifade etmiştir.

2.2.3.3.2. Yerel Gauss Dağılımına Enerji Sağlayan Aktif Konturlar

Yerel Gauss Dağılımına Enerji Sağlayan Aktif Konturlar (YGAK) ile oluşturulan bölge tabanlı modelde [80] ise, yerel görüntü parlaklık değerleri farklı ortalama ve varyans seviyelerindeki Gauss dağılımları ile ifade edilmektedir.

Ω görüntü alanı ve $\{\Omega_i\}_{i=1}^N$ ise N adet bölgeden oluşan ayrık görüntü bölgeleri kümesi olsun. Görüntü alanında verilen bir x noktası için enerji fonksiyonu aşağıdaki gösterimle ifade edilir [81].

$$E_x^{YGAK} = \sum_{i=1}^N \int_{\Omega_i} -w_\sigma(x-y) \log p_{i,x}(I(y)) dy \quad (34)$$

Bu fonksiyonda $w_\sigma(x-y)$, σ ölçek parametrelili bir Gauss çekirdeği olup, $p_{i,x}(I(y))$ olasılık yoğunluğu aşağıdaki şekilde tanımlanır.

$$p_{i,x}(I(y)) = \frac{1}{\sqrt{2\pi}\sigma_i(x)} \exp\left(-\frac{(u_i(x)-I(y))^2}{2\sigma_i(x)^2}\right) \quad (35)$$

Olasılık yoğunluğu tanımında yer alan $u_i(x)$ ve $\sigma_i(x)$ gösterimleri yerel parlaklık ortalamaları ve standart sapmalarını temsil etmektedir. Bölütleme işleminde tüm nesne sınırını elde etmek amacıyla bütün $x \in \Omega$ için E^{YGDF} enerji denklemini minimize eden C konturunun bulunması gereklidir. Bunun için E_x^{YGDF} integralinin Ω üzerinden minimizasyonu aşağıdaki gösterimdeki gibi sağlanmalıdır.

$$E^{YGAK} = \int_{\Omega} E_x^{YGAK} dx = \int_{\Omega} \left(\sum_{i=1}^N \int_{\Omega_i} -w(x-y) \log p_{i,x}(I(y)) dy \right) dx \quad (36)$$

YGAK modeli, Gauss dağılımının farklı ortalama ve varyanslarla tanımladığı yerel görüntü parlaklıklarını verimli bir şekilde kullanır. Yerel parlaklık ortalamaları ve varyansları uzamsal değişen fonksiyonlar olarak kabul edilirler. Böylece kurulan model hem gürültü, hem de parlaklık değerlerinin homojen olmaması ile ilgili problemleri çözebilecek hale gelir.

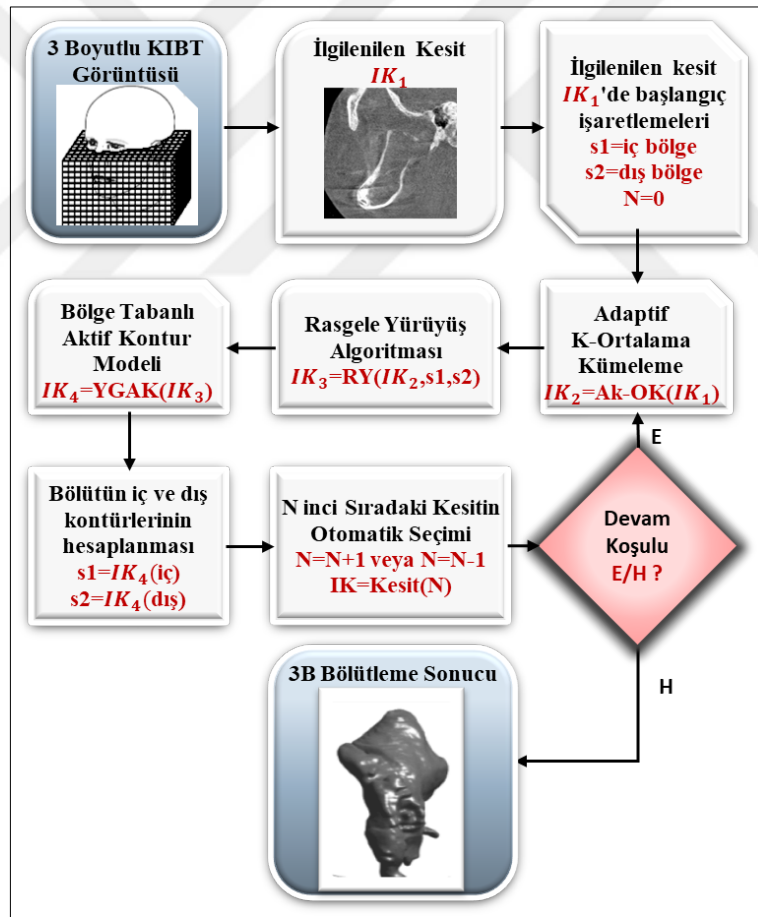
2.2.3.4. Lezyonlu Bölgelerin Yarı Otomatik Bölütlenmesi

Literatürde 3B medikal görüntülerin bölütlenmesi probleminin çözümü için çeşitli yöntemler önerilmiştir. Önerilen yöntemler genellikle problem odaklı olup, belirli tipteki patolojilerin veya anatomik yapıların görüntüden çıkartılması amacıyla kullanılmaktadırlar. Bu nedenle kimi görüntüler için başarılı olan bir yöntem, başka bir görüntü ve anatomik yapı üzerinde başarı göstermeyebilir.

KIBT görüntülerinde kullanılan yöntemlerin önemli bir kısmı dış, üst ve alt çeneler gibi parlaklık değerleri ve homojenlik düzeyi bakımından ayırt edicilik seviyesi yüksek olan

anatomik yapıları başarı ile bölütleyebilmektedirler. Ancak, diş kökü ve çene bölgesinde gözlemlenen, çeşitli şekillerdeki ve parlaklık seviyelerindeki, çoğunlukla homojen olmayan ve bazı durumlarda çene kemiği yıkımları sebebiyle oluşan perforasyonlar (kemikteki delinmeler) sonucu çevre dokular ile de benzer doku özellikleri gösteren lezyonların bölütlenmesi oldukça zordur. Çözümü oldukça zor olan bu probleme yönelik literatürde KIBT görüntülerindeki dental lezyonların bölütlenmesi için önerilen yöntemlerin sayısı oldukça azdır [38,41].

Bu çalışma kapsamında önerdiğimiz yarı otomatik bölütleme yöntemi [76], Ak-OK, RY ve YGAK yöntemlerinin sırayla uygulandığı işlem adımları sonucunda KIBT görüntülerinde tespit edilen dental lezyonları başarıyla bölütleyebilmektedir. Yarı otomatik bölütleme yönteminin çalışma prensibi aşağıdaki şekilde verildiği gibidir.



Şekil 20. Farklı algoritmaların sıralı bir düzende kullanılması ile elde edilen yarı otomatik bölütleme yöntemi işlem adımları [76].


Bölütleme işleminin ilk aşamasında hekim veya radyoloji uzmanı, geliştirilen yazılım ekranında yüklenmiş aksiyal, sagittal veya koronal eksenlerde lezyonlu bölgeyi tespit etmek için 3B KIBT verilerinden elde edilen 2B kesit görüntüleri boyunca incelemeler yapar. Lezyonlu bölgenin tespit edildiği, ilgili ekseninde N 'inci sıradaki kesit (IK_1) uzman tarafından başlangıç kesiti olarak seçilir. IK_1 'de lezyonun gözlemlendiği alanın içinde kalan bölgeye yazılımda sunulan çizim aracı kullanılarak bir kontur çizilir. Aynı işlem lezyonlu bölgenin dışını çevreleyecek diğer bir konturun çizilmesi ile tekrar edilir. Bu işaretleme işleminde iç bölgedeki konturun 2B görüntü kesitinde kesiştiği pikseller iç tohumlar, benzer şekilde lezyonun dışına çizilen kontur ile 2B görüntü kesitinin kesiştiği noktalarındaki pikseller de dış tohumlar olarak belirlenir. Daha sonraki işlem adımlarında RY yönteminde işleme sokulacak olan iç bölgedeki tohumlar s_1 sınıfı ile, dış bölgedeki tohumlar da s_2 sınıfı ile etiketlenirler.

İşaretleme ve beraberindeki etiketleme işleminin ardından, seçilen kesitteki 2B görüntüye Ak-OK yöntemi uygulanır ve IK_2 çıktısı elde edilir. Bu işlem adımında Hounsfield skalasındaki değer aralığında temsil edilen parlaklık değerleri adaptif olarak gruplanarak RY yönteminde girdi olarak sunulacaktır.

Ak-OK uygulanmış IK_2 görüntüsü ilk aşamadaki iç ve dış kontur çizimlerinden elde edilen s_1 ve s_2 etiketli tohumlar kullanılarak RY yönteminde bölütlenir ve IK_3 çıktısı elde edilir.

RY yöntemi ile elde edilen bölütleme sonucu büyük ölçüde lezyonlu bölgeye ait kısımları gösterse de ulaşılmak istenilen nihai sonuç değildir. RY bölütlemesinde lezyonlu bölgenin iç kısmında işaretlenmemiş, dış kısmında ise hatalı işaretlenmiş pikseller ortaya çıkabilir. Çoğunlukla birbirinden bağımsız küçük piksel veya piksel grupları halinde gözlemlenen bu hatalı işaretlemeler, bölge tabanlı aktif kontur modelleri yardımı ile bertaraf edilebilir. RY ile elde edilen IK_3 çıktısı, çalışmamızda bahsettiğimiz YGAK enerji minimizasyonu denkleminde girdi olarak sunulur. RY ile elde edilen konturun yinelemeli olarak evrimleşmesi sonucunda IK_4 çıktısı elde edilir. Elde edilen çıktı KIBT görüntüsü ile aynı boyuttaki boş 3B bölütleme matrisinde IK_1 ile temsil edilen kesitin karşılığındaki koordinata eklenir.

Yarı otomatik bölütleme işlemine ait bu adımlar örnek bir görüntü üzerinde uygulandığında aşağıdaki şekilde gözlemlenen sonuçlar elde edilir.



Şekil 21.Yarı otomatik lezyon bölütlemenin bir kesitte uygulanış adımları [76].

Bu aşamadan sonra algoritma, ilgili eksenindeki $N + 1$ sırasındaki sonraki kesite geçiş yapar ve bölütleme işlemini bu kesit için sürdürür. Bir sonraki kesit için başlangıç konturların çizilmesine gerek yoktur. Bir önceki bölütlemeye elde edilen IK_4 sonucuna ait kontur D ile temsil edilen bir uzaklığa doğru küçültülür. Bu işlem sonucu elde edilen iç kontur, mevcut kesit için s_1 sınıf etiketi ile temsil edilen iç tohumların elde edilmesi amacıyla kullanılacaktır. Benzer bir mantıkla IK_4 sonucuna ait kontur D ile temsil edilen bir uzaklığa bağlı olarak büyütülür. Elde edilen dış kontur bu sefer s_2 ile temsil edilen dış tohumların elde edilmesini sağlayacaktır. Tohumlar belirlendikten sonra bir önceki kesitte

sırasıyla uygulanan Ak-OK, RY ve YGAK işlem adımları tekrar edilir ve bu kesit için sırasıyla IK_2, IK_3 ve IK_4 çıktıları elde edilir.

Bir sonraki kesitte elde edilen bölütleme sonucundaki 2B bölge alanı kullanıcı tanımlı bir eşik değerin altında ise veya bölütlenen bölgedeki piksellerin parlaklık değerleri ortalaması önceki adımlarda bölütlenen bütün kesitlerin piksel parlaklık değerlerinin ortalamasından %10 daha fazla veya %10 daha az ise pozitif yönde sürdürülen bölütleme işlemi sonlandırılır ve $N - 1$ inci kesitten itibaren bölütleme devam ettirilir. $N - 1$ inci kesitten itibaren gerçekleştirilen bölütlemelerde her bir kesit için aynı işlemler gerçekleştirilir. Negatif yönde sürdürülen bölütleme işlemlerinde işlemi sonlandırmak için kontrol edilen koşullardan biri sağlandığı anda bölütleme bitirilir.

Başlangıç adımından itibaren bölütlenmiş bütün eksellere ait bilgilerin saklandığı 3B bölütleme matrisi, nihai bölütleme sonucu olarak kayıt edilir.


2.2.3.5. Bölütleme Performansının Karşılaştırılması

Görüntü bölütleme yöntemlerinin performanslarını ölçmek amacı ile karşılaştırma metriklerinden faydalanılır. Bu metrikler, otomatik veya yarı otomatik bölütleme yöntemi ile elde edilen bir sonucu mutlak doğru olarak kabul edilen manuel bölütleme sonucu ile kıyaslayan matematiksel formüller yardımıyla bulunur.

KIBT görüntülerinde gerçekleştirilecek yarı otomatik lezyon bölütleme işlemlerinden elde edilen 3B matris, manuel bölütleme yoluyla işaretlenen 2B kesitlerden elde edilen 3B matris ile kıyaslanarak yöntem performansı ölçülecektir. Karşılaştırma işlemleri Jaccard indeksi ve Dice katsayısı hesaplamaları ile gerçekleştirilecektir [82].

$$Jaccard\ indeks = \frac{\sum(B_1 \cap B_2)}{\sum(B_1 \cup B_2)} \quad (37)$$

$$Dice\ katsayısı = \frac{2 * \sum(B_1 \cap B_2)}{\sum(B_1) + \sum(B_2)} \quad (38)$$



Şekil 22. KIBT görüntüsünde tespit edilen lezyon için mutlak doğru referans olarak kabul edilen manuel bölütleme sonucu (solda) ve yarı otomatik bölütleme yöntemi ile elde edilen 3B sonuç görsellerin karşılaştırması [76].

2.2.4. Özniteliklerin Çıkartılması

Sınıflandırma işlemlerinde kullanılacak öznitelikler istatistiksel doku analizi yöntemleri yardımı ile elde edilecektir. Verileri iki ayrı sınıfa ayırabilmek için işaretlenmiş her bir 3B KIBT görüntüsündeki voksel parlaklıklarından elde edilen birinci basamak istatistiklerden ortalama, medyan, standart sapma, çarpıklık, basıklık ve entropi değerleri hesaplanacaktır.

2.2.4.1. Düzey İstatistikleri

Herhangi bir görüntü hakkında ayırıcı bilgi elde etmek için kullanılan en temel gösterge görüntüye ait birinci seviye istatistiklerdir. Birinci düzey istatistiklerin hesaplanması için görüntüye ait hesaplanmış histogram değerlerinden faydalanılır [83]. İki boyutlu görüntüde pikseller için hesaplanan histogram bilgisinin normalize edilmiş hali çalışmamızda kullandığımız 3B veri kümesinde voksel değerleri için aşağıda gösterildiği gibi hesaplanmaktadır.

$$P(D_i) = \frac{\sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \sum_{z=0}^{L-1} \delta(f(x, y) - i)}{NML} \quad (39)$$

Denklemden D_i histogramda temsil edilen ayrık parlaklık değerlerini, $P(D_i)$ histogramdaki parlaklık değerlerinin tekrar sayısından elde edilen olasılık yoğunluk değeri olarak temsil edilmektedir. $P(D_i)$ olasılık yoğunluk değerleri kullanılarak ortalama, standart sapma, çarpıklık, basıklık ve entropi değerleri sırasıyla aşağıdaki denklemler yardımıyla hesaplanabilmektedir.

$$\mu = \sum_{i=0}^{H-1} D_i P(D_i) \quad (40)$$

$$\sigma = \sqrt{\sum_{i=0}^{H-1} (D_i - \mu)^2 P(D_i)} \quad (41)$$

$$\mu_3 = \frac{1}{\sigma^3} \sum_{i=0}^{H-1} (D_i - \mu)^3 P(D_i) \quad (42)$$

$$\mu_4 = \frac{1}{\sigma^4} \sum_{i=0}^{H-1} (D_i - \mu)^4 P(D_i) - 3 \quad (43)$$

$$e = - \sum_{i=0}^{H-1} P(D_i) \log_2 [P(D_i)] \quad (44)$$

Medyan değeri ise 3B veri kümesindeki voksel değerlerinin küçükten büyüğe doğru sıralanması sonucu elde edilen vektörün ortasında yer alan değer olarak hesaplanmaktadır.

2.2.4.2. 3B Haralick Doku Öznitelikleri

Doku bilgileri medikal görüntülerin analiz edilmesi süreçlerinde sıklıkla hesaplanmaktadır. Bu bilgiler görüntü içerisinde tekrarlanan, birbirleri ile bağlantı halindeki farklı seviyede renk bilgileri içeren piksel veya voksel kümelerinden ibarettir. Dokuya ait anlamlı özniteliklerin elde edilmesi hedefiyle görüntüdeki varyasyonlar ölçülerek bölgesel bilgiler elde edilmeye çalışılır.

Haralick tarafından önerilen Gri Seviye Birlikte Görülme Matrisi (GSBGM), dokusal özniteliklerin elde edilmesi için kullanılan başlıca yöntemlerden birisidir [84]. Bu matris ile görüntüdeki gri seviye değerlerinin uzaysal bağımlılıklarını tespit edilebilmektedir. GSBGM

matrisi daha çok 2B görüntü bilgisi üzerinde tekrar eden gri seviye değerlerine ait bazı istatistiklerin elde edilmesi amacıyla hesaplanmaktadır.

GSBGM matrisi, tüm satır ve sütunların gri seviye parlaklık değerini gösteren kare bir matristir. Dolayısıyla, GSBGM'nin boyutları görüntüdeki gri seviye parlaklık değerlerinin sayısına bağlıdır.

Dokuya ait özneliklerin incelenmesi ile ilgili yapılan çalışmalar genellikle 2B görüntüler üzerine yoğunlaşmaktadır. 3B görüntülerin yaygınlaşması sonucunda dokunun volumetrik olarak incelenmesi gerekliliği doğmuştur. İki boyutlu görüntü kesitlerinde GSBGM sayesinde sadece o kesit içindeki gri seviyelerin x ve y eksenleri boyunca uzaysal bağımlılıkları elde edilebilmektedir. Halbuki volumetrik görüntüler için hesaplanabilen GSBGM matrisi sayesinde gri seviyelerin uzaysal bağımlılıkları, x ve y eksenlerine ek olarak z eksenini doğrultusunda volumetrik görüntüyü meydana getiren kesitler boyunca da elde edilebilmektedir. Bu çalışmada volumetrik görüntünün 2B kesitlere oranla daha çok ayırıcı bilgi ihtiva edeceği düşüncesiyle 3B Gri Seviye Birlikte Görülme Matrisi hesaplanacaktır. Bu amaç doğrultusunda 2B GSBGM matrisinin 3B görüntüler üzerine uyarlanmış hali aşağıdaki denklemde verilmiştir.

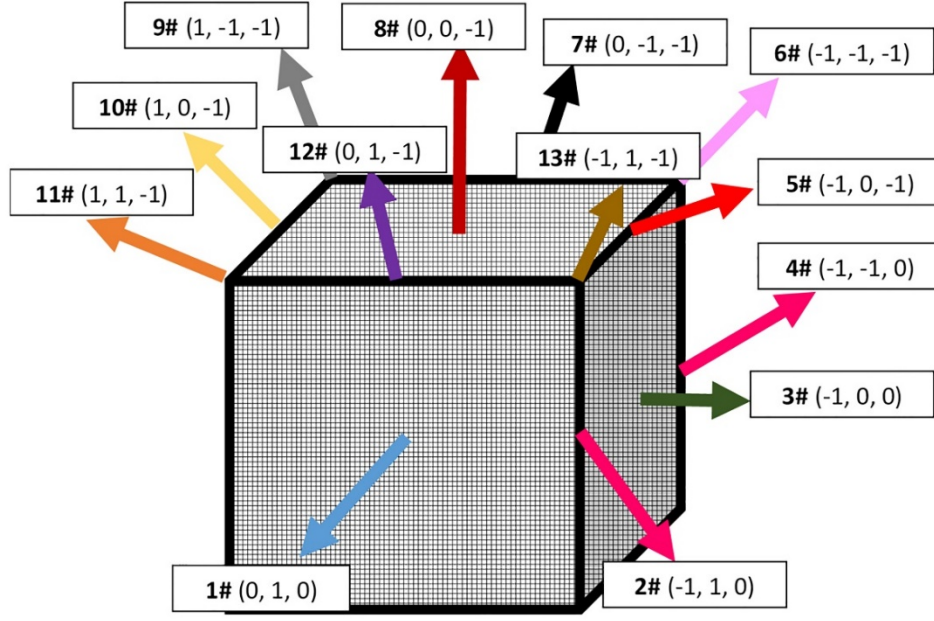
$$M_d(i, j) = \sum_{z=1}^{W_z-dz} \sum_{x=1}^{W_x-dx} \sum_{y=1}^{W_y-dy} \delta[G(x, y, z) = i \text{ AND } G(x+dx, y+dy, z+dz) = j] \quad (45)$$

if $\delta[\text{True}] = 1$, else $\delta[\text{False}] = 0$

Denklemde i ifadesi 3B GSBGM matrisinin i -inci kolonunu, j ifadesi ise j -inci satırını temsil ederken; d ise piksel çiftleri arasındaki ilişkiyi ifade etmektedir. $G(x, y, z)$ ve $G(x+dx, y+dy, z+dz)$ ifadeleri ($W_x \times W_y \times W_z$) kayan penceresinde (x, y, z) ve $(x+dx, y+dy, z+dz)$ pozisyonlarındaki gri seviye değerlerini, x, y, z değerleri ise volumetrik bilgi içerisinde kayan pencerenin pozisyonunu belirtmektedir.

GSBGM matrisleri $n \times n$ boyutlarında olup, n görüntüdeki gri seviye adedini ifade eder. Matrisin daha hızlı hesaplanabilmesi için gri seviyeler belirli aralıklara indirgenerek sayıları azaltılmaktadır.

3B GSBGM'de vokseller arasındaki ilişkinin hesaplanabilmesi için 2B yöntemden farklı olarak 26 yön kullanılmaktadır [85]. Bu eşleşmelerden 13 tanesi farklıdır (Şekil 22).



Şekil 23. 3B GSBGM'nin hesaplanmasında kullanılan 13 farklı yön vektörü [75].

Hesaplanan her bir 3B GSBGM matrisinden elde edilen 12 farklı öznitelik bilgisi çalışmamızda kullanılmıştır. Bu öznitelikler sırasıyla enerji, entropi, korelasyon, kontrast, varyans, ortalamaların toplamı, durağanlık, küme gölgesi, küme eğilimi, homojenlik, maksimum olasılık ve ters varyans olarak belirlenmiştir [86].

Çalışmamızda kullandığımız 3B GSBGM'de vokseller arasındaki ilişkilerin hesaplanması için 13 farklı yön ve 4 farklı mesafe bilgisi kullanılmıştır. Mesafe bilgilerini içeren bu dizi GSBGM matrisine ait formüldeki d ifadesi için sırasıyla [1;2;4;8] değerlerini almaktadır. Hesaplanan 52 farklı GSBGM'den 12 farklı öznitelik elde edilmiş ve toplamda 624 farklı 3B doku özniteliği bulunmuştur.

2.2.4.3. Öznitelik Vektörü

Öznitelik vektörünün oluşturulması adımlarında her bir veri kümesi için birinci düzey istatistikler iki farklı şekilde hesaplanmıştır. Birinci düzey istatistikler ilk olarak yalnızca lezyonu ifade eden veri kümelerinden hesaplanarak üretilmiştir. İkinci kez hesaplanan birinci düzey istatistiklerde ise bölütlenerek elde edilen lezyonlu bölgeyi çevreleyen dikdörtgenler prizmasına ait sınırlar içerisinde kalan orijinal Hounsfield değerleri kullanılmıştır. 3B doku özniteliklerini elde etmek için her bir 3B veri kümesinden 3B GSBGM hesaplanmış ve toplamda 624 farklı öznitelik elde edilmiştir. Sonuç olarak elde

edilen öznitelik vektörü birinci düzey istatistikler ve 3B doku özniteliklerinden meydana gelmiştir. Sınıflandırma adımlarında kullanılacak olan öznitelik vektörü bölütlenmiş her bir lezyonlu bölge için toplamda 636 adet öznitelik bilgisini içermektedir.

2.2.5. Sınıflandırma Yöntemleri


Çalışmamızda volumetrik görüntülerden elde ettiğimiz öznitelik vektörlerinden faydalanarak PK ve KOT patolojilerini teşhis edebilmek için k-En yakın komşuluk [87], Naive Bayes [88], karar ağaçları [89], rastgele orman [90], yapay sinir ağı [91], destek vektör makinaları [92], sınıflandırma yöntemleri ile deneyler gerçekleştirilecektir.

2.2.5.1. k-En Yakın Komşuluk

k-En yakın komşuluk (k-EYK) algoritması [87] en basit makine öğrenme yöntemidir. Önceden etiketleri belli olarak verilen ve n-boyutlu bir uzayda temsil edilen eğitim verilerine ait öznitelik bilgileri baz alınarak, verilen bir örneğin en yakın komşularına göre sınıflandırılması prensibiyle çalışır. Buradaki n sayısı kullanılan öznitelik adedini ifade etmektedir.

k-EYK algoritmasında sınıflandırılacak yeni bir test veri kümesine ait kullanılacak öznitelik bilgisinin daha önceki verilerden elde edilmiş olan etiketlenmiş eğitim kümesine ait özniteliklerin k tanesine olan yakınlığı ölçülür.

Çalışma prensibi oldukça basittir. Test amacıyla bilinmeyen bir veri kümesi sınıflandırıcıya verildiğinde seçilen k değerine bağlı olarak yeni veri kümesi eski verilerden hangisine daha yakın bir konumda ise o sınıfa dahil edilir. Örneğin $k = 3$ olarak kurulan bir sınıflandırıcıdaki bir veri eski verilerden en yakın 3 tanesine bakılarak o sınıfa dahil edilir.



Şekil 24. k-EYK yönteminde örnek bir veri noktasına en yakın komşuluk tespiti

Sınıflandırma sonucu, seçilen k parametresine göre değişkenlik gösterebilir. Eğer k çok küçük seçilirse verilerin yanlış bir kümeye dahil olma olasılıkları artar. Eğer k çok büyük seçilirse bu sefer veriler tek bir sınıfa ait olurlar. Sınıflandırıcının başarısı için k değerinin doğru seçilmesi gerekir. k-EYK, uygun bir k parametresinin seçilmesi durumunda en iyi performansı sağlayabilecek parametrik olmayan bir sınıflandırıcıdır

k-EYK sınıflandırmasının iki aşaması vardır; birincisi, en yakın komşuların belirlenmesidir. İkinci aşama ise bu komşuları kullanarak sınıfın belirlenmesidir.

$$E = \{(y_i, x_i), i = 1, \dots, n_L\} \quad (46)$$

olarak verilen x_i eğitim örneklerinden oluşan, E ile gösterilen bir eğitim veri kümesinde her bir eğitim örneği, $y_i \in \{1, \dots, s\}$ sınıf etiketiyle etiketlenmiş olsun. Sınıflandırıcıya verilen yeni bir (y, x) verisinin hangi sınıfa dahil olacağını bulmak amacıyla en yakın komşuları bir D mesafe fonksiyonu [93] ile belirlenebilir.

$$D(x, x_{(1)}) = \min_i (D(x, x_i)) \quad (47)$$

Burada $x_{(j)}$ ve $y_{(j)}$ gösterimleri x 'in j inci en yakın komşusunu ve bu komşuya ait sınıfı ifade etmektedir. En yakın komşuların belirlenmesi için genellikle tercih edilen mesafe fonksiyonları aşağıda verilmiştir.

$$D(x, x_{(j)}) = \sqrt{\sum_{j=1}^k (x - x_{(j)})^2} \quad (\text{Öklid mesafe fonksiyonu}) \quad (48)$$

$$D(x, x_{(j)}) = \sum_{j=1}^k |x - x_{(j)}| \quad (\text{Manhattan mesafe fonksiyonu}) \quad (49)$$

$$D(x, x_{(j)}) = \left(\sum_{j=1}^k |x - x_{(j)}|^q \right)^{\frac{1}{q}} \quad (\text{Minkowski mesafe fonksiyonu}) \quad (50)$$

Mesafe fonksiyonları kullanılarak (y, x) verisinin eğitim verilerine uzaklıkları hesaplanır ve en küçük mesafeden en büyük mesafeye doğru sıralanır. Seçilen k değerine göre en küçük mesafeye ait veriler en fazla hangi sınıfa dahil oluyolar ise, veri o sınıfa dahil edilir. Genellikle ikili sınıflandırma problemlerinde eşitlik çıkmaması için $k = 1, 3, 5$ gibi tek sayılardan seçilir.

2.2.5.1.1. Ağırlıklı k-En Yakın Komşuluk

Ağırlıklı k-En yakın komşuluk (Ak-EYK) [93], eğitim kümesinde (y, x) ile ifade edilen yeni bir gözleme yakın olan verilerin, daha uzakta olan verilere göre karar fonksiyonunda daha yüksek bir ağırlığın olması prensibine dayanır.

$E = \{(y_i, x_i), i = 1, \dots, n_L\}$ ile verilen bir eğitim kümesi, (y, x) de bu eğitim kümesi ile sınıflandırılacak yeni veri olsun. Ak-EYK sınıflandırmada seçilecek bir mesafe fonksiyonu kullanılarak x 'e $k + 1$ en yakın komşular bulunur. Burada $k + 1$ inci komşu k en küçük mesafelerin standartlaştırılması için

$$D_{(i)} = D(x, x_{(i)}) = \frac{d(x, x_{(i)})}{d(x, x_{(k+1)})} \quad (51)$$

aracılığı ile elde edilip kullanılır. Normalize edilmiş $D_{(i)}$ mesafeleri seçilecek bir $K(\cdot)$ çekirdek fonksiyonu aracılığı ile $w_{(i)} = K(D_{(i)})$ ağırlıklarına dönüştürülür. Yeni veri x 'in y ile gösterilen sınıf üyeliği tahmini için en yakın komşuların ağırlıklı bir çoğunluğunu gösteren sınıf seçimi aşağıdaki formülde gösterilmiştir.

$$\hat{y} = \max_r \left(\sum_{i=1}^k w_{(i)} I(y_{(i)} = r) \right) \quad (52)$$

2.2.5.2. Naive Bayes

Naive Bayes (NB) [88] Bayes Teoremine dayanan basit bir olasılıksal algoritmadır. Genel Bayes modellerinde sınıflandırma rasgele değişkenler arasındaki bağımlılıklar veya şartlı bağımlılıklardan türetilmektedir. Bu işlem bütün rasgele değişkenler arasındaki ilişkinin incelenmesini gerektirdiği için oldukça zaman alıcıdır. NB sınıflandırıcısı ise bir sınıfa ait bir özneliğin diğer öznelik bilgileri ile ilişkisinin olmadığı, yani bağımsız olduğunu varsaymaktadır. Bu “bağımsız öznelik modeli” olarak da ifade edilebilir. Bu yaklaşım hesaplamaları basitleştirdiğinden dolayı bu tür sınıflandırıcılar için “naive” ifadesi kullanılmaktadır.

Olasılık teorisinde Bayes teoremi rastgele gerçekleşen A ve B olayları arasındaki ilişkiyi tanımlamak amacıyla Thomas Bayes tarafından önerilmiş olup, matematiksel olarak aşağıdaki denklemdeki gibi gösterilir.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (53)$$

Burada A ve B gerçekleşen olayları, $P(A|B)$, B verildiğinde A 'nın koşullu olasılığını, $P(B|A)$ benzer bir şekilde A verildiğinde B 'ye ait koşullu olasılığı, $P(A)$ ve $P(B)$ ise A ve B 'nin birbirlerinden bağımsız olasılıklarını, diğer bir deyişle marjinal olasılıklarını ifade etmektedir.

Bayes teoremi ile çözülecek bir sınıflandırma problemi için $X = (x_1, x_2, \dots, x_n)$, n boyutlu bir olay olarak ifade edilmiş olup, $S = \{S_1, S_2, \dots, S_k\}$ ise sınıf etiketlerinin kümesi olarak verilmiş olsun [94]. Bu bilgilere göre Bayes teoremi kullanarak elde edilecek sınıflandırıcı denklemi aşağıdaki gibi elde edilir.

$$P(x|S_i) \times P(S_i) = P(S_i|x) \times P(x) \quad (54)$$

$$P(x) = \sum_{i=1}^K P(x|S_i) \times P(S_i) \quad (55)$$

$$P(S_i|x) = \frac{P(x|S_i)P(S_i)}{\sum_{i=1}^K P(x|S_i) \times P(S_i)} \quad (56)$$

Sınıflandırma denklemine göre, $P(S_i|x)$ diğer bütün $P(S_j|x)$, $i \neq j$ değerlerinden büyük ise, x verisi S_i sınıfı ile etiketlenecektir. Bu işlemin gerçekleştirilmesi aynı anda çok fazla sayıdaki olasılığın hesaplanmasını gerektirir. Bu nedenle klasik Bayes teorisine göre kurulacak bir sınıflandırıcı ile bu hesaplamaları yapmak oldukça zordur.

NB sınıflandırıcısı bu hesaplamaları kolaylaştırmak amacıyla, bir sınıfın belirli bir özelliğinin değerinin, diğer herhangi bir özelliğın değeriyle alakasız olduğunu varsayacak şekilde kurulur. Yani $P(x)$ değeri tüm sınıflar için sabit kabul edilir ve $P(S_i|x) = P(x|S_i)P(S_i)$ değeri maksimize edilir. Burada eğitim kümesindeki her x değeri için d tane nitelik olduğu varsayılmıştır. Bu sebeple $x = (x^1, x^2, \dots, x^d)$ olarak kabul edilerek aşağıdaki hesaplamalar gerçekleştirilir.

$$P(x|S_i) = \prod_{f=1}^d P(x^f | S_i) = P(x^1 | S_i) \times P(x^2 | S_i) \times \dots \times P(x^d | S_i) \quad (57)$$

Bu koşullara bağlı olarak oluşturulan NB kararı aşağıdaki eşitsizlikte sunulan yaklaşıma göre verilir.

$$P(S_i) \prod_{f=1}^d P(x^f | S_i) > P(S_j) \prod_{f=1}^d P(x^f | S_j), \forall j \neq i \quad (58)$$

Eşitsizlikte bir x 'in S_i sınıfına ait olup olmadığı test edilmektedir. Yukarıdaki ifadeye göre eşitsizliğin sol tarafındaki hesaplama sonucu sağ taraftaki hesaplama sonucundan daha büyük çikarsa x 'in S_i sınıfına ait olduğu kabul edilir.

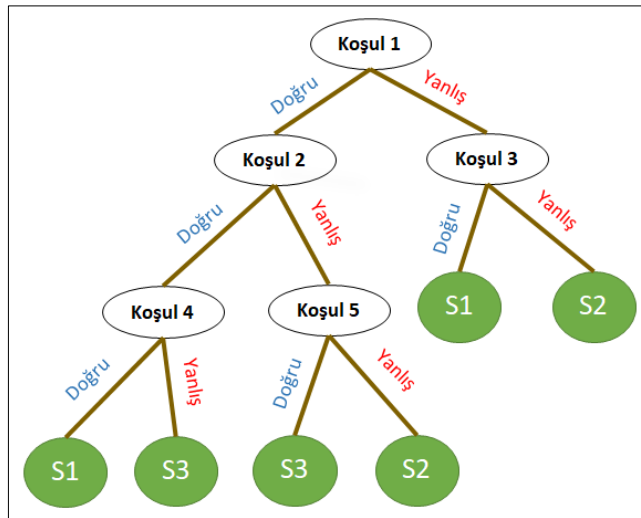
Naive Bayes kararında hesaplanacak $P(x|S_i)$ için, ayrı ayrı elde edilecek her bir olasılığın sıfırdan farklı olması gerekmektedir. Aksi takdirde $P(x|S_i)$ olasılığı sıfır olacaktır ve bu istenmeyen bir durumdur. Bu istenmeyen durumdan kurtulmak için Laplace düzeltmesi kullanılabilir [95].

2.2.5.3. Karar Ağaçları

Karar ağacı (KA), eldeki öznitelik vektörlerine dayanan ağaç benzeri bir akış diyagramı olarak ifade edilebilir. Bu algorithmada bir öznitelik vektör kümesine bağlı olarak dallar ve düğümlerden oluşan bir karar ağacının oluşturulması esastır [89]. Ağaçtaki düğümler özellikleri, dallar özellik değer bilgisini ve yaprak düğümler ise sınıf etiketini belirtmektedir.

Ağaçta üç tip düğüm bulunmaktadır. Bu düğümlerden ilki, kendisine gelen bir dal bulunmayan, kendisinden çıkan sıfır veya daha fazla dala sahip olan “kök düğümü” olarak tanımlanır. Kendisine gelen en az bir dal bulunup, kendisinden çıkan iki veya daha fazla dala sahip olan düğüme “iç düğüm” adı verilmektedir. Kendisine gelen bir dal bulunup çıkan dala sahip olmayan düğümler ise “yaprak” veya “uç düğüm” olarak adlandırılmaktadır.

Ağaç bir kök düğümden başlayarak büyük miktardaki veri kümesini alt dallara bölmek suretiyle ilerler. Her düğümde bir değişken üzerinde test uygulanır ve her dal uygulanan testin sonuçlarından birini ifade etmektedir ve her yaprak düğümü bir sınıf etiketini barındırmaktadır.



Şekil 25. KA yöntemi ile örnek bir sınıflandırma

Karar ağaçları kök düğümden itibaren artımlı olarak ayrılan dallara birer soru düğümü ekleyerek oluşturulur. Düğümler için belirlenecek olan, en az dallanma ile sonuca ulaştırılacak soruların seçimine rehberlik etmek için etiketli eğitim verileri kullanılır. Genellikle tek ve basit bir soru, eğitim örneklerini kolayca sınıflara bölebilmektedir. İyi bir soru, bir grup veriyi heterojen sınıf etiketlerine sahip alt kümlere böler. Böylece veriler her biri arasında küçük varyansları olan katmanlara ayrılmış olur [96]. Bu şekilde bölümlenen bir veri kümesinde homojensizlik veya safsızlık derecesini değerlendirmek için çeşitli ölçümler kullanılmaktadır. KA'da bir sonraki dallanma için homojensizlik veya safsızlık derecesinde kayda değer bir azalma ölçülmediyse, bölme işlemleri tamamlanır ve en alt daldaki mevcut düğüm sonuç düğümüne, diğer adıyla yaprak düğümüne dönüşür. Karar ağaçlarında homojensizlik veya safsızlık derecesinin belirlenmesi için yaygın olarak Entropi ve Gini indeksi ölçümlerinden faydalanılır.

KA oluşturmak için genellikle tercih edilen, CART, ID3 ve C4.5 vb. birkaç algoritma mevcuttur [97]. CART algoritmasında sınıflandırma metriği olarak Gini indeksi benimsenirken, ID3 algoritmasında ise Entropi fonksiyonunu ve buna bağlı olarak bilgi kazancını benimsenmektedir. C4.5 ise ID3 algoritmasının geliştirilmiş bir versiyonudur.

E ile gösterilen bir eğitim kümesinde, m farklı sınıfa ait etiketler S_i $i \in \{1, 2, \dots, m\}$ ile, S_i etiketli değerlerin olasılığı ise P_i ile gösterilmiş olsun. Bu bilgilere göre safsızlık derecesini belirlemek için hesaplanacak Entropi fonksiyonu aşağıdaki gibidir.

$$Entropi(E) = - \sum_{i=1}^n P_i \log_2(P_i) \quad (59)$$

Safsızlık derecesini belirlemek için kullanılan Gini indeksi, kümeden rastgele seçilen bir elemanın yanlış şekilde etiketlenmesinin ne kadar sık olduğunun bir ölçüsüdür. Gini indeksi aşağıdaki formülle hesaplanabilir.

$$Gini(E) = 1 - \sum_{i=1}^m P_i^2 \quad (60)$$

Kurulan karar ağacının performansı, sınıfları önceden bilinen yeni veriler ile kök düğümden başlanmak suretiyle test edilerek belirlenir.

2.2.5.4. Rastgele Orman

Rastgele orman (RO) algoritması ağaç tipi sınıflandırıcılar topluluğu olarak ifade edilebilir. Breiman tarafından geliştirilen bu yöntemde [90] tek bir karar ağacı üretmek yerine her biri farklı eğitim kümelerinde eğitilmiş çok sayıda ağacın kararlarını birleştirmek hedeflenmektedir. RO, bütün değişkenler arasında en iyi dalı kullanmak yerine her düğümde rasgele olan seçilen değişkenler arasından en iyisini kullanarak düğümleri dallara ayırmaktadır. Her veri kümesi orijinal veri kümesinden yer değiştirmeli olarak üretilir ve rasgele öznitelik seçilerek ağaçlar geliştirilir. Geliştirilen ağaçlar budanmaz.

RO'da her ağaç, her bir karar düğümü için eğitim verilerinden bootstrap yöntemi ile veri kümesinden rastgele seçilen örneklere göre eğitilirler. Tahminler, ağaçların çoğunluğuyla (sınıflandırma) veya çıktılarının ortalamasıyla (regresyon) yapılır [98]. Seçilecek altkümenin büyüklüğü belirlenirken, p toplam değişken sayısına bağlı olarak sınıflandırma için varsayılan değer $p^{1/2}$, regresyon için $p/3$ olarak seçilir. Breiman [90], RO'nun genelleme hatasının üst sınırının $r(1 - s^2) / s^2$ ile verildiği belirtmiştir. Burada r ağaçların arasındaki korelasyonun bir ölçüsü olup ve s ise bunların kuvvetlerinin bir ölçüsü olarak tanımlanmıştır.

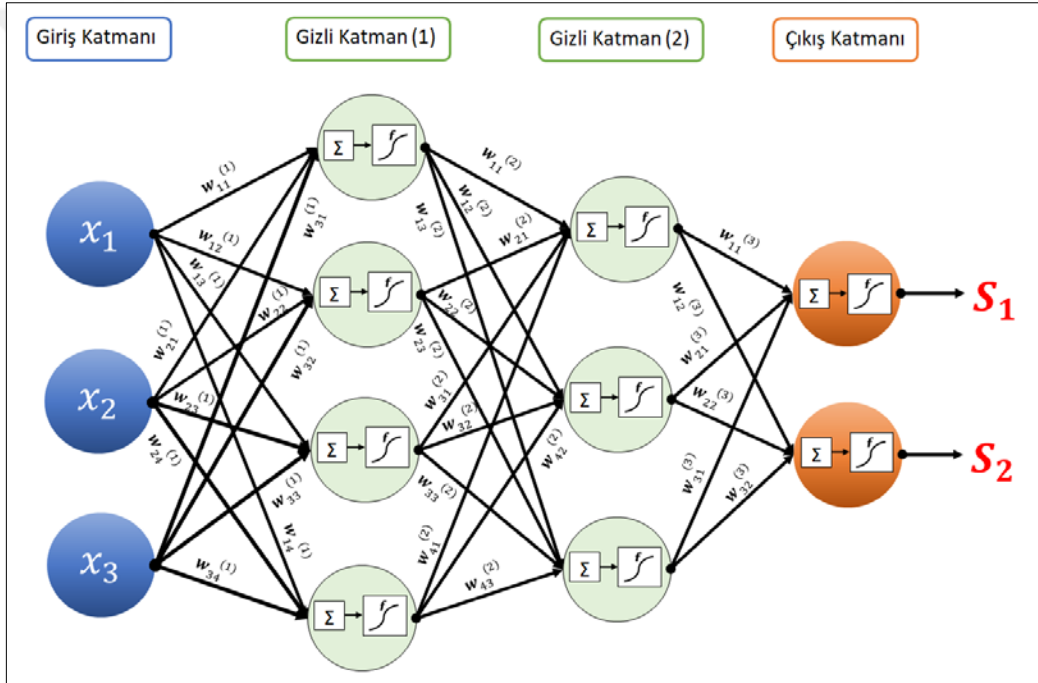
2.2.5.5. Yapay Sinir Ağları

Yapay sinir ağları (YSA) biyolojik nöron sistemlerini simüle eden matematiksel modellerdir [99]. YSA üç veya daha fazla tabakada yer alan nöronlardan oluşmaktadır. Yapay sinir ağında kullanılacak olan veriler giriş katmanından girip, bir veya daha fazla gizli katmandan geçerek çıkış katmanında dışarıya çıkarlar. Her katmandaki düğümler bir sonraki katmandaki düğümlerle bağlantı halindedirler. YSA'da veriler bir önceki katmanda yer alan düğümlerden bir sonraki katmanda yer alan düğümlere doğru bir transfer fonksiyonu aracılığı ile iletilip toplanırlar. Bu transfer fonksiyonu ilgili düğümde 1 veya 0 değeri üretir ve elde edilen sonucu bir sonraki katmandaki ilişkilendirilmiş düğümlere iletilir.

Bu sürecin ilk aşamasında YSA'da giriş katmanından verilen x_n değerleri bir sonraki katmanda yer alan düğümlere bir w ağırlık katsayısı ile işleme sokularak iletilirler. İlgili düğüme gelen değerler bu ağırlık katsayıları ile işleme sokulup toplama fonksiyonu ile toplanarak hücrenin net girdisi elde edilir. Elde edilen net girdi düğümdeki transfer fonksiyonu kullanılarak işleme sokularak y_n çıktısı üretilir ve çıktılar bir sonraki düğüme

aktarırlar. Her işlemin sonucunda öğrenme adımı olarak ifade edilen bir süreçte, w ağırlıkları elde edilen y_n çıkışına göre yeniden ayarlanır. YSA'nın öğrenmeyi tamamlayabilmesi için w ile temsil edilen ağırlık katsayılarındaki değişimin durağan hale gelmesi beklenir. Bu nedenle sisteme veri girişi yapılmaya devam edilerek öğrenme sürdürülür ve ağırlıkların değişimi durduğu zaman sistem öğrenmeyi tamamlamış olur.

Sınıflandırma işlemlerinde girdi tabakasının boyutu genellikle veri kümesindeki değişkenlerin sayısı kadardır. Çıkış tabakasının boyutu ise sınıfların sayısı ile ifade edilebilir. Yapay sinir ağlarında gizli tabakaların sayısı ve boyutları esnekler. Yapay sinir ağının boyutu genellikle deneysel sonuçlara bağlı olarak tespit edilmektedir.



Şekil 26. Bir YSA örneği

YSA'lar öğrenme sürecinde kullanılan eğitim verileri ile yapılandırıldıktan sonra, yeni veriler ile test edilerek genelleme performansları ölçülür. Kurgulanan YSA'lar her ne kadar verilen bir problemin çözümü için (doku, metin, işaret vb. sınıflandırma) tasarlanmış olsalar da kimi zaman farklı bir problemin çözümü için yeniden eğitilerek kullanılabilirler. Eğitim sürecinde kullanılan verilerde hata olması durumunda, bu hata sinir ağının tamamına dağıtılarak işlem sonuçlarına etki etmektedir. Sinir ağının yapısı, büyüklüğü ve bağlantı sayısının çokluğu gibi nedenlerden dolayı verideki hatanın sonuca etkisi düşüktür ve bu nedenle YSA'ların diğer yöntemlere göre hata toleransları daha fazladır.

YSA'ların öğrenme sürecinde sıklıkla kullanılan bazı aktivasyon fonksiyonları şunlardır.

$$f(x) = Cx \text{ (Doğrusal fonksiyon)} \quad (61)$$

$$f(x) = \frac{1}{1 + e^{-x}} \text{ (Sigmoid fonksiyon)} \quad (62)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \text{ (Hiperbolik tanjant fonksiyonu)} \quad (63)$$

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \leq 0 \end{cases} \text{ (Adım fonksiyonu)} \quad (64)$$

2.2.5.6. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayalı olarak çalışan, sınıflandırma problemlerinin çözümü için geliştirilmiş bir öğrenme algoritmasıdır. Orijinal DVM algoritması Vladimir Vapnik tarafından keşfedilmiştir ve şu anki mevcut hali 1995 yılında [92] Corinna Cortes ve Vladimir Vapnik tarafından temelde iki sınıfa ait verilerin doğrusal olarak birbirinden ayrılması için önerilmiştir. DVM'ler doğrusal olarak ayrılamayan, çok sınıfa sahip verilerin sınıflandırılabilmesi için de kullanılabilir. Standart DVM algoritması ikili sınıflandırma problemlerinin çözümü için, her biri iki kategoriden birine ait olarak işaretlenmiş bir dizi eğitim örneğinden yararlanarak, yeni bir örneğin bir kategoriye girip girmediğini veya başka bir kategoriye girip girmediğini öngören bir model oluşturur.

Sezgisel olarak bir DVM modeli[100], örneklerin uzaydaki noktalar olarak gösterilmesidir; ayrı kategorilerin örnekleri mümkün olduğunca açık bir boşluk ile bölünmüştür. Yeni örnekler daha sonra aynı boşluğa yerleştirilir ve boşluğun hangi tarafına düşüyorsa o taraftaki kategoriye ait olduğu öngörülür. Yeni örneklerin doğru sınıflandırılması için eğitim verilerinden elde edilen uzayda ayırıcı en uygun hiperdüzlemin belirlenmesi gerekmektedir. İki sınıfı birbirinden ayırabilecek sonsuz sayıda hiperdüzlemin elde edilmesi mümkündür. Ancak, ayırıcı hiperdüzlemin iki sınıfa ait olan eğitim verilerine en uzak mesafede olması yeni örneklerin en yüksek doğrulukla ayırt edilmesi için zaruri

olacaktır. Bu şarta uymayan, rastgele seçilen bir hiperdüzlem DVM sınıflandırıcının başarısını azaltacaktır.

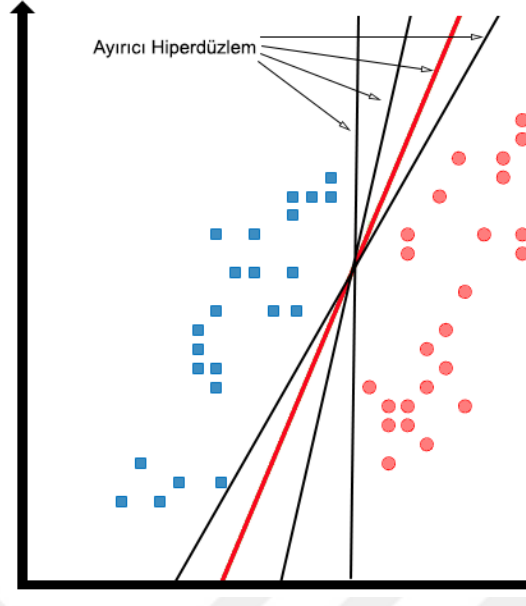
2.2.5.6.1. Destek Vektör Makinelerinin Özü

DVM özünde bir veri kümesi için belirli bir matematiksel fonksiyonun maksimize edilmesi için kullanılan bir algoritma veya matematiksel ifadedir. DVM sınıflamasının özünü anlamak için, sadece dört temel kavramı kavramak yeterlidir: ayırıcı hiperdüzlem, maksimum marjlı hiperdüzlem, yumuşak marj ve çekirdek fonksiyonu.

2.2.5.6.2. Ayırıcı Hiperdüzlem

DVM’de sınıflandırılacak verilerin aralarındaki sınırı belirleyen ayırıcıları, “ayırıcı hiperdüzlem” olarak ifade edebiliriz. İnsan gözü, görsel olarak bir, iki veya üç boyutlu uzayda yerleştirilmiş verileri ayırmakta oldukça başarılıdır. Ancak, DVM gibi sınıflandırma yöntemleri belirli matematiksel fonksiyonlar ve algoritmalar yardımıyla kimi zaman insan gözünün de kolaylıkla ayıramayacağı verileri ayırabilecek en uygun hiperdüzlemin belirlenmesini sağlayabilecek kapasitededirler.


Verilerin temsil edildiği uzaya göre sınıflandırma için farklı ayırıcılar kullanılabilir. Tek boyutlu uzayda bir nokta, iki boyutlu uzayda düz bir çizgi, üç boyutlu uzayda ise bir düzlem kullanarak sınıfları birbirinden ayırabiliriz. Sınıfları birbirinden ayırmak için kullanılan bu ayırıcıları ayırıcı hiperdüzlem olarak tanımlayabiliriz. Çoğunlukla verilerin temsil edildiği uzayda her iki sınıfı birbirinden ayırabilecek sonsuz adet ayırıcı hiperdüzlem çizilebilir.



Şekil 27. Örnek veri kümesi için DVM sınıflandırıcı ile elde edilebilecek olası ayırıcı hiperdüzlemler

2.2.5.6.3. Maksimum Marjlı Hiperdüzlem

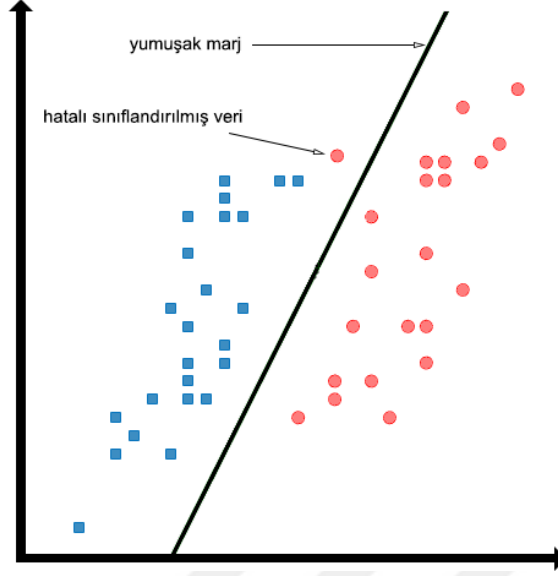
Sınıflandırılacak verilerin yüksek boyutlu bir alan içindeki noktalar olarak ele alınması ve onları birbirinden ayıran bir çizginin bulunması kavramı DVM'nin temel sınıflandırma yaklaşımıdır. Ancak; diğer hiperdüzlemlili sınıflandırıcılardan farklı olarak DVM'nin hiperdüzlem seçiminde kendine özgü kriterleri mevcuttur. DVM'nin amacı farklı sınıflarda yer alan etiketleri birbirinden ayıran en uygun sınır çizgisini belirlemektir. Ancak bu sınırı belirleyecek sonsuz adet sınır çizgisi çizilebilir. Önemli olan eğitim verilerinden yola çıkılarak tespit edilen bu sınır çizgilerinden en uygununu belirleyip, yeni gelecek olan verilerin sınıflandırma başarısını maksimuma çıkartmaktır. Maksimum sınıflandırma başarısı için eğitim verilerinde her iki sınıfa ait etiketlere maksimum mesafede çizilecek çizgi en uygun ayırıcı olarak belirlenir. Mesafeyi hiperdüzlemin marjı olarak ayıran, hiperdüzlemden en yakın ifade vektörüne olan uzaklık olarak tanımlarsak, DVM maksimum marjlı hiperdüzlemi seçer. Bu yöntemle seçilecek hiperdüzlem DVM'nin daha önce görülmeyen verileri doğru sınıflandırma yeteneğini en üst düzeye çıkartır.



Şekil 28. DVM’de maksimum marjlı hiperdüzlem örneği

2.2.5.6.4. Yumuşak Marj

DVM ile gerçekleştirilecek sınıflandırma işleminde gürültü veya üst üste çakışan veriler vb. etkenlerin varlığı sebebiyle sınıflar doğrusal olarak birbirinden ayrılmıyorsa bazı hatalı sınıflandırmalar göz ardı edilerek maksimum marjlı hiperdüzlem tespit edilmeye çalışılabilir. Esasen, yumuşak marj ile bazı veri noktalarının, nihai sonuca etki etmeksizin, ayırıcı hiperdüzlemin sınırının dışında kalması sağlanabilir. Ancak DVM’nin çok fazla hatalı sınıflandırma yapması da arzu edilmeyeceği için yumuşak marj ile yaklaşık kaç tane verinin düzlemin sınırını ihlal edebileceğini belirleyen bir hata parametresinin kullanılması gerekir. Bir hata fonksiyonu yardımı ile belirlenecek olan hata parametresi kullanılarak bir yandan doğrusal ayrılmayan bu veriler için maksimum marj ayarlanırken, diğer yandan ise sınıflandırma hatasının en aza düşürülmesi hedeflenmektedir. Bu parametreyi ayarlamak, doğru sınıflandırılmış örneklere göre hala geniş bir marj yaratmaya çalışmaktan dolayı karmaşıktır. Dolayısıyla, yumuşak kenar parametresi, hiperdüzlem ihlalleri ile marj boyutu arasındaki dengeyi belirtir.




Şekil 29. DVM'de yumuşak marj gösterimi

2.2.5.6.5. Çekirdek Fonksiyonu

DVM'lerin doğrusal olarak sınıflandırma yapamadığı durumlarda doğrusal olmayan sınıflandırma işlemlerini gerçekleştirmesi için kullanılan dönüştürücüler çekirdek fonksiyonları olarak ifade edilmektedirler. Çekirdek fonksiyonu (ÇF) DVM'lerde düşük boyutlu bir uzayda yerleştirilmiş veri kümesinin koordinatlarını daha yüksek boyutlu bir uzaya haritalandırılmasını sağlayan matematiksel ifadelerdir. Bu ifadeler verilerin sınıflara ayrılmasını kolaylaştırmak amacıyla kullanılırlar. Doğrusal olarak ayıramayan verileri için orijinal uzayda tespit edilemeyen maksimum ayırıcı hiperdüzlem, haritalandırma işlemi sonrasında yeni özellik uzayında kolaylıkla elde edilebilmektedir. DVM için seçilecek doğru bir çekirdek fonksiyonu ile veriler yüksek boyutlu uzayda ayrılabilir hale gelecektir. Fonksiyon belirlenirken verilerin ayrılmasına imkan tanıyan, fakat pek fazla alakasız boyuta da haritalandırma yapmayacak bir matematiksel ifadenin kullanılması beklenmektedir.

Seçilecek olan çekirdek fonksiyonu eldeki probleme göre değişkenlik gösterir. Kimi problemlerde polinomial bir fonksiyon en uygun çözümü sunarken, kimi problemde radyal tabanlı bir çekirdek fonksiyonunu tercih etmek daha doğru olabilir.

Sonuç olarak çekirdek fonksiyonları, doğrusal olarak ayıramayan verileri doğrusal ayrılabilir hale getirmektedir.



Şekil 30. DVM doğrusal ayrılamayan veriler (solda), çekirdek fonksiyonu uygulanan DVM sınıflandırma sonucunda elde edilen ayırıcı hiperdüzlem (sağda)

2.2.5.6.6. Doğrusal Destek Vektör Makineleri

Giriş verileri doğrusal olarak ayrılabilir durumda iseler bu verileri birbirinden ayrılabilir sonsuz sayıda ayırıcı vektör içerisinde marjini en yüksek olan ayırıcı vektör seçilir.

İkili sınıflandırma probleminde kullanılacak bir eğitim kümesi için;

$$(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l), x \in \mathcal{R}^n, y \in \{+1, -1\} \quad (65)$$

gösterimi n boyutlu uzayda verilerin yerleşimini belirtmektedir. Başlangıçta ikili sınıflandırma problemleri için $n = 2$ seçilerek iki boyutlu uzayda haritalandırılmış verilerin arasındaki sınırı belirleyecek en uygun hiperdüzlemin tespit edilmesi istenir. Karar sınırı olarak da adlandırılabilir olan hiperdüzlem

$$w_1 x_1 + w_2 x_2 + b = 0 \quad (66)$$

ifadesinin çözümü ile belirlenir [101]. Bu eşitlik ile doğrusal ayrılabilir verilere ait birden fazla karar sınırı bulunabilirken, önemli olan en iyi çözümün nasıl elde edilebileceğidir. Denklem çözümü için, eğitim aşamasında kullanılan giriş verilerinin her birine karşılık

düşecek olan parametrelerinin yer aldığı $w = [w_1 w_2 \dots w_n]^T$ ile b 'ye göre oluşturulacak olan karar fonksiyonu $d(x, w, b)$ elde edilir.

$$d(x, w, b) = w^T x + b = \sum_{i=1}^n w_i x_i + b \quad (67)$$

Karar fonksiyonu kullanılarak eğitim aşamasında kullanılmamış yeni bir x_p değeri için $d(x_p, w, b) > 0$ olması durumunda bu x_p etiketli veri sınıf 1'e, $d(x_p, w, b) < 0$ olması durumunda ise sınıf 2'ye dahil edilir. Ayırıcı hiperdüzlem ise,

$$d(x, w, b) = 0 \quad (68)$$

eşitliği ile elde edilir. Bu eşitlik ile sonsuz sayıda ayırıcı hiperdüzlem elde edilebilir, çünkü verilen bir $d(x, w, b)$ fonksiyonunda pozitif bir k değeri için $d(x, kw, kb)$ ifadesi de doğru karar fonksiyonu olarak kullanılabilir. Bu durumda kanonik hiperdüzlemi belirlemek gerekecektir.

$x \in X$ olarak verilen bir eğitim kümesi için kanonik hiperdüzlem

$$\min_{x_i \in X} |w^T x_i + b| = 1 \quad (69)$$

gösterimi ile ifade edilir.

Tek boyutlu giriş vektörü x için kanonik hiperdüzlem tektir. Daha yüksek boyutlu eğitim verileri için birden fazla kanonik hiperdüzlem elde etmek mümkündür. Bu nedenle, marjı maksimum olan bir kanonik hiperdüzlemi, diğer bir deyişle optimal marjlı kanonik hiperdüzlemi (OMKH) tanımlamaya ihtiyaç vardır.

Sınırlı bir eğitim verisinden elde edilen hiperdüzlem, maksimum marjine sahip olmalıdır, çünkü muhtemel yeni verileri daha iyi sınıflandırır. Kanonik formda olmalıdır, çünkü bu, destek vektörleri olarak adlandırılan değerlerin tespitini ve buna bağlı olarak hesaplamaları kolaylaştıracaktır. Bu şartları sağlayan hiperdüzlem eğitim verilerini ayırabilir durumda olacaktır. Bu bağlamda marjin:

$$M = \frac{2}{\|w\|} \quad (70)$$

olarak hesaplanır. Marjın maksimize edilmesi için denklemden de görüldüğü üzere hiperdüzlem normal ağırlık vektörünün normu $\|w\| = \sqrt{w^T w}$ 'nin minimize edilmesi gerekecektir. Bu durumda öğrenme problemi,

$$\text{enküçükle } \frac{1}{2} w^T w \quad (71)$$

olarak tanımlanır.

OMKH, yani $M = 2/\|w\|$ olarak anılan en büyük marjlı hiperdüzleme en yakın eğitim verilerinin, diğer bir deyişle destek vektörlerinin tespiti için

$$y_i [w^T x_i + b] \geq 1, \quad i = 1, \dots, l \quad (72)$$

koşulları sağlanmalıdır. Burada l ifadesi eğitim için kullanılan verilerin sayısını gösterir.

Bu denklemlerin çözümünü kolaylaştırmak adına optimizasyon problemi Lagrange fonksiyonunun eyer noktası ile çözülür.

$$L(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^l \alpha_i \{y_i [w^T x_i + b] - 1\} \quad (73)$$

Burada α_i Lagrange çarpanlarıdır. Uygun bir eğer noktasını tespit edebilmek için Lagrange fonksiyonu w ve b parametrelerine göre minimize edilmeli, $\alpha_i \geq 0$ şartını sağlayan α_i çarpanına göre maksimize edilmelidir. Bunu yapabilmek için Karush-Kuhn-Tucker (KKT) [101] koşullarını kullanırız. Bu koşulları sağlayabilmek için (w_0, b_0, α_0) eyer noktasında Lagrange fonksiyonunun türevi alınır.

$$\frac{\partial L}{\partial w_0} = w_0 - \sum_{i=1}^l \alpha_i y_i x_i \quad (74)$$

$$\frac{\partial L}{\partial b_0} = \sum_{i=1}^l \alpha_i y_i = 0 \quad (75)$$

Bunun haricinde KKT için aşağıdaki tamamlayıcı koşul da sağlanmalıdır.

$$\alpha_i \{y_i [w^T x_i + b] - 1\} = 0, \quad i = 1, \dots, l \quad (76)$$

Bütün bu dönüşümler sonucunda Lagrange fonksiyonu,

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (77)$$

olarak güncelleştirilir. Optimal hiperdüzlemi bulmak için Lagrange fonksiyonu negatif olmayan α_i 'ye göre maksimuma çıkartılmalıdır ve eşitlik kısıtlamasına göre aşağıdaki gibi olmalıdır:

$$\alpha_i \geq 0, \quad i = 1, l \quad \text{ve} \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (78)$$

İkili optimizasyon probleminin α_{0i} 'ye göre çözümünde optimal hiperdüzlemin bulunması için w_0 ve b_0 parametreleri aşağıdaki gibi bulunur:

$$w_0 = \sum_{i=1}^l \alpha_{0i} y_i x_i \quad (79)$$

$$b_0 = \frac{1}{N_{SV}} \left(\sum_{s=1}^{N_{SV}} \left(\frac{1}{y_s} - x_s^T w_0 \right) \right) = \frac{1}{N_{SV}} \left(\sum_{s=1}^{N_{SV}} (y_s - x_s^T w_0) \right), \quad s = 1, N_s \quad (80)$$

Sonuç olarak, w_0 ve b_0 parametreleri kullanılarak karar hiperdüzlemi şu şekilde hesaplanır:

$$D(x) = \sum_{i=1}^l w_{0i} \alpha_i + b_0 = \sum_{i=1}^l y_i \alpha_i x_i^T + b_0, \quad g_F = 0 = \text{sign}(d(x)) \quad (81)$$

2.2.5.6.7. Yumuşak Marjlı Doğrusal Destek Vektör Makineleri

Doğrusal destek vektör makinelerinde ifade edilen öğrenme prosedürü doğrusal ayrılabilir verilerin sınıflandırılması için geçerlidir. Ancak; üst üste çakışma sorunu bulunan eğitim verilerinde gerçekleştirilecek olan öğrenme sürecinde problemin çözümü için yumuşak marjın belirlenmesi, az bir hata ile doğru sınıflandırma yapılmasını mümkün kılacaktır.

Sınıfların çakışması durumunda, örtüşen veri noktaları doğru şekilde sınıflandırılmaz. Herhangi bir yanlış sınıflandırılmış eğitim veri noktası x_i için, karşılık gelen α_i sonsuza doğru eğilim gösterir ve α_i değeri maksimum sınırlara ulaştığında, artık etkisini artıramaz ve karşılık gelen nokta yanlış sınıflandırılır. Maksimum marjı olan bir sınıflandırıcı bulmak için karar sınırının yanlış tarafına veri bırakarak yumuşak bir marja izin verilmeli ve bu marj dahilindeki veriler ihmal edilmelidir. Yumuşak marjın genişliği uygun bir C parametresi ile kontrol edilerek eğitim hatası ile modelin Vapnik-Chervonenkis (VC) [102] boyutu arasındaki denge kurulabilir.

Bu problemin çözümü için öğrenme probleminin güncellenmesi gerekecektir

$$\text{enküçükle } \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i \quad (82)$$

Burada C ifadesi yanlış sınıflandırılmış veri noktalarının sayısı için marjın büyüklüğünün ayarlayan bir “ceza parametresi” olarak işlev görür. C değerinin büyük olması sınıflandırma hatalarının az olmasına sebep olur ve buna karşılık daha küçük bir marja yol açar. Çözüm için kullanılan ξ_i ifadesi, hatalı sınıflandırılan verilerin marja olan uzaklığını belirtmektedir.

Hiperdüzleme en yakın eğitim verilerinin, diğer bir deyişle destek vektörlerinin tespiti Denklem 82’de ξ_i ifadesinin de dahil edildiği aşağıdaki koşullar sağlanmalıdır.

$$y_i [w^T x_i + b] \geq 1 - \xi_i, \quad i = 1, \dots, l, \quad \xi_i \geq 0 \quad (83)$$

Benzer şekilde ξ_i ’nin dahil edildiği Lagrange fonksiyonu aşağıdaki gibi oluşturulur.

$$L(w, b, \xi, \alpha, \beta) = \frac{1}{2} w^T w + C \left(\sum_{i=1}^l \xi_i \right) - \sum_{i=1}^l \alpha_i \{ y_i [w^T x_i + b] - 1 + \xi_i \} - \sum_{i=1}^l \beta_i \xi_i \quad (84)$$

Aşağıdaki KKT tamamlayıcılık koşulları ile;

$$\alpha_i \{ y_i [w^T x_i + b] - 1 + \xi_i \} = 0, \quad i = 1, \dots, l \quad (85)$$

$$\beta_i \xi_i = (C - \alpha_i) \xi_i = 0, \quad i = 1, \dots, l \quad (86)$$

Lagrange fonksiyonu güncellenerek yumuşak marjın belirlenebilmesi için aşağıdaki formunu alır.

$$L_d(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \left(x_i^T x_j + \frac{\delta_{ij}}{C} \right) \quad (87)$$

$$\alpha_i \geq 0, \quad i = 1, l \quad \text{ve} \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (88)$$

2.2.5.6.8. Doğrusal Olmayan Destek Vektör Makineleri

Doğrusal olmayan destek vektör makinelerin amacı doğrusal olmayan bir karar hiperdüzlem oluşturabilen bir DVM ile doğrusal olmayan ayrılabilir verilerin sınıflandırılmasını gerçekleştirebilmektir. Doğrusal olmayan DVM'lerin tasarlanmasındaki temel fikir, $x \in \mathfrak{R}^n$ girdi vektörlerini daha yüksek boyutlu bir öznelik uzayı F 'ye haritalandırarak, $\Phi(x)$ vektörlerine dönüştürmek ve böylece yeni özellik uzayında probleme doğrusal bir çözüm bulmaktır.

$$x \in \mathfrak{R}^n \rightarrow \Phi(x) = [\phi_1(x), \phi_2(x), \dots, \phi_n(x)]^T \in \mathfrak{R}^f \quad (89)$$

Burada böyle bir haritalama yaparak, öğrenme algoritmamızın, yukarıda sunulan doğrusal DVM formülasyonunu uygulayarak, $\Phi(x)$ uzayında x 'e karşılık gelen verilerin doğrusal olarak ayrılabilmesi hedeflenir.

Bir x giriş uzayını daha yüksek dereceli bir F uzayına eşleştirirken, eğitim verilerine ait özneliklerin çok olması durumunda $\Phi^T(x) \Phi(x)$ 'nin hesaplanması zorlaşacaktır. Bu durum veri madenciliğinde “boyutun laneti” [103] olarak ifade edilmektedir. Bahsi geçen hesaplama sorunlarından kurtulabilmek için bulunacak çözüm, probleme uygun bir çekirdek fonksiyonunun tercih edilmesidir.

DVM sınıflandırıcısının gösteriminde yer alan eğitim verilerini skaler çarpımı $x_i^T x_j$ ifadesi yüksek dereceli bir F uzayında;

$$\Phi^T(x) \Phi(x)_i = [\phi_1(x), \phi_2(x), \dots, \phi_n(x)]^T [\phi_1(x_i), \phi_2(x_i), \dots, \phi_n(x_i)] \quad (90)$$

skaler çarpımına dönüştürülür. Bu skaler çarpım daha sonra çekirdek fonksiyonu:

$$K(x_i, x_j) = \Phi^T(x_i) \Phi(x_j) \quad (91)$$

olarak ifade edilir. K ile ifade edilen çekirdek fonksiyonu giriş uzayındaki bir fonksiyondur. Özellik uzayındaki $\Phi^T(x_i) \Phi(x_j)$ skaler çarpımı bir girdi uzayında verilen eğitim verisi vektörleri için $K(x_i, x_j)$ çekirdek fonksiyonu aracılığı ile doğrudan hesaplanabilir.

Bu hesaplamalarda sıklıkla tercih edilen bazı çekirdek fonksiyonları şunlardır:

$$K(x, y) = (x^T y) + c \quad (\text{lineer ÇF}) \quad (92)$$

$$K(x, y) = [(ax^T y) + c]^d \quad (\text{polinomal ÇF}) \quad (93)$$

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (\text{Gauss ÇF}) \quad (94)$$

$$K(x, y) = \sum_{k=1}^n \exp\left(-\sigma(x^k - y^k)^2\right)^d \quad (\text{ANOVA ÇF}) \quad (95)$$

$$K(x, y) = \begin{cases} \frac{3}{2} \left(1 - \left\| \frac{x, y}{\sigma} \right\|^2 \right), & \frac{\|x - y\|}{\sigma} \leq 1 \\ 0, & \text{diğer durum} \end{cases} \quad (\text{Epanechnikov } \text{ÇF}) \quad (96)$$

2.2.6. Veri Sınıflandırmada Doğrulama Teknikleri


Çapraz doğrulama, sınıflandırma problemlerinde kullanılan verileri bölümlere ayırarak sınıflandırıcıyı değerlendirmek ve test hatasını belirlemek için kullanılan istatistiksel bir yöntemdir. Tipik çapraz doğrulamada eğitim ve doğrulama kümeleri her bir turda çapraz olarak yer değiştirilerek doğrulama gerçekleştirilir [104].

2.2.6.1. 10-Kat Çapraz Doğrulama

10-kat çapraz doğrulama (10KÇD) tekniğinde, ilgili sınıflandırıcı için kullanılacak olan veriler $k = 10$ adet eşit (veya yaklaşık eşit) parçaya ayrılır [104]. Daha sonra ilk parçadan son parçaya kadar her bir parça 10 adet yineleme adımında işleme koyulur. Her bir yineleme adımında kullanılan parçalardan birisi test için ayrılır, geriye kalan $k - 1$ parça ise eğitim için kullanılır. Böylece her bir yineleme adımında veri kümesinin $9/10$ 'u eğitim için, $1/10$ 'u ise test için kullanılmış olur. Her yinelemede kullanılan parça ve buna bağlı olarak eğitim kümesi değişecektir. Bütün işlem adımları sonunda elde edilen sınıflandırma hatası:

$$SH = \frac{\sum_{i=1}^k SF(EP_i, D - EP_i)}{k} \quad (97)$$

eşitliği ile hesaplanacaktır. Burada D veri kümesini, $EP_i \in D, i = 1, \dots, k$ ilgili yineleme adımında kullanılan parçayı, $D - EP_i$ kullanılan parçanın dışında kalan verileri, SF ise kullanılan sınıflandırıcı fonksiyonunu temsil etmektedir. SH ifadesi ise, her adımda elde edilen SH_i sınıflandırma hatalarının toplamının $k = 10$ 'a bölünmesiyle elde edilen ortalama hata, ya da diğer deyişle performans sonucunu göstermektedir.



Şekil 31. 10-kat çapraz doğrulama yöntemi uygulaması

2.2.6.2. 2-Kat Çapraz Doğrulama

2-kat çapraz doğrulama (2KÇD) yönteminde, 10-kat çapraz doğrulama yöntemindekinden farklı olarak veri kümesi $k = 2$ adet rasgele alt parçaya ayrılır. İki yineleme adımının olduğu bu doğrulama sürecinde ilk adımda EP_1 eğitim, EP_2 test kümesi olarak sınıflandırıcıya verilir ve daha sonraki adımda ise EP_2 eğitim EP_1 test kümesi olarak işlem görür.

2.2.6.3. Birini Dışarıda Bırak Çapraz Doğrulama

Birini dışarıda bırak çapraz doğrulama (BDBÇD) yönteminde veri kümesindeki her bir veri için yinelemeli bir eğitim ve test modeli uygulanır. Her yineleme adımında eğitim kümesinden bir veri küme dışı bırakılır ve bunun dışındaki diğer tüm veriler eğitim aşamasında değerlendirilir. Eğitim aşamasından sonra küme dışında kalan değer eğitilen sınıflandırıcıya test aşaması için sunulur ve sınıflandırma performansı ölçülür. Bu işlem eğitim kümesindeki her bir veri için tekrar edilir. Elde edilen sınıflandırma hatası:

$$SH = \frac{\sum_{i=1}^n SF(x_i, D - x_i)}{n} \quad (98)$$

ile hesaplanır. Burada D veri kümesini, $x_i \in D, i = 1, \dots, n$ ilgili yineleme adımında test için kullanılacak değeri, $D - x_i$ eğitim aşamasında kullanılacak olan x_i değeri dışında kalan tüm verileri, SF ise kullanılan sınıflandırıcı fonksiyonunu belirtir. SH ifadesi ise her adımda elde edilen SH_i sınıflandırma hatalarının toplamının veri kümesi boyutunu gösteren n değerine bölünmesiyle elde edilen ortalama hatayı göstermektedir.

2.2.6.4. Bölünmüş Örnek Doğrulama

Bölünmüş örnek doğrulama (BÖD) yönteminde veri kümesi $k = 2$ adet alt parçaya ayrılır. D veri kümesinden tabakalı örnekleme [105] ile elde edilen, $EP_i \in D, i = 1, 2$ alt veri kümelerindeki tahmini ortalama değerlerin yaklaşık olarak eşit olması beklenir.

Tabakalama işleminde D veri kümesi EP_1, EP_2, \dots, EP_H ile temsil edilen ve her biri N_1, N_2, \dots, N_H adet elemana sahip örneklem kümelerine ayrılacaktır. İki kat çapraz doğrulamada iki tabaka oluşturulacağı için H değeri $k = 2$ değeri ile aynı kabul edilecektir. Tabakalama işleminde elde edilecek alt kümelere ait tahmini ortalama değerler aşağıdaki koşullara göre bulunur.

$$N = \sum_{h=1}^H N_h \quad (99)$$

$$T_h = \sum_{i=1}^{N_h} y_{hi} \Rightarrow T = \sum_{h=1}^H T_h \quad (100)$$

$$\bar{y}_h = \frac{T_h}{N_h} \Rightarrow \bar{y} = W_1 \bar{y}_1 + W_2 \bar{y}_2 + \dots + W_H \bar{y}_H \quad (101)$$

$$W_h = \frac{N_h}{N} \Rightarrow \sum_{h=1}^H W_h = 1 \quad (102)$$

Burada T_h ilgili örneklem kümesindeki değerler toplamını, \bar{y}_h ilgili örneklem kümesi ortalamasını, \bar{y} veri kümesinin tümünün ortalamasını, W_h ise Denklem 102'deki eşitliğin elde edilmesini sağlayan ve her bir kümeyle karşılık gelen ağırlık değerlerini temsil etmektedir. Eşit boyutlu iki veri kümesi elde etmek için $W_h = 0.5$ olarak elde edilecektir.

2.2.7. İleriye Doğru Seçim Algoritması

İleriye doğru seçim (İDS) [106] öznitelik vektöründen ilgili sınıflandırıcı için en yüksek performansı verecek uygun bir alt kümenin elde edilmesini sağlayan bir yöntemdir. İDS prosedürü öznitelik vektöründen her biri tek veriden oluşan alt kümeler oluşturularak başlatılır. Seçilen her bir öznitelik değeri sırası ile ilgili sınıflandırıcıda test edilir ve ilgili alt kümeyle ait sınıflandırma performansı belirlenir. Daha sonra iki elemanlı alt kümeler oluşturularak aynı performans testleri yinelenir. Bu prosedür üçlü, dörtlü ve daha fazla öznitelik barındıran alt kümelerin oluşturulması ve performans testleri ile sürdürülür. Bu testler sonucunda en yüksek başarıyı veren alt kümede tespit edilerek öznitelik seçimi gerçekleştirilmiş olur.

2.2.8. Temel Bileşenler Analizi

Temel bileşenler analizi (TBA) bir veri tablosundaki değerlerin birbiri ile ilişkili değerler ile tanımlanmasını sağlayan çok değişkenli bir tekniktir [107]. Bu tekniğin amacı önemli bilgileri veri tablosundan çıkartmak, onu temel bileşenler olarak adlandırılan yeni ortogonal değişkenler olarak temsil etmek, gözlemlerin ve değişkenlerin benzerlik örüntülerini haritalardaki noktalar olarak göstermektir [108].

TBA'nın kullanım amacı aşağıdaki maddelerde ifade edildiği gibidir.

1. Veri kümesinden en önemli bilgileri çıkartmak;
2. Yalnızca bu önemli bilgileri koruyarak veri kümesinin boyutunu sıkıştırmak;
3. Veri kümesinin tanımını basitleştirmek;
4. Gözlem ve değişkenlerin yapısını analiz etmek

Bu hedeflere ulaşmak için TBA, veri kümesindeki değerleri kullanarak yeni değişkenleri hesaplar. Yeni değişkenler asıl değişkenlerin doğrusal kombinasyonları olarak elde edilen temel bileşenler olarak adlandırılırlar. İlk temel bileşen mümkün olan en büyük varyansa sahip olmak zorundadır. İkinci bileşen birinci bileşene dik olma ve mümkün olan en büyük ataletle sahip olma kısıtlaması altında hesaplanır. Diğer bileşenler de benzer şekilde hesaplanarak temel bileşenler elde edilir. İlk hesaplanan temel bileşen toplam değişkenliği en iyi ifade eden değerdir. Sıradaki temel bileşenler de kalan değişkenlikleri en iyi şekilde ifade ederler. Bu özellikteki temel bileşenler aynı zamanda korelasyonsuzdurlar. Gözlemler için bu yeni değişkenlerin değerlerine faktör puanları denir ve bu faktörlerin

puanları geometrik olarak gözlemlerin temel bileşenler üzerine izdüşümü şeklinde yorumlanabilir.

TBA herhangi bir veri matrisine uygulanabilir. TBA ayrıca çok değişkenli bir analizin ilk adımı olarak verilerin yapısında bir ön izlenim elde etmek için, aykırılıkların tanımlanması, sınıfların tasvir edilmesi vb. sebeplerle kullanılabilir. Bununla birlikte amaç bir değişken grubunun sınıflandırılması ile ilgili ise bu problemlerin çözümü için daha verimli olan TBA uzantıları mevcuttur. Bu doğrultuda TBA ile birlikte kullanılacak çekirdek fonksiyonlarından yararlanılabilir.



3. BULGULAR VE İRDELEME


3.1. Görüntülerde Ön İşleme Çalışmaları

KIBT görüntülerinde meydana gelebilecek gürültülerin bertaraf edilmesi, görüntülerin kalitesinin artmasını sağlayacaktır. Görüntü kalitesindeki artış, ilerleyen işlem adımlarında gerçekleştirilecek bölütlemelerin performanslarının da iyileştirilmesine katkı sağlayacaktır.

3.1.1. Gürültü Seviyesi Kestirim Deneyleri

Ön işlem adımı için verilecek karar KIBT görüntüsünde gürültü bilgisinin mevcut olup olmadığını tespit edilmesi ile ilişkilidir. Gürültü tespit edilen görüntülere ön işlem uygulanırken, gürültü tespit edilmeyen görüntülere ön işlem uygulanmayacaktır.

Gürültü seviyesi tespiti için kullanılacak olan kestirim metodunun [64] çalışma prensibini açıklamak amacıyla bazı deneyler gerçekleştirilmiştir. İlk deney grubunda 512x512 boyutlarında 0-256 gri seviye aralıklarında tek bir değer alan bir test görüntüsü üretilmiştir. Bu test görüntüsüne farklı seviyelerde Gauss gürültüsü eklenmiş ve gürültü seviyesi kestirim metodu kullanılarak eklenen gürültünün seviyesi tespit edilmiştir.




Şekil 32. Homojen, tek gri seviye (128) değerli 512x512 boyutundaki sentetik görüntü (solda), sentetik görüntüye $\sigma_g=5$ değerli gauss gürültüsü uygulaması sonucunda elde edilen çıktı ve tahmin edilen gürültü seviyesi $\sigma_n=4.9289$ (sağda)

Tablo 3. 512x512 ebatlı tek gri seviyeli görüntüye uygulanan gürültüler ve gürültü seviyesi kestirim sonuçları

Gri Seviye Değeri	Gürültü Değeri (σ_g)	Gürültü Seviyesi (σ_n)
128	5	4,9167
100	5	4,9249
70	5	4,927
50	5	4,9386
30	5	4,9408
128	10	9,8218
100	10	9,864
70	10	9,8685
50	10	9,8744
30	10	9,8945

İkinci deney grubunda 512x512 boyutlarında 0-256 aralıklarında değerler alan 16 farklı gri seviye değerli dama tahtası görünümünde bir test görüntüsü oluşturulmuştur. Bir önceki deneyde olduğu gibi bu görüntüye de farklı seviyelerde Gauss gürültüsü eklenip gürültü seviyesi kestirim metodu yardımıyla eklenen gürültünün seviyesi belirlenmiştir.




Şekil 33. 512x512 boyutunda 0-256 aralığında 16 farklı gri seviye değerli sentetik dama tahtası görüntüsü (solda), sentetik görüntüye $\sigma_g=5$ değerli gauss gürültüsü uygulaması sonucunda elde edilen çıktı ve tahmin edilen gürültü seviyesi $\sigma_n=4.9458$ (sağda)

Tablo 4. 512x512 ebatlı, 0-256 aralığında 16 gri seviye değerli sentetik dama tahtasına uygulanan gürültüler ve gürültü seviyesi kestirimi sonuçları

Gürültü Değeri (σ_g)	Gürültü Seviyesi (σ_n)
1	0,98624
3	2,9696
5	4,9507
7	6,9027
10	9,8761
15	14,8504
20	19,7339
25	24,7863
30	29,4988

Deneilerin sonucunda gürültü seviyesi kestirim yönteminin, teorisinde de ifade edildiği üzere, görüntüdeki zayıf doku parçalarından faydalanarak görüntüdeki gürültü seviyesini doğruya çok yakın bir değerde tahmin ettiği gözlemlenmiştir. Bunun nedeni, gürültünün zayıf doku parçalarında daha baskın olmasıdır.

Gürültü seviyesi kestirim yönteminin etkilerini gözlemlemek için KIBT cihazı ile elde edilmiş, Hounsfield [15] skalasına göre DICOM [109] formatındaki 10 farklı veri kümesi için de deneyler gerçekleştirilmiştir. Veri kümesinden elde edilen 10 farklı görüntü kesiti önceki deney gruplarında olduğu gibi 0-256 aralığına ölçeklenmiş ve bu görüntülere farklı seviyelerde sentetik Gauss gürültüsü eklenmiştir. Ardından, gürültü seviyesi kestirim metodu yardımıyla eklenen gürültülerin seviyeleri belirlenmiştir.



Şekil 34. KIBT ile elde edilen örnek bir görüntü kesiti ($\sigma_g=10$ değerli gauss gürültüsü uygulaması sonucunda elde edilen çıktı ve tahmin edilen gürültü seviyesi $\sigma_n=10.0151$ (sağda)

Tablo 5. KIBT ile elde edilen 10 farklı görüntü kesitlerine uygulana gürültü değerleri ve gürültü seviyesi kestirim yöntemi ile tahmin edilen gürültü seviyeleri

σ_g	σ_n									
	Dosya1	Dosya2	Dosya3	Dosya4	Dosya5	Dosya6	Dosya7	Dosya8	Dosya9	Dosya10
1	0,9494	0,9218	0,9359	0,9503	0,9388	0,9407	0,9405	0,9648	0,9418	0,9594
3	2,9216	2,8197	2,8905	2,9226	2,9579	2,8832	2,9013	2,9456	2,9083	2,9238
5	4,9481	4,815	4,9734	4,901	4,9861	4,9337	4,9748	5,0155	4,9256	4,9188
7	6,9981	6,8342	6,982	7,0023	6,997	6,9816	7,0185	7,0361	6,9811	6,9821
10	9,9857	9,8262	9,9539	9,9884	9,9932	9,9875	9,9949	9,9657	9,9858	9,9944
15	14,9002	14,9576	14,9404	14,9813	14,8711	14,9982	14,8878	14,8532	15,0016	14,9865
20	19,8192	19,9284	19,8046	19,9572	19,7617	19,8801	19,8131	19,9025	19,8622	19,8096

Bu deneylerin sonucuna göre gürültü seviyesi kestirim yöntemi, uygulanan sentetik gürültülerin seviyesini çok küçük hata payları ile doğru tespit etmiştir. Bu veriler ve konu ile ilgili daha önce gerçekleştirilen çalışmalar da [68,73] gürültü seviyesi kestirim yönteminin doğru sonuçlar verdiğini ortaya koymuştur.

3.1.2. Gürültü Temizleme Deneyleri

Ön işlem adımında kullanılacak gürültü temizleme yönteminin performansı sonraki işlem adımlarında uygulanacak bölütleme yönteminin performansını da etkileyecektir. Bu amaçla Bölüm 2.2.1’de önerilen gürültü temizleme yaklaşımı, bir diğer ifade ile adaptif AY metodu kullanılarak diğer yöntemlerin performanslarının karşılaştırıldığı deneyler gerçekleştirilmiştir.

KIBT görüntüleri arasında gürültü bilgisi içermeyen kesitlerin tespit edilmesi deneylerde kullanılacak veri kümesinin belirlenmesi için ilk aşamadır. İlgili kesitler gürültü seviyesi belirleme yöntemi kullanılarak gürültü değeri sıfır olarak tespit edilen KIBT kesitleri arasından seçilmektedir. Bu işlem adımı sonucunda 1200 adet, gürültü bilgisi içermeyen 2B KIBT görüntü kesitleri deney kümesi olarak belirlenmiştir.

Deney kümesinde yer alan kesitlerin her birine farklı seviyelerde Gauss ve Poisson gürültüleri uygulanmıştır. Böylece, aynı görüntülerin mutlak doğru kabul edilecek gürültüden arındırılmış ve deneylerde kullanılacak gürültü uygulanmış versiyonları elde edilmiştir.

Gürültü temizleme deneylerinde 15 yineleme adımlı konvansiyonel AY filtreleme [66], Tsiotsios & Petrou tarafından geliştirilen otomatik AY filtreleme [110] ve önerdiğimiz adaptif AY filtreleme [73] yöntemleri sırasıyla denenmiştir.

Her üç yöntemin uygulanması sonucunda elde edilen çıktılar, gürültü temizleme performansının ölçülmesi için kayıt edilmiş ve mutlak doğru kabul edilen orijinal, gürültü içermeyen versiyonlarla karşılaştırılmıştır. Karşılaştırmalar sonucunda DSGO ve MHO değerleri elde edilmiş ve ilgili yöntemin performansı belirlenmiştir.

Gerçekleştirilen deneylerin sonuçları Tablo 6 ve Tablo 7’de gösterilmiştir.

Tablo 6. 1200 KIBT görüntü kesitinde Gauss gürültüsü temizleme deneylerine ait sonuçlar [73].

Gürültü Temizleme Metodu	Performans Metriği	Gürültü Seviyesi (Sigma)			
		0.01	0.025	0.05	0.1
AY Metodu (15 yinelemeli)	DSGO	77.362	75.828	73.894	70.127
	MHO	0.0252	0.0308	0.0423	0.0695
Tsiotsios & Petrou Metodu	DSGO	77.388	75.333	73.079	69.835
	MHO	0.0257	0.0335	0.0447	0.0670
Adaptif AY Metodu	DSGO	78.571	76.243	73.922	70.988
	MHO	0.0230	0.0305	0.0410	0.0605

Tablo 7. 1200 KIBT görüntü kesitinde Poisson gürültüsü temizleme deneylerine ait sonuçlar [73].

Gürültü Temizleme Metodu	Performans Metriği	Gürültü Seviyesi (Genel Ortalama)
AY Metodu (15 yinelemeli)	DSGO	76.953
	MHO	0.0274
Tsiotsios & Petrou Metodu	DSGO	71.068
	MHO	0.0575
Adaptif AY Metodu	DSGO	78.475
	MHO	0.0233


Sonuçlar değerlendirildiğinde önerilen adaptif AY gürültü temizleme yaklaşımı, diğer yöntemlere göre daha iyi performans göstermiştir ve ön işlemede kullanıma uygundur.

3.2.Manuel Bölütleme

Çalışmamızda yarı otomatik bölütleme performanslarının incelenmesi ve aynı zamanda sınıflandırma deneylerinde kullanılacak öznelik vektörlerinin elde edilmesi işlemlerinde mutlak doğru kabul edilecek olan 3B bölütlerin çıkartılması gerekmektedir. Bu


amaçla geliştirilen yazılımda mevcut bulunan manuel bölütleme araçları kullanılmış ve 50 adet KIBT görüntüsündeki lezyonların tamamı uzmanlar tarafından işaretlenerek bölütlenmiştir. Manuel bölütleme işlemi işlem adımları şu şekilde gerçekleşmektedir:

1. Manuel bölütleme işleminde kullanılacak olan DICOM formatındaki 3B KIBT verisi, yazılım ekranından yüklenir.
2. Uzman KIBT görüntüsünde üç farklı kesitte gözlemler yaparak lezyonlu bölgenin yerini tespit eder.
3. Seçilen bir eksenden (aksiyal, sagittal veya koronal) başlayarak 2B görüntüde lezyonlu bölgeye karşılık gelen alan yazılımda yer alan çizim aracı ile serbestçe işaretlenir.
4. Bölütleme işlemi ilgili kesit ekseni boyunca lezyonlu bölgeye karşılık gelen diğer 2B kesitlerin işaretlenmesi ile tamamlanır.



Şekil 35. Manuel bölütleme aşaması görselleri. 2B kesitte işaretlenmemiş lezyonlu bölge (solda), işaretleme sonrası 2B görüntü kesiti (sağda) [76].

Bu uygulamada 50 farklı hastaya ait KIBT görüntüsünde tespit edilen lezyonlar için her bir görüntüde ortalama 127 kesit, toplamda ise 6397 adet kesitte işaretleme gerçekleştirilmiştir.



Şekil 36. Kullanılan veri kümesinde manuel bölütleme işlemleri sonucunda elde edilen lezyonlu bölgelerin 3B gösterimleri

3.3. Yarı Otomatik Bölütme Deneyleri

KIBT görüntülerinde gözlemlenen lezyonların manuel bölütlenmesi uzun süren ve zahmetli bir işlemdir. Medikal görüntülerdeki patolojilerin tespit edilmesi ve tanımlanması

için geliştirilen karar destek sistemlerinin önemli özelliklerinden birisi otomatik veya yarı otomatik bölütleme mekanizmalarıdır. Tezin ikinci bölümünde bahsedilen yarı otomatik bölütleme yaklaşımı KIBT görüntülerindeki lezyonların kısa sürede, zahmetsizce ve yüksek doğruluk oranı ile işaretlenmesini gerçekleştirmek hedefiyle önerilmiştir.

Çalışmamızda 50 farklı KIBT görüntüsünden elde edilen lezyonlu bölgeler yarı otomatik bölütleme yöntemi ile işaretlenmişlerdir. Bu amaçla her lezyon için gerçekleştirilen işlem adımları aşağıda maddeler halinde sıralanmıştır.

1. Yatı otomatik bölütleme işleminde kullanılacak olan DICOM formatındaki 3B KIBT verisi, yazılım ekranından yüklenir.
2. Hekim KIBT görüntüsünde üç farklı kesitte gözlemler yaparak lezyonlu bölgenin yerini tespit eder.
3. Seçilen bir eksenden (aksiyal, sagittal veya koronal) başlayarak 2B görüntüde lezyonlu bölgeye karşılık gelen alanın içine bir kapalı kontur, dışına da başka bir kapalı kontur çizilerek bölütleme işlemi başlatılır.
4. İlgili kesitte elde edilen bölütleme sonucu bir sonraki kesit için başlangıç konturu olarak belirlenir. Bu konturun başlangıçta kullanıcı tarafından belirlenen bir mesafeye kadar genişletilmesi ile dış, yine belli bir mesafeye kadar daraltılması ile de iç kontur otomatik olarak oluşturulur.
5. Otomatik oluşturulan iç ve dış konturlara göre ilgili kesitte bölütleme gerçekleştirilir ve bu işlem adımları diğer kesitlerde eşik değeri kontrolüne bağlı olarak sürdürülür.
6. Eşik değeri aşıldığı durumda bölütleme tamamlanır ve 2B kesitlerdeki her bir bölüte karşılık gelen 3B matrisi oluşturulur ve görselleştirilir.

Yarı otomatik bölütleme sonuçlarının performansları, aynı lezyonlu bölgeye ait olan ve mutlak doğru kabul edilen manuel bölütleme sonucu ile karşılaştırılarak hesaplanır. Gerçekleştirilen deneylere bağlı olarak 50 KIBT görüntüsündeki periapikal kist ve KOT lezyonlarının yarı otomatik bölütleme performansları Tablo 8’de verilmiştir.

Tablo 8. 50 KIBT görüntüsünde yarı otomatik lezyon bölütleme benzerlik karşılaştırmaları sonuçlarına ait ortalama performans değerleri

Düzlem	Jaccard indeksi		Dice katsayısı	
	Ortalama	Standart sapma	Ortalama	Standart Sapma
Aksiyal	0.76	± 0.12	0.86	$\pm 0,09$
Sagital	0.77	± 0.10	0.87	$\pm 0,06$
Koronal	0.75	± 0.13	0.85	$\pm 0,09$
En iyi sonuç	0.80	± 0.11	0.89	$\pm 0,07$

3.4. Sınıflandırma Deneyleri

Bu kısımda, tezin ikinci bölümünde açıklanan sınıflandırma yöntemlerinin performanslarını karşılaştırılmıştır. Elde edilen öznitelik vektörlerinin içerdiği bilgilerin kullanıldığı sınıflandırma deneylerinin gerçekleştirilmesi için veri madenciliği yazılımından [111] faydalanılmıştır. Sınıflandırma deneylerinde bu tez kapsamında detaylı olarak anlatılan k-EYK, NB, KA, RO, YSA ve DVM sınıflandırıcıları ile işlemler gerçekleştirilmiştir. Gerçekleştirilen deneylerde her sınıflandırıcı için farklı parametreler kullanılarak testler gerçekleştirilmiş ve ilgili sınıflandırıcı için en iyi parametre değerlerinin tespit edilmesi sağlanmıştır.

3.5. Eğitim ve Test

Daha önceki deneyler sonucunda manuel bölütlenen 50 farklı KIBT görüntülerinden elde edilen öznitelik vektörleri sınıflandırma deneylerinde kullanılmıştır. Her sınıflandırıcı için farklı parametre konfigürasyonlarını deneyerek en başarılı performans değerleri belirlenmiştir [75].

Eğitim ve test aşamalarında hesaplanan sınıflandırma doğruluğu (SD) ve F1 skoru (f-score) verileri [112] sınıflandırıcı performanslarının karşılaştırılması amacıyla kullanılmıştır. Performans metriklerinde ikili sınıflandırma için kullanılan karışıklık matrisi (confusion matrix) hesaplanmıştır.

Tablo 9. İkili sınıflandırma için oluşturulan karışıklık matrisi

Veri sınıfı	Pozitif olarak sınıflandırılan	Negatif olarak sınıflandırılan
Pozitif	tp	fn
Negatif	fp	tn

Tablo 9’da gösterilen karışıklık matrisinde ikili sınıflandırma için tp doğru pozitif, tn doğru negatif, fp yanlış pozitif, fn yanlış negatif değerleri ifade etmektedir.

Sınıflandırma performanslarının belirlenmesinde en çok kullanılan metrik olan sınıflandırma doğruluğu, sınıflandırıcının genel etkinliğini ölçmek için kullanılmaktadır:

$$SD = \frac{tp + tn}{tp + tn + fp + fn} \quad (103)$$

Sınıflandırıcı performansları hakkında sağlıklı bir karar verebilmek için sınıflandırma doğruluğu haricindeki metriklerin sonuçları da değerlendirilmelidir. Bu amaçla hesaplanan F1 skoru verilerin pozitif etiketleri ile sınıflandırıcı tarafından verilenlerin arasındaki ilişkiyi ölçmektedir.

$$Fskoru = \frac{(\beta^2 + 1)tp}{(\beta^2 + 1)tp + \beta^2 fn + fp} \quad (104)$$

İkili sınıflandırma deneylerinde F1 skoru değeri $\beta = 1$ alınarak hesaplanmakta ve bu değer özelde F1 metrik olarak ifade edilmektedir.

$$F1 = \frac{2tp}{2tp + fp + fn} \quad (105)$$


3.6. Sınıflandırma Sonuçları

Sınıflandırma deneylerinin tamamı 50 adet KIBT görüntü kümesinden manuel bölütlemeler sonucu elde edilen veriler kullanılarak gerçekleştirilmiştir. Gerçekleştirilen deneylerde her bir bölütten elde edilen 636 adet öznitelik bilgisi kullanılmıştır. Deneylerde

10KÇD, BDBÇD ve teknikleri kullanılmış olup, öznitelik seçiminde İDS algoritması kullanılmıştır. Son deney grubunda ise Anova çekirdek fonksiyonlu TBA kullanılarak 636 öznitelik bilgisi içeren öznitelik vektöründen daha düşük boyutlu yeni bir öznitelik vektörü elde edilmiştir. İlk altı deney grubunda her bir doğrulama tekniği için ilk aşamada öznitelik vektörünün tamamı işlemlerde kullanılırken, ikinci aşamada ise öznitelik seçim yöntemi kullanılarak aynı işlemler tekrar edilmiş ve sonuçlar elde edilmiştir.

Birinci deney grubunda oluşturulan modellerin eğitilmesi ve doğrulanmaları amacıyla her biri 636 adet öznitelik bilgisi barındıran 50 öznitelik vektörünün tamamı kullanılmıştır. Modellerin doğrulanması için 10KÇD metodu tercih edilmiştir.

Gerçekleştirilen birden fazla deneyin sonucunda kurulan modeller arasında birçok bağımsız değişken ile baş edebilme yeteneğine sahip olan DVM sınıflandırıcısı %94.00 SD ve %94.00 F1 değerleri ile birlikte en iyi performansı vermiştir. Bu değerler Anova ÇF yapısına sahip DVM ile elde edilmiştir.




Şekil 37. 10KÇD metodu ile 636 özniteliğin kullanıldığı ilk deney grubuna ait sonuçların gösterimi [75].

YSA sınıflandırıcısı %92.00 SD ve %91.67 F1 değeri ile en iyi ikinci performans sonuçlarını sağlamıştır. Farklı parametre kombinasyonları arasından bu sonucu veren YSA'da 3 gizli katman kullanılmış, eğitim döngü sayısı 500, öğrenme değeri ise 0.9 olarak ayarlanmıştır. NB sınıflandırıcısı sadece Laplace düzeltme parametresi ile en iyi üçüncü sonucu vermiştir. Bu sonuçları sırasıyla KA, RO ve k-EYK sınıflandırıcıları ile elde edilen sonuçlar takip etmiştir.

İkinci deney grubunda 636 adet öznitelik bilgisi barındıran 50 adet öznitelik vektörünün boyutlarının azaltılması için İDS yönteminden faydalanılmıştır. Her bir sınıflandırıcı için seçilen farklı parametrelerde en iyi sonucu veren özniteliklerin kombinasyonundan uygun öznitelik vektörlerini elde edilmiştir. Modellerin doğrulanması için ilk deney grubunda olduğu gibi 10KÇD metodunu kullanılmıştır.


Gerçekleştirilen birden fazla deneyin sonucunda, kurulan modeller arasında DVM sınıflandırıcısı %100 SD ve %100 F1 değerleri ile birlikte en iyi performansı vermiştir. Aşırı öğrenmeye daha az meyilli olup ve öznitelik seçimi sonucunda aşırı öğrenmenin daha da azaldığı DVM sınıflandırıcısı [97] ile ulaşılan bu sonuç dot ÇF kullanılarak elde edilmiştir.



Şekil 38. 10KÇD metodu ile İDS yöntemi uygulanan ikinci deney grubuna ait sonuçların gösterimi [75].

NB sınıflandırıcısı %98.00 SD, %98.00 F1 değerleri ile en iyi ikinci performansı göstermiştir. Öznitelik vektöründen elde edilen alt kümenin kullanıldığı bu deneylerde NB başarısında artış gözlemlenmiştir. Farklı parametre kombinasyonları arasında NB sınıflandırıcısıyla ulaşılan bu sonuç, Laplace düzeltme parametresiyle bulunmuştur. Bu deney grubunda YSA sınıflandırıcısı en iyi üçüncü sonucu vermiş, bu sonuçları sırasıyla k-EYK, RO ve KA sınıflandırıcıları performansları takip etmiştir.

Üçüncü deney grubunda 50 öznitelik vektörü 2KÇD ile birlikte her biri 25 öznitelik vektörü içeren iki gruba ayrılarak model doğrulama gerçekleştirilmiştir. Oluşturulan gruplar ile kurgulanan modellerin eğitim ve test işlemleri sonucunda herhangi bir öznitelik seçimi uygulamadan, her bir öznitelik vektöründeki 636 değerın tamamı kullanılmıştır. Bu testlerde 25 öznitelik verisi ile sınıflandırıcılar eğitildikten sonra eğitilen sınıflandırıcılardan elde edilen modellerin doğrulanması için daha önce kullanılmayan 25 öznitelik verisini test işlemlerinde kullanılmıştır. Daha sonra aynı işlemler gruplar yer değiştirilerek tekrar edilmiştir.




Şekil 39. 2KÇD metodu ile 636 özniteliğin kullanıldığı üçüncü deney grubuna ait sonuçların gösterimi [75].

Gerçekleştirilen birden fazla deneyin sonucunda kurulan modeller arasında DVM sınıflandırıcısı %96.00 SD ve %96.00 F1 değerleri ile birlikte en iyi performansı göstermiştir. DVM bu sınıflandırma performansına ANOVA ÇF kullanımı sonucunda erişmiştir.

NB sınıflandırıcısı sadece Laplace düzeltme yöntemi kullanılarak %92.00 SD ve %92.37 F1 değeriyle birlikte en iyi ikinci sonucu vermiştir. YSA, 1 gizli katman, 500 eğitim döngü sayısı ve 0.9 öğrenme değerinin kullanıldığı deneyler sonucunda en iyi üçüncü sonucu vermiştir. Bu sonuçları sırasıyla KA, RO ve k-EYK sınıflandırıcı performansları takip etmiştir.

Dördüncü deney grubunda, üçüncü deney grubunda uygulandığı gibi 50 öznitelik vektörü 2KÇD kullanılarak her biri 25 öznitelik vektörü içeren iki gruba ayrılmış ve model doğrulama gerçekleştirilmiştir. 636 adet öznitelik bilgisi barındıran vektörlerin boyutlarının azaltılması için İDS yönteminden faydalanılmıştır.




Şekil 40. 2KÇD metodu ile İDS yöntemi uygulanan dördüncü deney grubuna ait sonuçların gösterimi [75].

Gerçekleştirilen birden fazla deneyin sonucunda kurulan modeller arasında DVM sınıflandırıcısı %96.00 SD ve %96.00 F1 değerleri ile birlikte en iyi performansı göstermiştir. DVM sınıflandırıcısı bu sonucu ANOVA ÇF ile elde etmiştir.

RO sınıflandırıcısı en iyi ikinci performansı %92.00 SD ve %92.86 F1 değerleri ile elde etmiştir. RO bu sonuca 10 ağacın yer aldığı 0.25 güven aralığı değerinin kullanıldığı sınıflandırıcı modeli sonucunda ulaşmıştır. YSA ve NB sınıflandırıcıları %92.00 SD ve %92.00 F1 değerleri ile birlikte en iyi üçüncü performansı göstermişlerdir. YSA 2 gizli katmanlı ağı, 500 eğitim döngü sayısının ve 0.9 öğrenme değerinin kullanıldığı, NB ise Laplace düzeltme yönteminin tercih edildiği deneyler sonucunda bu değerleri elde etmişlerdir. Bu sonuçları sırasıyla k-EYK ve KA sınıflandırıcıları ile hesaplanan sonuçlar takip etmiştir.

Beşinci deney grubunda oluşturulan modellerin eğitilmesi ve doğrulanmaları amacıyla her biri 636 adet öznitelik bilgisi barındıran 50 öznitelik vektörünün tamamını kullanılmıştır. Modellerin doğrulanması için BDBÇD metodu tercih edilmiştir.




Şekil 41. BDBÇD metodu ile 636 öznitelikliğin kullanıldığı beşinci deney grubuna ait sonuçların gösterimi [75].

Birden fazla deneyin sonucunda kurulan modeller arasında DVM sınıflandırıcısı %88.00 SD ve %88.00 F1 değerleri ile birlikte en iyi performansı vermiştir. Bu değerler dot ÇF kullanılarak elde edilmiştir.

YSA sınıflandırıcısı %88.00 SD ve %87.50 F1 değeri ile en iyi ikinci performans sonuçlarına ulaşmıştır. Bu sonucu veren YSA'da 3 gizli katman kullanılmış, eğitim döngü sayısı 500, öğrenme değeri ise 0.3 olarak ayarlanmıştır. Bu sonuçları sırasıyla KA, RO, NB ve k-EYK sınıflandırıcıları ile elde edilen sonuçlar takip etmiştir.

Altıncı deney grubunda 50 öznitelik vektörünün tamamı modellerin eğitilmesi ve test edilmesi amacıyla yeniden kullanılmıştır. Öznitelik vektörler boyutlarının azaltılması için İDS yönteminden faydalanılmış ve her bir sınıflandırıcı için seçilen farklı parametrelerde en iyi sonucu veren özniteliklerin kombinasyonundan uygun öznitelik vektörleri belirlenmiştir. Modellerin doğrulanması için BDBÇD metodu tercih edilmiştir.




Şekil 42. BDBÇD metodu İDS yöntemi uygulanan altıncı deney grubuna ait sonuçların gösterimi [75].

Bu gruptaki deneylerin sonucunda, kurulan modeller arasında DVM sınıflandırıcısı %94.00 SD ve %93.88 F1 değerleri ile birlikte en iyi performansı göstermiştir. DVM sınıflandırıcısı ile ulaşılan bu sonuç Epechenikov ÇF kullanılarak elde edilmiştir.

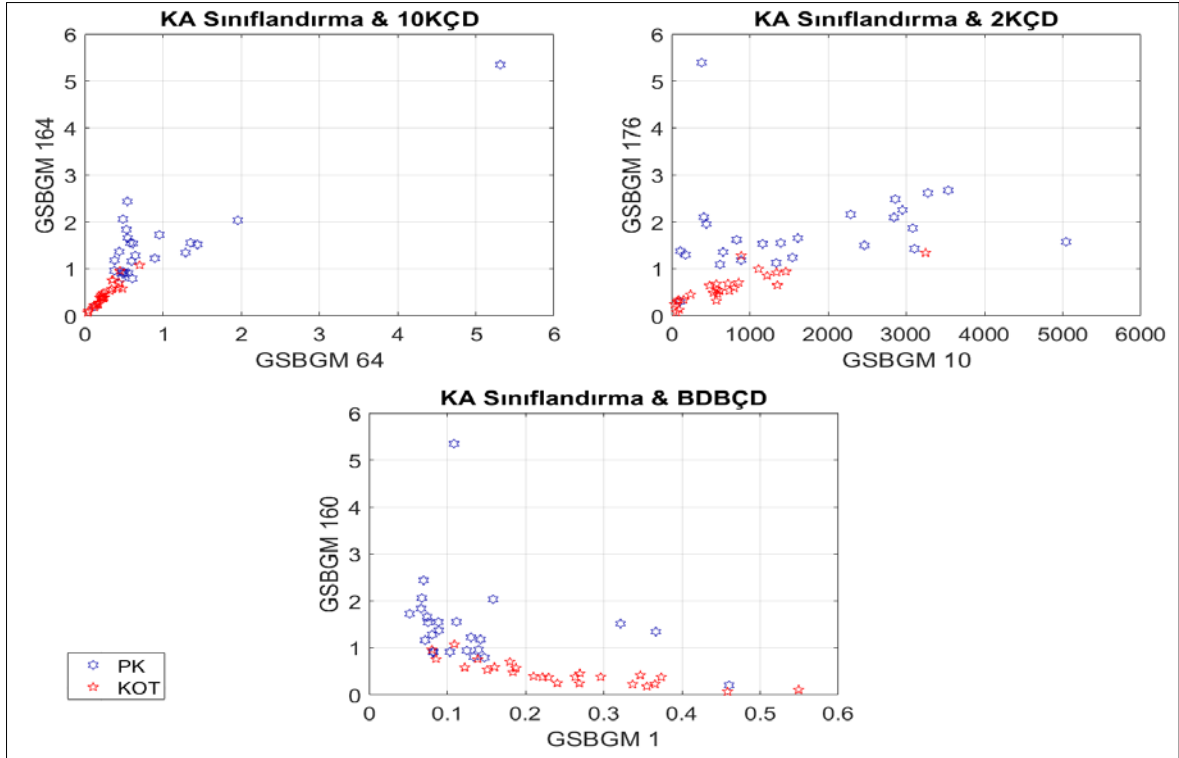
NB ve YSA sınıflandırıcılarının her ikisi de %92.00 SD, %92.00 F1 değerleri ile en iyi ikinci performansı göstermiştir. NB sınıflandırıcısı ile ulaşılan bu sonuç, Laplace düzeltme parametresi ile, YSA ile ulaşılan sonuç ise 2 gizli katmanlı ağ, 500 eğitim döngü sayısı ve 0.3 öğrenme değeri ile elde edilmiştir. Bu sonuçları sırasıyla RO, KA ve k-EYK sınıflandırıcıları sonuçları takip etmiştir.

İkinci, dördüncü ve altıncı deney gruplarında İDS metodu kullanılarak 636 adet öznitelik bilgisini barındıran öznitelik vektörünün boyutunun azaltılması hedeflenmiştir. DVM sınıflandırıcısı ve 10KÇD kullanılan deneylerde tek öznitelik, 2KÇD ve BDBÇD yöntemlerinin kullanıldığı deneylerde ise iki öznitelik ile en başarılı sonuçlara ulaşılmıştır. Bu özniteliklerin tümü 3B GSBGM ile elde edilen bilgilerdir.


Diğer sınıflandırıcılar ise 1 ile 3 adet arasında değişen öznitelik bilgisi kombinasyonundan oluşan öznitelik vektörleri ile en başarılı sonuçları elde etmişlerdir.




Şekil 43. İDS yönteminin kullanıldığı deneylerde her bir sınıflandırıcı için seçilen özniteliklerin sayısı [75].




Şekil 44. KA sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznelikleri gösteren saçılım grafikleri



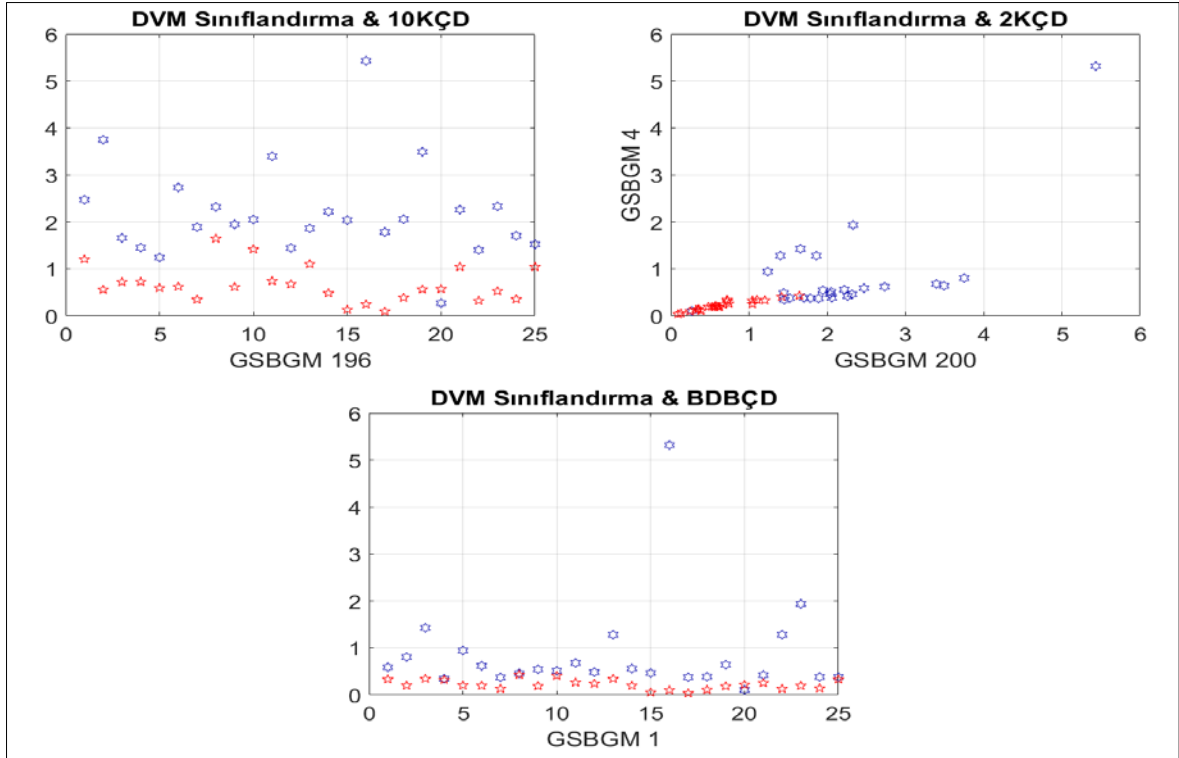
Şekil 45. k-EYK sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznelikleri gösteren saçılım grafikleri




Şekil 46. RO sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznelikleri gösteren saçılım grafikleri



Şekil 47. NB sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznelikleri gösteren saçılım grafikleri




Şekil 48. DVM sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznelikleri gösteren saçılım grafikleri



Şekil 49. YSA sınıflandırıcı ile gerçekleştirilen deneyler sonucu İDS yöntemi ile seçilen öznelikleri gösteren saçılım grafikleri

Yedinci deney grubunda 50 öznitelik vektörü her biri 25 öznitelik vektörü içeren iki gruba ayrılmıştır. Bölünmüş örnek doğrulama (BÖD) uygulanarak kurgulanan modellerde birinci grup veriler sadece eğitim amaçlı kullanılırken, ikinci grup veriler ise sadece test işlemlerinde değerlendirilmiştir. Gerçekleştirilen testlerde ANOVA ÇF TBA ile her bir öznitelik vektöründeki 636 değer birbiri ile ilişkisi olmayan 50 farklı öznitelik bilgisi hesaplanmıştır. Hesaplanan bu değerler ile sınıflandırıcı testlerinde kullanılan yeni öznitelik vektörleri oluşturulmuştur. Bu testlerde 25 öznitelik verisi ile sınıflandırıcılar eğitildikten sonra eğitilen sınıflandırıcılardan elde edilen modellerin doğrulanması için daha önce kullanılmayan 25 öznitelik verisi test işlemlerinde kullanılmıştır.

dosya	etiket	Glc3D_1	Glc3D_2	Glc3D_3	Glc3D_4	Glc3D_5	Glc3D_6
51	CYST	0.074	1.403	0.130	0.588	0.183	7.384
52	CYST	0.070	1.467	0.099	0.803	0.195	9.669
53	CYST	0.321	0.956	0.295	1.426	0.240	2.375
55	CYST	0.134	1.136	0.282	0.342	0.162	3.370
57	CYST	0.130	1.141	0.325	0.941	0.342	2.497
58	CYST	0.067	1.448	0.093	0.618	0.189	10.481
59	CYST	0.082	1.326	0.167	0.371	0.160	5.809
62	CYST	0.081	1.395	0.081	0.458	0.212	12.174
63	CYST	0.075	1.402	0.111	0.545	0.220	8.763
67	CYST	0.089	1.324	0.169	0.510	0.202	5.667




dosya	etiket	kpc_1	kpc_2	kpc_3	kpc_4	kpc_5	kpc_6
51	CYST	49174269.670	17434266.333	31199300.546	74586820.109	59038634.179	6778996.178
52	CYST	44564079.125	18068627.223	42157366.774	74671222.222	60870010.521	952134.195
53	CYST	88925467.613	17003868.480	43622624.411	43992414.556	41962843.458	372955.959
55	CYST	94380436.514	25241814.240	95018458.480	73900596.785	62218826.996	-7917389.064
57	CYST	97098648.739	23349433.072	65119112.206	30123343.696	52782881.103	15159699.248
58	CYST	49764075.206	13098231.220	24565491.944	137478130.4...	59297828.545	8699497.749
59	CYST	56792239.620	6464378.130	12962578.864	45014711.119	42706700.172	19891128.422
62	CYST	51301993.965	16489936.761	27575151.821	182156206.1...	26608170.764	3438783.575
63	CYST	43493986.804	25354521.227	60397784.489	104243906.3...	95675695.033	-11682529.182
67	CYST	65323025.633	26668608.633	39824509.289	65874908.533	123680863.4...	-10119536.512

Şekil 50. KIBT ile elde edilen öznitelik kümesinde Anova çekirdek fonksiyonlu TBA uygulama sonucu

Gerçekleştirilen birden fazla deneyin sonucunda, kurulan modeller arasında DVM sınıflandırıcısı %92,00 SD ve %92,31 F1 değerleri ile birlikte en iyi performansı göstermiştir. DVM bu sınıflandırma performansına ANOVA ÇF kullanımı sonucunda erişmiştir.

NB sınıflandırıcısı en iyi ikinci performansı %96.00 SD ve %96.00 F1 değerleri ile elde etmiştir. NB bu sonucu Laplace düzeltme yönteminin kullanıldığı sınıflandırıcı modeli ile elde etmiştir. RO ve k-EYK sınıflandırıcıları %88.00 SD ve %88.67 F1 değerine ulaşmış ve en iyi üçüncü sonucu vermiştir. Bu sonuçları sırasıyla YSA ve KA sınıflandırıcı performansları takip etmiştir.



Şekil 51. TBA ile elde edilen öznitelik vektörünün kullanıldığı, bölünmüş örnek doğrulama sonuçları gösterimi

Sekizinci deney grubunda 50 öznitelik vektörü her biri 25 öznitelik vektörü içeren iki gruba ayrılmıştır. BÖD uygulanarak kurgulanan modellerde birinci grup veriler sadece eğitim amaçlı kullanılırken, ikinci grup veriler ise sadece test işlemlerinde değerlendirilmiştir. Gerçekleştirilen testlerde ANOVA ÇF TBA ile her bir öznitelik vektöründeki 636 değer birbiri ile ilişkisi olmayan 50 farklı öznitelik bilgisi hesaplanmıştır.


Hesaplanan bu değerler ile sınıflandırıcı testlerinde kullanılan yeni öznelik vektörleri oluşturulmuştur. Öznelik vektörler boyutlarının azaltılması için IDS yönteminden faydalanılmış ve her bir sınıflandırıcı için seçilen farklı parametrelerde en iyi sonucu veren özneliklerin kombinasyonundan uygun öznelik vektörleri belirlenmiştir.

Bu testlerde 25 öznelik verisi ile sınıflandırıcılar eğitildikten sonra eğitilen sınıflandırıcılardan elde edilen modellerin doğrulanması için daha önce kullanılmayan 25 öznelik verisi test işlemlerinde kullanılmıştır.


Gerçekleştirilen birden fazla deneyin sonucunda kurulan modeller arasında NB sınıflandırıcısı %100,00 SD ve %100,00 F1 değerleri ile birlikte en iyi performansı göstermiştir. NB bu sınıflandırma performansına Laplace düzeltme yöntemi ile ulaşmıştır.

DVM sınıflandırıcısı %96,00 SD ve %92,31 F1 değeri ile en iyi ikinci performansı göstermiştir. DVM sınıflandırıcısı bu sonuca ANOVA ÇF kullanılan deneyler sonucunda ulaşmıştır.


RO ve k-EYK sınıflandırıcıları en iyi üçüncü performansı göstermiştir. Bu sonuçları sırasıyla KA ve YSA sınıflandırıcı performansları takip etmiştir.




Şekil 52. TBA ile elde edilen öznelik vektörünün kullanıldığı, bölünmüş örnek doğrulama sonuçları gösterimi




Şekil 53. KA sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özneliklere ait saçılım grafiği




Şekil 54. k-EYK sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özneliklere ait saçılım grafiği




Şekil 55.RO sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özneliteliklere ait saçılım grafiği



Şekil 56.NB sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özneliteliklere ait saçılım grafiği



Şekil 57. DVM sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özneliklere ait saçılım grafiği




Şekil 58. YSA sınıflandırıcı ve BÖD ile gerçekleştirilen deneyler sonucu İDS yöntemi kullanılarak seçilen özneliklere ait saçılım grafiği


3.7. Yarı Otomatik Bölütleme ve Sınıflandırma Deneyleri

Bu tezin amaç ve kapsamı dahilindeki çalışmaların ve deneylerin sonucunda KIBT ile elde edilen 3B görüntülerde PK ve KOT lezyonların tespiti ve analizini gerçekleştirebilen bir karar destek sistemi (KDS) geliştirilmiştir. Geliştirilen KDS yardımı ile gerçekleştirilen deneylerde, 50 KIBT veri kümesi yazılım arayüzüne yüklenmiş, görüntülerde var olan gürültüler önerilen gürültü temizleme yaklaşımı ile temizlenmiştir. Her bir KIBT verisi için uzman tarafından yarı otomatik bölütleme yöntemi kullanılarak bölütlemeler gerçekleştirilmiş ve elde edilen bölütleme sonuçlarından anlık olarak 636 farklı özneliği barındıran öznelik vektörü elde edilmiştir. Elde edilen öznelikler daha önceki sınıflandırma deneylerimizde eğitilen DVM sınıflandırıcısı ile işleme alınarak ilgili lezyona ait patolojinin tahmini gerçekleştirilmiştir.

Gerçekleştirilen deneylerin tamamında lezyonlar ortalama %89 Dice doğruluk skoru ile bölütlenmiş ve bu lezyonların tamamı ortalama %94 SD ve %94 F1 değerleri ile doğru sınıflara ayrılmıştır.



Şekil 59. KDS sisteminde manuel ve yarı otomatik bölütleme ve sınıflandırma sonuçları gösterimi



Şekil 60. KDS sisteminde gürültülü KIBT verisi için manuel, yarı otomatik (gürültülü), yarı otomatik (gürültüsüz) bölütleme ve sınıflandırma sonuçları gösterimi

4. SONUÇLAR VE KARŞILAŞTIRMA

Bu tezin ana konusu 3B KIBT görüntülerinde tespit edilen PK ve KOT lezyonların yarı otomatik bir yöntemle bölütlenmesi ve bölütlenen lezyonların doğru sınıflara ayrılmasıdır. Çalışmalarda KTÜ Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi ABD'na rutin kontroller için gelen 50 farklı hastaya ait KIBT görüntüleri kullanılmıştır.

Gerçekleştirilen deneylerin tamamı 16 GB RAM, 2.40-GHZ 8 çekirdekli Intel i7 4700HQ işlemcili bilgisayarda uygulanmıştır. Bu tez kapsamındaki algoritmaların önemli bir kısmı MATLAB R2016b platformunda geliştirilmiş ve çalıştırılmıştır. Sınıflandırma deneyleri ise Rapidminer [111] platformunda gerçekleştirilmiştir.

Çalışmanın ilk aşamasında tespit edilen lezyonlu bölgelere karşılık gelen kesitlerin tamamı manuel işaretlenerek lezyonlu bölgeyi içeren 3B veri kümesi elde edilmiştir. Elde edilen volumetrik bölütlerden birinci seviye istatistikler ve 3B GSBGM matrisinden hesaplanan değerler çıkartılmış ve öznitelik vektörü elde edilmiştir. Her bir lezyonlu bölge için elde edilen öznitelik vektörü toplamda 636 adet öznitelik bilgisinden meydana gelmiştir. Veri kümesinde yer alan lezyonların PK ve KOT olarak ayrılmaları için sınıflandırma deneyleri gerçekleştirilmiştir. Sınıflandırma deneyleri için altı farklı sınıflandırıcı (k-EYK, NB, KA, RO, YSA, DVM) kullanılmıştır. KIBT aracılığı ile elde edilen görüntülerde PK ve KOT lezyonlarının sınıflandırılması amacıyla yedi farklı deney tasarlanmıştır.

İlk deney grubunda 50 öznitelik vektörünün tamamı 10KÇD uygulanarak eğitim ve test işlemleri gerçekleştirilmiştir. Her bir sınıflandırıcı için farklı parametre kombinasyonları denenerek en iyi performansın elde edilmesi hedeflenmiştir. Sonuçlara göre DVM sınıflandırıcısı en iyi performansı vermiştir.

İkinci deney grubunda İDS yöntemi ve 10KÇD yöntemi ile, üçüncü deney grubunda ise 2KÇD ve 636 öznitelik değerinin tamamı kullanılarak DVM sınıflandırıcısı en iyi sonucu vermiştir. Dördüncü deney grubunda 2KÇD ve İDS seçim yöntemi ile yine DVM sınıflandırıcısı en iyi sonucu vermiş olup bir önceki deney grubuna göre de sınıflandırma performansı yükselmiştir.

Beşinci ve altıncı deney gruplarında BDBÇD kullanılarak doğrulama gerçekleştirilmiştir. Beşinci deney grubunda 636 öznitelik değerinin tamamı, altıncı deney grubunda ise İDS yöntemi sonucunda seçilen öznitelik alt kümesi kullanılmıştır. Her iki deney grubunda da DVM sınıflandırıcısı en iyi performansı göstermiştir.

Yedinci ve sekizinci deney gruplarında BÖD uygulanarak kurgulanan modellerde TBA ile ANOVA ÇF kullanılarak mevcut öznitelik vektörlerinden birbiri ile ilişkisi olmayan yeni öznitelik değerleri hesaplanmış ve bu değerler deneylerde kullanılmıştır. Yedinci deney grubunda TBA ile elde edilen 50 öznitelik değerinin tamamı, sekizinci deney grubunda ise İDS yöntemi sonucunda seçilen bu öznitelik alt kümesi kullanılmıştır. Yedinci deney grubunda da DVM sınıflandırıcısı, sekizinci grupta ise NB sınıflandırıcısı en iyi performansı göstermiştir

Deneylerin sonucuna göre işaretlenmiş KIBT verilerinden elde edilen öznitelikler dental lezyonların PK veya KOT olarak sınıflandırılması için kullanıma oldukça elverişlidir. Özellikle İDS metodu yardımıyla her bir sınıflandırıcıya özel olarak öznitelik vektörü boyutunun azaltılması sınıflandırıcı performanslarında artış sağlamıştır. Bu çalışmanın sonucunda, 50 farklı KIBT veri kümesinde PK ve KOT lezyonlarına ait işaretlenmiş verilerin sınıflandırılması deneylerinde en iyi performans sonuçlarından biri DVM sınıflandırıcısı kullanılarak %100 SD ve %100 F1 olarak elde edilmiştir. Bu sonuçlara, 10KÇD ile model doğrulama ve İDS ile öznitelik azaltma kullanılarak ulaşılmıştır. DVM sınıflandırıcısı 2KÇD ve İDS yöntemlerinin kullanıldığı deneylerde en iyi sonuçları %96.00 SD ve %96.00 F1 ile elde etmiştir. Bu sonuçlara ek olarak DVM BDBÇD ve İDS yöntemleri ile gerçekleştirilen sınıflandırma deneylerinde en iyi sonuçlara %94.00 SD ve %93.88 F1 skorları ile ulaşılmıştır.

ANOVA ÇF TBA kullanılan ve elde edile yeni öznitelik vektöründe İDS ile öznitelik azaltma işlemi gerçekleştirilen deneylerde de NB sınıflandırıcısı %100,00 SD ve %100,00 F1 değerleri ile birlikte en iyi performansı göstermiştir. NB bu sınıflandırma performansına Laplace düzeltme yöntemi ile ulaşmıştır.

Önceki çalışmalar göz önüne alındığında KIBT verilerinden elde edilen öznitelikler çeşitlilik ve sayı bakımından lezyonların doğru sınıflara ayrılması ile ilgili daha fazla ayırıcı bilgi sunmuştur. Deneylerde kullanılan sınıflandırıcıların sayısı ve her sınıflandırıcı için denemiş olan çeşitli parametreler ile çalışmanın etki alanı geniş tutulmuştur.

Çalışmanın önemli hedeflerinden birisi olan ve farklı bölütleme yöntemlerinin özelliklerinden faydalanılarak geliştirilen yarı otomatik bölütleme yaklaşımı, veri kümesindeki lezyonların işaretlenmesi deneylerinde kullanılmıştır. Sırasıyla Ak-OK, RY ve YGAK yöntemlerinin ardı sıra uygulanması ile gerçekleşen deneylerde ortalama 0.89 Dice benzerlik katsayı sonucunda ulaşılmıştır. Elde edilen sonuçlara göre, önerilen yarı otomatik bölütleme yaklaşımı literatürdeki diğer yöntemlere nazaran KIBT görüntülerindeki lezyonların tespitinde daha başarılı sonuçlar vermiştir.

Yarı otomatik bölütleme deneylerinde elde edilen başarıya gürültü tespit edilen görüntülere uygulanan gürültü temizleme yaklaşımı sonuçları da olumlu yönde etki etmiştir. KIBT görüntüleri üzerinde gerçekleştirilen deneylerde bu çalışma özelinde önerilen gürültü temizleme yönteminin diğer yöntemlere göre DSGO ve MHO değerleri göz önüne alındığında daha başarılı sonuçlar verdiği görülmüştür.

Tablo 10. Literatürde KIBT görüntülerinde lezyon bölütleme çalışmaları sonuçları ile tez çalışması sonuçları karşılaştırması

Çalışma	Flores et al. [38]	Abdolali et al. [41]	Yılmaz, E.
Veri Kümesi	17 KIBT	97 KIBT	50 KIBT
Bölütleme Yöntemi	Rasgele Yürüyüş	Çevre Dönüşümü ve Küresel Harmonikler	Yarı Otomatik Bölütleme (Bölüm 2.2.3.4)
Jaccard Benzerlik	Sunulmamış	Periapikal = 0.83 Dentigeröz = 0.87 KOT = 0.80	Periapikal ve KOT 0.89
Dice Benzerlik	Sunulmamış	Periapikal=0.72 Dentigeröz= 0.75 KOT= 0.69	Periapikal ve KOT 0.80

Tablo 11. Literatürde KIBT görüntülerinde lezyon sınıflandırma çalışmaları sonuçları ile tez çalışması sonuçları karşılaştırması

Çalışma	Flores vd. [38]	Abdolali vd. [41]	Kauke vd. [43]	Yılmaz, E.
Veri Kümesi	17 KIBT	96 KIBT	114 KIBT	50 KIBT
Öznitelik Adet	8	Sunulmamış	2	636
Öznitelikler	Minimum Entropi Ortalama Medyan Maksimum Standart Sapma Çarpıklık Basıklık	Konturlet SPHARM	Şekil Öznitelikleri (Hacimsel) Ortalama Standart Sapma	Ortalama Standart Sapma Çarpıklık Basıklık Entropi 3B GSBGM
Sınıflandırıcı	Lineer Diskriminant Analiz (LDA), Adaboost	DVM Ayrık Diskriminant Analiz (ADA)	Sunulmamış	DVM
Sonuçlar	LDA & BDBÇD SD=73.08% Adaboost & BDBÇD SD=74.05%	DVM SD=94.29% ADA SD=96.48%	SD=93.00%	DVM & 10KÇD & İDS SD =100.00% DVM & BÖD & PCA SD=99.05%

Bahsi geçen yöntemlerin bir arada uygulanmasını sağlayan yazılım bu çalışma özelinde geliştirilmiştir. Veri kümesindeki 50 KIBT görüntüsünün tamamının yarı otomatik bölütlenmesi, öznelüklerin çıkartılması ve sınıflandırıcı testi ile en uygun sınıfa ayrılmasına yönelik deneyler gerçekleştirilmiştir. Gerçekleştirilen deneyler sonucunda lezyonlar önceki işlem adımıında ifade edildiği şekilde 0.89 Dice katsayısı ile bölütlenmiştir. Bölütlenen lezyonlar %94.00 SD ve %94.00 F1 skoru ile ilgili sınıflara ayırmıştır.



5. ÖNERİLER

Görüntü işleme alanındaki uygulamalara paralel olarak, biyomedikal görüntülerde hastalıkların teşhisi ve anatomik yapıların tespitine yönelik karar destek sistemlerinin geliştirilmesi ile ilgili çalışmalar son yıllarda hız kazanmıştır. Bu çalışmaların önemli bir kısmı 2B medikal görüntüler ile gerçekleştirilirken, volumetrik görüntü elde eden cihazların kullanımının yaygınlaşması ile birlikte 3B görüntü işleme çalışmalarında da artış olmuştur.

Volumetrik görüntü üreten KIBT cihazları özellikle boyun ve baş bölgesindeki anatomik yapıların ve patolojilerin 3B olarak izlenmesi ve tespitine imkan tanımaktadır. Diş hekimliği alanında da kullanımı yaygınlaşan bu cihazlar, dişler, çene kırıkları ve lezyonların tespiti ile implant planlamaları ve kanal tedavilerinin planlanması vb. durumlarda kullanılmaktadır.

KIBT ile elde edilen görüntülerde dişlerin, çene yapılarının görüntü işleme yöntemleri aracılığı ile tespiti çok zor değildir. Dişler ve çene kemiklerinin 3B bölütleme yöntemleri ile tanımlanması, bu yapıların homojen oluşları ve voksel değerlerinin belirli gri seviye aralığında olmaları sebebiyle nispeten kolaydır. Çoğu bölütleme yöntemi bu yapıların tespitinde başarılı sonuçlar verebilmektedirler. Ancak; dental lezyonlar için diş ve çene kemiklerinde kullanılan bu yaklaşımlar tek başına yeterli olmamaktadır.

Dental lezyonlar, diş kökünde ve çene kemiklerindeki yerleşimleri ve yayılımları bakımından çeşitli varyasyonlar göstermektedirler. Kimi lezyonlar hacimsel olarak oldukça büyük ve kenarları düzgün eliptik şekillere sahip olabilirken, kimi lezyonlar da küçük ve girintili yapıları ile düzensiz şekillere sahiptirler. Lezyonlar sadece şekilleri bakımından değil homojenlikleri ve gri seviye değerlerindeki varyasyonları bakımından da çeşitlilik göstermektedirler. Bazı lezyonların çene kemiğinde yıkıma sebep olarak dışarı taşma eğilimi göstermeleri nedeniyle bu patolojiler KIBT görüntülerinde yumuşak dokulara ait gri seviye bölgeleri ile karışmaktadır. Bütün bu hususlar geleneksel bölütleme ve öznel çıkartma yöntemlerinin KIBT görüntülerindeki lezyonların tespiti ve sınıflandırılması çalışmalarında yeterli olmadığını ortaya koymaktadır.

Bu çalışmada KIBT görüntülerinde tespit edilen PK ve KOT türlerindeki lezyonların bölütlenmesi ve sınıflandırılması ile ilgili bir KDS oluşturulması amaçlanmıştır. Gerçekleştirilen çalışmaların her bir aşaması bu problemin çözümü ile ilgili literatüre önemli katkılar sağlayacak gelişmelere yol açmıştır.

KIBT görüntülerinde çeşitli sebeplerle meydana gelebilecek gürültüler nedeniyle görüntü kalitesi azalabilmekte ve görüntü işleme algoritmalarının çalışma performanslarında da önemli ölçüde düşüşler meydana gelmektedir. Çalışmamızda KIBT görüntülerinde kullanılabilecek çeşitli gürültü temizleme yöntemlerinin performansları gerçekleştirilen deneylerle incelenmiş ve AY yönteminin diğer yöntemlere göre en iyi performansı sunduğu tespit edilmiştir.

AY yöntemi yinelemeli olarak uygulanan bir filtreleme yaklaşımı olmakla beraber, bu çalışmada yineleme adedinin ilgili görüntüye bağlı olarak tespit edileceği bir gürültü temizleme yaklaşımı önerilmiştir. Bu yaklaşım gürültü seviyesi tespiti ve bulanıklık metriği ölçüm değerlerinden faydalanacak şekilde geliştirilmiş olup, KIBT görüntülerindeki gürültülerin temizlenmesinde en başarılı sonuçların elde edilmesini sağlamıştır.

Çalışma kapsamında önerilen bu yaklaşımın yalnızca 3B KIBT görüntüleri için değil, 2B ve 3B tüm medikal görüntüler başta olmak üzere çeşitli türdeki diğer görüntülerde de başarılı sonuçlar vereceği düşünülmektedir. Önerilen yaklaşımın farklı KIBT görüntülerinde lezyon tespitine yönelik ön işlem adımı olarak önerilmiştir. Ancak aynı yaklaşım diğer türdeki görüntüler için de başarılı sonuçlar verebilir. Gelecek çalışmalarda KIBT harici görüntüler ile de deneyler tekrarlanacak ve belirlenecek nihai bir gürültü temizleme yaklaşımı ile literatüre önemli bir katkı sağlayacaktır.

Bu katkının yansıra önerilen gürültü temizleme yönteminde bulanıklık metriği ile DSGO ve MHO değerleri arasından kurulan lineer korelasyonun sonucunda AY yönteminde yinelemenin 0.5 bulanıklık değeri ile durdurulması önerilmiştir. Gelecek çalışmalarda gerçekleştirilecek deneylerde, kullanılacak KIBT görüntü kesit sayısı artırılıp elde edilecek sonuçların farklı regresyon teknikleri ile ilişkilendirilmesi hedeflenecektir. Böylelikle, AY yinelemenin ilgili görüntüye ait gürültü seviyesine bağlı olarak kurulacak regresyona uygun olarak bir bulanıklık metriği değeri ile durdurulması sağlanabilir.

Bu çalışma özelinde KIBT görüntülerinde lezyon tespiti için çeşitli bölütleme yöntemlerinin birlikte uygulandığı bir bölütleme yaklaşımı önerilmiştir. Önerilen bölütleme yaklaşımı farklı boyutlarda, şekillerde ve homojenlikteki lezyonların 3B olarak elde edilmesi amacıyla literatürde kullanılan yaklaşımlara göre başarılı sonuçlar elde etmiştir. Kullanılan yöntemin test edildiği görüntüde gürültü bilgisi mevcut ise ön işlem gerçekleştirilmiş ve bölütleme performansının bu türdeki görüntülerde artırılması sağlanmıştır. Aynı yaklaşımın çeşitli medikal görüntüler için 3B bölütleme işlemlerinde denenmesi ile elde edilecek sonuçlara bağlı olarak yöntem güncellenebilir.

Çalışmanın literatüre önemli katkılarında birisi, KIBT ile elde edilen görüntülerde PK ve KOT türündeki lezyonların birbirlerinden ayırt edilmeleri için belirlenen sınıflandırma yöntem ve parametreleridir. Bu amaçla 3B görüntülerden hesaplanan istatistikler ve özellikle 3B GSBGM değerleri, sınıflandırma deneylerinde işleme alınacak 636 farklı öznelik değerini içeren öznelik vektörünü meydana getirmiştir. Sınıflandırma deneylerinde kullanılan öznelikler, sınıflandırıcı parametre çeşitliliği ve kullanılan sınıflandırıcı adediyle literatürde bu alanda yürütülmüş çalışmalara oranla oldukça kapsamlı deneyler gerçekleştirilmiştir. Bu deneylerin sonucunda elde edilen çıktıların literatürdeki diğer yöntemlerden elde edilen sonuçlara göre başarısının daha yüksek olduğu da görülmektedir.

Çalışmanın veri kümesinden elde edilen lezyonlara ait 3B hacimsel bölgeler ve öznelik vektörleri, <http://www.dentalimagedataset.com/database/dentalcbct001> adresinde anonimize edilmiş haliyle erişime açılmıştır. Bu adreste yer alan özgün veriler literatürde bu alanda yürütülen ve yürütülecek olan diğer çalışmalara da önemli katkı sağlayacaktır.

Tezin nihai çıktısı olarak, bu çalışmada önerilen yöntemlerin ve sınıflandırıcı parametrelerinin birlikte kullanıldığı bir KDS geliştirilmiştir. Geliştirilen KDS, KIBT verilerinin 3B olarak DICOM formatındaki dosyalardan yüklenmesini, varsa görüntülerdeki gürültülerin önerilen yaklaşımla temizlenmesini, görüntülerdeki lezyonların yarı otomatik yöntemle bölütlenmesini mümkün kılmaktadır. İlgili sistemde bölütlenmiş verilerden elde edilen öznelik vektörü, çalışmada en iyi performans gösteren sınıflandırıcı ve öznelik parametre kombinasyonları ile ilgili lezyon sınıfına ayrılabilir.

Önerilen KDS ile gerçekleştirilen deneylerde çalışmaya ait veri kümesindeki bütün veriler işleme alınmıştır. Deneylerde görüntü yükleme, var olan gürültüleri temizleme, yarı otomatik bölütleme, elde edilen bölütten öznelik çıkartılması ve lezyonun sınıflandırılması işlemleri sırasıyla gerçekleştirilmiştir. Sonuç olarak, KDS'nin lezyonları başarıyla bölütleyebildiği, bölütlenen lezyonların PK veya KOT sınıflarına yüksek doğruluk oranı ile ayırdığı gözlemlenmiştir.

Çalışma her ne kadar KIBT görüntüleri kullanılarak gerçekleştirildiyse de oral muayeneler esnasında sıklıkla tercih edilen 2B panoramik radyografi görüntülerinde de benzer işlem adımları uygulanabilir. Bu çalışma kapsamında kullanılan gürültü temizleme, yarı otomatik bölütleme ve sınıflandırma bileşenleri 2B görüntülere uygun olarak geliştirilerek kullanılabilir. Gelecek çalışmalarda hem KIBT hem de panoramik radyografi görüntülerinden faydalanılacaktır.

Bu çalışmanın PK ve KOT türleri dışındaki farklı lezyon türleri için de geliştirilmesi çalışmanın etki alanının genişlemesini sağlayacaktır. Çalışmanın etki alanını genişletecek diğer bir etken de kullanılan veri kümesindeki örneklerin sayısını arttırmak olacaktır. Bu hedeflerin gerçekleştirilmesi durumunda kurgulanacak KDS'nin diğer dental lezyon türlerinin bölütlenmesi ve sınıflandırılması problemlerinin çözümüne olan etkisi genişleyecek ve performansı artacaktır. Radyoloji uzmanlarının radyolojik incelemeler için yararlanabilecekleri bu uygulamalar, teşhis ve tedavi planlama aşamalarının daha kısa sürede, daha sağlıklı ve etkili bir şekilde gerçekleştirilmesini mümkün kılacaktır.



6. KAYNAKLAR

1. Ziskin, D.E, Dental Infections: Comparative Systemic Effects of Quantitative Apical Changes: A Study of 1503 Full-Mouth X-Rays, Journal of Dental Research, 11 (1931) 285–304.
2. White, S. ve Pharoah, M., Oral Radiology: Principles and Interpretation, 6th edition, Elsevier, Çin, 2013.
3. Sarment, D., Cone Beam Computed Tomography, John Wiley & Sons, Chichester, 2013.
4. Röntgen, W.C., Ueber Eine Neue Art Von Strahlen, Annalen der Physik, 300 (1898) 1–11.
5. Kells, C.E., Roentgen Rays, Dental Cosmos, 41 (1899) 1014–1029.
6. Iannucci, J. ve Howerton, L.J., Dental Radiography: Principles and Techniques, Elsevier Health Sciences, ABD, 2013.
7. Basrani, B., Endodontic Radiology, John Wiley & Sons, Birleşik Krallık, 2012.
8. Scarfe, W.C. ve Farman, A.G., What is Cone-Beam CT and How Does it Work?, Dental clinics of North America, 52 (2008) 707–30.
9. Kau, C.H., Bozic, M., English, J., Lee, R., Bussa, H. ve Ellis, R.K., Cone-Beam Computed Tomography of the Maxillofacial Region - An Update, The International Journal of Medical Robotics + Computer Assisted Surgery : MRCAS, 5 (2009) 366–80.
10. Tsiklakis, K., Donta, C., Gavala, S., Karayianni, K., Kamenopoulou, V. ve Hourdakis, C.J., Dose reduction in maxillofacial imaging using low dose Cone Beam CT, European Journal of Radiology, 56 (2005) 413–7.
11. Silva, M.A.G., Wolf, U., Heinicke, F., Bumann, A., Visser, H. ve Hirsch, E., Cone-Beam Computed Tomography for Routine Orthodontic Treatment Planning: A Radiation Dose Evaluation, American Journal of Orthodontics and Dentofacial Orthopedics, 133 (2008) 640-1.
12. Roberts, J.A., Drage, N.A., Davies, J. ve Thomas, D.W., Effective Dose From Cone Beam CT Examinations in Dentistry, The British Journal of Radiology, 82 (2009) 35–40.
13. Büyük, S. ve Ramoğlu, S.İ., Cone Beam Computed Tomography in Orthodontic Diagnosis, Journal of Health Sciences, 20 (2011) 227–234.
14. Council, N.R., Mathematics and Physics of Emerging Biomedical Imaging, National Academies Press, Washington, D.C., 1996.

15. Hounsfield, G.N., Computerized Transverse Axial Scanning (Tomography): Part I. Description Of System, The British Journal of Radiology, 68 (1995) H166-72.
16. Epstein, C.L., Introduction to the Mathematics of Medical Imaging, Society for Industrial and Applied Mathematics, Philadelphia, 2007.
17. Patel, S., Dawood, A., Ford, T.P. ve Whaites, E., The Potential Applications of Cone Beam Computed Tomography in the Management of Endodontic Problems, International Endodontic Journal, 40 (2007) 818–30.
18. Scarfe, W.C., Farman, A.G. ve Sukovic, P., Clinical Applications of Cone-Beam Computed Tomography in Dental Practice, Journal of Canadian Dental Association, 72 (2006) 75–80.
19. Dawood, A., Patel, S. ve Brown, J., Cone beam CT in dental practice, British Dental Journal, 207 (2009) 23–28.
20. Simon, J.H.S., Enciso, R., Malfaz, J-M., Roges, R., Bailey-Perry, M. ve Patel, A., Differential Diagnosis of Large Periapical Lesions Using Cone-Beam Computed Tomography Measurements and Biopsy, Journal of Endodontics, 32 (2006) 833–7.
21. Sukovic, P., Cone Beam Computed Tomography in Craniofacial Imaging, Orthodontics and Craniofacial Research, 6 (2003) 31–36.
22. Holberg, C., Steinhäuser, S., Geis, P. ve Rudzki-Janson, I., Cone-Beam Computed Tomography in Orthodontics: Benefits and Limitations, Journal of Orofacial Orthopedics, 66 (2005) 434–44.
23. Kapila, S., Conley, R.S., Harrell ve W.E., The Current Status of Cone Beam Computed Tomography Imaging In Orthodontics, Dentomaxillofacial Radiology, 40 (2011) 24–34.
24. De Vos, W., Casselman, J. ve Swennen, G.R.J., Cone-Beam Computerized Tomography (CBCT) Imaging of the Oral and Maxillofacial Region: A Systematic Review of the Literature, International Journal of Oral and Maxillofacial Surgery, 38 (2009) 609–25.
25. Van Assche, N., Van Steenberghe, D., Guerrero, M.E., Hirsch, E., Schutyser, F., Quirynen M ve Jacobs, R., Accuracy of Implant Placement Based on Pre-Surgical Planning of Three-Dimensional Cone-Beam Images: A Pilot Study, Journal of Clinical Periodontology, 34 (2007) 816–21.
26. Kim, S-H., Choi, Y-S., Hwang, E-H., Chung, K-R., Kook, Y-A. ve Nelson G., Surgical Positioning of Orthodontic Mini-Implants with Guides Fabricated on Models Replicated with Cone-Beam Computed Tomography, American Journal of Orthodontics and Dentofacial Orthopedics, 131 (2007) S82-9.
27. Gohel, A., Villa, A. ve Sakai, O., Benign Jaw Lesions., Dental Clinics North America 60 (2016) 125–41.

28. Johnson, N.R., Gannon, O.M., Savage, N.W. ve Batstone, M.D., Frequency of Odontogenic Cysts And Tumors: A Systematic Review, Journal of Investigative and Clinical Dentistry, 5 (2014) 9–14.
29. Shear, M., Speight ve Paul, M., Wiley InterScience (Online service), Cysts of the Oral and Maxillofacial Regions, Blackwell, Birleşik Krallık 2007.
30. Lofthag-Hansen, S., Huuonen, S., Gröndahl, K. ve Gröndahl, H-G., Limited Cone-Beam CT and Intraoral Radiography for the Diagnosis of Periapical Pathology, Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology, 103 (2007) 114–119.
31. Patel, S., Wilson, R., Dawood, A. ve Mannocci, F., The Detection of Periapical Pathosis Using Periapical Radiography and Cone Beam Computed Tomography - Part 1: Pre-Operative Status, International Endodontic Journal, 45 (2012) 702–710.
32. Jones, A.V., Craig, G.T. ve Franklin C.D., Range and Demographics of Odontogenic Cysts Diagnosed in a UK Population Over a 30-Year Period, Journal of Oral Pathology & Medicine, 35 (2006) 500–507.
33. Daley, T.D, Wysocki, G.P. ve Pringle G.A., Relative Incidence of Odontogenic Tumors and Oral and Jaw Cysts in a Canadian Population, Oral Surgery, Oral Medicine, Oral Pathology, 77 (1994) 276–280.
34. Escoda Francolí, J., Almendros Marqués, N., Berini Aytés, L. ve Gay Escoda, C., Nasopalatine Duct Cyst: Report Of 22 Cases and Review of the Literature, Medicina Oral, Patología Oral y Cirugia Bucal, 13 (2008) E438-43.
35. Barnes, L., Pathology and Genetics of Head and Neck Tumours, IARC, Lyon, 2005.
36. Aydemir, O. ve Kayikcioglu, T., Comparing Common Machine Learning Classifiers In Low-Dimensional Feature Vectors for Brain Computer Interface Applications, International Journal of Innovative Computing, Information and Control, 9 (2013) 1145–1157.
37. Sevik, U., Kose, C., Berber, T., ve Erdol, H., Identification of Suitable Fundus Images Using Automated Quality Assessment Methods., Journal of Biomedical Optics, 19 (2014) 046006.
38. Flores, A., Rysavy, S., Enciso, R. ve Okada, K., Non-Invasive Differential Diagnosis of Dental Periapical Lesions In Cone-Beam CT, 2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro, Haziran 2009, Boston, Bildiriler Kitabı: 566–569.
39. Mikulka, J., Gescheidtová, E., Kabrda, M. ve Peřina, V., Classification of Jaw Bone Cysts and Necrosis via the Processing of Orthopantomograms, Radioengineering, 22 (2013).
40. Okada, K., Rysavy, S., Flores, A. ve Linguraru, M.G., Noninvasive Differential Diagnosis of Dental Periapical Lesions In Cone-Beam CT Scans, Medical Physics, 42 (2015) 1653–1665.

41. Abdolali, F., Zoroofi, R.A., Otake, Y. ve Sato, Y., Automatic Segmentation of Maxillofacial Cysts In Cone Beam CT Images, Computers in Biology and Medicine, 72 (2016) 108–119.
42. Abdolali, F., Zoroofi, R.A., Otake, Y. ve Sato, Y., Automated Classification of Maxillofacial Cysts In Cone Beam CT Images Using Contourlet Transformation and Spherical Harmonics, Computer Methods and Programs in Biomedicine, 139 (2017) 197–207.
43. Kauke, M., Safi, A.F., Grandoch, A., Nickenig, H.J., Zöller, J. ve Kreppel, M., Volumetric Analysis of Keratocystic Odontogenic Tumors and Non-Neoplastic Jaw Cysts - Comparison and its Clinical Relevance, Journal of Cranio-Maxillofacial Surgery, 46 (2018) 257–263.
44. Duda R.O., Hart P.E. ve Stork D.G., Pattern Classification, John Wiley & Sons, ABD, 2012.
45. Nurtanio I., Classifying Cyst and Tumor Lesion Using Support Vector Machine Based on Dental Panoramic Images Texture Features, IAENG International Journal of Computer Science, 40 (2013).
46. Estrela, C., Bueno, M.R., Azevedo, B.C., Azevedo, J.R. ve Pécora, J.D., A New Periapical Index Based on Cone Beam Computed Tomography, Journal of Endodontics, 34 (2008) 1325–31.
47. Patel, S., Dawood, A., Mannocci, F., Wilson, R., ve Pitt Ford, T., Detection of Periapical Bone Defects In Human Jaws Using Cone Beam Computed Tomography and Intraoral Radiography, International Endodontic Journal, 42 (2009) 507–15.
48. Liang, Y.H., Jiang, L., Gao, X.J., Shemesh, H., Wesselink, P.R. ve Wu, M.K., Detection and Measurement of Artificial Periapical Lesions by Cone-Beam Computed Tomography, International Endodontic Journal, 47 (2014) 332–8.
49. Pinsky, H.M., Dyda, S., Pinsky, R.W., Misch, K.A. ve Sarment, D.P., Accuracy of Three-Dimensional Measurements Using Cone-Beam CT, Dentomaxillofacial Radiology, 35 (2006) 410–6.
50. Kayipmaz, S., Sezgin, O.S., Saricaoglu, S.T. ve Çan, G., An in Vitro Comparison of Diagnostic Abilities of Conventional Radiography, Storage Phosphor, and Cone Beam Computed Tomography to Determine Occlusal and Approximal Caries, European Journal of Radiology, 80 (2011) 478–82.
51. Kayipmaz, S., Sezgin, O.S., Saricaoglu, S.T., Bas, O., Sahin, B. ve Küçük, M., The Estimation of the Volume of Sheep Mandibular Defects Using Cone-Beam Computed Tomography Images and a Stereological Method, Dentomaxillofacial Radiology, 40 (2011) 165–9.
52. Sezgin, O.S., Kayipmaz, S. ve Sahin, B., The Effect of Slice Thickness on the Assessment of Bone Defect Volumes by the Cavalieri Principle Using Cone Beam Computed Tomography, Journal of Digital Imaging, 26 (2013) 115–8.

53. Rysavy, S., Flores, A., Enciso, R. ve Okada, K., Segmentation of Large Periapical Lesions Toward Dental Computer-Aided Diagnosis In Cone-Beam CT Scans, *Medical Imaging 2008: Image Processing*, Ocak 2008, San Diego, Bildiriler Kitabı: 691444.
54. Freund, Y. ve Schapire, R.E., A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting, *Journal of Computer and System Sciences*, 55 (1997) 119–139.
55. Kohavi, R., A Study of Cross-validation and Bootstrap for Accuracy Estimation and Model Selection, 14th International Joint Conference on Artificial Intelligence (IJCAI), Ağustos 1995, Montreal, Bildiriler Kitabı: 1137–1143.
56. Costaridou, L, *Medical Image Analysis Methods*, CRC Press, ABD, 2005.
57. Toennies, K.D., *Guide to Medical Image Analysis*, Springer London, Londra, 2012.
58. Dhawan, A.P., *Medical Image Analysis*, John Wiley & Sons, Singapur, 2011.
59. Norouzi, A., Rahim, M.S.M., Altameem, A., Saba, T., Rad, A.E., Rehman, A. ve diğerleri, *Medical Image Segmentation Methods, Algorithms, and Applications*, *IETE Technical Review*, 31 (2014) 199–213.
60. Schulze, R., Heil, U., Gross, D., Bruellmann, D.D., Dranischnikow, E., Schwanecke, U. ve diğerleri, *Artefacts in CBCT: A Review.*, *Dentomaxillofacial Radiology*, 40 (2011) 265–73.
61. Zhang, H., Liu, Y., Han, H., Fan, Y., Wang, J. ve Liang, Z., A Comparison Study on KL Domain Penalized Weighted Least-Squares Approach to Noise Reduction For Low-Dose Cone-Beam CT, 2012 IEEE Nuclear Science Symposium and Medical Imaging Conference Record (NSS/MIC), Kasım 2012, Kaliforniya, Bildiriler Kitabı: 3328–3332.
62. Kroon, D. ve Slump, C., Coherence Filtering To Enhance The Mandibular Canal in Cone-Beam CT Data, 4th Annual Symposium of the Benelux Chapter of the IEEE Engineering in Medicine and Biology Society (EBMS), Kasım 2009, Enschede, Bildiriler Kitabı: 41–44.
63. Zhu, L., Wang, J. ve Xing, L., Noise Suppression in Scatter Correction for Cone-Beam CT, *Medical Physics*, 36 (2009) 741.
64. Liu, X., Tanaka, M. ve Okutomi, M., Noise Level Estimation Using Weak Textured Patches of a Single Noisy Image, 2012 19th IEEE International Conference on Image Processing, Eylül 2012, Orlando, Bildiriler Kitabı: 665–668.
65. Crete, F., Dolmiere, T., Ladret, P. ve Nicolas, M., The Blur Effect: Perception and Estimation With a New No-Reference Perceptual Blur Metric, *Human Vision and Electronic Imaging XII*, Ocak 2007, Kaliforniya, Bildiriler Kitabı: 1–11.
66. Perona, P. ve Malik, J., Scale-Space and Edge Detection Using Anisotropic Diffusion, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12 (1990) 629–639.

67. Gerig, G., Kubler, O., Kikinis, R. ve Jolesz, F.A., Nonlinear Anisotropic Filtering of MRI Data, IEEE Transactions on Medical Imaging, 11 (1992) 221–232.
68. Yilmaz, E., Kayikcioglu, T. ve Kayipmaz, S., Experimental Comparison of Different Noise Reduction Techniques on Cone Beam Computed Tomography Images, 2014 22nd Signal Processing and Communications Applications Conference (SIU), Nisan 2014, Trabzon, Bildiriler Kitabı: 2086–2089.
69. Buades, A, Coll, B. ve Morel. J., A Non-Local Algorithm for Image Denoising, Computer Vision and Pattern Recognition, 2 (2005) 60–65.
70. Lim, J.S., Two-dimensional Signal and Image Processing, Prentice Hall, ABD, 1990.
71. Dabov, K., Foi, A., Katkovnik, V. ve Egiazarian, K., Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering, IEEE Transactions on Image Processing, 16 (2007) 2080–2095.
72. Huynh-Thu, Q. ve Ghanbari, M., Scope of Validity of PSNR In Image/Video Quality Assessment, Electronic Letters, 44 (2008) 800.
73. Yilmaz, E., Kayikcioglu, T. ve Kayipmaz, S., Noise Removal of CBCT Images Using an Adaptive Anisotropic Diffusion Filter, 2017 40th International Conference on Telecommunications and Signal Processing (TSP), Temmuz 2017, Barselona, Bildiriler Kitabı: 650–653.
74. Shapurian, T., Damoulis, P.D., Reiser, G.M., Griffin, T.J. ve Rand, W.M., Quantitative Evaluation of Bone Density Using the Hounsfield Index, International Journal of Oral & Maxillofacial Implants, 21 290–7.
75. Yilmaz, E., Kayikcioglu, T. ve Kayipmaz, S., Computer-Aided Diagnosis of Periapical Cyst and Keratocystic Odontogenic Tumor on Cone Beam Computed Tomography, Computer Methods and Programs in Biomedicine, 146 (2017) 91–100.
76. Yilmaz, E., Kayikcioglu, T. ve Kayipmaz, S., Semi-Automatic Segmentation of Apical Lesions In Cone Beam Computed Tomography Images, 2017 25th Signal Processing and Communications Applications Conference (SIU), Mayıs 2017, Antalya, Bildiriler Kitabı: 1–4.
77. Li, W., Modified K-Means Clustering Algorithm, 2008 Congress on Image and Signal Processing, Mayıs 2008, Sanya, Bildiriler Kitabı, 618–621.
78. Grady, L., Random Walks for Image Segmentation., IEEE Transactions on Pattern Analysis and Machine Intelligence, 28 (2006) 1768–1783.
79. Kass, M., Witkin, A. ve Terzopoulos, D., Snakes: Active Contour Models, International Journal of Computer Visison, 1 (1988) 321–331.
80. Wang, L., He, L., Mishra, A. ve Li, C., Active Contours Driven by Local Gaussian Distribution Fitting Energy, Signal Processing, 89 (2009) 2435–2447.

81. Wang, H.J. ve Liu, M., Active Contours Driven by Local Gaussian Distribution Fitting Energy Based on Local Entropy, International Journal of Pattern Recognition and Artificial Intelligence, 27 (2013) 1355008.
82. Zou, K.H., Warfield, S.K., Bharatha, A., Tempany, C.M.C., Kaus, M.R., Haker, S.J. ve diğerleri, Statistical Validation of Image Segmentation Quality Based on a Spatial Overlap Index I, Academic Radiology, 11 (2004) 178–89.
83. Gonzalez, R.C. ve Woods, R.E., Digital Image Processing (3rd edition), Prentice Hall, ABD, 2008.
84. Haralick, R.M., Shanmugam, K. ve Dinstein, I., Textural Features for Image Classification, IEEE Transactions on Systems, Man, and Cybernetics, 3 (1973) 610–621.
85. Ben Othmen E., Sayadi, M. ve Fnaiech, F., 3D Gray Level Co-Occurrence Matrices for Volumetric Texture Classification, 3rd International Conference on Systems and Control, Ekim 2013, Algiers, Bildiriler Kitabı: 833–837.
86. Varjo, J., Implementing texture analysis software frame for magnetic resonance image data in MATLAB, Yüksek Lisans Tezi, Tampere University of Technology, 2014.
87. Cover, T. ve Hart, P., Nearest Neighbor Pattern Classification, IEEE Transactions on Information Theory, 13 (1967) 21–27.
88. Friedman, N., Geiger, D. ve Goldszmidt, M., Bayesian Network Classifiers, Machine Learning, 29 (1997) 131–163.
89. Rokach, L., Data Mining with Decision Trees: Theory and Applications, World Scientific, Singapur, 2007.
90. Breiman, L., Random Forests, Machine Learning, 45 (2001) 5–32.
91. Lippmann, R.P., Pattern Classification Using Neural Networks, IEEE Communications Magazine, 27 (1989) 47–50.
92. Cortes, C. ve Vapnik, V., Support-Vector Networks, Machine Learning, 20 (1995) 273–297.
93. Hechenbichler, K. ve Schliep, K., Weighted k-Nearest-Neighbor Techniques and Ordinal Classification, https://epub.uni-muenchen.de/1769/1/paper_399.pdf 20 Nisan 2017
94. Ren, J., Lee, S.D., Chen, X., Kao, B., Cheng, R. ve Cheung, D., Naive Bayes Classification of Uncertain Data, 2009 Ninth IEEE International Conference on Data Mining, Aralık 2009, Miami, Bildiriler Kitabı: 944–949.
95. Manning, C.D., Raghavan, P. ve Schütze, H., Introduction to Information Retrieval, Cambridge University Press, Birleşik Krallık, 2008.
96. Kingsford, C. ve Salzberg, S.L., What are Decision Trees?, Nature Biotechnology, 26 (2008) 1011–3.

97. Han, J., Kamber, M. ve Pei, J., *Data Mining: Concepts and Techniques* 3rd ed., Morgan Kaufmann Publishers Inc., ABD, 2011.
98. Svetnik, V., Liaw, A., Tong, C. ve Wang, T., Application of Breiman's Random Forest to Modeling Structure-Activity Relationships of Pharmaceutical Molecules, *International Workshop on Multiple Classifier Systems MSC 2004*, Haziran 2004, Cagliari, Bildiriler Kitabı: 334–343.
99. Haykin S.S., *Neural Networks: A Comprehensive Foundation*, Prentice Hall, Hindistan, 1999.
100. Noble, W.S., What is a Support Vector Machine?, *Nature Biotechnology*, 24 (2006) 1565–1567.
101. Wang, L., *Support Vector Machines: Theory and Applications*, Springer, Heidelberg, 2005.
102. Blumer, A., Ehrenfeucht, A., Haussler, D. ve Warmuth, M.K., Learnability and the Vapnik-Chervonenkis Dimension, *Journal of the ACM*, 36 (1989) 929–965.
103. Sammut, C. ve Webb, G.I., *Encyclopedia of Machine Learning and Data Mining*, Springer US, Boston, 2017.
104. Liu, L ve Özsu, M.T., *Encyclopedia of Database Systems*, Springer US, Boston, 2009
105. Shahrokh Esfahani, M. ve Dougherty, E.R., Effect of Separate Sampling on Classification Accuracy, *Bioinformatics*, 30 (2014) 242–50.
106. Stearns, S., On Selecting Features for Pattern Classifiers, 3rd International Conference on Pattern Recognition, Kasım 1976, Coronado, Bildiriler Kitabı: 71–75.
107. Wold, S., Esbensen, K. ve Geladi, P., Principal Component Analysis, *Chemometrics and Intelligent Laboratory systems*, 2 (1987) 37–52.
108. Abdi, H. ve Williams, L.J., Principal Component Analysis, *Wiley Interdisciplinary Reviews: Computational Statistics*, 2 (2010) 433–459.
109. Pianykh, O.S., *Digital imaging and communications in medicine (DICOM)*, Springer, Berlin, 2008.
110. Tsotsios, C. ve Petrou, M., On the Choice of the Parameters for Anisotropic Diffusion In Image Processing, *Pattern Recognition*, 46 (2013) 1369–1381.
111. Mierswa, I., Wurst, M., Klinkenberg, R., Scholz, M. ve Euler, T., YALE, 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Ağustos 2006, New York, Bildiriler Kitabı: 935-940
112. Sokolova, M. ve Lapalme, G., A Systematic Analysis of Performance Measures for Classification Tasks, *Information Processing & Management*, 45 (2009) 427–437.

ÖZGEÇMİŞ

1979 yılında Trabzon'da doğan Ercüment YILMAZ; ilköğrenimini Dumlupınar İlkokulu'nda, orta ve lise eğitimini Trabzon Kanuni Anadolu Lisesi'nde tamamladı. 1997 yılında girdiği KTÜ Fen Edebiyat Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü'nden 2001 yılında üçüncülük derecesiyle mezun oldu. Aynı yıl KTÜ Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2002 yılında KTÜ Rektörlük Örgütü, Enformatik Bölümü'nde Öğretim Görevlisi olarak göreve başladı. 2006 yılında "Karayolu Trafik Simülasyonu" adlı yüksek lisans tezini tamamladı. Aynı yıl KTÜ Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. 2008 yılında aynı enstitüde bulunan Bilgisayar Mühendisliği Anabilim Dalı'na yatay geçiş yaptı. 2014 yılında TÜBİTAK tarafından TEYDEB 1512 kodlu program ile desteklenen "Şehir İçi ve Şehirlerarası Trafik Şebekelerinin Bilgisayar Ortamında Modellenmesi Analizi ve Simülasyonunu Gerçekleştirecek Yerli Bir Yazılımın Üretilmesi" başlıklı projeyi kurmuş olduğu Yılmaz Bilişim Ltd. Şirketi bünyesinde yürütücü olarak tamamladı. Ercüment YILMAZ kurucusu ve müdürü olduğu Yılmaz Bilişim Ltd. Şirketi bünyesinde proje çalışmalarını sürdürmekte olup aynı zamanda KTÜ Trabzon Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü'nde Öğretim Görevlisi olarak görev yapmaktadır. Yabancı dil olarak iyi derecede İngilizce bilmektedir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Yılmaz, E., Kayıkcıoğlu,T., Kayıpmaz, S., Computer-aided diagnosis of periapical cyst and keratocystic odontogenic tumor on cone beam computed tomography, Comput. Methods Programs Biomed. 146 (2017) 91–100.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

2. Yılmaz E., Kayıkcıoğlu T., Kayıpmaz S., Sezgin Ö.S., "Konik Işınlı Bilgisayarlı Tomografi Görüntülerindeki Çene Patolojilerinin Rasgele Yürüyüşle Belirlenmesi", 8. Uluslararası İstatistik Kongresi, Antalya, Türkiye, 27-30 Ekim 2013, pp.272-273

3. Yilmaz, E., Kayikcioglu, T., Kayipmaz, S., Experimental comparison of different noise reduction techniques on cone beam computed tomography images, in: 2014 22nd Signal Process. Commun. Appl. Conf., IEEE, 2014: pp. 2086–2089.
4. Yilmaz, E., Kayikcioglu, T., Kayipmaz, S., Noise removal of CBCT images using an adaptive anisotropic diffusion filter, in: 2017 40th Int. Conf. Telecommun. Signal Process., IEEE, 2017: pp. 650–653.
5. Yilmaz, E., Kayikcioglu, T., Kayipmaz, S., Semi-automatic segmentation of apical lesions in cone beam computed tomography images, in: 2017 25th Signal Process. Commun. Appl. Conf., IEEE, 2017: pp. 1–4.

