

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN
OTOMATİK MERKEZİ PULMONAR EMBOLİ TESPİTİ

ESRA DİNÇER

KOCAELİ 2016

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

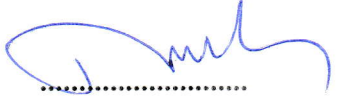


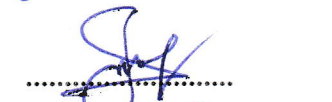

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN
OTOMATİK MERKEZİ PULMONAR EMBOLİ TESPİTİ

ŞERİFE ESRA DİNÇER

Prof. Dr. Nevcihan DURU
Danışman, Kocaeli Üniv.
Prof. Dr. Sarp ERTÜRK
Jüri Üyesi, Kocaeli Üniv.
Prof. Dr. Hasan OCAK
Jüri Üyesi, Kocaeli Üniv.
Prof. Dr. İbrahim SOĞUKPINAR
Jüri Üyesi, Gebze Teknik Üniv.
Prof. Dr. Celal ÇEKEN
Jüri Üyesi, Sakarya Üniv.


.....

.....

.....

.....

.....

Tezin Savunulduğu Tarih: 18.07.2016

ÖNSÖZ VE TEŞEKKÜR

Görüntü işleme ve analiz yöntemleri tıbbi görüntülerin bilgisayar destekli yorumunda veya gözle yapılan yorumu destekleyici tanı bilgilerini güçlendirmeyi hedefliyor. Genellikle belli dönüşüm yöntemleri görüntülenme kalitesini artırıyor ve ilgilenilen özellikleri nitelendirmede kullanılıyor. İnteraktif ve bilgisayar destekli akıllı tıbbi görüntü analizi yöntemleri tıbbi görüntülerin yorumlanmasında hem sayısal hem de nitelleyici açıdan verimli araçlar sağlıyorlar.

Doktora çalışmam boyunca beni destekleyen ve yardımcı olan tez danışmanım Prof Dr. Nevcihan Duru'ya, değerli önerileriyle tezimi yönlendiren Prof Dr. Hasan Ocak ve Prof Dr. Sarp Ertürk'e sonsuz teşekkürlerimi sunarım.

Aldığım doktora araştırma bursuyla, doktora çalışmamın 1 yılını, Arizona State University'de geçirmemi sağlayan Tübitak-BİDEB'e teşekkürlerimi sunarım.

Haziran – 2016

Esra DİNÇER

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ.....	vii
SİMGELER VE KISALTMALAR DİZİNİ.....	viii
ÖZET.....	ix
ABSTRACT.....	x
GİRİŞ.....	1
1. GENEL BİLGİLER.....	8
1.1. Tıbbi Görüntülerin Analiz.....	8
1.1.1. Mevcut inceleme yöntemleri.....	8
1.1.2. Donanım gereksinimleri.....	9
1.1.3. Bilgisayarın tıbbi görüntü işlemedeki yeri.....	10
1.1.4. Görüntü verisinin karmaşıklığı.....	10
1.1.5. Modellemenin karmaşıklığı.....	11
1.2. Tıbbi Görüntü İşlemede Kullanılan Görüntü İşleme Yöntemleri.....	12
1.3. Veri Madenciliği İle Görüntü İşleme.....	13
1.4. Akciğer Anatomisi.....	14
1.5. Bilgisayar Tomografisinin Özellikleri.....	16
1.5.1. Hounsfield skalası.....	19
1.5.2. Dicom görüntü formatı.....	21
1.5.3. Akciğer tomografi kesitlerinin anatomisi.....	21
1.6. Akciğer Embolisi.....	23
1.6.1. Akciğer embolisinin türleri.....	25
1.6.2. Merkezi akciğer embolisi.....	28
1.6.3. Akciğer embolisi tespitindeki zorluklar.....	29
1.7. Bilgisayar Destekli Tespit Sistemleri.....	30
1.8. Tıpta Görüntü Analizi Yöntemlerinin Değerlendirilmesi.....	33
1.8.1. Görüntü analiz problemlerinin türleri.....	34
1.8.2. Temel performans ölçütleri.....	36
1.8.2.1. Ölçüm problemlerinde performans ölçütü.....	36
1.8.2.2. Tespit problemlerinde performans ölçütü.....	36
1.8.2.3. Görüntü bölütleme problemlerinde performans ölçütü.....	44
1.8.3. Eğitim ve sınama yöntemleri.....	49
1.8.3.1. Yarım-yarım.....	49
1.8.3.2. Birini dışarda bırak.....	51
1.8.3.3. N-çeşit çapraz doğrulama.....	51
1.8.4. İstatistiksel sınamalar.....	52
1.9. Tıbbi Görüntü İşlemede Bölütleme ve Kullanılabilen Yöntemler.....	54
1.9.1. Kenar tabanlı yöntemler.....	59
1.9.1.1. Kenar belirleme ve bağlantı kurmak.....	60
1.9.1.2. Sınır izleme.....	61
1.9.1.3. Hough dönüşümü.....	62

1.9.2. Piksel tabanlı doğrudan sınıflandırma yöntemleri	63
1.9.2.1. Eşikleme.....	64
1.9.2.2. Kümeleme aracılığı ile piksel sınıflandırma	69
1.9.3. Bölge tabanlı yöntemler	78
1.9.3.1. Bölge büyütme	78
1.9.3.2. Bölge parçalama yöntemi	79
1.9.4. Diğer yöntemler.....	80
1.9.4.1. Aktif çevreler	80
1.9.4.2. Watershed bölütlemesi.....	82
2. AKCİĞER BÖLÜTLEMESİ	85
2.1. Histogram Tabanlı K-means İle Bölütleme.....	85
2.1.1. Başlangıç küme merkezlerinin seçimi.....	89
2.1.1.1. Düzgün dağılım yöntemi	89
2.1.1.2. Örnekleme yöntemi.....	90
2.1.1.3. Yöntemlerin karşılaştırılması.....	90
2.1.2. Küme merkezlerine olan uzakların hesaplanması	93
2.1.3. Yeni küme merkezlerinin hesaplanması	94
2.1.4. Amaç fonksiyonu ile küme merkezlerini doğrulama	96
2.1.5. Kümeleme doğruluğunun değerlendirilmesi.....	99
2.2. FCM Algoritmasının Uygulanması	102
2.2.1. Sentetik görüntünün karşılaştırılması.....	104
2.2.2. Kesitlerin karşılaştırılması.....	106
2.3. Lob Bölütleme Uygulaması.....	109
2.4. Makale Karşılaştırma ve Uygulama	109
2.4.1. Uygulanan makaleler.....	109
2.4.2. Karşılaştırılan makaleler	110
2.5. Lob Girintilerinin Kapatılması	120
2.5.1. Lob kenarlarının düzleştirilmesi.....	125
3. MERKEZİ PULMONAR EMBOLİ TESPİTİ.....	127
3.1. Kullanılan Görüntülerin Özellikleri	127
3.2. Geliştirilen Programların Adımları	128
3.3. Trake İzlenerek Truncusun Tespiti.....	129
3.4. Ana Arterlerin Ayrıştırılması	131
3.5. Pulmonar Arterin İşlenmesi.....	133
3.6. Bitişik Dokuların Çıkartılması	134
3.7. Merkezi Embolinin Tespiti.....	135
3.7.1. Damar duvarına tutunan emboli.....	136
3.7.2. Damar duvarına tutunmayan emboli	136
3.7.3. Truncusun içinde emboli	137
3.7.4. Tam tıkalı ana arter.....	138
3.7.5. Volüm kontrolü	139
3.8. Değerlendirme	140
3.8.1. Literatürdeki çalışmaların verileri	143
3.8.2. FP sayısı için literatürdeki çalışmalardan örnekler	145
3.8.3. Çalışmadaki zorluklar.....	145
4. SONUÇLAR	147
KAYNAKLAR	150
KİŞİSEL YAYINLAR VE ESERLER	157
ÖZGEÇMİŞ	158

ŞEKİLER DİZİNİ

Şekil 1.1.	Akciğerin yapısı	14
Şekil 1.2.	Akciğer damarları ve hava kesecikleri	15
Şekil 1.3.	Akciğer damarlarının BT ile alınan görüntüsü.....	16
Şekil 1.4.	Bilgisayarlı tomografi cihazı	17
Şekil 1.5.	X-ışını kaynağı 360 derecelik bir dönüş yapar	18
Şekil 1.6.	Voksel	19
Şekil 1.7.	Hounsfield skalası	20
Şekil 1.8.	Kesitlerin anatomik bilgileri	22
Şekil 1.9.	Akciğer embolisi küçük parçalardan oluşur	23
Şekil 1.10.	Akciğer embolisinin damar içinde yerleşebileceği konumlar	24
Şekil 1.11.	Damar içindeki emboli bölgeleri	25
Şekil 1.12.	Merkezi akciğer embolisine örnek	28
Şekil 1.13.	Ana arterlerde emboli örneği.....	29
Şekil 1.14.	Cad sisteminin bulduğu bir emboli örneği	31
Şekil 1.15.	Cad sisteminin hatalı tespit ettiği emboli örneği	32
Şekil 1.16.	Tıbbi görüntü işleme işlemlerinin sonucuna göre gruplanması	33
Şekil 1.17.	ROC eğrisine bir örnek	40
Şekil 1.18.	Özellik değerlerinin dağılımı	41
Şekil 1.19.	Bir tespit algoritması için ROC eğrisinin oluşturulması	42
Şekil 1.20.	Aynı AUC değerine sahip iki farklı ROC eğrisi	43
Şekil 1.21.	Kısmi AUC hesaplama yolları	43
Şekil 1.22.	Örnek bir FROC eğrisi	45
Şekil 1.23.	a) bölütlenmiş görüntü, b) referans görüntü.....	47
Şekil 1.24.	Performans ölçümlerinin kullanımı	57
Şekil 1.25.	Yarım-yarım yöntemi.....	50
Şekil 1.26.	“birini dışarda bırak” yöntemi.....	50
Şekil 1.27.	N çapraz doğrulama yöntemi	51
Şekil 1.28.	İstatistiksel bir sınamada olası hata türleri	54
Şekil 1.29.	(a) Retinal damar (b) Sobel işlemi sonrası, (c) eşikleme sonrası.....	60
Şekil 1.30.	(a) Gürültülü görüntü (b) Sobel işlemi sonrası (c) eşikleme sonrası	60
Şekil 1.31.	(a) Filtreli görüntü (b) Sobel işlemi sonrası (c) eşikleme sonrası	61
Şekil 1.32.	Sınır izleme yöntemi	61
Şekil 1.33.	xy düzlemi ve parametre uzayı.....	63
Şekil 1.34.	Optimal eşikleme.....	65
Şekil 1.35.	Uyarlanabilir eşikleme	68
Şekil 1.36.	Yerel uyarlanabilir eşikleme	68
Şekil 1.37.	K-means kümeleme algoritması.....	71
Şekil 1.38.	K-means algoritmasının adımları	72
Şekil 1.39.	Oyun kağıtlarının k=2 ve k=4 için kümelenmesi	73
Şekil 1.40.	Küme sayısına göre K-means algoritmasının sonuçları	74
Şekil 1.41.	Tek noktadan bölge büyütme örneği.....	78
Şekil 1.42.	Aktif çevreler yöntemi ile oluşan bir görüntü	82
Şekil 1.43.	Başlangıççı iyi belirlenen diğer bir örnek	82
Şekil 1.44.	Watershed yönteminin ikili görüntüye uygulanması	83

Şekil 1.45. Watershed yönteminin bulanık görüntüye uygulanması.....	84
Şekil 2.1. Dicom kesitten lob bölgesini elde etme işleminin aşamaları	86
Şekil 2.2. Geliştirilen K-means algoritmasının adımları	88
Şekil 2.3. Düzgün dağılım ile ilk küme merkezleri.....	91
Şekil 2.4. Düzgün dağılım ile son küme merkezleri	91
Şekil 2.5. Histogram eğrisi üzerinde örnekleme aralığı	92
Şekil 2.6. Örnekleme ile ilk küme merkezleri.....	93
Şekil 2.7. Örnekleme ile son küme merkezleri.....	93
Şekil 2.8. Aritmetik ortalama ile son küme merkezlerinin dağılımı	95
Şekil 2.9. CT000050 kestine uygulanan amaç fonksiyonlarının grafikleri.....	98
Şekil 2.10. Amaç fonksiyonlarının kesitlere göre grafiksel gösterimi	102
Şekil 2.11. CT000200 kesitinin amaç fonksiyonun iterasyona göre değişimi	103
Şekil 2.12. Görüntünün dört kümeye ayrılması.....	104
Şekil 2.13. Görüntünün beş kümeye ayrılması.....	105
Şekil 2.14. CT000150 kesitinin karşılaştırması.....	107
Şekil 2.15. Kümelenen loblar	108
Şekil 2.16. İlk ve son küme merkezleri	108
Şekil 2.17. Lob bölütleme sonuçları	109
Şekil 2.18. Elaine.tiff görüntüsü	112
Şekil 2.19. Örnekleme ile başlangıç küme merkezleri	113
Şekil 2.20. Son küme merkezleri ve küme sınırları.....	113
Şekil 2.21. Görüntünün 3 kümeye ayrılmış sonucu	114
Şekil 2.22. Görüntünün 4 kümeye ayrılmış sonucu	114
Şekil 2.23. Uygulanan makalenin görsel sonuçları	114
Şekil 2.24. CT00150 kesitinin bölütlenmesi	118
Şekil 2.25. CT00200 kesitinin bölütlenmesi	118
Şekil 2.26. IMG00060 kesitinin bölütlenmesi.....	119
Şekil 2.27. EE004437 kesitinin bölütlenmesi	119
Şekil 2.28. CT00103 kesitinin orijinal görüntüsü	120
Şekil 2.29. CT00103 kesitinin 4 kümeye ayrılmış hali	121
Şekil 2.30. CT00103 kesitine kümeleme ve bağlı bileşen uygulaması	121
Şekil 2.31. (a-d) ve (b-e) görüntüsü birleştirilerek elde edilen lob (c-f)	122
Şekil 2.32. Girintileri kapatma işleminin son aşaması	122
Şekil 2.33. Farklı işlem gerektiren kesitlere örnek.....	123
Şekil 2.34. CT000068 kesitine uygulanan işlemler.....	124
Şekil 2.35. CT000106 kesitine uygulanan işlemler	124
Şekil 2.36. Lob kenarlarının düzleştirilmesi.....	125
Şekil 2.37. CT000075 kesitine uygulanan işlemler	126
Şekil 3.1. Trakeden başlayıp truncusun bulunmasının adımları.....	128
Şekil 3.2. Truncusun taranma işleminin adımları.....	129
Şekil 3.3. Kesit kümesinin ilk kesiti ve truncusun bulunduğu kesit.....	130
Şekil 3.4. Trakeden truncusa ulaşma adımları.....	131
Şekil 3.5. Sol (a) ve sağ (b) ana pulmonary arterler	132
Şekil 3.6. Dallanma noktasının tespiti	132
Şekil 3.7. Truncusun seçilmesi ve arterlerin işaretlenmesi	133
Şekil 3.8. Ayrıştırılan a) sol arter b) sağ arter	133
Şekil 3.9. Bitişik dokuların çıkartılması	134
Şekil 3.10. Damar duvarına tutunan emboli.....	136
Şekil 3.11. Damar duvarına tutunmayan emboli	137

Şekil 3.12. Truncusun içindeki emboli	138
Şekil 3.13. Tam tıkalı ana arterler	138
Şekil 3.14. İşaretlenebilen tam tıkalı ana arter	139
Şekil 3.15. Ana arterde işaretlenen merkezi emboliler.....	139
Şekil 3.16. Toplam 32 vakaya ait duyarlılık FROC eğrisi	142
Şekil 3.17. Hatalı tespitlere neden olan bitişik dokulara örnekler-1	146
Şekil 3.18. Hatalı tespitlere neden olan bitişik dokulara örnekler-2	146



TABLolar DİZİNİ

Tablo 1.1. Dicom formatlı görüntü özelliklerinden bazıları	21
Tablo 1.2. Doğru ve yanlış pozitif ve negatiflerin tanımı.	37
Tablo 2.1. Karşılaştırılan örnek kesit.....	90
Tablo 2.2. Düzgün dağılım ve örnekleme yöntemlerinin karşılaştırılması	90
Tablo 2.3. Aritmetik ve ağırlıklı aritmetik ortalamanın karşılaştırılması.....	96
Tablo 2.4. Amaç fonksiyonlarının min iterasyon sayıları.	99
Tablo 2.5. Küme sayısı doğrulama.....	101
Tablo 2.6. Amaç fonksiyonlarına doğrulama indisinin uygulanması.....	102
Tablo 2.7. Dört kümenin ilk ve son merkezleri.....	105
Tablo 2.8. Beş kümenin merkezleri.....	106
Tablo 2.9. Örnek kesitlerin karşılaştırma sonuçları.....	107
Tablo 2.10. Elaine görüntüsü için ilk küme merkezleri	112
Tablo 2.11. Örnekleme ile elde edilen küme merkezleri	112
Tablo 2.12. K-means ve AFKM algoritmalarının sonuçları	115
Tablo 2.13. CT000150 kesitinin eşikleme adımları	117
Tablo 2.14. CT000200 kesitinin eşikleme adımları	117
Tablo 3.1. Görüntülerin özellikleri	127
Tablo 3.2. Sonuç tablosu	141
Tablo 3.3. Eşik değerlerine karşılık elde edilen hassasiyet ve FP/vs oranları.....	142
Tablo 3.4. Merkezi emboli tespit çalışmasının sonuçları	142
Tablo 3.5. Tıbbi makalelerde merkezi embolinin bulunma oranları	143
Tablo 3.6. Merkezi embolinin gözden kaçma oranları.....	143
Tablo 3.7. Literatürdeki merkezi pulmonar emboli tespit oranları.....	144
Tablo 3.8. Literatürde merkezi emboliyi içeren çalışmaların tespit oranları.....	145
Tablo 3.9. Literatürdeki bazı çalışmaların FP sayıları ve diğer tespitler.....	145

SİMGELER VE KISALTMALAR DİZİNİ

c	: Küme merkezleri
d	: Uzaklık (birim)
E	: Hata olasılığı
f	: Örnekleme aralığı
h	: Hausdorff uzaklığı (birim)
i	: Kesişim (intercept)
I	: Görüntü matrisi
k	: Küme sayısı
m	: Histogram fonksiyonu
n	: Eleman sayısı
p	: Yoğunluk fonksiyonu
P	: Olasılık
s	: Eğim
T	: Eşik değeri
μ	: Ortalama
σ	: Standart sapma

Kısaltmalar

BT	: Bilgisayarlı Tomografi
BTAG	: Bilgisayarlı Tomografi Anjiyografi Görüntüsü
CAD	: Computer Aided Detection (Bilgisayar Destekli Tespit)
CTPA	: Computed Tomographic Pulmonary Angiography (Bilgisayarlı Tomografik Akciğer Anjiyografisi)
DICOM	: Digital Imaging and Communication in Medicine (Tıpta Sayısal Görüntüleme ve Haberleşme)
FCM	: Fuzzy C-means (Bulanık C-means)
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Pozitif)
FP/vs	: False Positive (Vaka Sayısı)
FPF	: False Positive Fraction (Yanlış Pozitif Oran)
FROC	: Free Receiver Operating Characteristic (Serbest Yanıtlı Karar İşletim Karakteristiği)
HU	: Hounsfield Units (Hounsfield Ünitesi)
NPV	: Negative Predictive Value (Negatif Tahmin Değeri)
PACS	: Picture Archiving and Communication System (Resim Arşivleme ve Haberleşme Sistemi)
PE	: Pulmonary Embolism (Pulmoner Emboli)
PPV	: Positive Predictive Value (Pozitif Tahmin Değeri)
TN	: True Negative (Doğru Negatif)
TP	: True Positive (Doğru Pozitif)
TPF	: True Positive Fraction (Doğru Pozitif Oran)

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDEN OTOMATİK MERKEZİ PULMONAR EMBOLİ TESPİTİ

ÖZET

Akciğer embolisi, tanısı zor, ölüm oranı ve karşılaşıma oranı yüksek bir akciğer hastalığıdır. Belirgin emboliler modern bilgisayarlı tomografik görüntülerle tespit edilmektedir. Ancak çeşitli etkenlerden dolayı görüntülerin doğru ve etkili şekilde yorumlanamadığı durumlar olmaktadır. Yorumlama ve tespit başarısını artırmak için çeşitli bilgisayar destekli tespit sistemleri ve yöntemleri geliştirilmektedir.

Bu tez çalışmasında Bilgisayarlı Tomografi Anjiyografi Görüntülerinden (BTAG), otomatik olarak merkezi pulmonar emboli tespit eden bir yöntem geliştirilmesi amaçlanmıştır. Çalışmanın birinci kısmında geliştirilen histogram tabanlı k-means algoritması ile akciğer bölütlenerek loblar elde edilmiştir. Bu yöntem literatürde ilk defa akciğer bölütlemesine uygulanmıştır. Farklı yoğunluk değerlerindeki kesitler normalizasyon işlemi gerekmeden işlenebilmiştir. Histogram tabanlı k-means algoritmasının performansı, geleneksel k-means, Fuzzy C-means ve optimal eşikleme algoritması ile karşılaştırılarak daha başarılı bulunmuştur. Birinci kısımda bölütleme başarısı %96 olarak elde edilmiştir. İkinci kısımda otomatik merkezi pulmonar emboli tespit eden bir sistem geliştirilmiştir. İşlem, kesit setinin başlangıcında soluk borusunun tespit edilmesiyle başlamıştır. Ardından kesitler sıralı olarak okunarak her bir kesitte soluk borusu takip edilmiştir. Soluk borusunun dallanma noktasını içeren kesitte truncus bulunmuştur. Truncusun yer aldığı kesitlerde emboli araması yapılmıştır. Bu kısımda bölütleme yapılmaması ve kural tabanlı algoritma yaklaşımı kullanılması sayesinde işlem maliyeti düşüktür. Çalışmanın ikinci kısmında 32 vaka işlenmiştir, bir radyolog tarafından onaylanan 60 embolinin 56 tanesi doğru tespit edilmiştir. Hassasiyet oranı %93, FP/vs oranı 2,56 olarak bulunmuştur. Literatürdeki benzer çalışmalarda hesaplama maliyeti yüksek daha karmaşık algoritmalar kullanılmış ve elde edilen en yüksek hassasiyet oranı %87 olarak bildirilmiştir.

Anahtar Kelimeler: Bilgisayar Destekli Tanı, Görüntü Bölütleme, K-means Kümeleme Algoritması, Merkezi Pulmonar Emboli.

AUTOMATIC DETECTION OF CENTRAL PULMONARY EMBOLISM IN COMPUTED TOMOGRAPHIC IMAGES

ABSTRACT

Pulmonary embolism is a lung disease which can be difficult to diagnosis, has a high occurring rate and a mortality rate. The explicit embolus can be detected by using the modern computed tomographic scans. However there are cases which could not be understood correctly and efficiently due to the various factors. It has been developing various computer aided diagnosis systems and methodologies in order to increase the understanding and diagnosis success.

In this doctorate study, it is aimed to develop a method to detect central pulmonary embolism automatically by using Computed Tomographic Pulmonary Angiography (CTPA) images. In the first part of the study, the histogram based K-means algorithm was developed to segment the lungs and to extract the lobes. This method has been applied on lung segmentation for the first time in the literature. The slices which have different intensity values, have not been normalized to be processed. The performance of this algorithm was compared with the traditional k-means, the Fuzzy C-means and the optimal thresholding algorithms and found that it had better success rates. In the first part of the study, the segmentation success rate was 96%.

In the second part of the study, a system has been developed to detect central pulmonary embolism automatically. The process started by detecting the trachea in the beginning slice of each case. Then the trachea was traced down through the slices. When the trachea bifurcation area was reached, the truncus was extracted from the slice. The truncus was searched for embolus through the slices until it disappears in the slice. The computational cost was low as no segmentation was performed and the rule based approach was used. In this study, 56 of 60 embolus in 32 cases were detected and confirmed by a radiologist. The achieved sensitivity is 93% and FP/ds rate is 2,56. In the literature, the similar studies used complex algorithms with high computational cost and the max sensitivity rate was reported as 87%.

Keywords: Computer Aided Diagnosis, Image Segmentation, K-means Clustering Algorithm, Central Pulmonary Embolism.

GİRİŞ

Geçtiğimiz 20 yılda tıbbi görüntüleme ve bilgisayarlı tıbbi görüntü işleme konusunda önemli gelişmeler kaydedilmiştir. Çok boyutlu görüntüleme biçimleri tanısal radyolojide önemli klinik araçlar haline gelmiştir. Teşhis ve tedavide radyolojik görüntüleme biçimlerinin klinik önemi tartışılmaz.

Görüntü işleme ve analiz yöntemleri tıbbi görüntülerin bilgisayar destekli yorumunda veya gözle yapılan yorumu destekleyici tanı bilgilerini güçlendirmeyi hedeflemektedir. Genellikle belli dönüşüm yöntemleri görüntülenme kalitesini artırmakta ve ilgilenilen özellikleri nitelendirmede kullanılmaktadır. İnteraktif ve bilgisayar destekli akıllı tıbbi görüntü analizi yöntemleri, tıbbi görüntülerin yorumlanmasında hem sayısal hem de nitelleyici açıdan verimli araçlar sağlamaktadırlar. Bu araçlar hastalık ve tedaviye cevapla ilişkili fizyolojik süreçte anlama konusunda, tedavi izleme, müdahale ve tanı için yardımcı olabilmektedirler [1].

İnsan vücudunun dolaşım sisteminin görevi, besinleri vücut dokularına taşımak, artık maddeleri uzaklaştırmak ve yaşam koşullarını sağlamak için vücut dokularının gereksinimlerini karşılamaktır. Bu sisteminin merkezi organı kalptir. Kirli kanı vücuttan toplar, temizlenmesi için akciğerlere yollar ve temizlenen kanı vücuda pompalar. Dolaşım sistemi problemlerinden biri akciğer embolisidir (PE-pulmonar emboli). Akciğerlerin atardamarında biriken kan pıhtısı ile damarların tıkanması sonucu ortaya çıkan bir klinik tablodur. Akciğer embolisi derin ven trombozu adı verilen ve genellikle bacak veya baldır toplardamarlarında oluşan bir pıhtı parçasının yerinden kopup dolaşıma katılması ve akciğer damarlarına gelerek bir tıkanmaya yol açması ile oluşur.

Akciğer embolisi, tanısı zor, ölüm oranı ve karşılaşımla oranı yüksek bir akciğer hastalığıdır. Belirgin emboliler modern Bilgisayarlı Tomografi Anjiyografi Görüntülerinden (BTAG) tespit edilmektedir. Her bir tomografi çekimi, boyundan başlayıp karaciğerde sonlanan ortalama 600 kesit görüntü içermektedir. Tomografi

çekimi öncesinde hastanın damarlarına kontras madde verilmektedir. Bu madde sayesinde akciğer damarları çekimde parlak görünür. Parlak damarların içindeki koyu bölgeler emboliyi düşündürür. Bilgisayarlı Tomografi Anjiyografi Görüntülerinde yoğunluk değerleri Hounsfield Unit (HU) ile ölçülür. Farklı HU değerleriyle bölgeler birbirinden ayrıştırılır. Örneğin akciğer bölgesi ve bronşlar -500 HU'dan daha düşüktür. Kontras madde verilmiş kan damarları ve kemikler 200 HU'dan daha yüksektir. Ancak çeşitli etkenlerden dolayı görüntülerin doğru ve etkili şekilde yorumlanamadığı durumlar olmaktadır. Yorumlama ve tespit başarısını artırmak için çeşitli bilgisayar destekli tespit sistemleri ve yöntemleri geliştirilmektedir.

Akciğer embolisi bulunduğu yere göre lobar, segmental ve subsegmental olarak sınıflandırılır. Ana ve lobar arterlerde oluşan pıhtı, merkezi pulmonar emboli, segmental ve subsegmental dallarda oluşan pıhtı ise çevresel (peripheral) pulmonar emboli olarak adlandırılır. Akciğer embolisinin bilgisayar destekli tespit çalışmalarında, her bir sınıf için, sınıfın özelliklerine göre geliştirilen birbirinden farklı yöntemler kullanılır.

Bu tez çalışmasında, Bilgisayarlı Tomografi Anjiyografi Görüntülerinden otomatik olarak merkezi pulmonar emboli tespit eden bir yöntem geliştirilmesi amaçlanmıştır. Çalışma öncesinde Kocaeli Üniversitesi Tıp Fakültesi Radyoloji Bölümünün Dekanlığı ile görüşülerek, görüntü işleme konusu kapsamında geliştirilmesi yararlı olabilecek konularda fikirleri alınmıştır. Otomatik pulmonar emboli tespiti Radyoloji Bölümünün geliştirilmesini önerdiği bir konu olarak seçilmiştir. Çalışmanın birinci kısımda geliştirilen histogram tabanlı k-means algoritması ile akciğer bölütlenerek loblar elde edilmiştir. İkinci kısımda otomatik merkezi pulmonar emboli tespit eden bir sistem geliştirilmiştir.

Tıbbi görüntü analizinde ve sınıflandırılmasında kullanılan başlıca yöntemlerden biri k-means'dir. K-means bir kümeleme yöntemidir ve görüntü verisinin kümelenmesinde ve sınıflandırılmasında kullanılmaktadır. Görüntü bölütlemesinde k-means kümeleme algoritmasının kullanıldığı literatür çalışmalarından bazıları şöyledir; Isa ve arkadaşları boş kümelerin oluşumunun önlenebildiği, gürültüden daha az etkilenen ve ilk merkezleri seçme başarısı daha yüksek bir görüntü

bölütleme algoritması elde etmek için k-means algoritmasını geliştirmişlerdir [2]. Beyin tomografisi görüntülerinin bölütlenerek normal ve anormal bölgelerin ayrıştırılmasında [3] ve beyin görüntülerinin kümelenecek tümör tespitinde [4] k-means kullanılmıştır. Başka bir çalışmada MR görüntülerinin tıbbi analizi k-means ve watershed yöntemiyle beraber gerçekleştirilmiştir [5]. Kawata ve ekibi akciğer tomografi görüntülerindeki yoğunluk dağılımını k-means ile kümeleyerek nodülleri sınıflandırmışlardır [6]. K-means algoritmasının üç boyutlu tıbbi görüntüleri [7] ve ultrasonografik görüntüleri [8] bölütlemek için kullanıldığı çalışmalar bulunmaktadır. Histogram tabanlı k-means algoritmasının beyin MR görüntülerine [9] ve akciğer MR görüntülerine [10] uygulanarak tespit amaçlı kullanılmıştır. Literatürde bölütleme yapan çalışmalarda, genel olarak k-means algoritması tek başına değil, başka yöntemlerle birleştirilerek kullanılmıştır.

Çalışmanın ilk kısmında geliştirilen histogram tabanlı k-means algoritması ile normalizasyon işlemi gerekmeden akciğer bölgesi bölütlenebilmiştir ve akciğer lobları çevre dokulardan ayrıştırılmıştır. Ayrıca lob içindeki dokular da bölütlenebilmiştir. Toplam 20 kesit seti işlenmiş ve bölütleme başarısı %96 olarak elde edilmiştir. Yöntemde veri değerleri olarak alınan görüntüdeki yoğunluk değerleri bir boyutlu sayı serisi olarak ele alınmıştır. Bu sayede, noktalar arası uzaklıklar kartezyen sisteme göre hesaplanmadığı için aralarında bağlantı olmayan ve farklı yerlerde olan aynı tür dokuların aynı kümeye dahil olması sağlanmıştır. Boş küme oluşumu engellenmiştir. Yoğunluk değerlerinin kümeleme işlemleri histogram değerleri üzerinden gerçekleştirilmiştir. Histogram tabanlı k-means algoritması, Fuzzy C-means (FCM) ve optimal eşikleme yöntemleriyle karşılaştırıldığında iterasyon sayısı ve bölütleme doğruluğu açısından daha verimli bulunmuştur.

Tez çalışmasında geliştirilen bu yöntem, akciğer bölütlemesinde ilk defa kullanılmıştır. Literatürdeki diğer çalışmalardan farkı, başka yöntemlerle birleştirmeden tek başına akciğer bölgesini verimli olarak bölütleyebilmesidir. Bu yöntem akciğer bölgesinin bilgisayar destekli çeşitli analiz işlemlerinde ilk adım olarak kullanılabilir.

Tez çalışmasının ikinci kısmında otomatik merkezi pulmonar emboli tespit eden bir sistem geliştirilmiştir. Merkezi pulmonar emboli sağ veya sol ana arterde ayrı ayrı

olabileceği gibi arterin dallanma noktasında da bulunabilir. Pulmonar arterlerdeki kan akışını engellemesi nedeniyle ölümcül olabilmektedir. Bu nedenle merkezi pulmonar embolinin hızlı tespiti, segmental ve subsegmental embolinin tespiti kadar önemlidir.

Literatürde merkezi pulmonar emboli konusunu araştıran tıbbi makalelerin elde ettikleri sonuçlar şöyledir; Vedovati et al. tarafından 579 hasta üzerinde yapılan bir araştırmada %60 oranında merkezi emboli bulunmuştur [11]. Sun et al. ise 88 pulmonar emboli vakasının %64 oranında merkezi emboli olduğunu raporlamıştır [12]. Kanne et al. çalışmasında ise bu oran 214 hastanın %12,1'i oranındadır [13]. Merkezi emboli tespiti için görüntüleme sistemlerinin performansını karşılaştıran bir çalışmada Remy et al, 42 vakanın %37'sinde kısmi, %46'sında tam tıkalı damar bulunduğunu belirtmiştir [14]. Varlığı fark edilmeyen ve otopsi sonucu tespit edilen sessiz pulmonar emboli üzerine yapılan bir çalışmada, Stein et al, 5233 vakanın %32'sinde sessiz pulmonar emboli tespit etmiştir. Sessiz pulmonar emboli merkezi pulmonar emboliyi de kapsamaktadır [15]. Bir çalışmada pulmonar arterin dallanma noktasına yerleşen merkezi emboli nedeniyle ölüm oranı %29 olarak verilmiştir [16]. Furlan'ın akut emboli araştırmasında, 635 vakanın 333 tanesinde merkezi pulmonar emboli (182 mediastinal, 151 lobar) bulunmuştur [17].

Kontrast maddenin yayılımına engel oluşturuyorsa, damar duvarına tutunan ve kısmi tıkanıklığa neden olan büyük merkezi emboliler teşhiste gözden kaçabilmektedir. CAD performansının değerlendirildiği bir çalışmada, uzmanların gözle yaptığı incelemede merkezi emboli %11,5 oranında atlanmıştır [18]. Diğer bir çalışmada 65 merkezi pulmonar embolinin 3 tanesi uzmanlar tarafından tespit edilememiştir, 1 tane de yanlış tespit yapılmıştır [19]. Gözden kaçan pulmonar emboli oranının araştırıldığı diğer bir çalışmada ise incelenen 329 pulmonar emboli vakasının 18 tanesinin atlandığı raporlanmıştır. Bunların 3 tanesi (%16,7) merkezi pulmonar emboli vakasıdır [20]. Literatürde pulmonar emboli tespit etmek amacıyla geliştirilen uygulamaların çoğu segmental ve subsegmental emboliyi aramaktadır, otomatik olarak pulmonar emboli tespit edilen bir sistemde merkezi pulmonar emboli de ele alınmalıdır. Philips tarafından geliştirilen bir CAD sistemi merkezi emboliyi tespit etmemektedir [21].

Literatürde bilgisayar yazılımı aracılığı ile merkezi emboli tespiti yapılan çalışmalarda elde edilen sonuçlar şöyledir; Blackmon [18], 13 merkezi emboli içeren veri kümesi üzerinde %69,2 hassasiyet elde etmiştir. Buhman [19] 65 merkezi emboli içeren veri kümesinde %74 hassasiyet elde etmiş ancak 17 gibi yüksek bir sayıda emboli tespit edilememiştir. Engelke'nin [22] hassasiyet oranı %21 olarak çalışmaların içindeki en düşük orandır. En yüksek hassasiyet oranını %87 bildiren Wittenberg'in [23] çalışmasında sadece 23 merkezi emboli verisi bulunmaktadır. Bu çalışmalarda hesaplama maliyeti yüksek karmaşık yöntemler kullanılmıştır. Yüksek hassasiyet oranı elde çalışmaların tespit edilememesi oranları (FN) yüksek [19] ve veri sayısı düşüktür [23].

Geliştirilen bu çalışma, bilgisayarlı tomografi görüntüleri üzerinden pulmonar truncus ve arterlerde yer alan merkezi emboliyi tespit etmektedir. Sistem iki aşamalıdır. İlk aşamada kesit kümesinin ilk kesitinden okumaya başlanmış, ilerleyen kesitlerde soluk borusu takip edilmiş ve pulmonar arterin (truncus) görüldüğü kesit bulunmuştur. İkinci aşamada, pulmonar truncus, sağ ve sol arterler sırayla tarayarak merkezi emboli adayları tespit edilip işaretlenmiştir. Emboli, truncus ve arterler içinde değişik biçimlerde ve yerlerde olabilmektedir. Damara tutunan, damarın ortasında görülen, çeşitli şekiller damarı tam veya yarım tıkayan formlar görülebilir. Çalışma tüm olası durumlar ele alınmıştır.

Hesaplama maliyetini düşürmek ve verimli bir sistem geliştirmek amacıyla kural tabanlı bir yaklaşım geliştirilmiştir. Kurallar bilgiyi temsil etmenin etkili bir yoludur ve bilgisayar bilimlerinde, bilgileri yorumlamak için etkili bir yöntem olarak kural tabanlı sistemlere başvurulur. Geliştirilen sistemin tespit ettiği emboli sonuçları bir uzmanın işaretlediği sonuçlarla karşılaştırılarak doğruluk hesaplanmıştır. Bu çalışma emboli tespiti yapan bir sistemin bir parçası olarak çalışabilir. İşlenen görüntülerin sonucunda hassasiyet oranı %93, FP/vs oranı 2,56, tespit edilemeyen emboli sayısı (FN) 4 olarak elde edilmiştir.

Literatürde merkezi emboli tespiti yapan az sayıda çalışma mevcuttur. Tez çalışmasında geliştirilen bu sistemin literatürdeki diğer çalışmalardan farkları şöyledir; diğer çalışmalarda kullanıldığı gibi hesaplama maliyeti yüksek karmaşık yöntemler kullanmadan, diğerlerinden yüksek hassasiyet oranına sahip verimli bir

sistemdir. Embolinin pulmonar arterlerde bulunabileceği bütün durumlar ele alınmıştır. Kesit kümesi başlangıç kesitinden itibaren okunarak soluk borusu takip edilmiş ve soluk borusunun dallanma noktası içeren kesitte pulmonar arterlere ulaşılmıştır ve bu sayede sistem otomatikleştirilmiştir. Kesit setinin okunmasından işaretli embolilerin görüntülenmesine kadar süren işlemler kesintisizdir. Diğer çalışmalarda emboli aramasına başlanılan kesite ulaşmak için geliştirilen bir yöntem belirtilmemektedir. Diğer birçok çalışmanın tersine, akciğer içinde bölütleme yapılmamış ve bu sayede işlem maliyeti ile çalışma süresi düşük tutulmuştur.

Merkezi pulmonar emboli tespiti için geliştirilen bu sistemde, 60 adet merkezi pulmonar emboli içeren 32 vakaya ait veri kümesi kullanılmıştır. İyi çekilmiş görüntülerin yanı sıra, çekimden kaynaklanan koyu yoğunluk değerine sahip bölgeleri (artifakt) içeren görüntüler de veri kümesine dahil edilmiştir. Veriler Kocaeli Üniversitesi Tıp Fakültesi Radyoloji Bölümü ve Mayo Clinic'den alınmıştır. Tez çalışmasındaki bütün kodlar Matlab programı ile geliştirilmiştir. Kullanılan bilgisayar 4 Gb Ram, 2,4 Ghz kapasitesindedir.

Bu tez çalışması aşağıdaki şekilde düzenlenmiştir;

Birinci bölümde tez konusuyla ilgili genel bilgiler yer almaktadır. Tıbbi görüntülerin analizi ve tıbbi görüntü işlemede kullanılan görüntü işleme yöntemleri konusunda bilgi verilmiştir. Ardından üzerinde çalışılan organ olan akciğerin anatomisi tanıtılmıştır. Bilgisayar tomografisi ve akciğerin tomografi kesitlerinin anatomisi görüntülerle açıklanmıştır. Akciğer embolisi ve tespitindeki zorlukların açıklanmasının ardından bilgisayar destekli tespit sistemleri örnekle anlatılmıştır. Tıpta görüntü analizi yöntemlerinin değerlendirilmesi hakkında bilgi verilmiştir.

İkinci bölümde tez çalışmasında akciğer bölütlemesi ile ilgili geliştirilen uygulama anlatılmıştır. Geliştirilen histogram tabanlı k-means algoritması ile lobların bölütlenme aşamaları gösterilmiştir. Yöntemin başlangıç küme merkezlerinin seçimi, küme merkezlerine olan uzakların hesaplanması detaylandırılmış ve küme merkezlerinin doğrulaması ve kümeleme doğruluğunun değerlendirilmesi için kullanılan hesaplamalar açıklanmıştır. Fuzzy C-means (FCM) algoritması ile histogram tabanlı k-means algoritmasının performans sonuçları karşılaştırılmıştır.

Geliştirilen algoritmanın loblara uygulanmasının sonuçları gösterilmiştir. Lob görüntüleri üzerinde yapılan çalışmalara yer verilmiştir.

Üçüncü bölümde merkezi pulmonar emboli tespiti için geliştirilen yöntem anlatılmıştır. Trake izlenerek truncusun tespit aşamaları ve pulmonar arterin ayrıştırılması gösterilmiştir. Bitişik dokuların çıkartılma yöntemi gösterilmiştir. Merkezi embolinin arterler içinde bulunduğu şekil ve konumlar örnek görüntülerle açıklanmıştır.

Dördüncü bölümde, çalışmada elde edilen sonuçlara yer verilmiştir. Akciğer bölütleme ve merkezi emboli tespiti için geliştirilen yöntemler değerlendirilmiştir.



1. GENEL BİLGİLER

1.1. Tıbbi Görüntülerin Analizi

Tıbbi görüntüleme teknolojisindeki hızlı gelişmeler ve yeni klinik uygulamaların ortaya çıkması tıpta görüntü analizini aktif bir araştırma alanı haline getirmektedir. Görüntü kalitesindeki gelişmeler, klinik ihtiyaçların değişmesi, bilgisayar donanımındaki ilerlemeler ve tıbbi görüntü işlemedeki algoritmik gelişim tıbbi görüntü analizinin ulaştığı gelişim seviyesini doğrudan etkilemektedir. Bu gelişmeler sonucunda insan vücudundan yüksek çözünürlüklü ve üç boyutlu görüntülerin elde edilmesi mümkün hale getirmiştir. Bugün tek bir çekimde elde edilen iki boyutlu görüntülerin sayısı 150'den 3000'e kadar çıkabilmektedir. Her bir çekimde elde edilen büyük miktarda görüntü ve klinik uygulamalarda tıbbi görüntülemenin artan önemi radyologların iş yükünü artırmakta ve bilgisayar destekli tıbbi görüntü analizine duyulan ihtiyacı açıklamaktadır.

1.1.1. Mevcut inceleme yöntemleri

Geleneksel olarak tıbbi görüntüler kesitler halinde gösterilen iki boyutlu görüntülerin gözle incelenmesi ile yorumlanırlar. Bu tarz bir inceleme, kişinin algısına bağlı olarak kişiye göre farklı yorumlar ortaya çıkmasına neden olabilir. Diğer taraftan 3 boyutlu vücut yapılarının iki boyutlu gösterildiği durumlarda, radyolog ardışık görüntü kesitlerine bakarak üçüncü boyutu düşüncesinde canlandırır.

Günümüzde hastanelerin radyoloji bölümlerinde birbiriyle haberleşen birçok bilgisayardan oluşan ağlar bulunmaktadır. Birçok modern hastanede bilgisayar donanım ve yazılım sisteminden oluşan ve "Picture Archiving and Communication System" (PACS) adı verilen sistem kullanılır. Bu sistem bütün sayısal görüntü çeken cihazlara ağ aracılığı ile bağlıdır. Görüntüyü çeken cihazın bilgisayarında yeniden yapılandırılan görüntüler, görüntü arşivine gönderilir. Arşivde görüntüler standart formatta saklanır. Uygun bir bilgisayardan izlenip analiz edilebilir.

1.1.2. Donanım gereksinimleri

Tıbbi görüntüler genellikle çok boyutlu ve geniş dinamik erime sahiptir. Bu verilerini saklamak ve işlemek için büyük bellek kapasitesine ve bilgisayar işlemci kapasitesine gereksinim vardır. Sayısal fotoğraflar için genellikle her piksel için 8 bit veya 1 byte yeterli olurken tıbbi görüntülerde her piksel için 12 bit veya 2 byte gerekebilir.

Özellikle üç boyutlu görüntü verilerini saklamak için geniş bellek kapasitesine ihtiyaç vardır. Örneğin yüksek çözünürlüklü bir beyin MR görüntüsü her biri 512 X 512 piksel olan 200'den fazla kesit içerir. Bu da 50 milyondan fazla voksel (kesit kalınlığının piksel yüzeyi ile çarpımı sonucu oluşan hacim) anlamına gelir. Sayısal tıbbi görüntülerde her bir pikselin yoğunluğu 2 byte ile temsil edildiği için bir beyin MR'ının saklanması için 100 MB'dan fazla bellek alanına gereksinim olur. Yüksek çözünürlüklü bir bilgisayarlı tomografi her biri 512 X 512 piksel olan 1000 görüntü içerebilir ve bu da her bir görüntüleme için 500 MB bellek alanına gerek olduğunu gösterir. İki boyutlu sayısal röntgen görüntüsü 2000 X 2000 pikselden oluşur ve herbir görüntü 8 MB yer kaplar. Zamana bağlı analizin yapıldığı veya birçok cisim için çoklu taramaların incelendiği klinik çalışmalarda işlenen verinin miktarı 10 GB'ı kolayca geçebilir.

Bilgisayar ekranında her bir pikseli 2 byte'lık tıbbi görüntüleri göstermek için uygun gri değer dönüşümünün yapılması gerekir. Parlaklık ve karışıklık ayarlarındaki değişiklikler ekrandaki bir cismin görüntüsünü etkiler. Özellikle yoğunluk cisimden arka fona doğru aşamalı olarak değişim gösteriyorsa, parlaklık ve karışıklık ayarlarındaki küçük değişiklikler cisim sınırlarında belirgin yer değişimine neden olur. Bu da ekran parametrelerindeki değişimin lezyonun algılanan büyüklüğünü değiştireceği anlamına gelir. Elle yapılan sınır belirleme işlemlerinde bu konu önemli bir problemdir. Radyoloji uygulamalarında incelenen bölgelere özel ekran standardı belirlemek sıkça yapılan bir uygulamadır. Örneğin BT görüntüleri için "akciğer penceresi" veya "kemik penceresi" gibi ayarlar yapılır. Diğer taraftan harici aydınlatma koşulları da cismin büyüklüğünün değerlendirilmesinde etkili olabilir.

1.1.3. Bilgisayarın tıbbi görüntü işlemedeki yeri

Günümüzde tıbbi görüntü cihazlarının çoğu, bilgisayarla kolayca işlenebilen sayısal görüntüler oluşturmaktadır. Üç boyutlu görüntü işleme ve görselleştirme teknikleri ile üç boyutlu görüntüden tetkik yapılabilmesi olanaklı hale gelmiştir. Böylece tıbbi görüntülerden çeşitli ölçümler yapılmakta ve büyüklük bilgisi gibi objektif ve sayısal bilgiler elde edilebilmektedir ve bu konuda araştırmalar sürmektedir.

Bilgisayarla ölçümleme konusuna örnek olarak radyoterapide uygun radyasyon terapisini hesaplamak için üç boyutlu görüntülerden ışınlama yapılacak bölgelerin ve riskte olan çevre organların sınırları çizilerek belirlenmektedir. Nörolojide Alzheimer veya şizofren hastalarında MR görüntülerden beynin şekli ve dokudaki değişimler ölçümlenmektedir. Kardiyolojide ise kalp kaslarının doku karakteristiği ve dinamiği ölçümlenerek kalbin durumu değerlendirilmektedir.

Sınır belirleme işlemine örnek olarak; radyolog bilgisayar ekranında bir lezyonun (doku bozukluğu) sınırlarını belirleyebilir, çerçevelenen lezyonun büyüklüğündeki değişimi görmek için başka bir zamanda çekilmiş görüntüden aynı bölge ile karşılaştırabilir. Ancak ekranın renk kontrast ve parlaklık ayarlarının değişmesi veya kişilerin aynı lezyonun sınırlarını farklı çizmeleri elde edilen sonucu etkiler. Bütün bilgisayar gereklilikleri sağlansa bile elle yapılan sınır belirleme işlemleri inceleyen kişinin algısıyla doğrudan ilişkili olan kişisel bir iştir ve zaman alıcıdır. Ölçme işleminin bilgisayar ile otomatikleştirilmesi sonucu daha objektif hale getirir. Ancak otomatik analizdeki algoritmik hataları gidermek için hala elle yapılan işleme gerek duyulmaktadır.

Görüntü analizinde çok çeşitli yöntemler bulunmaktadır. Ancak bunların çok az tıbbi görüntülere uygulanabilmektedir. Bunun nedeni hem tıbbi görüntü verisinin hem de ve modellerin oldukça karmaşık olmasıdır.

1.1.4. Görüntü verisinin karmaşıklığı

Gelişmiş teknolojik cihazlarla alınan görüntüler bile, görüntüleme işleminin teknolojik ve fiziksel kısıtları nedeniyle her zaman istenen kalitede bir sonuç vermez. Bunun nedenleri şöyle sıralanabilir;

- Sıklıkla teknik olarak mümkün olandan daha az çözünürlükte çekim yapılır. Bunun nedenleri arasında BT çektiren hastanın daha az radyasyon alması veya MR çekim süresinin kısaltılması olabilir. Ancak karmaşık şekilli küçük cisimlerin doğru ölçümlendirilmesi gereken bazı uygulamalarda görüntüleme çözünürlüğü yetersiz bulunabilir.
- Görüntülerde gürültü ve artefakt (çekimden kaynaklanan gerçekte olmayan bölgeler) gibi etkenlerden dolayı cisim yoğunlukları eşit olmaz. Düşük kontrast ve yetersiz çözünürlük nedeniyle bitişik yapıların sınırları keskin değildir.
- Üç boyutlu tomografik görüntüler her bir kesitte genellikle daha yüksek çözünürlük içerirler. Küresel cismin sınırlarının yeri kesitlerle dikey kesildiğinde belirlenebilir ancak kesitlere paralel olduğunda anlaşılabilir.
- Cisim sınırlarına yakın vokseller hem cismin dokusunu hem de çevre dokuları içerebilir. Kısmi hacim etkisi (partial volume effect) adı verilen bu durum keskin olmayan sınırlar oluşturur.
- MR'da kullanılan fonksiyonel veya yayılım (diffusion) hareketleri içeren görüntülerde sinyal oranı düşük olduğundan istatistiksel yöntemlerle alanlar ayrıştırılır. Geometrik bozulma ve yoğunluğun eşit şekilde yayılmaması gibi artefaktların sayısal ölçümlere olumsuz etkisi vardır.

1.1.5. Modellemenin karmaşıklığı

Tıbbi görüntü analizi çok farklı yapıların veya çok farklı özelliklerin incelenmesini gerektirir. İncelenen cisimler anatomik yapılar (omurga, beyin zarı, kalp atar damarları gibi), patolojik yapılar (tümör, miyokard enfarktüsü, ödem, iltihap gibi) fonksiyonel alanlar (glokoz metabolizması, motor korteks gibi), suni cisimler (implant, elektrodlar gibi) olabilir. Konular arasında önemli biyolojik çeşitlilik vardır.

Modelleme, ön bilgiye dayalı olarak cisim tanımlamaktır ve elde bu kadar çok çeşidin bulunduğu bir konuda zor bir iştir. Bunun için iki yöntem kullanılabilir. Birincisi belirli bir cismin olabilecek her çeşit görünüşünü içeren genel belirlemelerden yararlanmaktır. Diğer yaklaşımda ise aynı cismin değişik konulardaki durumları istatistiksel olarak analiz edilerek görüntü çeşitliliği dikkate alınır. Cisim tahmini ortalama şekil ve belirli değişim durumları ile tanımlanır.

Anatomik şekillerin karmaşıklığı cisimlerin modellenmesini karmaşık bir iş haline getirir. Bu karmaşık şekiller ve özellikleri matematiksel fonksiyonlarla kolayca ifade edilemez. İstatistiksel modellemede de şekil çeşidinin çok olması zorlaştırıcı bir faktördür. İstenen modelin oluşturulması için bu yapılar hiyerarşik olarak ilişkilendirilmiş veya bir bütünün parçaları şeklinde tanımlanan bileşenler kümesi olarak ele alınmalıdır. Patolojik cisimler için modelleme yapılmaz. Tümör gibi her bir durumun kendine özel olduğu ve diğerlerine benzemediği patolojik cisimler için şekil modelleri oluşturulamaz. Benzer şekil örneklerine ait elde bilgi olmadığı durumlarda patolojik cisimlerin otomatik bölütlemesi oldukça karmaşıktır [24].

1.2. Tıbbi Görüntü İşlemede Kullanılan Görüntü İşleme Yöntemleri

Tıbbi görüntü analizinde ve sınıflandırılmasında kullanılan başlıca yöntemler genel olarak aşağıdaki üç kategoride listelenebilir:[1]

1. Kenar tabanlı yöntemler
 - 1.1. Kenar tespit işlemleri
 - 1.2. Sınır izleme
 - 1.3. Hough dönüşümü
2. Piksel tabanlı doğrudan sınıflandırma yöntemleri
 - 2.1. Optimal global eşikleme
 - 2.2. Kümeleme aracılığı ile piksel sınıflandırma
 - 2.2.1. K-means kümeleme
 - 2.2.2. Bulanık c-means kümeleme
 - 2.2.3. Uyarlanabilir bulanık c-means kümeleme
3. Bölge tabanlı yöntemler
 - 3.1. Bölge büyütme (region-growing) yöntemi
 - 3.2. Bölge parçalama (region-splitting) yöntemi
4. Diğer yöntemler
 - 4.1. Yaklaşık modelleme tabanlı uyarlanabilir bölütleme
 - 4.2. Sınır ağları kullanarak bölütleme
 - 4.3. Watershed bölütleme [25]

1.3. Veri Madenciliği İle Görüntü İşleme

Görüntüler veri madencileri için işlenecek zengin bilgiler içerir ve görüntü veri analizi içeren birçok literatür çalışmasında gelişmiş teknikler sunulmaktadır. Diğer taraftan veri madenciliğindeki gelişmeler yeni yöntemlerin görüntü analizi için de uygulanmasını elverişli hale getirmektedir. Bu yöntemlere örnek olarak yaygın model (frequent pattern), sıralı model (sequential pattern), ve yapısal model analiz yöntemleri verilebilir. Model tabanlı analiz yöntemleri (pattern-based analysis methods) ise görüntü içinde çok boyutlu kümeleme için kullanılabilir [26].

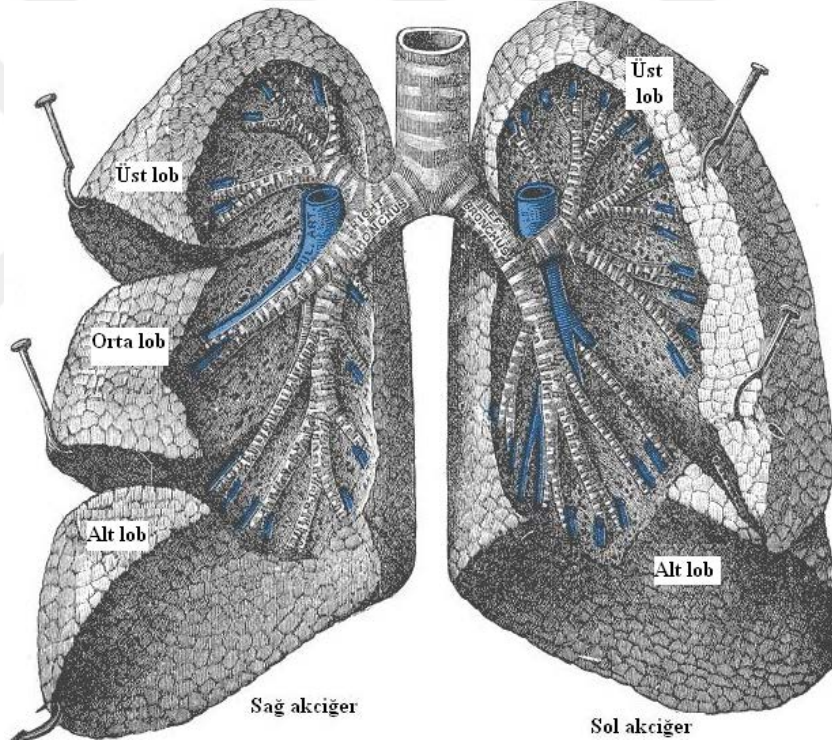
Görüntü işleme için kullanılan veri madenciliği yöntemlerinden biri de birliktelik kuralı kümeleme sistemidir (Association Rule Clustering System-ARCS). Bu yaklaşımda veriler iki boyutlu bir ızgara yapıda ele alınır. Veri içinde belirli bir kategorik nitelik koşulla örtüşen satırlar için sayısal nitelik çiftleri ortaya çıkartılır. Daha sonra veri ızgarası, birliktelik kuralları oluşturulan nokta kümeleri için taranır.

Kümeleme analizi görüntü işleme de dahil olmak üzere şekil tanıma ve pazar analizi gibi bir çok uygulama alanında yaygın olarak kullanılır. Hiyerarşik yöntemler, yoğunluk tabanlı yöntemler, bölmeleme tabanlı yöntemler, ızgara tabanlı yöntemler, model tabanlı yöntemler, kısıtlama tabanlı yöntemler kümeleme analizinin belli başlı yöntemleridir. Çok boyutlu verinin kümelenmesinde clique, proclus ve yaygın model tabanlı kümeleme yöntemleri kullanılmaktadır. K-means algoritması sıkça kullanılan bir kümeleme yöntemidir ve görüntü verisinin kümelenmesinde de kullanılmaktadır [27].

Görüntü bölütleme, nesnelere veya bölgeleri ayırt etmek için görüntünün anlamlı bölgelere bölünmesi işlemidir. Bölgeler belirlendiğinde, nitelikleme, analiz ve sınıflandırma için bölgeleri temsil edecek özellikler hesaplanabilir. Tıbbi görüntü analizinde, radyolojik değerlendirilmenin sınıflandırılmasında ve bilgisayar destekli tanıda bölütleme önemli bir işlem adımıdır. Görüntü bölütleme kümeleme işlemi gibi ele alınabilmektedir. Sayısal görüntü bölütleme uygulamalarında, ilgilenilen alanları parçalara ayırmak ve/veya nesnelere sınırlarını belirlemek amacıyla kümeleme tekniklerinin kullanılması yaygındır. Görüntü bölütlemesinde k-means kümeleme algoritmasının kullanıldığı çalışmalara literatür araştırması kısmında yer verilmiştir.


1.4. Akciğer Anatomisi

Akciğer nefes alan bütün canlıların ana solunum organıdır. Kan damarları, hava yolları ve hava keseciklerinden oluşur ve süngersi bir yapıya sahiptir. Akciğerler göğüs kafesinin içinde, kalbin her iki yanında iki parça halinde bulunur. Parçalar Şekil 1.1’de görüldüğü gibi birbirine eşit değildir, sağ taraf üç, sol taraf iki tane olmak üzere lob adı verilen kısımlardan oluşurlar. Sol tarafta kalp çeperine uygun kaviste bir girinti yer alır. Gırtlaktan inen soluk borusu, bronş adı verilen iki kısma ayrılarak akciğerlerin içine uzanır. Bronşlar akciğerlerin içinde alt solunum damarlarına (bronşiyel) ayrılır ve bir ağaç yapısı oluşturur. Dallanan damarlar hava keseleriyle sonlanır.



Şekil 1.1. Akciğerin yapısı


Akciğerin başlıca işlevi ağız veya burun yoluyla vücuda alınan oksijeni kan damarlarına aktarmak ve kan damarlarındaki karbondioksiti vücuttan dışarı vermektir. Bu gaz değişimi Şekil 1.2’de görülen çok küçük hava kesecikleri (alveoli) tarafından gerçekleştirilir. Oksijensiz kan kalp tarafından akciğer atardamarları üzerinden akciğere pompalanır, hava keseciklerinde karbondioksit oksijen ile yer değiştirir. Oksijenli kan akciğer toplardamarları tarafından dolaşıma gönderilmek üzere kalbe pompalanır [28].



Şekil 1.2. Akciğer damarları ve hava kesecikleri

Akciğerde görülen hastalıklar çok çeşitlidir. Zatürre gibi akut enfeksiyon hastalıkları, doku arası (interstisyel) hastalıkları gibi kronik iltihaplı hastalıklar, anfizem gibi kronik tahrip edici hastalıklar ve çeşitli tümörler sayılabilir. Akciğer hastalıklarının teşhisinde klinik inceleme ve organ fonksiyonlarının ölçülmesi aşamaları yer alır. Fonksiyonların ölçülmesi işleminde ağızdaki nefes gücü, akciğer hacmi ve havanın akciğerde değişim oranı ölçülür. Bütün bu ölçümler genel akciğer fonksiyonlarıyla ilgili önemli bilgiler sağlar ancak yapısal olarak sağlıklı durumlarda görülen olağan dışı bölgesel bilgiler vermez. Bunlar x-ışınli bilgisayar tomografi (BT) taraması ile elde edilir. BT taraması sonucunda olası hastalık sürecini tanımlamaya yardımcı olabilecek akciğer dokusundaki anormallikler ve havayolu ağacı patolojisi incelenir.

Bilgisayar tomografisi ile elde edilmiş ön yüzden göğüs görüntüsünde akciğer damarlarının oluşturduğu ağaç yapısı Şekil 1.3'de görülmektedir.



Şekil 1.3. Akciğer damarlarının BT ile alınan görüntüsü [29]

1.5. Bilgisayar Tomografisinin Özellikleri

Tomografi, bilgisayar teknolojisi kullanılarak x-ışınları yardımıyla vücudun incelenmek istenen bölgesinin kesit şeklinde görüntülenmesini sağlayan bir radyolojik tanı şeklidir. Bilgisayarlı tomografi (BT) teknolojisi ile birlikte, önceden klasik yöntemlerle görülemeyen yumuşak dokular detaylı olarak görüntülenebilmektedir. Böylece teşhis ve tanıda daha kesin ve güvenilir sonuçlar elde edilmektedir.




Şekil 1.4. Bilgisayarlı tomografi cihazı

Bilgisayarlı tomografi cihazı, elektronik aksamının yanı sıra bir de hastanın uzanacağı bir masaya sahiptir. Şekil 1.4’de bir örneği görülen cihaz çalıştırılmadan önce hasta masaya uzanıp kıpırdamaksızın yatar. Hastanın uzandığı bilgisayarlı tomografi cihazının masası, el ile ya da uzaktan kontrol edilerek cihazın boşluğuna sokulur. Cihazdaki x-ışını kaynağı Şekil 1.5’deki gibi hastanın çevresinde 360 derecelik bir dönüş yaparken detektörler vücudun içinden geçen x-ışınlarını tespit eder ve gelen verileri bilgisayara aktarır. Cihazın çalıştırılıp istenen bölgenin tomografisinin yani kesit olarak görüntüsünün alınması yaklaşık 15 dakika içinde gerçekleşir [30].

Çekim sonucunda dokuların birbiri ardı sıra kesitsel görüntüleri oluşturulur. Bu görüntüler bilgisayar ekranından izlenebilir, filme aktarılabileceği gibi gerektiğinde tekrar bilgisayar ekranına getirmek üzere optik diskte depolanabilir. Ayrıca görüntüler bilgisayar tarafından işleme tabi tutularak birbirine dik eksenlerde yeniden yapılandırılmış görüntüler elde edilebilir. Bu görüntülerin de yardımıyla 3 boyutlu görüntüler oluşturulabilir.

Yeni gelişmekte olan teknolojilerle sanal endoskopi yapma olasılığını vermektedir. Bu şekilde soluk borusunun, yemek borusunun, midenin, ince ve kalın bağırsakların, damarların ve idrar yollarının içeriden görüntülerini elde etmek mümkün olmaktadır. Bu yeni görüntüleme yöntemleri şimdilik endoskopik yöntemlerin eksikliklerini tamamlamak amacı ile kullanılmaktadır.




Şekil 1.5. X-ışını kaynağı 360 derecelik bir dönüş yapar

Bilgisayarlı tomografi diğer x-ışın incelemelerine göre bazı avantajlara sahiptir. Özellikle organların, yumuşak doku ve kemiklerin şekil ve yerleşimini oldukça net gösterir. Ayrıca BT incelemeleri hastalıkların ayırıcı tanısını yaparak tedavi yöntemlerini değiştirmektedir. Diğer görüntüleme yöntemlerinden daha erken ve doğru şekilde birçok hastalığın teşhisini sağlamaktadır.

Anjiyografi vücut damarlarının görüntülenmesi demektir. Damar içine damarların görünür hale gelmesini sağlayan ve kontrast madde olarak tanımlanan ilaç verilerek, özel röntgen cihazları yardımıyla DSA adı verilen filmler elde edilir. Anjiyografi sayesinde organları besleyen damarlar görüntülenerek damar hastalıkları veya bu damarlardan beslenen organlara ait tanı koydurucu bilgiler edinilir. Ayrıca elde edilen bilgiler doğrultusunda anjiyografi tedavi amaçlı olarak da kullanılır [31].

Kesit tamamlandıktan sonra toplanan veriler bilgisayara sayısal olarak geçer, işlenir ve sayısal resim şeklinde izlenebilir. Bilgisayara yüklenen BT görüntüsü “piksel” adı verdiğimiz resim elemanlarının bir matrisinden ibarettir. Her resim elemanı seçilen kesit kalınlığına göre bir hacme sahiptir. Birçok BT aygıtında kesit kalınlığı 1,5-12 mm arasında değişir. Seçilen kesit kalınlığının piksel yüzeyi ile çarpımı sonucu oluşan hacme “voksel” adı verilir.



Şekil 1.6. Voksel

Bir piksel, organizmadaki karşılığı olan vokselin ortalama x-ışını zayıflama değerini gösterir. Şekil 1.6'da görüldüğü gibi vokselin içini kısmen dolduran bir oluşum ayrı bir nesne olarak seçilemez. Piksel yoğunluğu da vokselin içindeki yapıların ortalama yoğunluğudur. “Kısmi hacim etkisi” denilen bu olaya bağlı olarak lezyonların çevreye invazyonları sağlıklı bir şekilde gösterilemez. “Kısmi hacim etkisi”, kesit kalınlığı düşürülerek azaltılabilir.

BT görüntülerinin matrisi 256 X 256, 320 X 320 veya 512 X 512 büyüklüğündedir. Bu sayıların çarpımı görüntünün matris eleman sayısını verir. Yeni aygıtlarda matris sayıları giderek artmaktadır. Dolayısıyla görüntüler daha detaylı olmaktadır.


Tomografik görüntülerin özellikleri

- Kesit kalınlığı 2 cm'nin altına olduğunda gürültü görülmektedir, genel olarak kesit kalınlığı azaldıkça gürültü artmaktadır.
- Farklı çekimlerde akciğerin görüntü içindeki yeri değişebilmektedir ve eksenlere tam olarak yerleşmemiş olabilir.
- Her bir çekimin çözünürlüğü farklı olabilmektedir.
- Görüntülerde kişiden kişiye değişebilen farklılıklar olabilir.
- Görüntülerin altında çekim alanından kaynaklanan beyaz çizgiler olabilmektedir, bunun akciğerden ayırt edilmesi gerekir.

1.5.1. Hounsfield skalası

Organizmayı geçen x-ışınlarının zayıflama değeri sayısal olarak saptanır. Her voksel için sayısal bir karşılık vardır. Bu sayılar suyun zayıflama değerini sıfır kabul eden bir ölçeğe göre düzenlenmiştir. Hounsfield, BT ve MR görüntüleme, her voksel için x-ışınlarının zayıflama miktarını tanımlayan bir ölçü birimidir ve HU

(Hounsfield Unit) olarak ifade edilir. Bu ölçüm 1972 yılında ilk BT görüntülemesini yapan Nobel ödüllü İngiliz mühendis Godfrey Hounsfield tarafından ortaya koyulmuştur.



Şekil 1.7. Hounsfield skalası

Genellikle vokseller 12 bit ile temsil edilir ve $2^{12} = 4096$ çeşit değer alabilir. Bu değerler -1024 HU ile +3071 HU arasındaki ölçekte düzenlenmiştir. Havanın zayıflama değeri -1000 HU, suyun 0 HU olur. Kemik +400 HU veya üstü değer alabilir. Metal implantlar genellikle +1000 HU değerindedir. Şekil 1.7’de Hounsfield skalası örneklenmiştir. Zayıflaması yüksek olan yumuşak doku, hematoma, kalsifikasyon, kemik gibi yapılar skalanın pozitif tarafında, zayıflama değeri sudan düşük olan yağ ve hava gibi maddeler de skalanın negatif tarafında yer alırlar. Örneğin yumuşak dokuların yoğunluğu +40 ile +60 HU, yağ dokusunun yoğunluğu ise -60 ile -100 HU arasında olabilir [32].

BT verilerinin HU birimine çevrilmesi için veriye Denklem (1.1)’deki dönüşümün uygulaması gerekir;

$$HU = I(x,y)s + 1 \quad (1.1)$$

$I(x,y)$, x ve y noktasındaki görüntünün piksel değeri, s eğim (slope), i kesişim (intercept) değerleridir. Eğim ve kesişim değerleri DICOM formatındaki görüntüler için başlık bilgisinden elde edilebilir.

1.5.2. DICOM görüntü formatı

DICOM (Digital Imaging and Communications in Medicine) tıbbi görüntüleme yaygın kullanılan bir formattır. MR, BT taramaları ile ultrason sonuçlarını görüntülemek, saklamak, yazdırmak ve dağıtmak için National Electrical Manufacturers Association (NEMA) tarafından oluşturulmuştur. Dosya formatı tanımları ve TCP/IP ağ haberleşme protokolünü içerir.

1980'li yılların başında tomografi ve mr makinaların oluşturduğu görüntülerin kodlarını üretici firma dışında kimse çözemiyordu. Radyologların görüntüleri radyasyon tedavisi için doz planlamada kullanmak istemeleri bu formatın ortaya çıkmasını sağladı. DICOM NEMA'nın geliştirdiği üçüncü standart versiyondur.




DICOM formatı ile görüntüler çeşitli üreticilerin tarayıcı, sunucu, iş istasyonları, yazıcı ve ağ donanımı bir arada PACS (picture archiving and communication system) sistemi üzerinden kullanılabilir. Hastanelerde yaygın olarak kullanılan bu format küçük doktor ofislerinde de yaygınlaşmaktadır. DICOM formatlı görüntünün özelliklerinden bazıları Tablo 1.1'de yer almaktadır.

Tablo 1.1. DICOM formatlı görüntü özelliklerinden bazıları


FileSize: 526626	ColorType: 'grayscale'	BitDepth: 16
Width: 512	Height: 512	PixelRepresentation: 1
Modality: 'CT'	SliceThickness: 2	PixelSpacing: [2x1]
BitsAllocated: 16	BitsStored: 16	HighBit: 15
WindowWidth: 1500	WindowCenter: -650	
RescaleIntercept: 0	RescaleSlope: 1	

1.5.3. Akciğer tomografi kesitlerinin anatomisi

Bütün tomografi kesitleri vücudun boyundan karaciğere kadar olan bir bölgesini ayak tarafından bakış yönü ile gösterir. Görüntülerde önce sağ akciğerin tepesi görülmeye başlar, her iki akciğer bölgesi giderek belirginleşir. Sol akciğer sol alttan, sağ ile sağ üstten küçülerek görüntüden çıkar [33]. Şekil 1.8'de 4 kesit üzerinden anatomik bilgiler yer almaktadır.



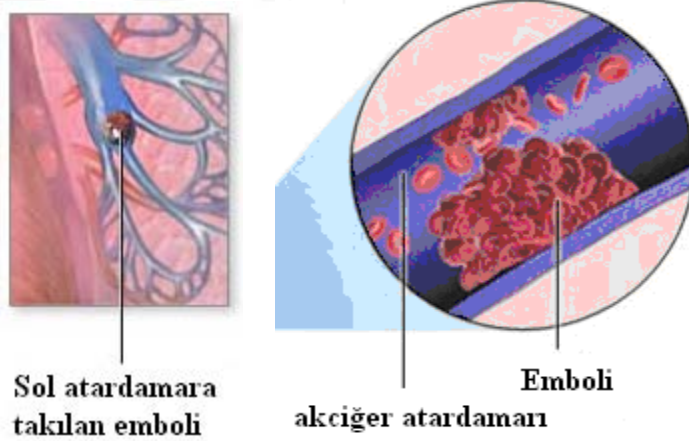
Şekil 1.8. Kesitlerin anatomik bilgileri (devam)



Şekil 1.8. Kesitlerin anatomik bilgileri.

1.6. Akciğer Embolisi

Akciğer embolisi, tıbbi adıyla pulmonar emboli (ing. pulmonary embolus) tanısı zor, ölüm oranı ve karşılaşımla oranı yüksek bir akciğer hastalığıdır. Acil servisteki ölüm nedenlerinin arasında Amerika Birleşik Devletleri'nde yapılan çalışmalara göre 3. sırada yer almaktadır. Kesin belirti ve bulgularının olmaması nedeni ile acil serviste tanısı atlanılan hastalıkların başında gelmektedir [34].



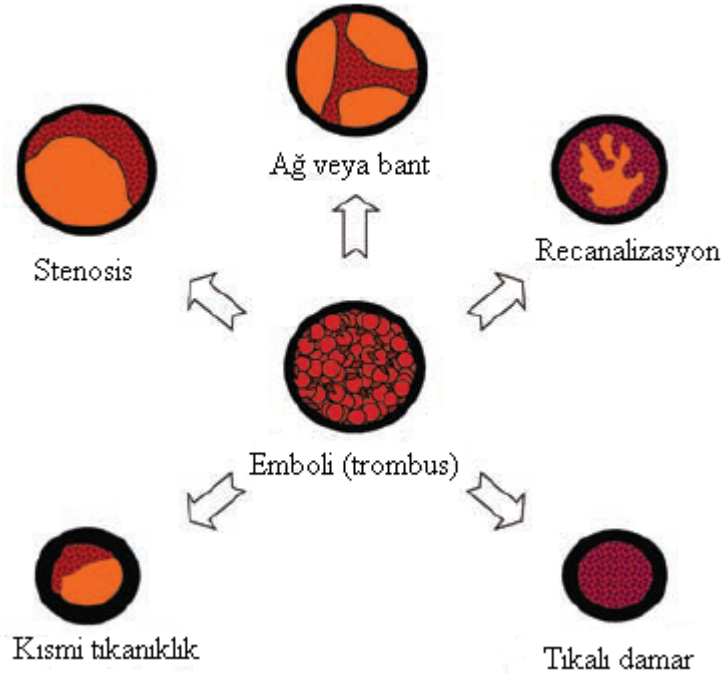
Şekil 1.9. Akciğer embolisi küçük parçalardan oluşur

Genellikle bacadan ya da pelvis bölgesinden kaynaklanan ve vücutta serbest dolaşan bir kan pıhtısının (emboli) kan damarları aracılığıyla akciğerlerdeki bir arteri tıkanması sonucunda oluşur (bkz Şekil 1.9) Akciğerdeki kan akışının engellenmesi sonucunda kalbin sağ karıncığında basınç oluşur. Akciğer embolisinin belirtileri arasında nefes alma zorluğu, nefes alma sırasında göğüs ağrısı, kalp çarpıntısı sayılabilir. Ağır emboli durumu baygınlık, çok düşük kan basıncı ve ani ölüme neden


olabilir. Kanser, uzun süreli yatış pozisyonu gibi çeşitli durumlar emboli riskini artırır.

Bilgisayarlı tomografik akciğer anjiyografisi (CTPA Computered Tomographic Pulmonary Angiography) tanıda ilk sırayı almaktadır. Bilgisayarlı tomografi x-ışını (röntgen) kullanılarak vücudun incelenen bölgesinin kesitsel görüntüsünü oluşturmaya yönelik radyolojik teşhis yöntemidir. Birbiri ardı sıra alınan yüzlerce kesitsel görüntüyü içerir. Bu görüntüler bilgisayar tarafından işlenebilir ve 3 boyutlu görüntüler oluşturulabilir. Akciğer embolisinin damar içinde olabileceği çeşitli durumlar Şekil 1.10'da gösterilmiştir.

Akciğer embolisinin tespit edilmesi için damar içine renklendirici, damarların içini parlak göstermeyi sağlayan bir sıvı (serum albumin) verilir. Sıvının damarlarda yayılması (perfüzyon) sonrasında tomografi çekilir. Damar içlerinde parlaklığın olmadığı veya az görüldüğü bölgeler akciğer embolisini düşündürür. Damar içini kaplayan bir doku olan embolinin belirli bir şekli yoktur. Şekil 1.11'de içinde emboli olan bir damar görülmektedir [35].



Şekil 1.10. Akciğer embolisinin damar içinde yerleşebileceği konumlar [35]



Şekil 1.11. Damar içindeki emboli bölgeleri [36]

1.6.1. Akciğer embolisinin türleri

Akciğer embolisi bulunduğu yere göre lobar, segmental ve subsegmental olarak, biçimine göre kronik ve akut olarak sınıflandırılır. Ana ve lobar arterlerde oluşan pıhtı, merkezi emboli (central pulmonary embolus), segmental ve subsegmental dallarda oluşan pıhtı ise çevresel (peripheral) emboli olarak adlandırılır.

Akciğer embolisi sadece pulmoner arterlerde olur ve kontrast maddesiyle dolu arterlerdeki ortalama piksel değerinden daha düşük yoğunluk değerine sahiptir. Akciğer embolisi bölgesiyle, onu çevreleyen arter bölgesi arasındaki kontrast TP akciğer embolisi lezyonlarını tespit etmede en önemli özelliktir. Emboli bulunması durumunda, pulmoner arterin içindeki basınç artacağından pulmoner arterde ve pulmoner truncusta genişleme olur [37]. Truncus, diğer adıyla ana pulmonary arter, kirli kanı kalpten akciğerlere aktaran damardır ve akciğerlere bağlantı yerinde pulmoner arter adı verilen iki damara ayrılır. Pulmoner emboli, lobların içinde heterojen bölgelerdir. Ve doku değişikliklerini doğru şekilde karakterize etmek için görüntü analizinin lokal yapılması gerekir. Ancak çok ayrıntılı bir lokal analiz, büyük ölçekteki anlamlı doku desenlerinin atlanmasına neden olabilir.

Pulmonar arter vücuttan gelen oksijensiz kanı kalpten geçerek akciğere dağıtır. Kalbin sağ karıncığından yükselerek kıvrılır, sol ve sağ ana arterlere ayrılarak loblara bağlanır. Sol arter 7 segmental arterden oluşur; iki tane üst lob, iki tane lingula, ve üç tane alt lob. Sağ arter ise 9 segmental arterden oluşur; üç tane üst lob, iki tane orta lob, ve dört tane alt lob. Subsegmental damarları tespit etmek zaman alıcı bir işlemdir. Çünkü akciğerin içinde dağılmış, kısmi hacim etkisi nedeniyle görünürlüğü düşük olan çok sayıda damar mevcuttur [38].

Bir akciğer embolisi lezyonu birden çok iki boyutlu görüntüde yer alabilir. Bundan dolayı bir akciğer embolisi CAD tarafından birden çok kez farklı tespit skorlarıyla tespit edilebilir. Farklı kesitlerdeki akciğer embolisi lezyonlarının gruplayıcı bir algoritma ile birleştirilmesi gerekir. Veya bir gruba ait sadece bir kesit işaretlenerek, takip eden kesitlerdeki kısmi radyoloğun görmesi sağlanır. Birbirini takip eden iki kesitte yer almayan akciğer embolisi adayları dikkate alınmayabilir [39].

Akciğerin büyük damar ağına sahip olması nedeniyle CAD sistemlerinin tespit ettiği akciğer embolisi adayları arasında çok sayıda akciğer embolisi olmayan (FP) dokular da yer almaktadır. Geliştirilen sistemlerin klinik olarak kabul görmesi için akciğer embolisi olmayan (FP) doku tespitlerinin azaltılması gerekmektedir. Bu amaçla yapılmış çalışmalar bulunmaktadır [40].

Damar bölütleme çok zaman alıcıdır ve genellikle akciğer embolisinin bulunduğu ince damarlarda sorun oluşabilmektedir. Ancak damar bölütlemesi yapılmaması durumunda, aynı yoğunluk değerlerine sahip akciğer embolisi ile damar duvarının ayırt edilmesi gerekir. [36]

Atardamar ile toplardamarın (ven) yoğunluk dağılımı ve desenleri farklıdır. Kontrast maddesinin düzgün yayılmaması, atardamarın (arter) toplardamar gibi görülmesine neden olmaktadır. Arterlerin venlerden ayırt etmenin bir yolu, arterlerin bronkusa yakın olmasıdır [41].

Lenf nodları hava taşıyan damarlara tutunur, ancak akciğer embolisine yakın yoğunluk değerindedir. Damar bölütlemesi veya takibi yapılmadan, eşikleme yoluyla bölütleme yapıldığında FP'lerin üçte bir oranı lenf nodundan gelir.

Kalp bölgesi aort, vena cava ve pulmoner arter ve ven damarlarını içerir. Kontrast maddesi ile dolmuş damar yapıları benzer yoğunluk değerlerine sahiptir ve birbirlerine bitişiktir. Bu görüntülerde pulmonar arteri diğer damarlardan ayırmak zordur. Akciğer embolisine benzeyen görüntüler, artefaktlar, kısmi hacim etkisi, lenf nodları, ve damar çatallarıdır.

FP oranını düşürmek için; 3 pikselden küçük ve 500 pikselden büyük olan segmentleri elenir. Birbirini takip eden iki kesitte yer almayan akciğer embolisi adayları elenir ve gürültü için filtre uygulanır.

Akciğerin geniş damar ağı nedeniyle CAD sistemleri çok sayıda emboli adayı tespit etmektedir ve FP oranı yüksektir. FP oranını düşürecek etkili yöntemlere gereksinim vardır. Bu yöntemler ön işlemden sonra gerçek lezyon ile hatalı tespiti birbirinden ayırt etmelidir. Aday bölgelerin boyut, biçim, yoğunluk değişimi ve lokasyon bilgisi işlenir. FP oranını düşürmek için, doğrusal veya doğrusal olmayan makina öğrenme yöntemlerinin özellikleri seçip, bir karar değişeninde birleştirilmesi etkili bir yöntemdir [40].


Akut akciğer embolisi hastalarının akciğer BT anjiyografilerinde, kalbin sağ karıncık çapı (RV) ile sol karıncık çapının (LV) oranında (RV/LV) artış olması, kısa süre içinde vefat ile ilişkilidir. Akciğer BT anjiyografilerinde pıhtı hacmi ölçüsü, sağ kalbi genişlemiş hastalarda RV/LV oranı 1'den küçük olanlara oranla daha büyüktür. Son zamanlarda yapılan çalışmalarda, akciğer BT anjiyografilerinde kan pıhtısının hacminin ölçülmesi, akut akciğer embolisi hastaları için yeni bir BT biomarker olarak kullanılabileceği ortaya koyulmuştur.

BT çekimlerine son yıllarda yeni bir teknoloji eklenmiştir. Çift enerjili tomografi (dual energy computed tomography DECT) sistemi tek bir taramada 4 boyutlu veri üretmektedir. Bilgiler üç boyutlu uzamsal koordinatlarda örneklenir ve x-ray enerji seviyesi tutulur. DECT sisteminin özelliklerinden bir tanesi de birbirine yakın yoğunluk değerlerine sahip dokuları ayırt etme imkânı sağlamasıdır. Yapılan çalışmalar, DECT sisteminin akciğer parankiması içinde perfüzyon dolum sorunlarını daha net ortaya çıkarttığını göstermiştir [42].

1.6.2. Merkezi akciğer embolisi

Emboli üç kategoriye ayrılmıştır; pulmonar truncusun dallanma noktasında veya en az bir ana pulmonary arterde yer alan merkezi emboli, en az bir lobar arterde yer alan lobar emboli ve uç dallarda yer alan segmental veya subsegmental olan distal emboli [43]. Merkezi akciğer embolisi örnekleri Şekil 1.12’da yer almaktadır. Merkezi embolinin tespit edilmesi için öncelikle pulmonar truncusun bulunması gerekir.

Kontrast maddenin yayılımına engel oluşturuyorsa, damar duvarına tutunan ve kısmi tıkanıklığa neden olan büyük merkezi emboliler teşhiste gözden kaçabilmektedir.



Şekil 1.12. Merkezi akciğer embolisine örnek [43]

Akciğer embolisi damar içinde farklı şekillerde konumlanabilir. Damar duvarına tutunabilir ve kan akışı daralmış bir alandan olur. Damar duvarına tutunan embolinin bir parçası damarın ortasında durabilir. Embolinin damarı tamamen kaplaması durumunda kan akışı engellenir. Şekil 1.13 a ve b’de görüldüğü gibi merkezi emboli sağ veya sol ana arterde ayrı ayrı olabileceği gibi arterin dallanma noktasında da bulunabilir.



Şekil 1.13. Ana arterlerde emboli örneği, (a) Sağ ana arter (3201-231), (b) sol ana arter (3003-219)

1.6.3. Akciğer embolisi tespitindeki zorluklar

Belirgin akciğer embolisi modern tomografik taramalarda tespit edilmektedir. Ancak akciğeri yüzlerce kesite ayıran bu taramaları incelemek zahmetli ve zaman alıcıdır. Diğer taraftan akciğer embolisine benzeyen lenf nodları, solunum hareketi artefaktları gibi çeşitli artefaktlardan ayırt edilmesi gerektiği için karmaşık bir iştir. Gözden kaçması veya göz yanılması gibi insani kusurlar tomografideki çok sayıda görüntünün doğru ve etkili şekilde yorumlanmasını engeller. Kesitlerden çıkarılan sonuçlar inceleyen kişinin algısına bağlı olarak değişik olabilir.

Bu nedenlerle doğru ve etkili şekilde radyoloğa yardımcı olabilecek bilgisayar destekli tespit (computer aided detection, CAD) sistemlerinin olması arzu edilmektedir. Bunlar inceleyen kişinin tespit başarısını artırmak için ilgilenilen bölgeleri bulmada yardımcı olan yazılım ve donanımdan oluşan sistemlerdir. Bu sistemlerin klinik olarak kabul görece kadar az yanılma oranına ve yüksek tespit hassasiyetine sahip olması beklenir. Ayrıca akciğer embolisinin acil doğası gereği gerçek zamanlı gereksinime de cevap verebilmelidir.

Bilgisayar destekli akciğer embolisi tespiti için farklı yöntemler kullanan birçok sistem geliştirilmiştir. Yapılan çalışmaların birçoğunda bölütleme tabanlı yöntemler kullanılmıştır [44,45,46]. Bu çalışmalarda ilk olarak bölütleme yoluyla akciğer damar yapısı ortaya çıkartılmış, ardından bölütlenmiş damarlar içinde emboli araması yapılmıştır. Çalışmaların değerlendirmesinde damar bölütlemenin zaman alıcı olduğu, ince damar yapılarında sorunlu olduğu belirtilmiştir. Ayrıca akciğer damar yapısının doğru bir şekilde bölütlenmesine rağmen görüntünün büyük bir kısmı ilgilenilen kısımları içermediğinden çıkartılmaktadır [36].

Akciğer embolisi akciğer atardamarları içinde bulunur ve genellikle damar duvarına yapışıkır. Tomografi görüntüsünde -50 ile 100 HU (Hounsfield unit) arasında değişen yoğunlukta koyu bölgeler olarak görülür. İçinde bulunduğu damarın iç rengi daha açık ve parlaktır. Buna rağmen, kısmi hacim etkisi (birden çok doku tipinin aynı vokselde görülmesi) nedeniyle damar sınırlarının çevresindeki pikseller de aynı HU aralığına sahiptir. Bu nedenle embolinin damar duvarından etkin şekilde ayrıştırılması, damar sınırları çevresinden kısmi hacim etkisinin giderilmesi ve emboli piksellerinin doğru bir şekilde belirlenmesi gerekir. Bu zorluk yapılan bir çalışmada tobogganing isimli yöntemle çözülmeye çalışılmıştır [36].

Akciğer embolisinin tespiti için damarlara özel bir renklendirme sıvısı verilerek tomografi görüntüsü alınmaktadır. Bu sıvının damarlarda yayılmasında sorun oluştuğunda görüntüden tam bir bilgi almak zorlaşır. Damarların koyu renk görüldüğü bölgeler yanıltıcı olabilir.

Akciğer damarları kesitten kesite çok farklı tomografi değerleri gösterebilir. Pıhtı damarlarda tamamen veya kısmen yer alıyorsa damarların sürekliliği kesitlerde izlenemez ve bu nedenle doğru bir şekilde bölütleme yapılamaz. Bu yüzden 3 boyutlu görüntüde bölütleme tabanlı yaklaşımla damar yapısını görüntülemek zor olmaktadır [47].


Görüntülerde akciğer embolisi çok çeşitli piksel değerlerine sahiptir. Bu nedenle birçok renk bir emboliyi gösterebilir ve bir emboli bu renklerden herhangi biriyle tanımlanabilir [48].

Tomografi çekimi sırasında hastanın hareketinden, vücudun doğal kas ve kan hareketinden, çekim yapan cihazın mekanik titreşimlerinden veya çekim alanındaki çeşitli titreşimlerden dolayı alınan görüntü olumsuz etkilenir. Bu durum hem insan gözüyle yapılan incelemeyi hem de bilgisayar sistemleriyle yapılan analizi etkilemektedir ve tespitte yanıltıcı olabilmektedir [23].

1.7. Bilgisayar Destekli Tespit Sistemleri

Akciğer embolisinin tespiti yapan bir CAD sisteminin (prototip yazılım, Philips Healthcare) çalışma algoritması şöyle özetlenebilir; sistem akciğer bölgesinin

otomatik bölütlenmesi ile başlar. Morfolojik işlem sonrası doku ve hava içeren akciğer bölgesi elde edilir. Ardından,-100 HU üzerindeki bütün yapılardan başlayarak bölge içindeki akciğer damarları bölütlenir. Görüntü içindeki damarları seçmek için bir damar takip algoritması uygulanır [49]. Damarların budanmasından sonra, eksene göre dikey damar kesit görüntüleri oluşturulur. Akciğer embolisi için aday kısımları bulmak amacıyla bu kesit görüntülere gri değer analizi uygulanır. Akciğer embolisini tanımlayan özellikler, damarların esnemesi de dahil, renklendirici sıvı içeren alanlarda tıkanıklıktır. CAD sisteminin akciğer embolisi olarak tanımladığı aday lezyonların bulunduğu damarların çevresi ilgilenilen bölge olarak işaretlenerek incelemeye sunulur. Şekil 1.14’de sistemin bulduğu bir emboli örneği görülmektedir. İşlem her inceleme için yaklaşık 30 saniye sürer ve ilk değerlendirmenin oluşturulması sonrasında, değerlendirme radyolog tarafından incelenirken arka planda program otomatik olarak çalışmayı sürdürür.




Şekil 1.14. Cad sisteminin bulduğu bir emboli örneği [23]

Otomatik akciğer embolisi tespit eden başka bir prototip sistemde (Siemens Medical Solutions) bölütleme kısmına daha az önem verilerek hızlı ve eş zamanlı bir tarama yapılması amaçlanmıştır. Bu sistemde kaba bir bölütleme sonrasında hızlı uyarlanabilir tobogganing kümeleme algoritması ile emboli bölgeleri bulunmuştur. Kümelerin oluşturulmasında kayan komşu voksel yaklaşımı kullanılmıştır. Yoğunluğu -50 ile 100 HU arasında olan vokselardan başlanıp düşük yoğunluklu

komşu voksellere doğru kaydırma yapılmıştır. Bir emboli pikseli bulunduğunda piksel kümeleri birleştirilmiş ve aranan bölge olarak işaretlenmiştir. Sistem ayrıca her aday bölge için vokselle yoğunluk dağılımını, bölgenin civarında vokselle yoğun alanları ve tanımlayıcı üç boyutlu şekli oluşturur.

Ne var ki CAD sistemlerinin başarısı sınırlıdır. Yukarıda tanıtılan ilk sistemin performansının incelendiği bir çalışmada, tomografi görüntüleri hem radyologlar hem de sistem tarafından okunmuş ve tespit başarıları karşılaştırılmıştır. Buna göre akciğer embolisi hastalarının %10'u radyologlar tarafından atlanmış ama sistem tarafından tespit edilmiştir. Buna karşın sistemin, emboli olmayan bölgelerde Şekil 1.15'de görüldüğü gibi hatalı tespitleri görülmüştür. Şekilde CAD sisteminin harekete dayalı görüntü yanılgısı nedeniyle tespit ettiği hatalı emboli görülmektedir. İnceleyen kişinin sistemin çalışma şeklini anlaması, sistemi daha verimli kullanmayı sağlayacaktır. Çalışmanın değerlendirmesinde CAD sisteminin ikinci kontrol olarak kullanılması yararlı görülmüştür [23].

İkinci sistem için yapılan değerlendirmede, emboliye benzeyen ancak emboli olmayan bölgelerin işaretlenme sayısının yüksekliği, belirli bölgelerde ve ince damarlarda tespit başarısının düşüklüğü belirlenmiştir. Diğer taraftan sistemin doktorlara inceleme hızı sağlaması ve gözden kaçabilecek doğru noktalara dikkat çekmesi açısından ikinci okuma aracı olarak kullanılması yararlı bulunmuştur [50].



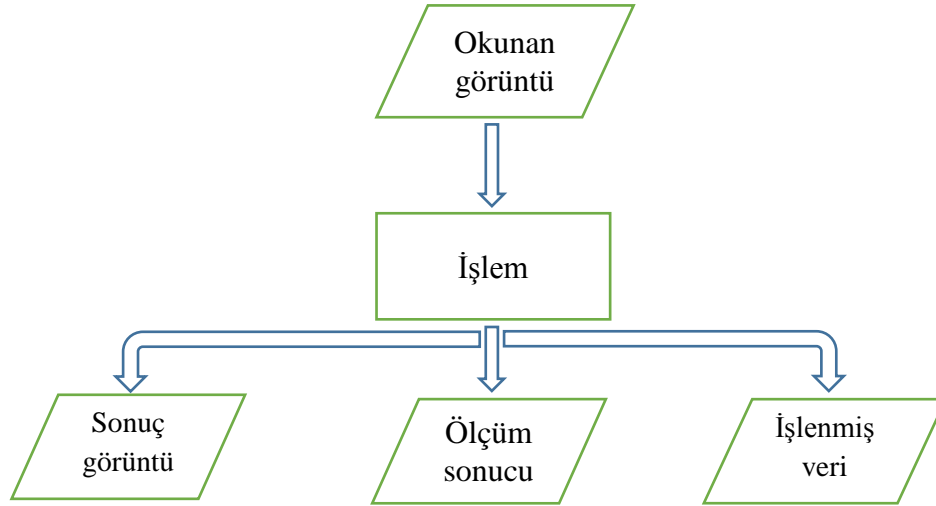
Şekil 1.15. Cad sisteminin hatalı tespit ettiği emboli örneği [23]

1.8. Tıpta Görüntü Analizi Yöntemlerinin Değerlendirilmesi

Görüntü işleme, şekil tanıma yöntemleri ve sinyal işleme çeşitli tıbbi görüntüleme ve tanısal radyoloji uygulamalarında yer alır. Uygulamalar ürettikleri sonuca göre aşağıdaki üç kategoriden birine dahil edilir;

- Görüntü analizi, okunan bir görüntüden ölçüm sonucu elde edilmesidir. Bu grup otomatik tespit ve teşhis, organ veya volüm bölütleme, boyut ölçümü ve risk tahminleri gibi uygulamaları içerir.
- Görüntü işleme, okunan bir görüntüden içeriği benzer başka bir görüntünün üretilmesidir. Bu grup görüntü iyileştirme, sıkıştırma, kaydetme ve yeniden oluşturma gibi uygulamaları içerir.
- Görüntü anlama, okunan bir görüntüden dönüşümler, piksel haritaları gibi farklı seviyede tanımlar içeren sonuçlar üretir.

Uygulamanın amacına göre aşağıdaki şekilde görülen işlem bir sinyal işleme algoritması, şekil tanıma algoritması, kontrast iyileştirme veya görüntü azaltma fonksiyonu, bir dönüşüm, matematiksel bir ölçüm veya bunların bir kaçının birleşimi olabilir.



Şekil 1.16. Tıbbi görüntü işleme işlemlerinin sonucuna göre gruplanması

Bugüne kadar en yoğun ve başarılı gelişim bilgisayar destekli teşhis (Computer Aided Diagnosis) ve bilgisayar destekli tespit (Computer Aided Detection) alanında gerçekleşmiştir. Bilgisayar destekli tespit artık bir klinik gerçeklik haline gelmiştir. Ticari olarak halen kullanılan uygulamalara ilaveten ve çeşitli uygulamaların

geliştirilmesi sürmektedir. Bilgisayar destekli tespit (CAD) işlemi, tıbbi görüntüler üzerinde şüpheli alanların otomatik tespiti ve yerlerinin inceleme için işaretlenmesi işlemlerini içerir. Olası anormalliği işaretlemenin yanı sıra, CAD tespit algoritmaları, bulunan akciğer nodülü, kalsifikasyon veya kitle gibi lezyonların sınırlarını belirlemek için bölütleme adımı da içerebilir. CAD teşhis ve CAD tespit, bilgisayar aracılığı ile veya uzman gözüyle tespit edilen lezyonların hastalıklı veya hastaliksız olarak sınıflandırılması açısından farklıdır.

Tıbbi görüntülerde kullanılan referans veri (ground truth veya gold standart) radyolojiden alınan ve görüntü bilgisini içeren klinik ispat, laboratuvar, klinik inceleme veya patolojik bilgileri içeren klinik bilgiler ve uzman görüşü ile elde edilir.

Bilgisayar algoritmaları söz konusu olduğunda performans terimi genellikle iki anlamda kullanılır. Birincisi algoritmanın bilgisayarda çalışma süresidir. Bu anlamda daha az hesaplama zamanı daha iyi performans demektir. İkincisi algoritmanın ne sıklıkta doğru karara ulaştığıdır. Bu da daha sık doğru sonuç veren algoritmanın daha performanslı olduğu anlamına gelir. Bu kısımda ikinci anlam açısından algoritma performansının ölçümü ele alınmıştır.

Algoritma performansının ölçülmesinin sebepleri; algoritmalar arasında güvenilir karşılaştırma yapılabilmesi ve klinik ortamda kullanıldığında algoritmanın nasıl çalışacağına güvenilir bir öngörüsüne sahip olmaktır. Diğer taraftan aşağıdaki faktörler performansın işe yararlılığını etkilemektedir;

- Veri kümesinin çok az olması,
- Farklı tahminlerde farklı verilerin kullanılması,
- Veri kümesinin klinik problemi temsil etmemesi,
- Performans ölçütlerinin zayıf tanımlanmış olması,
- Eğitim/sına yönteminin zayıf olması.

1.8.1. Görüntü analiz problemlerinin türleri

Performans analizi kapsamında görüntü analiz problemleri üç farklı kategoriye ayrılabilir. Genel olarak her problem kategorisine uygun bir performans analizi yaklaşımı bulunmaktadır ve her birinin kendine has araç ve yöntemleri vardır. Kategoriler aşağıda açıklanmaktadır;

- Ölçümleme ve tahmin problemleri

Görüntü analiz algoritmasının amacı görüntünün bazı özelliklerini ölçmektir. Sonuç olarak sayısal veya vektörel bir çıktı alınır. Örneğin bir görüntü içindeki anormallik hacmini veya alanını ölçmek bir amaç olabilir. Veya iki görüntüyü hizalamak için kullanılacak belirli bir dönüşümünü tahmin etmek olabilir. Bu tip bir problemde ölçüm veya tahmin hatası, kesin veya göreceli ölçek bazında hesaplanabilir. Uygun performans ölçeğinin hesaplanması oldukça basit olabilir.

- Görüntü sınıflandırma ve anormallik tespiti problemleri

Bu tip bir problemde, görüntü analizinin amacı görüntülenen doku veya organın durumuyla ilgili mantıksal dayanak vermektir. Sınıflama genellikle zararlı veya zararsız lezyon, normal veya anormal durum, hastalıklı veya hastaliksız, tip bir veya iki şekilde yapılır. Bilgisayar destekli tespit açısından amaç görüntü içeriğini normal veya anormal olarak sınıflandırmak olabilir. Teşhis açısından ise amaç görüntü içeriğini zararlı veya zararsız bir durum olarak sınıflandırmak olabilir. Anormallik tespiti problemine bir örnek mamografide kanser belirtilerine yönelik analiz yapmaktır. Buradaki önemli nokta sonucun bütün görüntü için mantıksal bir koşulu belirtmesidir. Mantıksal dayanakla ilgili olarak görüntü içinde uzamsal bölge tanımlanması gerekli değildir.

- Görüntü bölütleme problemleri

Genel olarak görüntü bölütleme problemi belirli bir benzerlik ölçüsüne dayanarak bir görüntünün belli sayıda farklı bölgeye bölünmesi işlemidir. Bu tür bir problemde performans ölçütleri anormallik tespit algoritmalarına oranla daha karmaşıktır. Bunun nedeni performans ölçeğinin, görüntü bölütleme algoritmasının sembolik sonuçlarının doğru bölütlenmiş görüntüyle nasıl eşleştiğini yansıtması gerekliliğidir. Bu problemin iki çeşidi bulunmaktadır. Problemin alt seviye bölütleme çeşidinde amaç, bütün görüntü içeriğini açıkça tarifleyecek mantıksal doğrulama üretmektir. Anormallik tespiti ve yer belirleme problemlerinde ise amaç görüntü içindeki bütün anormallikleri tarif edecek mantıksal doğrulama üretmektir. Burada görüntünün diğer kısımları tarif edilmez. Bu kategorinin karmaşıklığı, her biri görüntünün belirli bölgesiyle ilişkili birden çok mantıksal doğrulamanın sonuçta yer alabilmesidir.

Böylece farklı hatalar yapılabilir ve daha karmaşık performans ölçeğine gerek duyulur.

1.8.2. Temel performans ölçütleri

Bu kısımda temel hata ölçümlerinin tanımlarına yer verilmiştir.

1.8.2.1. Ölçüm problemlerinde performans ölçütü

Amaç belli bir değeri veya vektörü tahmin etmek olduğunda, hesaplanan sonuçtan doğru değer ölçümü çıkartılır. Farkın mutlak değeri doğru değer boyutuna göre değişeceğinden ortalama göreceli hata (mean relative error) şöyle hesaplanır;

$$\text{ortalama göreceli hata} = \frac{(\text{ölçülen değer}) - (\text{doğru değer})}{(\text{doğru değer})} \quad (1.2)$$

1.8.2.2. Tespit problemlerinde performans ölçütü

Tespit problemlerinin hata ölçümleri, alınan kararların doğru ve yanlış olarak göreceli oranlarını içerir. Üst seviye performans ölçümleri temel performans ölçümlerinden türetilir. Görüntüleme de dahil olacak şekilde herhangi bir tıbbi bir sınamada klinik performansı genellikle doğru negatif (True Negative -TN), yanlış negatif (False Negative -FN), doğru pozitif (True Positive -TP), yanlış pozitif (False Positive -FP), hassasiyet (sensitivity), özgünlük (specificity), pozitif tahmin değeri (Positive Predictive Value-PPV), negatif tahmin değeri (Negative Predictive Value-NPV) ve doğruluk (accuracy) değerleri ile belirlenir. “Görüntüde bir anormallik var mı?” sorusunun cevabı bu değerlerle tarif edilir.

a) Doğru ve yanlış pozitif ve negatifler

Görüntü içinde bir anormalliğin olup olmadığının belirlenmesinde doğru (true) ve yanlış (false), pozitif ve negatifler, true positive, false positive, true negative, false negative şeklinde sıkça kullanılır. Bu terimlerden positive ve negative, tespit algoritması tarafından verilen kararı ifade eder, true ve false terimleri ise asıl durum ile tespit algoritmasının kararının uyumlu olup olmadığını gösterir. True positive (TP) tespit algoritmasının anormal durumun varlığına ilişkin kararının doğru olduğunu belirtir. False positive (FP) ise tespit algoritmasının anormal durumun

varlığına ilişkin kararının yanlış olduğunu ifade eder. True negative (TN) tespit algoritmasının anormal durum olmadığına dair kararının doğru olduğunu, false negative (FN) tespit algoritmasının anormal durum olmadığına dair kararının yanlış olduğunu ifade eder. Konu Tablo 1.2’de özetlenmiştir.

Tablo 1.2. Doğru ve yanlış pozitif ve negatiflerin tanımı

		Algoritmanın kararı	
		Anormal durum var	Anormal durum yok
Klinik olarak doğru durum	Anormal durum var	True positive	False negative
	Anormal durum yok	False positive	True negative

b) Hassasiyet ve özgünlük

TP/FP ölçeklerinden hassasiyet (sensitivity), ve özgünlük (specificity) gibi çeşitli performans ölçekleri türetilmiştir. Tespit algoritmasının hassasiyeti örnekler içinde olan anormalliğin raporlanma sıklığını belirtir. Diğer bir deyişle mevcut anormalliklerin doğru şekilde raporlanma oranıdır. Hassasiyet 0 ile 1 arasında bir değer veya 0 ile 100 arasında bir oran ile ifade edilebilir. Tanımı true positive ve false negative değerleri kullanılarak yapılabilir. True positive ve false negative değerlerinin toplamı anormallikleri içeren bütün örneklerin kümesidir. Hassasiyetin formülü şöyledir;

$$\text{hassasiyet} = \frac{\text{TP}}{(\text{TP}+\text{FN})} \quad (1.3)$$

Hassasiyetin en düşük değerinde (0 veya %0) olması mevcut anormalliklerin tespit edilemediğini, en yüksek değerinde olması (1 veya %100) bütün anormalliklerin tespit edildiğini gösterir. Hassasiyet true positive fraction (TPF) olarak da ifade edilir.

Özgünlük tespit algoritmasının hiçbir anormalliğin olmadığı durumda normalliğin raporlanma sıklığını belirtir. Diğer bir deyişle normal vakaların yanlışlıkla anormal olarak ifade edilme oranıdır. Hassasiyet gibi özgünlük de 0 ile 1 arasında bir değer veya 0 ile 100 arasında bir oran ile ifade edilebilir. Tanımı true negative ve false positive rakamları ile yapılabilir. Tanım olarak, true negative ve false positive toplamı bütün normal örneklerin kümesidir. Özgünlük formülü şöyledir;

$$\text{özgünlük} = \frac{TN}{(TN+FP)} \quad (1.4)$$

Özgünlük değerinin 1 olması, her normal örneğin doğru bir şekilde normal olarak raporlandığı anlamına gelir. False positive fraction (FPF) olarak da ifade edilir.

İdeal bir tespit algoritmasının, hassasiyet ve özgünlük değerleri 1 veya %100 olmalıdır. Bu değer mevcut anormal örneklerin ve anormal olmayan örneklerin doğru bir şekilde raporlandığı anlamına gelir [51].

c) Tahmin değerleri ve doğruluk

Temel performans ölçümlerinden türetilen diğer üst seviye performans ölçümleri tahmin değerleri ve doğruluktur. Pozitif tahmin değeri (Positive Predictive Value-PPV);

$$PPV = \frac{TP}{TP+FP} \quad (1.5)$$

Negatif tahmin değeri (Negative Predictive Value-NPV);

$$NPV = \frac{TN}{TN+FN} \quad (1.6)$$

PPV ve NPV değerleri hassasiyet ve özgünlük değerlerine bağlıdır. Yaygınlık (Prevalence-PR) ise anormallik olan sınıma kümesindeki vakaların miktarıdır ve aşağıdaki gibi hesaplanır;

$$PR = \frac{TP+FN}{TP+FP+TN+FN} \quad (1.7)$$

Doğruluk (accuracy) yaygınlık durumuna doğrudan bağlıdır ve şöyle ifade edilir;

$$\text{Doğruluk} = PR(\text{hassasiyet} - \text{özgünlük}) + \text{özgünlük} \quad (1.8)$$

Yaygınlık %0 ise doğruluk hassasiyete eşittir [51]

d) Alıcı işletim karakteristiği eğrisi

Alıcı işletim karakteristiği eğrisi (Receiver Operating Characteristic- ROC) CAD dahil bilgisayar algoritmaları ve yeni tıbbi görüntüleme sistemlerinin

değerlendirilmesinde kullanılan standart bir araçtır. Temeli sinyal tespit teorisine dayanır ve ismini buradan alır. Gözlemcinin belirli bir değerlendirme ölçeği kullanarak görüntü içinde ilgilenilen sinyalin olup olmadığını belirlemesi esasına dayanır. ROC ile bütün görüntüleme sistemi, gözlemci ve görüntüleme koşullarının performansı ölçülür. İki farklı gözlemcinin performansları, iki farklı görüntüleme sistemi veya iki farklı görüntü formatı arasında karşılaştırma yapılır. ROC ölçümlerinin sonucunda, gözlemci karar kriterinin bir fonksiyonu olarak isabet oranı veya karar eşliğine karşılık yanlış isabet oranını içeren bir eğri ortaya çıkar.

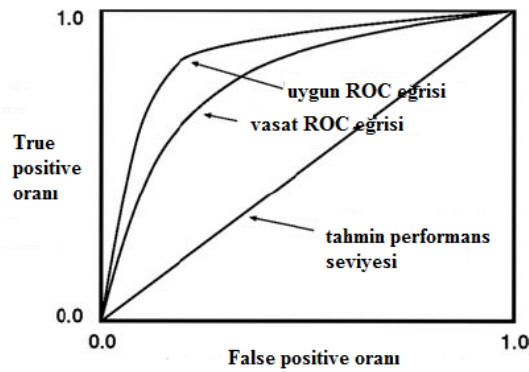
Başarılı bir ROC çalışması oluşturmak ve anlamlı bir sonuç ortaya çıkmasını sağlamak için tasarım parametrelerinin iyi hazırlanması gerekir. Uygulama öncesi bir ROC çalışması için gerekli faktörler şöyledir;

1. Hipotezin ve karşılaştırılacak bilgilerin iyi tanımlanması gerekir. Karşılaştırılan çalışmaların eşitliği veya birinin üstünlüğü ortaya çıkartılır.
2. İstatistiksel açıdan gerekli gözlemci sayısı belirlenir. Üç veya dört gözlemcinin katıldığı başarılı ROC sınamaları bulunmaktadır. Gözlemci sayısı, performansı ve vaka sayısı birbirinden bağımsız konulardır. Kullanılan vaka sayısı, gözlemci sayısından ve gözlemci performansından daha önemlidir. Genellikle yakın eğitim ve deneyim seviyesinde gözlemciler tercih edilir.
3. Veri kümesinin içeriği ve örnek sayısı belirlenir. Veri kümesinin boyutu gözlemci sayısı ve performansı ile ilişkilidir. Örneğin beş gözlemcinin olduğu bir çalışmada, ortalama performans 0,85 veya altı olacak şekilde 50 pozitif ve 50 negatif vaka kullanılır. Pozitif vakalar kanser, kırık kemik gibi ilgilenilen bilgiyi veya “sinyali” içerir, negatifler ise sinyalin olmadığı veya iyi huylu tümör bulunması gibi farklı özelliğe ait sinyalin bulunması durumudur.
4. Değerlendirme yöntemi ve ölçek (sürekli, ayırık beş nokta veya ayırık on nokta değerlendirme ölçeği gibi) belirlenir.
5. Bağımsız veya sıralı okuma modu seçilir. Son zamanlarda CAD algoritmalarının ROC çalışmalarında, bilgisayar destekli okuma ile standart okuma arasında, zaman aralığı olmaksızın vakaları peş peşe okuma yönteminin daha hassas olduğu ifade edilmiştir.
6. ROC analizinde kullanılacak yazılım aracı seçilir.

7. Kesin veya göreceli performans tahmini ve performans farklılığı için ölçek belirlenir. ROC analizinde çeşitli global, lokal ve bölgesel performans indisleri kullanılabilir. Bunların bazıları ROC eğrisinin altındaki alan, kısmi alan indisi, seçilen bir FPF için TPF, karar eşliğidir.
8. Gerçekleştirme adımı tasarımın son işlemidir. Burada okuma ortamının ayrıntıları belirlenir. Örneğin ortamın ışıklılığı, oturma pozisyonu okuma süresi, raporlama yöntemi gibi konular ele alınır.

Tıbbi görüntü teknolojilerinin değerlendirilmesinde güçlü bir araç olan ROC analizinin kısıtları şöyle özetlenebilir; Seçilen veri kümesi için iyi bir referans veriye (ground truth) gerek vardır ancak tıbbi görüntüleme bunu elde etmek her durumda mümkün değildir. Sonuç veri kümesine bağlıdır ve seçilen kümenin genel popülasyonu temsil etme oranına göre sonuç da etkilenir. Çalışmalar maliyetli, zaman alıcı ve karmaşıktır. İşlem lezyon yerini içermediğinden, tek veya birden çok lezyon olan vakalar açısından analizde bir farklılık olmamaktadır [52].

ROC eğrisi bir algoritmanın hassasiyet ve özgünlük arasındaki olabilecek değişimleri özetler. Tipik bir ROC eğrisinin x ekseninde özgünlük (False Positive Fraction - FPF), y ekseninde hassasiyet (True Positive Fraction - TPF) yer alır. Bu uzayda ideal işletim noktası, TP'nin 1, FP'nin 0 olduğu üst sol köşedir.

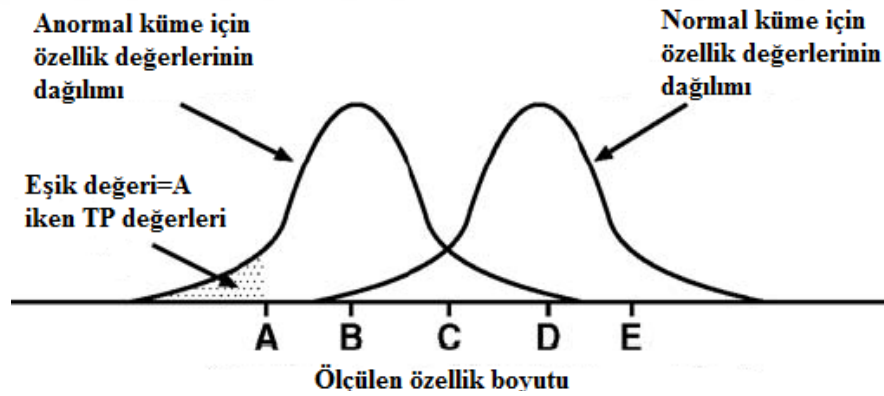


Şekil 1.17. ROC eğrisine bir örnek

Şekil 1.17'deki ROC grafiğinde yer alan diyagonal çizgi performans seviyesidir ve algoritmanın bunun altında bir performans sergilememesi beklenir. Eğer bunun altında değerler alınırsa o zaman yöntemin sonucunun tersi alınarak çizginin üstünde bir ROC eğrisi elde edilir.

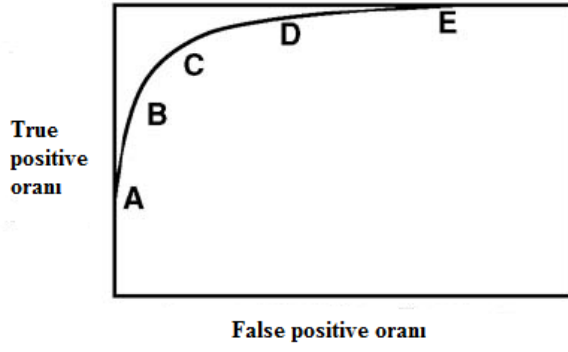
ROC eğrisinin deneysel olarak geleneksel oluşturulma biçimi insan gözüyle yapılan değerlendirmedir. Klinik olarak normal olan ve olmayan bir görüntü kümesi ele alınır. Gözlemcilerden bireysel olarak görüntü kümesini normal olan ve olmayan olarak derecelendirmeleri istenir. Örneğin “kesinlikle normal” ile “kesinlikle normal değil” arasında beş kesinlik seviyesi olabilir. ”işletim noktası”nı tanımlamak amacıyla görüntü kümesinin farklı TP, FP sonuçları her kesinlik seviyesi eşik değeri gibi kullanarak sınıflandırılır. İnsan gözlemine dayalı başka farklı ROC çalışmaları da mevcuttur.

Bilgisyardaki bir görüntü analizi algoritmasını kullanarak yapılan çalışma daha farklıdır. İdeal durumda, algoritmanın kararları sonucu oluşan hassasiyet ve özgünlük arasındaki değişimleri doğrudan kontrol eden bir algoritma parametresi tanımlanır. Bu parametre gözlemcinin karar verme parametresine benzer şekilde normal olan ile olmayan arasında farklı değerler alır. En basit senaryoda algoritma bir eşik değeri kullanır, öyle ki bu değer bazı özellik değerlerinin iki normal (Gaussian) dağılımını ayırtmada karar sınırı olarak kullanılır. Şekil 1.18’de özellik değerlerinin dağılımına bir örnek görülmektedir.



Şekil 1.18. Özellik değerlerinin dağılımı

Farklı eşik değerleriyle değişik TP, FP kombinasyon değerleri elde edilerek Şekil 1.19’de örneği yer alan bir ROC eğrisi oluşturulur. Burada iki önemli konu vardır. Birincisi ROC eğrisinin oluşturulması için uygun parametrenin tanımlanmasıdır. Görüntü tanıma veya geleneksel görüntü sınıflama teknikleri kullanılıyorsa uygun parametre bulmak kolaydır ancak yapay sinir ağları veya diğer “şeffaf” olmayan sınıflandırıcılar kullanılırsa parametre seçimi zorlaşabilir.



Şekil 1.19. Bir tespit algoritması için ROC eğrisinin oluşturulması

Bazı görüntü analiz algoritmalarının tespit oranını etkileyen birden fazla parametresi bulunabilir ve bu durumu karmaşık hale getirir. İkinci konu uygun “eğit ve sına” yöntemlerinin kullanılmasıdır. Algoritma geliştirme işlemi genel olarak, algoritmanın tekrarlanan şekilde güncellendiği ve her güncellenme değerinin ROC eğrisini etkilediği aşamalar içerir. Bu gelişim aşamalarının sonucu “ROC eğrisinin eğitilmesi” olur.

e) ROC eğrisinin altındaki alan

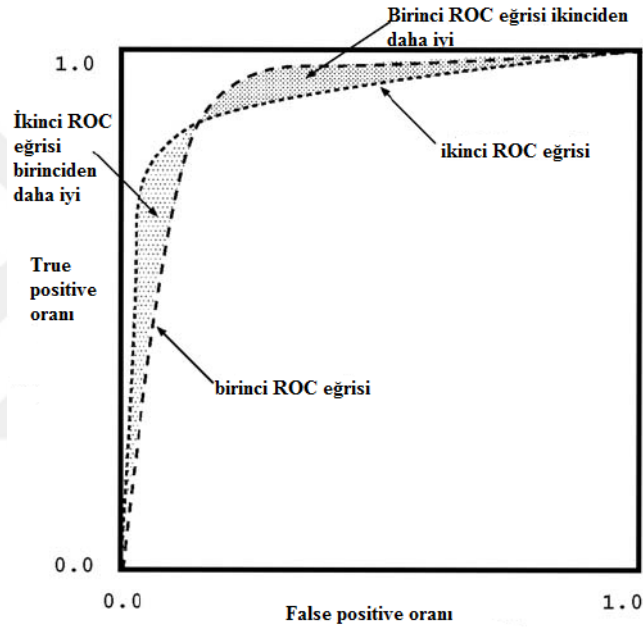
ROC eğrisinin altındaki alan (Area Under ROC-AUC) global performans ölçüğü olarak sıkça kullanılır. AUC, 0 ile 1 arasında değişir. Rastgele tahminlerle karar oluşturan bir algoritmanın ROC eğrisi diyagonal çizgide oluşursa AUC değeri 0,5 olur. AUC değeri arttıkça doğru karar verilme olasılığı da artar. İki ROC eğrisinden AUC değeri yüksek olan eğri bir bütün olarak daha iyi kabul edilir. Ancak geçerli bir karşılaştırma için belirli unsurlar göz önüne alınmalıdır. Örneğin ROC eğrileri farklı veri kümeleri ile oluşturulmuş ise veri kümelerinin zorluk dereceleri aynı kabul edilir.

İnsan gözleminin sonuçlarına göre oluşturulan bir ROC eğrisinin AUC değeri eğri uydurma işlemi ile hesaplanır. Bunun nedeni insan gözleminin sonuçlarıyla oluşturulan ROC eğrisinin veri noktalarının (örneğin beş sıralı nokta ve iki uç nokta gibi) seyrek aralıklı olmasıdır. Belli başlı ROC eğrisi uydurma yöntemleri mevcuttur. Bilgisayarda tıbbi görüntü analizi algoritması tarafından oluşturulan bir ROC eğrisi genelde 10’larca veya 100’lerce noktadan oluşur. Bu durumda eğri uydurma işlemine


gerek olmaz. Verilen k işlem noktası için (TP_i, FP_i) , $i=1, \dots, k$, ve i değerinin artışıyla TP değerlerinin azalmadığı varsayılarak yamuk kuralı ile AUC şöyle hesaplanır;

$$AUC = \sum_{i=1}^{k-1} (FP_{i+1} - FP_i)(TP_i + TP_{i+1})/2 \quad (1.9)$$

AUC genel bir performans ölçümü olduğu için bazı önemli ayrıntılar gözden kaçabilir. İki farklı ROC eğrisi Şekil 1.20’de görüldüğü gibi aynı AUC değerine sahip olabilir. Bu durumda ROC eğrisinin altında, belirli TP aralığı için veya FP aralığı için veya her ikisi için kısmi bir bölge hesaplamak uygun olur.



Şekil 1.20. Aynı AUC değerine sahip iki farklı ROC eğrisi



Şekil 1.21. Kısmi AUC hesaplama yolları

Şekil 1.21’de görüldüğü gibi oluşturulan kısmi AUC, 0-1 aralığına normalize edilir. Bu uygun bir TP veya FP aralığını temsil eden işlem noktalarını kullanarak yapılabilir. Örneğin TP_m ve TP_n aralığı için kısmi AUC şöyle hesaplanabilir;

$$AUC = \frac{\sum_{i=m}^{i=n-1} (FP_{i+1} - FP_i) \left(\frac{TP_i + TP_{i+1}}{2} - TP_m \right)}{TP_n - TP_m} \quad (1.10)$$

Genel olarak aynı TP veya FP aralığında kısmi AUC'ları karşılaştırmak uygun olur. Eğer bir nedenden dolayı farklı TP aralıkları için hesaplanan AUC'lar arasında karşılaştırma yapmak gerekirse, farklı TP aralıklarında mümkün olan en az sayıda farklı değerler üzerinden normalizasyon yapılmalıdır. Kısmi AUC için en küçük değer diyagonal çizgiden belirlenebilir. Bu şekilde normalize etmekle bile farklı TP aralığındaki AUC'ların karşılaştırılması pek anlamlı olmaz.

1.8.2.3. Görüntü bölütleme problemlerinde performans ölçütü

Görüntü bölütleme problemleri iki çeşittir. Tespit problemiyle ilişkili olan ilki, “görüntüdeki her bir “x”in tanımlanması” şeklinde karakterize edilir. Bu problem çeşidinde sonuç, “anormallik” gibi bazı anlamlı etiketleri olan birden çok bölgenin bulunması veya hiçbir bölgenin bulunamamasıdır. Bununla birlikte görüntünün kalan alanı farklılaştırılmamış olarak kalır. Daha genel olan ikinci problem, “görüntünün bütün temel bölgelerinin tanımlanması” ile karakterize edilir. Bu durumda bütün görüntü nispeten eşdeğer içerikli bölgelere ayrılır. Her iki problemin de bir çözüm kümesi vardır. Doğru ve yanlış sonuçların sayılması, basit ölçüm veya tespit probleminden daha karmaşık bir iştir [51].

Bölütleme sonucunun doğrulanmasında, ilgilenilen nesnenin gerçek uzamsal özelliklerini içeren referans görüntünün (ground truth) elde olması temel bir gerekliliktir. Ancak tıbbi görüntüler referansı tanımlamanın açık ve kesin bir yolu yoktur. Bu nedenle başvuru yöntem uzman kişilerin referansı tanımlamasıdır. Organların dış sınırları veya tümör gibi ilgilenilen alanların elle çizilmiş örnekleri referans olarak alınır. Bu işlem masraflı ve zaman gerektirmesinin yanı sıra uzman kişiye göre değişen sonuçlar vermesi açısından tutarsız da olabilir. Bu işlemde doğruluğun artırılması ve tutarsızlığın azaltılması için birden çok uzman ayrı ayrı veya karışık bir şekilde olarak kullanılmaktadır. İşlemi hızlandırmak ve maliyeti düşürmek için ise denetimli veya denetimsiz olarak eğitilmiş teknisyenlerden yararlanma yoluna gidilmektedir. Yarı otomatik bir diğer yöntemde ise, uzman ilgilenilen alanın dış sınırlarına sadece belirli noktalar koyar, noktalar algoritma


aracılığı ile birleştirilir. Sınır çizme işleminin sonucu uzman tarafından doğrulanabilir veya doğrulanmayabilir.

Doğrulama için uzman kişiler tarafından oluşturulan klinik referans bilgisini kullanmaya alternatif yol simülasyon veya model kullanılmasıdır. Bunlar, sonuç üzerindeki etkiye bakarak, veya klinik teşhise göre bölütlemenin değerlendirilmesi şeklinde göreceli performans ölçekleri veya dolaylı ölçümlerdir. Bunların kendi kısıtları vardır ve genele uygulanamaz. Araştırmacılar özel uygulama için model veri veya simülasyon oluştururlar veya herkese açık veritabanlarını kullanırlar [52].

a) Alıcısız Roc eğrisi

Amaç görüntü içindeki bütün anormal oluşumların tanımlanması olduğunda bu tip bir performans ölçeği seçilebilir. Standart ROC eğrisinde görüntü ile ilgili algoritmanın bir senaryosu olduğu varsayılır ve görüntü için “anormallik yok” veya “anormallik var” kararı verilir. Eğer “anormallik var” kararı yanlışlıkla verilmişse bütün görüntü FP olur. Bir görüntü için sadece bir FP olabilir. Dolayısıyla bir görüntü kümesi içinde olabilecek FP sayısı görüntü sayısı kadar olur.

Daha genel bir senaryoda algoritma görüntü içindeki her türlü anormal bölgeyi tanımlar. Bu senaryoda, bir görüntü için birden fazla FP olabilir. Olabilecek en fazla FP sayısı algoritma tarafından belirlenir. ROC eğrisinin bu türü alıcısız ROC eğrisi (Free Response ROC- FROC) olarak adlandırılır. FROC eğrisinde tespit algoritması, görüntü içinde herhangi bir yere özel sonuç üretebilir. Olabilecek en yüksek FP sayısı sabit olmadığından, x eksenini 0 ile 1 arasında değerler içermez. Bunun yerine her görüntü için alınan FP cevaplarının ortalama sayısı yer alır. Şekil 1.22'deki örnekteki gibi TP ve FP seviyelerinde 0 değer oluşması mümkündür.



Şekil 1.22. Örnek bir FROC eğrisi

FROC eğrisi algoritmanın genelleştirilmiş özgünlüğü ve hassasiyeti arasındaki değişim uzayını temsil eder. X eksenindeki sabit bir en yüksek değer olmadığı için, TP değeri en yüksek rakama ulaşırsa veya görüntü uygulama için çok büyükse bazı FP değerleri kırılır.

Eğri altındaki alanları kullanarak iki FROC eğrisi karşılaştırılabilir. Genel olarak eğri altındaki alan yamuk kuralı uygulanarak tahmin edilebilir. İki FROC eğrisini aynı TP ve FP aralığında karşılaştırmak anlamlı olur.


b) Görüntü bölgelerinin karşılaştırılması

Bölütlenmiş görüntü sonucunu referans görüntü ile (ground truth) karşılaştırırken aşağıdaki beş durumdan biri ortaya çıkabilir. Bu durumlar referans görüntü ile bölütlenmiş görüntü arasındaki örtüşme miktarını belirten T eşik değeri ile ifade edilebilir. Bu durumlar şöyledir;

1. Doğru bölütlenmiş bölge : referans görüntü ile bölütlenmiş görüntü arasında karşılıklı örtüşmenin T eşik değerini karşıladığı durumda bölütleme doğru gerçekleşmiştir.
2. Fazla bölütlenmiş bölge: bölütlenmiş görüntüdeki birden çok bölgenin referans görüntüde tek bir bölgeye karşılık gelmesi durumudur. Referans görüntüdeki tek bir bölge en az %T oranında bölütlenmiş görüntüdeki bölgelerle örtüşür. Aynı şekilde bölütlenmiş görüntüde karşılık gelen bölgelerde her biri, referans görüntüdeki bölgeyle en az %T oranında örtüşür.
3. Az bölütlenmiş bölge: referans görüntüde birden fazla bölgenin bölütlenmiş görüntüde tek bir bölgeye karşılık gelmesi durumudur. Fazla bölütlenmiş bölgelerdeki gibi bölgeler karşılıklı en az %T oranında örtüşürler.
4. Atlanmış bölge : referans görüntüde işaretlenmiş bir bölgenin bölütlenmiş görüntüde bulunmaması veya bulunan bir bölge ile yeterli derecede örtüşmemesi durumudur. Bu koşul diğerlerinden farklı olarak tek yönlüdür, yani bölütlenmiş görüntüde aranan karşılık yoktur.
5. Gürültülü bölge : bölütlenmiş görüntüde olan ancak referans görüntüde karşılığı olmayan bölgenin olması durumudur.


Şekil 1.23'de yer alan bölütlenmiş görüntüdeki A bölgesi referans görüntüdeki 1 numaralı bölgeye karşılık gelerek doğru bölütlenmiş bölgeyi temsil etmektedir. C, D

ve E bölgeleri 5 numaralı bölgeye karşılık gelerek fazla bölütlenmiş bölgelerdir. B bölgesi 2,3 ve 4 numaralı bölgelere karşılık gelen az bölütlenmiş bölgelerdir. 6 numaralı bölge atlanmış bölgedir. F bölgesi gürültülü bölgedir.



Şekil 1.23. (a) bölütlenmiş görüntü, (b) referans görüntü

Algoritmadaki parametrelerin değiştirilmesiyle bölgelerin durumları da değişebilir. Ayrıca T eşik değerinin artırılması genel olarak doğru bölütlenmiş bölge sayısını azaltır ve hatalı bölge sayısını artırır. Buradan T eşik değerinin bir fonksiyonu olabilecek değişik performans ölçütleri içeren grafikler aracılığı ile bölütleme algoritması değerlendirilir [51]. Şekil 1.24'de bölütleme algoritmalarını karşılaştırmak amacıyla performans ölçümlerinin kullanımı örneği yer almaktadır.



Şekil 1.24. Performans ölçümlerinin kullanımı

Performans karşılaştırma ölçekleri şöyle hesaplanabilir;

Referans görüntü oluşturulduktan sonra çeşitli ölçeklerle bölütleme sonuçları doğrulanabilir. Ölçütler uygulamaya göre seçilir. Bu ölçeklerden bazıları şunlardır;

1. Hausdorff uzaklığı $h(A,B)$; aynı bölgeye ait, bilgisayarın (B) oluşturduğu sınırlarla bir uzmanın (A) hazırladığı sınırlar arasındaki uzaklık için kullanılır.

$A=\{a_1, a_2, \dots, a_m\}$ ve $B=\{b_1, b_2, \dots, b_m\}$ her iki sınırdaki yer alan nokta kümeleridir ve her nokta x ve y koordinatıdır. a_i noktasının B kümesindeki en yakın noktaya olan uzaklığı şöyledir;

$$d(a_i, B) = \min_j \|b_j - a_i\| \quad (1.11)$$

Benzer şekilde b_j noktasının A kümesindeki en yakın noktaya olan uzaklığı ise;

$$d(b_j, A) = \min_i \|a_i - b_j\| \quad (1.12)$$

Hausdorff uzaklığı $h(A, B)$, iki sınır arasındaki yukarıdaki uzaklıkların en yüksek olanı olarak şu şekilde tanımlanır;

$$h(A, B) = \max[\max_i \{d(a_i, B)\}, \max_j \{d(b_j, A)\}] \quad (1.13)$$

2. A ve B sınırları ile çevrelenen G ve E alanları arasındaki çakışma derecesi OL ; çakışma iki alanın kesişim ve birleşimlerinin oranı olarak aşağıdaki gibi tarif edilir;

$$OL = \frac{G \cap E}{G \cup E} \quad (1.14)$$

Denklem (1.14)'de G referans alanı, E bilgisayar tarafından oluşturulan alanı temsil etmektedir. Eğer oran 1 ise mükemmel örtüşme olduğu, 0 ile hiç örtüşme olmadığı anlaşılır.

3. Ortalama mutlak sınır uzaklığı (Mean Absolute Contour Distance –MACD); iki sınır arasındaki mesafe ölçөгüdür. Hesaplamak için iki eğrinin noktalar arasında birebir karşılaştırma gerekir. Karşılık gelen noktalar arasındaki uzaklıkların ortalaması ortalama mutlak sınır uzaklığıdır. Bundan başka eğriler arasında işaretlenmiş noktalar arasında uzaklık hesaplanarak algoritmanın çalışması izlenebilir veya bölütleme işlemi üzerindeki bölgesel etkilerin görülebilir.

Birinci ve ikinci ölçөгler boyuta, bölütlenen nesnelerin biçimine duyarlıdır ve ayrıca görüntünün uzamsal çözünürlüğüne bağlıdır. Üçüncü ölçөг ise görüntü çözünürlüğünden ve nesne boyutundan bağımsızdır ve uygulamada farklı kaynaklardan alınan farklı çözünürlüklü görüntüler kullanıldığında tercih edilir [52].

1.8.3. Eğitim ve sına yöntemleri

Bu kısımda, eğitim (training) ile kast edilen bir algoritmanın geliştirilmesi ve parametre seçimi için yapılan bütün işlerdir. Sınama (testing) ise algoritma performansının değerlendirildiği son aşamadır. Her tür görüntü analiz algoritmasının performansını değerlendirirken uygun bir eğitim/sına yönteminin kullanılması önemlidir.

Eğit/sına yönteminin temel prensibi sınama için kullanılan verinin eğitim aşamasında kullanılan farklı olmasıdır. Bu konuda en sık yapılan hata, sınama aşamasından sonra algoritmanın performansının artırılması için güncellenmesi ve güncellenen algoritmanın bir önceki sınamada kullanılan veri kümesiyle çalıştırılmasıdır. Bu durumda sınama için kullanılmış veri kümesi eğitim veri kümesi haline gelmektedir. Eğitim aşamasında kullanılan veriler ile performans sınaması yapılırsa “eğitim verisiyle sınama işlemi” olarak adlandırılır. Geliştirmede kullanılan eğitim veri kümesi, performans değerlendirme için yapılan sınama veri kümesinden farklı olmalıdır.

İkinci temel prensip eldeki sınırlı miktardaki verinin etkili kullanılmasıdır. Verinin kaynağı ve seçimi önemlidir, geliştirilen algoritmanın hedefine uygun olmalıdır. Ayrıca eğitim ve sınama verileri hedeflenen sonucu (ground truth) açık bir şekilde içermelidir. Tespit algoritmalarında hedef, genellikle görüntü içindeki anormal bölgenin ana hatlarıdır. Görüntü çakıştırma (registration) algoritmaları için doğru çakıştırma dönüşüm bilgisidir. Hedeflenen sonucun (ground truth) oluşturulması ve kaydedilmesi genellikle çalışılan alanda uzman kişinin desteğini gerektirir.

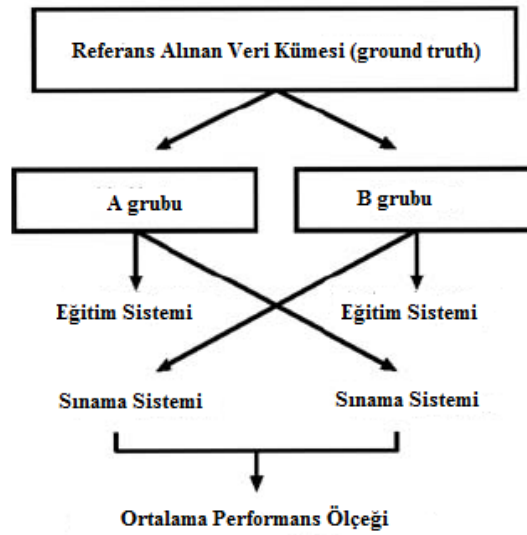
Eğit/sına yöntemleri aşağıdaki gibi gruplanabilir;

1.8.3.1. Yarım-yarım

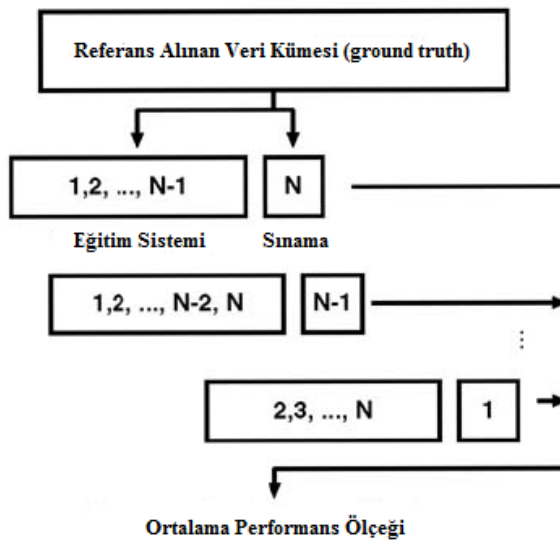
Eğit/sına yöntemlerinden sık kullanılan bir tanesi yarım-yarım (half-half) yöntemidir. Adından da anlaşılacağı gibi eldeki veri A ve B olarak iki gruba ayrılır. Eğitim ve sınama hem A hem de B veri kümesi kullanılarak yapılır. Her iki kümeden alınan performans değerlendirmelerinin ortalaması genel performans ölçümünü verir.

Verilerin iki kümeye ayrılması rastgele olmalıdır. Aynı zamanda her iki kümede de verinin önemli karakteristik özellikleri bulunmalıdır. Örneğin 200 görüntü içeren bir veri seti, 100'lik iki kümeye ayrıldığında her iki kümede de 50 zararlı, 50 zararsız veri örneği bulunmalıdır.

Tespit algoritması için ROC eğrisi oluştururken yarım-yarım yöntemi şöyle uygulanır; öncelikle A grubu ile tespit algoritması çalıştırılır. Sistem eğitim aşamasını tamamladığında B grubu üzerinden sına yapılarak ROC eğrisi hesaplanır. Ardından B grubuna ile eğitim algoritması uygulanır ve bu kullanılarak A grubu için ROC sınaması hesaplanır. Konu Şekil 1.25'de örneklenmiştir.



Şekil 1.25. Yarım-yarım yöntemi



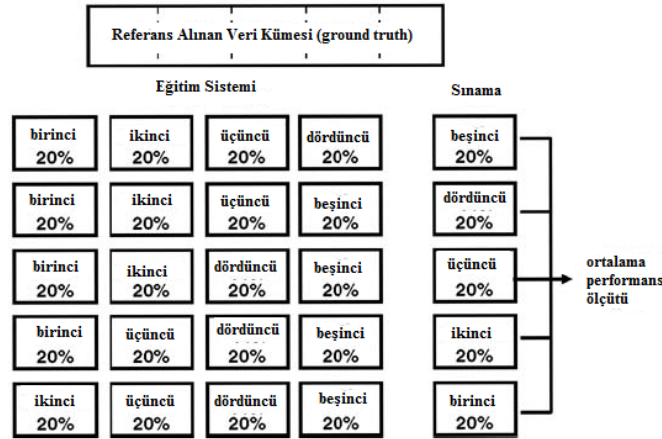
Şekil 1.26. "birini dışarda bırak" yöntemi

1.8.3.2. Birini dışarda bırak

Sıkça kullanılan diğer bir yöntem “birini dışarda bırak (leave-one-out)” olarak adlandırılır. Şekil 1.26’de örneklenen bu yaklaşımda N boyutlu bir veri kümesi, N-1 eğitim ve 1 sına olcak şekilde N farklı şekilde ele alınır. Böylece eğitim N-1 tane veri ile, sına sadece 1 veri ile yapılır. Performans değerlendirmesi N verinin sonucunun ortalamasıdır. Bu yöntemin sorunu eğitim adımının N kere tekrarlanması gereği nedeniyle hesaplama maliyetinin yüksek olmasıdır.

1.8.3.3. N-çesit çapraz doğrulama

Yukarıda anlatılan “birini dışarda bırak” yönteminin genelleştirilmiş hali N-çesit çapraz doğrulamadır (N-way cross-validation). Bu yaklaşımda eğitim ve sına verinin belirli bir yüzdesi ayrılır. Örneğin %90 eğitime ve %10 sınaya ayrılır. Bu durumda 10 farklı veri grubu oluşturulur. Ardından 10 tane rastgele 90/10 ayırımında veri oluşturulur. Bütün sistemin performansı N kümenin ortalamasından oluşturulur. Yöntem Şekil 1.27’de örneklenmiştir.



Şekil 1.27. N çapraz doğrulama yöntemi

Bu yöntemlerin hangisinin kullanılacağına karar vermek için eldeki veri miktarına ve algoritmanın eğitimi için ayrılan süreye bakmak gerekir. Genel olarak büyük veri kümesi sistem performansının daha iyi ortaya çıkmasını sağlar. Ancak veri ile performans arasındaki ilişki doğrusal değildir. Veri kümesi küçük olduğunda eğitim kümesinin boyutunda küçük artışlar yapılarak performansta fark edilebilir artış sağlanabilir. Eğitim kümesi büyük olduğunda eğitim kümesinin boyutunda büyük

artışlar yapılarak performansta fark edilir artış elde edilemeyebilir. Veri kümesi büyük olduğunda yarım-yarım yaklaşımı hem doğru bir performans ölçümü verir hem de hesaplama süresini azaltır. Bunun dışındaki durumlarda N çapraz doğrulama sıklıkla kullanılır.

Büyük ve küçük erimleri için sabit rakamlarla ifade edilen genel referanslar yoktur. Hedef verilerin karmaşıklığına göre uygun seçilecek veri kümesinin boyutu ile ifade edilir. Eldeki veri kümesi küçük ise çoğunun eğitim için kullanılması arzu edilir. Bu durumda “birini dışarda bırak” yöntemi seçilebilir. Eldeki veri kümesi büyük ise yarım-yarım hem hesaplama süresini azaltır hem de doğru performans ölçüğü oluşturur. Bunların dışındaki durumlarda veya performans ölçüğünde değişim uygulanmak isteniyorsa N-çeşit çapraz doğrulama kullanılır.

Performans ölçüğünün ROC eğrisi olduğu durumda, eğitim ve sınama için ROC değerleri hesaplanacaktır. ROC eğrisi için noktalar oluşturmak amacıyla algoritmada kullanılan eşikleme değerlerinin örneklenmesi eğitim verilerinden bağımsız olarak yapılabilir veya eğitim verilerinden “öğrenilebilir”. Eğer eğitim verilerinden öğrenilmiş ise, aynı eşik değerleri sınama ROC eğrisi oluşturmak için kullanılabilir. Bu örneklenme değerleri TP ve FP aralığını kapsıyorsa, eğitim kümesinde olduğu gibi sınama kümesinde aynı olmayabilir [51].

1.8.4. İstatistiksel sınamalar

ROC çalışması yapılmayan yerlerde veriler arasındaki farkı ortaya koymak için istatistiksel analiz yapılır. Doğrulama işleminin son adımı, farklı bölütleme algoritmaları arasında ölçülen parametreler arasındaki uyumun veya bilgisayar ile gözlemcinin performanslarının karşılaştırılmasını içeren istatistiksel analizdir. Bilgisayar ile uzman veri arasında çeşitli istatistiksel araçlar kullanılarak karşılaştırma yapılır. Bunlardan belli başlıları; bölütlenmiş çeşitli kümelerin ortalamaları arasındaki ilişkiyi inceleyen lineer regresyon analizi, bilgisayar yöntemleri ile uzmanların arasındaki uyumu belirleyen t-test çifti, algoritmalar veya gözlemciler arasındaki sonuçların ana hatlarını inceleyen Williams indeksi ve ROC analizidir [52].

Bilimsel yayınlarda istatistiksel sonuçlar vermek bir gerekliliktir. Bu konuda üç önemli nokta vardır. Birincisi istatistiksel bir sınamanın gerekli olup olmadığıdır. Gereksiz veya sadece formalite gereği yapılmış birçok istatistiksel sınaama bulunur. İkincisi istatistiksel sınamanın duruma uygunluğudur. Örneğin iki klinik ölçümü değerlendirmek amacıyla korelasyon katsayısını kullanmanın uygunsuzluğu gibi. Üçüncü konu istatistiksel olarak farklılığın uygulamada önemli olup olmadığıdır.

Tıbbi görüntü analizi algoritmalarının performans değerlendirmesinde uygulanacak çok sayıda istatistiksel yöntem bulunur. İstatistiksel sınamanın başlangıç kavramı “boş hipotez” ve “alternatif hipotez” denklemleridir. Boş hipotez, karşılaştırılan değerler arasında örnek alınan popülasyon anlamında gerçek bir fark olmadığı ifade eder. Bu durumda farklılık gözlemlenirse bunun örnekler içinde tesadüfi bir değişim olduğu kabul edilir. Örneğin farklı algoritmalarından elde edilen ROC eğrilerinin altındaki alanların (AUC) arasındaki farkın sınıandığı bir durumda boş hipotez (H_0) bu alanların eşit olmasıdır. Alternatif hipotez (H_1) ise alanların eşit olmaması veya birinin diğerinden büyük olması olabilir. Bu durum şöyle ifade edilebilir;

$$H_0:AUC_1=AUC_2, H_1:AUC_1>AUC_2 \text{ veya } H_1:AUC_1\neq AUC_2$$

Bu durumda istatistik sınaama şu iki sonuçtan birini verecektir; birincisi verilerden doğru olmadığını gösterdiği için boş hipotezin kabul edilmemesi, diğeri verilerin kabul edilmemesini doğrulamadığı için boş hipotezin kabul edilmesidir.

İstatistiksel sınaama yapılırken tip 1 hatası (önem seviyesi veya üreticinin hatası) adı altında bir değer (α) tanımlanır. Sınaama sonucu boş hipotez doğru çıkıyorsa α oranında boş hipotezin doğrulanmaması kabul edilebilir. Diğeri bir deyişle tip 1 hatası, doğru olan boş hipotezin bir hata nedeniyle göz ardı edilmesidir ve bu hata yanlış pozitiftir. Benzer şekilde tip 2 hatası (tüketici hatası) değeri (β) oranı alternatif hipotezin doğruluğu durumunda, bunun tersinin elde edilme miktarını ifade eder. Diğeri bir deyişle tip 2 hatası, doğru olmayan boş hipotezin bir hata nedeniyle göz ardı edilmemesidir ve bu hata yanlış negatiftir. Şekil 1.28’de özetlendiği gibi bu sınaama, örneklerin büyüklüğüne, doğru elde edilen veri büyüklüğüne ve sınaama için seçilen önem seviyesine bağlıdır [51].

	AUC'ların farklı olması durumu	
	Mevcut	Mevcut değil
Boş hipotez red	$1 - \beta$	α
Kararın doğruluğu	β	$1 - \alpha$

Şekil 1.28. İstatistiksel bir sınamada olası hata türleri

Birçok çalışmada $\alpha=0,05$ (veya %5 önem seviyesi) $\beta =0,2$ (veya %80 etki) olarak alınır [52].

1.9. Tıbbi Görüntü İşlemede Bölütleme ve Kullanılabilen Yöntemler

Görüntü birbirine bağlı belli sayıda bölgeden oluşur. Her bölge belirli bir ölçüte göre kendi içinde homojendir. Bölütleme bir görüntünün önceden tanımlanan benzerlik koşuluna göre komşu piksellerin birlikte gruplanmasıyla belirgin bölgelere ayrılması işlemidir. Benzerlik koşulu piksellerin belirli özellik ve nitelikleri kullanılarak belirlenir. İdeal bölütlenmiş bir görüntüde her bölge gri seviye veya desen açısından homojen olmalıdır. Bitişik bölgeler belirgin şekilde farklı karakter ve özelliklere sahip olmalıdır.

Böylece görüntü bölütleme, görüntü içindeki benzer bölgelerin kenar veya bölge tabanlı olarak ayrıştırılabildiği bir piksel sınıflandırma yöntemi olarak düşünülebilir. Bölgeler tanımlandığında sınıflandırma ve analiz için bölgeleri temsil etmek amacıyla istatistiksel veya diğer özellikler hesaplanabilir. Bölütleme bilgisayar analizinde gerekli bir adımdır.

Tıbbi görüntü işlemede bölütleme ilgilenilen özelliklerin ortaya çıkarılması açısından önemli bir işlemdir. Görüntünün bilgisayar destekli ileri analizi, bilgisayar destekli tanı, tanı değerlendirmesinin sınıflandırılması, operasyon simülasyonları, eşleştirme, lezyon belirleme gibi birçok yararlı uygulamada kenar, bölge, desen içeren özelliklerin ve anatomik yapıların ortaya çıkartılmasında kullanılmaktadır [53] [54].

Bütün görüntüleme uygulamalarında istenen sonucu üretecek tek bir standart bölütleme tekniği yoktur. Kullanılan özellik ve tekniğe bağlı olarak sınıflandırılabilen birçok bölütleme yöntemi bulunmaktadır. Genellikle yöntemler

görüntüleme ortamına (MR, BT gibi) uyacak şekilde optimize edilir veya belirli anatomik yapıları (beyin, akciğer veya kalp gibi) bölütleyecek şekilde modellenir. Son zamanlardaki araştırmalardan ulaşılan sonuçlara göre MR, BT'den alınan anatomik yapıların bölütlenmesinde şu üç tip bilgiden yararlanılabilmektedir [53] ;

1. Bağımsız yapıların gri seviyelerini tanımlayan yoğunluk modelleri
2. Farklı yapıların biçimlerini tanımlayan biçim modelleri
3. Görüntüleme işleminin karakteristiklerini içeren görüntüleme modelleri

Bölütleme yöntemleri üç temel sınıfa ayrılabilir; kontrollü (supervised), otomatik (unsupervised) ve yarı otomatik. Kullanılan görüntüleme şekli ve teşhis karmaşıklığına göre yöntem seçilir. Genel olarak bölütlemeye şu yol izlenir [55];

1. Piksellerin bazı benzersiz nitelik veya özelliklerine göre bütün görüntü alt bölgelere ayrılır,
2. Farklı bölgelerde bulunan bölütlenmiş piksel değerlerinin farklılığına göre her bir bölge etiketlenir,
3. Her bölge görüntüden ayrıştırılır. Böylece anatomik olarak farklı yapılar farklı bölgelerde yer almış olur.

Bölütleme teknikleri içeriksel (bağlamsal) olan ve olmayan olarak gruplanabilir. İçeriksel olmayan teknikler görüntü içindeki özellikler arasında bulunan ilişkileri göz ardı eder. Pikseller basitçe gri seviye gibi bazı global niteliklere göre gruplanmıştır. Grilik değerine göre her pikselin belirli bir bölgeye atanma yöntemi olan yoğunluk tabanlı eşikleme içeriksel olmayan bir tekniktir. İçeriksel tekniklerde ilaveten görüntü özellikleri arasındaki ilişkilerden yararlanır. Burada benzer gri seviyeleri olan veya gradyan değerleri olan pikseller birlikte gruplanır. Bu yöntemlere örnek olarak piksellerin benzerliğine göre oluşan bölgelerin belirlendiği bölge büyütme (region growing) tekniği, bölgeler arasında sınırları ortaya çıkaran kenar tabanlı yöntemlerin kullanıldığı sınır tabanlı teknikler, aktif kontürler ve watershed bölütleme gibi diğer yöntemler sayılabilir [25]. Akciğer bölütlemesi ve hava yollarının bölütlenmesinde kullanılan yöntemler şöyledir;

- Akciğer bölütlemesi

Akciğer bölütlemesi çoğu akciğer analiz yöntemlerinde ilk adım olarak gerçekleştirilir. Burada amaç akciğer dokusunun piksellerini çevresindeki anatomik

yapıların piksellerinden ayırıştırılmaktadır. Akciğer çevresinde kaburgalar, karaciğer ve göğüs gibi anatomik yapılar yer alır. Akciğer tomografisinde bölütleme uygulanan anatomik kısımlar akciğerin kendisi, hava yolları, damarlar ve loblardır. Atardamarlar, bronşlar gibi yapıların çevre dokulara yakın gri seviyelerine sahip olması bölütlemeye bir problemdir. Bu nedenle renge dayalı bir ayırım tek başına yeterli olmamaktadır. Her akciğer atardamar ve toplardamar ağaçları içerir. Kontras sıvısını kullanımı damar bölütlemesini kolaylaştırır.

Stokastik görüntüleme modelleri fiziksel dünya ve görüntüleme işlemiyle ilgili genel kabulleri ve doğal kısıtlamaları nicel olarak belirlemede kullanışlıdır. Rastgele alan (random field) modelleri uzamsal içeriğin piksel etiketlemeye dönüştürülmesine izin verir. Bu modeller BT üzerinden akciğer bölütlemesinde kullanılabilir [53].

CAD sisteminin ön işleme adımı olarak bölütlemenin hassasiyetle yapılması önemlidir. Kullanılan bölütleme algoritması yapılan işleme özel olarak seçilmelidir. Armato ve Sensakovic [56] tarafından yapılan bir çalışmada nodül tespitinde ön işleme adımı olarak yapılan bölütleme sonrasında test verileri içinden nodüllerin %5-17 oranında kaybolduğu görülmüştür. Esas olarak akciğer, vücut içinde bir hava torbasına benzer. Bu nedenle BT kesitlerinde karanlık bölge olarak görülür. Akciğerin ve çevre dokularla oluşturduğu bu renk farklılığı birçok bölütleme yönteminin temelini şekillendirir. Analiz için geliştirilen çalışmalarda iki boyutlu işlemeden üç boyutlu doğru bir artış gözlemlenmektedir.

Kullanılan bölütleme yöntemlerinin bir çoğu kural tabanlıdır. Akciğer bölgesini bulmada genel olarak iki yöntem kullanılır;

- Birinci yöntemde gri düzeyli eşikleme ve bileşen analizi yapılır. Ardından boyut ve yer kısıtlamaları ile akciğerler belirlenir.
- Diğer yöntemde soluk borusundan bölge-büyütme (region growing) yöntemiyle akciğerler bulunur. Soluk borusu iki boyutlu ilk kesitlerde hava dolu dairesel bölgeleri arayarak veya üç boyutlu kesitlerin üst yarısının merkezinde bulunan hava dolu boru şekli aranarak bulunabilir.

Akciğer ve hava yolları bir bütün olarak tanımlandıktan sonra sağ ve sol akciğer ayrılır, soluk borusu ve bronş yolları çıkartılır. İçinde boşluklar olmayan, yumuşak sınırları olan akciğer bölgesini elde etmek için morfolojik işlem uygulanır.

Akciğer embolisi tespitinde genel olarak aşağıdaki iki yol kullanılmıştır;

1. Damarların içindeki HU değerlerinden yararlanarak pıhtıları doğrudan belirlemek
2. Sıvının damarların içindeki yayılımında normal olmayan bölgeler tespit edilerek dolaylı şekilde belirlemek.

Tespitte ince kesitlerden tarama yapılması tercih edilmektedir. Doğrudan belirleme yöntemini uygulayarak CAD geliştiren çok az çalışma bulunmaktadır.

Akciğer bölütlemesinde aşağıdaki sorunlarla karşılaşmaktadır;

1. Ana bronş ve damarların akciğere girdiği yerlerde hangi noktaların kesileceği genellikle belirsiz kalır.
2. Sol ve sağ akciğer arasındaki ön ve arka bağlantı noktaları bölütlemeye özel bir dikkat gerektirir. Bu bağlantı noktaları çok dar ve kısmi hacim etkisi nedeniyle düşük kontrastlı olabilir. Bu duruma çözüm olarak sıkça başvurulan yöntem her bir kesitte tahmini bir arama bölgesi tanımlamak ve içinde dokuları ayıran bir bağlantı çizgisini belirlemektir. Bu çizgi önden arkaya doğru en kısa uzaklığı tanımlayarak veya gri değerlerle en düşük değer yolunu arayarak izlenen yumuşak doku ara yüzü ile bulunur.
3. Akciğer sınırına bağlı yüksek yoğunluklu sağlıklı dokular (patolojiler) bölütlemeyi etkilemektedir. Çünkü akciğer ve çevre dokuların arasında renk farklılığı olmadığı için kural tabanlı eşikleme yöntemleri akciğer ile çevre dokuları ayırtıramadığı için başarısız olmaktadır. Biçim modeli uygulayan istatistiksel yöntemler bu durumda daha başarılı olmaktadır.

Çalışmalarda geliştirilen algoritmalarından beklenen özellikler şöyle sıralanabilir;

- Algoritmaların patolojik ve anatomik çeşitliliğe, görüntüdeki gürültü ve çekim sırasındaki parametrik ayarların farklılığına karşı daha az duyarlı olmaları yararlı olacaktır.
- Test verileri patolojik çeşitliliği, değişik gürültü seviyelerini, çekimden kaynaklanan farklılıkları içermelidir.
- Algoritmalar performans açısından da sınanmalıdır.
- Başarısız durumların tespiti (failure detection) otomatik sistemlerde önemli bir adım olmasına rağmen akademik araştırmalarda sıkça dikkate alınmamaktadır.

Akciğer embolisi tespiti bilgisayar destekli sistemlerin geliştirilebileceği bir alandır ve bu konuda umut verici çalışmalar yapılmaktadır. Bu alanda birkaç büyük şirket ürün geliştirmektedir ve prototiplerini incelemeye çıkartmışlardır. Ancak yayınlanan çalışma sayısı azdır. Akciğer embolisinin tespiti kadar ölçümlenebilmesi de önemlidir. Bu konuda da çalışmalar çok az sayıdadır.

Radyologlar genellikle analiz programları kullanmadıkları için yeni araçların pazara çıkması kolay değildir. Sadece tespit başarısının düşük olduğu konularda (akciğer kanseri tespiti, küçük nodül tespiti, nodül hacminin ölçülmesi gibi) analiz programları talep görebilir. Klinik uygulamada bir programın başarılı olabilmesi için;

- Kullanım ihtiyacı olması; yeterli sayıda radyolog tarafından klinik olarak gereksinim duyulması,
- Kullanımı kolay ve hızlı olması, artan kesit sayısına cevap verebilmesi,
- Güvenilir olması, çok sayıda vakada doğru sonucu vermesi,
- Algoritmanın başarısız olması durumunda kolayca düzeltilebilmesi,

Diğer bir araştırma konusu otomatik sistemlerde kullanıcı geribildirim alınması veya kullanıcı ile etkileşimli bölütleme araçlarının geliştirilmesidir. Ayrıca otomatik sistemin başarısızlığının hangi noktada oluştuğunun tespit edilebilmesi önemlidir.

Akciğer sorunlarının sınıflandırılması ve ölçülmesi açısından otomatik tespit sistemleri, klinik uygulama alanlarına göre şu beş grupta toplanabilir:

- Anfizem
- Akciğer kanseri
- Akciğer embolisi
- Havayolu bozuklukları
- Akciğer yayılma bozuklukları (diffuse lung disease)

Hava yollarının bölütlemesinde, akciğer bölütlemesinden farklı yöntemler kullanılır.

- Hava yollarının bölütlemesi

Hava yolları yarıçapı gittikçe azalan silindirik damarların oluşturduğu bir ağaç yapısı şeklindedir. Nefes borusu sağ ve sol ana bronkuslara dallanır. Dallanma 23 alt

seviyeye kadar uzanabilir. İçi hava dolu olan bronşiyal damarlar göreceli olarak yüksek BT değerine sahip duvarla çevrilidir. Normal bir BT’de damarlar 7. seviyeye kadar gözle takip edilebilir. Bundan sonrasında kısmi hacim etkisi çok arttığından bronşiyal damarlar ve duvarları ayırt edilemez bir kütle halinde görünür.

Hava yolu ağaç yapısını bölütlemek için geliştirilen teknikler 4 ana grupta toplanabilir;

1. Bilgi tabanlı bölütleme
2. Bölge büyütme/dalga yayılımı (wave propagation)
3. Merkez çizginin çıkartılması
4. Matematiksel morfoloji

Çoğu çalışma bu yöntemlerin birkaçını bir arada kullanmaktadır.


Bölge büyütme/dalga yayılımı (wave propagation) yöntemlerine bir örnek ani artış kontrollü (explosion controlled) bölge büyütmedir. Ani artış kontrolü bir adımda yayılan toplam voksel sayısı çok fazla artış gösterene kadar artan eşik değeri ile çalışan iteratif bir bölge büyütme işlemidir. Matematiksel morfoloji yöntemleri hava yolunun parçası olabilecek bölgeleri tanımlamaya odaklanır. Örneğin gri düzeyli vadileri bulmak için artan kernel boyutuyla gri düzeyli kapamalar yapılabilir [57].

1.9.1. Kenar tabanlı yöntemler


Sınır tabanlı yöntemler (boundary based methods) pikseller arası farklılığı bulmaya dayalı yöntemlerdir. Amaç iç kısım (nesne veya ön plan) ve dış kısım (arka fon) olarak tanımlanabilecek kapalı sınırları tespit etmektir. Sınır tabanlı yöntemlerde görüntünün birinci ve ikinci seviye gradyen bilgisini elde etmek için uzamsal filtreler kullanılır. Sınır tabanlı bölütlemelerde kullanılan çeşitli gradyen operatörlerden bazıları Roberts, Sobel, Laplacian, Canny’dir. Kenarlar belirlendikten sonra kapalı bölgeleri ortaya çıkartmak için kenar bağlantı algoritmaları çalıştırılır. Görüntünün gradyen bilgisi ilişkili kenarları takip etmek ve bağlantı kurmak için kullanılabilir. Bu aşamada gürültü ve bozukluklar ile ilgilenmek gerekir [54].

1.9.1.1. Kenar belirleme ve bağlantı kurmak

Görüntü içindeki kenarlar Sobel operatörü gibi gradyan operatörler kullanılarak ve görüntünün gradyan değerlerini eşikleyerek belirlenir. Belirgin kenarlar kesintisiz görülürken zayıf olanlar kırık çizgiler halinde görünür (Şekil 1.29). Gürültülü görüntüler Şekil 1.30'da görüldüğü gibi aslında olmayan kenarların ortaya çıkmasına neden olur. Gürültülü görüntüler yumuşatılarak yanlış kenarlar azaltılır ancak bu durumda Şekil 1.31'deki gibi zayıf kenarlar tamamen ortadan kaybolur ve diğer kenarlar genişler. Gürültülü retinal damar görüntüsünün Butterworth filtresi ile düzleştirildikten sonraki hali Şekil 1.31 (a)'da yer almaktadır.




Şekil 1.29. (a) Retinal damar (b) Sobel işlemi sonrası, (c) eşikleme sonrası



Şekil 1.30. (a) Gürültülü görüntü, (b) Sobel işlemi sonrası, (c) eşikleme sonrası


Kenar tespiti yapıp kenarlar arasında bağlantı kurarak (edge detection and linking) sınırları ortaya çıkartmak gerekir. Bitişik kenar piksellerinin benzer nitelikleri (gradyan büyüklüğü gibi) varsa birbirine bağlanması gerekir. Bağlantı kurulmasından sonra sınırlar ortaya çıkar. Kenar arasında bağlantı işlemi genellikle sonradan içleri doldurulacak küçük boşluklarla arası açılmış piksel kümelerini bulmak için ilave bir işlemle devam eder.



Şekil 1.31. (a) Filtreli görüntü (b) Sobel işleminin sonrası (c) eşikleme sonrası

1.9.1.2. Sınır izleme

Sınır izleme (boundary tracking) sadece sınır bilgisi içeren herhangi bir görüntüye veya gradyan görüntülere uygulanabilir. Sınır üzerinde tek bir nokta tanımlandıktan sonra, en yüksek gri seviyenin yerini belirleyip sınırı takip ederek analiz yapılır. Tek bir uygulamada, en yüksek gri seviye piksellerinin araştırılması her iki taraftan bir pikselin türevi alınarak önceki adımda olduğu gibi tek yönde gerçekleşir. Şekil 1.32’de görüldüğü gibi birinci adımda yanındaki pikseli bulmak için 8 komşu taranır ve ikinci adımda her iki taraftan bir pikselin türevi alınarak aynı yönde aramaya devam edilir.



Şekil 1.32. Sınır izleme yöntemi


Bu basit yöntem yüksek gürültüde ve ani yön değişikliklerinde başarısız olur. Önce gürültünün alçak geçiren filtre ile temizlenmesi gerekebilir. Kan damarı gibi ince ve uzun bir nesnenin her iki tarafının izlenmesi işleminde her adımda sürekli olarak diğer sınırın kontrol edilmesi gerekir. Nesnenin dallanması veya başka nesnelere

tarafından kesilmesi durumunda izleme zorlaşır. Sınır izleme yüzeylerde karmaşıktır [25].

1.9.1.3. Hough dönüşümü

Hough dönüşümü, sayısal görüntülerdeki düz çizgileri, çember, elips gibi kıvrımlı çizgileri tespit için sıkça kullanılan bir görüntü analiz algoritmasıdır. Ayrıca nesnenin parametreleri biliniyorsa rastgele biçimli nesnelerin sınırlarını belirlemede kullanılır. Elbette bunların hepsi için ayrı parametreler ve denklemler geliştirilmiştir. Temel olarak görüntü uzayında (uzamsal domain) temsil edilen düz çizgi, çember veya kapalı şekil gibi bir analitik fonksiyon parametre uzayında da temsil edilir. Örneğin düz çizginin genel denklemi $y=mx+c$ olarak ifade edilir. Burada m eğim, c ise y -kesişimidir. Noktanın yeri eğim ve y -kesişimi parametreleri ile temsil edilir. Yani görüntü uzayındaki bir çizgi parametre uzayında (m,c) noktası olarak yer alır. Bunun gibi görüntü uzayındaki bir nokta parametre uzayında bir çizgi olarak biçimlenir. Görüntü uzayında bir çizgi oluşturan noktaların yeri parametre uzayında, kesişimi görüntü uzayındaki çizginin parametrelerini veren bir çizgi kümesi oluşturur. Eğer gradyen görüntü kenar piksellerini elde edecek şekilde eşiklenirse, her kenar pikseli parametre uzayında eşleşebilir. Eşleşme parametre uzayındaki nokta kutuları kullanılarak yapılabilir. Görüntü uzayındaki düz çizgilerin her bir kenar pikseline parametre uzayında karşılık gelen kutu güncellenir. En sonunda içinde en fazla sayı olan kutu, görüntü içinde tespit edilen düz çizginin parametrelerini temsil eder. Belirli bir eğrinin sınırlarının belirlenmesi ve eşleştirilmesi için bu yöntem kullanılabilir.

Hough dönüşümü ile nesnelerin sınırlarının belirlenmesi için nesnenin parametre modelinin oluşturulması gerekir. Nesne modeli R-tablosu adı verilen bir tabloya dönüştürülür. R-tablosu vektör listesini içeren tek boyutlu bir dizi olarak düşünülebilir. Model tanımındaki her nokta için gradyen değeri ve buna karşılık gelen sınır noktasından merkeze uzayan vektör hesaplanır. Gradyen R-tablosu içinde bir index görevi alır [54].



Şekil 1.33. xy düzlemi ve parametre uzayı [58]

Aslında doğrusal olan veya olmayan doğruların tespiti işleminde, sayısal görüntünün üzerinde gezdirilecek bir operatör de piksel komşuluklarına bakarak bu işlemi gerçekleştirebilmektedir. Fakat n tane noktadan yola çıkılarak bu işlemin gerçekleştirilmesi için, n^2 adet işlem gerçekleştirilmesi gerekmektedir. Ayrıca bu işlemin görüntüdeki obje yakalama verimliliği de tartışmaya açık bir konudur. Hough dönüşümündeyse, görüntüden yakalanmak istenen objenin özelliklerine bağlı olarak oluşturulan parametreler sayesinde çok daha az işlem yaparak, aynı işi gerçekleştirmek mümkündür. Üstelik bu yöntem, obje kenarlarını yakalama konusunda çok daha duyarlı ve istenmeyen objeleri hiçbir şekilde sonuç ekranına yansıtmayan bir algoritmadır [58].

1.9.2. Piksel tabanlı doğrudan sınıflandırma yöntemleri

Görüntünün piksel piksel sınıflandırılması için tekli veya çoklu eşik tanımlanmasında histogram istatistikleri kullanılır. Pikselleri sınıflamada kullanılan eşik değeri görüntünün histogram analizinden elde edilir.

Gri seviyeli görüntülerin iki tepeli (bimodal) histogramlarda vadinin taban noktasına karşılık gelen nokta eşik değeri olarak atanabilir. Diğer durumlar için görüntü özelliklerini kullanarak yapılan deneysel yöntemlerle (heuristic) görüntü birden çok bölgeye bölünür. Her bölgenin histogramı eşikleri belirlemek için kullanılabilir. Seçilen eşik değeri ile her pikselin gri seviyesi karşılaştırılarak pikseller iki sınıftan birine atanır [54].

1.9.2.1. Eşikleme

Yoğunluk/parlaklığa göre eşikleme, katı nesnelere içeren görüntüler için basit bir tekniktir. Her piksel eşik değeri ile karşılaştırılır, eğer değeri yüksek ise piksel ön plan olarak değerlendirilir ve rengi beyaz yapılır. Eğer düşük veya eşit ise piksel arka fon olarak değerlendirilir ve rengi siyah yapılır. Eşiklemenin başarısı eşik değerinin seçimine bağlıdır. İdeal durumda, gri seviyeli histogram, ön plan nesnelere ve arka fonu temsil eden ve çakışmayan iki farklı dağılım içerir. Eşik değeri bu iki dağılım arasındaki vadiden seçilir.

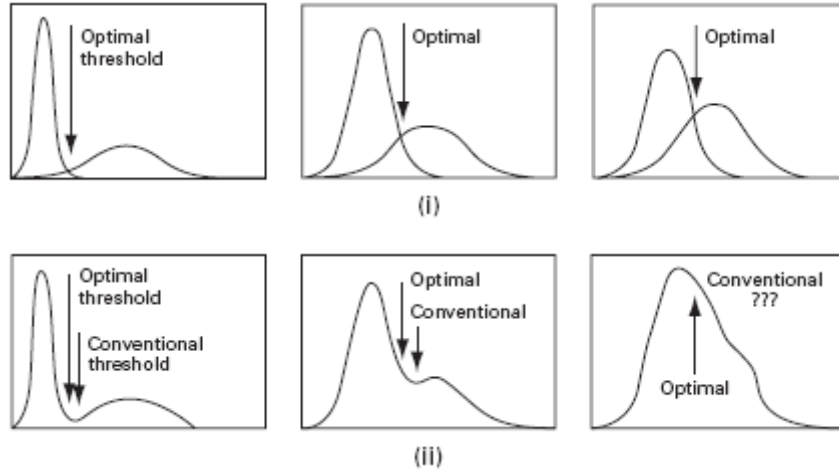
Eşikleme değerinin seçimini zorlaştıran bazı durumlar vardır; Düşük görüntü kontrastlığı ön ve arka planın ayrıştırılmasını zorlaştırır. Arka planın değişik yoğunluklarda olması bütün görüntü için kullanılacak tek bir eşik seçimini imkansızlaştırabilir. Düşük uzamsal çözünürlük, değişik parlaklık seviyelerindeki nesnelere ayrı bir zorluk nedenidir. Eşik değeri genellikle görüntüye özel ve deneyimle seçilir [25].

a) Optimal eşikleme

Gri seviyeli histogramda tepe noktalarının arasındaki vadinin tabanı optimal eşik değildir. Optimal eşikleme görüntünün histogramı iki veya daha fazla olasılık yoğunluklarının ağırlıklı toplamı olarak ele alınır. Bu şekilde sınıflandırılmamış en düşük sayıda pikselden alınan gri seviye eşik değeri olarak atanır. Bu seviye iki normal dağılımı kesişim noktasına karşılık gelir. Şekil 1.34 (i)'de iki normal dağılımın kesişimi optimal eşiği, (ii)'de optimal ve geleneksel histogramın sonuçları yer almaktadır.

Gürültü piksellerinin yanlış sınıflandırılmasına neden olabileceği için eşikleme öncesi ortalama veya median filtreleme yapılır.

Optimal eşikleme için kullanılacak birçok yöntem bulunur. Genel yaklaşımda pikseller arka fon ve ön plan pikselleri olarak iki sınıf veya kümeye ait düşünülür. Amaç bir eşik değeri seçerek, eşik değerinin her iki tarafındaki her bir pikselin kendi tarafındaki piksel ortalama değerine yakın olmasını sağlamaktır.



Şekil 1.34. Optimal eşikleme

Optimal eşikleme için kullanılabilecek yöntemler:

- Otsu yöntemi: görüntünün gri seviyeli histogramını olasılık dağılımı olarak ele alınır.
- Maksimum entropi eşikleme: sınıflar arasında entropi (belirsizlik ölçüsü) yüksek tutularak Otsu yöntemine benzer yöntem kullanılır.
- Isodata (iterative self-organizing data analysis technique algorithm) : kmeas kümeleme algoritmasına benzer yöntem iki küme için uygulanıyor. Her iki tepe noktasının piksel ortalamasının ortalaması ile görüntü eşiklenir. Eşiğin altı ve üstü için alınan ortalama ile yeni eşik belirlenir ve aynı işleme devam edilir.
- Çoklu eşikleme ve sınıflama : Birden çok sınıfın olduğu ve birden çok eşik değerinin istendiği durumlarda kullanılır. Genellikle aynı sahneye ait birden çok görüntünün olduğu durumlarda başvurulur. Parlaklık, desen ve gradyen gibi çoklu özellikler kullanılabilir. Ortaya çıkan sınıflar renklerle ayrıştırılabilir. Gelişmiş Otsu yöntemi burada uygulanabilir [25].

b) Optimal global eşikleme

Görüntü bölütleme için optimal global gri değer eşiğini belirlemek için parametrik dağılım yöntemleri görüntünün histogramına uygulanabilir. Bölütlenecek görüntünün histogramı nesne ve arka plan gibi iki sınıfa ait Gauss dağılımı içerdiğini varsayalım. Histogram olasılık yoğunluk fonksiyonu $p(z)$ ile şöyle gösterilebilir:

$$p(z)=P_1p_1(z)+P_2p_2(z) \quad (1.15)$$

$p_1(z)$ ve $p_2(z)$ Gauss dağılımının 1. ve 2. sınıflarıdır. Sınıf olasılıkları P_1 ve P_2 için aşağıdaki denklik mevcuttur;

$$P_1 + P_2 = 1 \quad (1.16)$$

Gri değer eşiği T kullanılarak ile görüntü içindeki $f(x,y)$ pikseli, bölütlenmiş $g(x,y)$ görüntüsü içinde şöyle sınıflandırılır;

$$g(x,y) = \begin{cases} \text{Class1} & \text{if } f(x,y) > T \\ \text{Class2} & \text{if } f(x,y) \leq T \end{cases} \quad (1.17)$$

Bir pikselin yanlış sınıflandırılması durumundaki hata olasılığı;

$$E_1(T) = \int_{-\infty}^T p_2(z) dz \quad (1.18)$$

$$E_2(T) = \int_{-\infty}^T p_1(z) dz \quad (1.19)$$

$E_1(T)$ ve $E_2(T)$ sırasıyla birinci sınıfın bir pikselini ikinci sınıfa ve ikinci sınıfın bir pikselini birinci sınıfa hatalı şekilde atama olasılıklarıdır. T eşik değerini kullanarak piksel sınıflandırmada oluşabilecek tüm hata olasılığı şöyle ifade edilir;

$$E(T) = P_2(T)E_1(T) + P_1(T)E_2(T) \quad (1.20)$$

Görüntü bölütleme için amaç piksel sınıflandırmada tüm hata olasılığını en aza indiren optimal eşik değerini (T) bulmaktır. Optimizasyon işlemi olasılık yoğunluk dağılımını ve sınıf benzerliğini parametrik hale getirmeyi gerektirir. Bu parametreler bir modelden veya bir grup görüntü üzerinden belirlenebilir.

Optimal global eşikleme (T) değerinin belirlenmesinde şu yol izlenebilir;

i sınıfları için Gauss olasılık yoğunluk fonksiyonunun standart sapması σ_i , ortalaması μ_i ise olasılık yoğunluk fonksiyonu şöyle hesaplanır;

$$p(z) = \frac{P_1}{\sqrt{2\pi}\sigma_1} e^{-(z-\mu_1)^2/2\sigma_1^2} + \frac{P_2}{\sqrt{2\pi}\sigma_2} e^{-(z-\mu_2)^2/2\sigma_2^2} \quad (1.21)$$

$$A = \sigma_1^2 - \sigma_2^2 \quad (1.22)$$

$$B=2(\mu_1\sigma_2^2-\mu_2\sigma_1^2) \quad (1.23)$$

$$C=\sigma_1^2\mu_2^2-\sigma_2^2\mu_1^2+2\sigma_1^2\sigma_2^2 \ln(\sigma_2P_1/\sigma_1P_2) \quad (1.24)$$

$AT^2 + BT + C = 0$ denklemini sağlayan ve olasılık yoğunluk fonksiyondaki karışık dağılım ile tüm hata olasılığı $E(T)$ değerini en aza indiren genel bir çözüm bularak belirlenebilir.

Her iki sınıfın da değişimle değerleri σ^2 değerine eşit kabul edilebilirse optimal eşik değeri (T) şöyle belirlenebilir;

$$T = \frac{\mu_1 + \mu_2}{2} + \frac{\sigma^2}{\mu_1 - \mu_2} \ln\left(\frac{P_2}{P_1}\right) \quad (1.25)$$

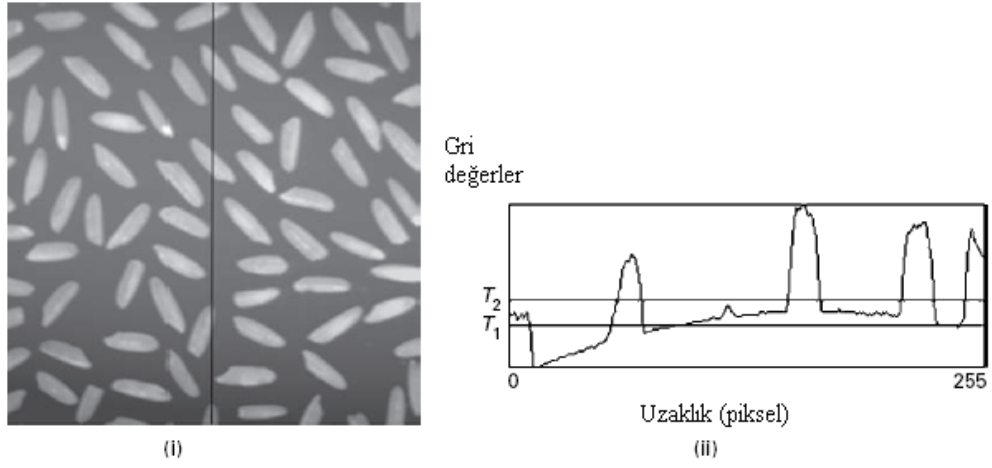
Sınıfların eşit olması durumunda bu optimal eşik değeri formülü iki sınıfın ortalama değerlerinin ortalamasını verir [25].

c) Uyarlanabilir eşikleme


Tek bir eşik değeriyle görüntünün bölütlenmesi mümkün olmayabilir. Örneğin arka fonun değişik yoğunluk değerleri içermesi durumunda sabit eşik değerleri işe yaramaz Şekil 1.35 (i)'de yer alan görüntü arka fonu değişik yoğunluk değerleri içermektedir. Görüntüye uygulanabilecek T1 ve T2 eşik değerleri, (ii)'deki gibi arka fon ve ön planın ayırt edilmesini sağlamıyor.

Bu soruna çözüm için kullanılacak bir yöntem eldeki görüntü bulanıklaştırma ile elde edilen veya ayrıca elde edilen arka fon görüntüsünden çıkartılır (veya bölünür) veya morfolojik eşikleme yapılır. Bu yönetime alternatif olarak uyarlanabilir eşikleme (adaptive thresholding) kullanılabilir.

Uyarlanabilir eşikleme yönteminde görüntünün bütün piksellerine tek bir eşik değeri uygulamak yerine dinamik olarak değişen eşik değeri uygulanır. Yerel uyarlanabilir eşiklemede her pikselin $n \times n$ komşusu olduğu varsayılır, eşik değeri bu komşuların ortalaması veya medyanı ile hesaplanır. Piksel değeri, hesaplanan eşik değerinin altında veya üstünde olmasına göre siyah veya beyaz yapılır.



Şekil 1.35. Uyarlanabilir eşikleme



Şekil 1.36. Yerel uyarlanabilir eşikleme

Komşuluk sayısı n hem arka fon hem de ön plan piksellerini kapsayacak büyüklükte olmalıdır. Bu yöntem hesaplanan eşik değerinden bir C sabitinin çıkartılmasıyla daha başarılı hale gelmektedir.

$$T = \{\text{ortalama veya medyan}\} - C. \quad (1.26)$$

Bu yöntem n ve C 'nin denemelerle belirlenmesini gerektirdiğinden tam otomatik değildir [25]. Şekil 1.36 (i)'daki orijinal görüntünün histogramı (ii)'de ve yerel uyarlanabilir eşikleme ile ($n=45$, $C=3$) bölütlenmiş görüntü (iii)'de yer almaktadır.

1.9.2.2. Kümeleme aracılığı ile piksel sınıflandırma

Görüntüler ilgilenilen özellikler kümelenecek piksel sınıflandırması ile bölütlenebilir. Küme sayısı sınıf sayısını belirtir. Küme sınıflarına ayrılma işleminde aynı sınıf etiketi ile komşu pikseller taranarak bölütlenmiş bölgeler elde edilir. Ancak kümelemede tek pikseli bölgeler veya deliklerle kopuk görünen bölgeler oluşabilir. Görüntü verisi kümelendikten ve piksel sınıflandırması yapıldıktan sonra bölge büyütme, piksel bağlantılılığı veya kural tabanlı algoritmalar gibi algoritmalarla bölge bölütlemesi tamamlanır [25].

a) K-Means Algoritması

En iyi bilinen ve yaygın kullanılan algoritmalarından biri olan k-means, verileri sınıflandıran bir kümeleme algoritmasıdır. Verilen nesnelere nitelik veya özelliklerine göre k adet sınıfa ayırmak amacıyla kullanılır. Sınıflandırma, verilerin en yakın veya benzer oldukları küme merkezleri (centroid) etrafına yerleştirilmesi ile gerçekleştirilir.

Bu çalışmada kullanılan k-means algoritması, J. MacQueen [59] tarafından 1967 yılında tanıtılmıştır. Çalışma yönteminde, Öklit uzaklığı temel alınarak kümeleme yapılmaktadır. Bu yöntem yıllardır bilimsel ve endüstriyel uygulamalarda en yoğun kullanılan kümeleme algoritması haline gelmiştir.

Algoritmaya k-means adı verilmesinin nedeni, algoritmanın çalışmasından önce sabit bir küme sayısına ihtiyaç duyulmasıdır. Küme sayısı k ile gösterilir ve elemanlarının birbirlerine olan yakınlıklarına göre oluşacak grup sayısını ifade eder. Buna göre k önceden bilinen ve kümeleme işlemi bitene kadar değeri değişmeyen sabit bir pozitif tamsayıdır.


Çok yaygın kullanımı olan bu algoritmanın aşağıda belirtildiği gibi birtakım zayıf yanları da bulunmaktadır:

- Algoritmanın başında giriş parametresi olarak bir k sayısına ihtiyacı vardır. Elde edilecek olan sonuçlar k sayısına göre değişkenlik gösterebilir. Eğer küme sayısı belirli değil ise deneme yoluyla en uygun sayı bulunur.
- Aşırı gürültü ve istisna veriler algoritmayla hesaplanan ortalamayı değiştirdiği için k-means algoritması gürültü ve istisnaya karşı çok duyarlıdır. Algoritma uygulanmadan önce veriler gürültü veya istisnadan temizlenebilir.
- Çakışan kümelerde iyi sonuç vermez.
- Her eleman aynı anda verilen bir kümenin içindedir veya dışındadır.
- K-means algoritması sadece sayısal veriler ile kullanılabilir. Kategorik verilerin kümelenebilmesi için k-means algoritması bir çözüm sunmaz .

Açıklamada kolaylık olması açısından, bu bölümde algoritma iki boyutlu diyagramlar kullanılarak örneklenmiştir. Ancak uygulamada çok boyutlu elemanlarla, diğer bir deyişle çok eleman vektörü ile çalışılabilmektedir. Boyut sayısının artması algoritmada değişiklik yapılmasına neden olmamaktadır [60].

K-means algoritmasının pek çok çeşidi bulunmaktadır. Bir çok ticari yazılım paketi kümeleme işleminde bu algoritmanın çeşitlerini kullanmaktadır. Başlangıç küme merkezlerinin seçim şekli, kayıtları kümelerle ilişkilendirirken uzaklık yerine olasılık yoğunluğunun kullanılması gibi yaklaşımlar bu çeşitliliği oluşturmaktadır [60].

K-means algoritmasının çalışma şekline bir örnek Şekil 1.37'de görülmektedir. Bu örnekte $k = 3$ olarak seçilmiş ve beyaz $\diamond \blacktriangle \blacksquare$ simgeleri Şekil 1.37 (a)'da rastgele seçilen küme merkezlerini temsil etmektedir. Şekil 1.37 (b)'de geri kalan noktalar ($\blacklozenge \blacktriangle \blacksquare$) aynı şekilli ve beyaz renk olan küme merkezlerine dahil edilerek ilk kümeler oluşturulur. Bu işlem sonunda küme merkezleri her kümedeki elemanların ortalaması dikkate alınarak tekrar hesaplanır. Değişen küme merkezleri Şekil 1.37 (b)'de oklar ile gösterilmiştir. Şekil 1.37 (c)'de aynı işlem tekrar edildiğinde küme merkezlerinin değişimi görülmektedir. Bu şekilde başlangıç durumunda rastgele seçilen küme merkezleri, sürekli yinelemeler ile gerçek kümeleme alanlarının ortasına doğru yaklaşır. Bu işleme merkeze yakınsama (convergence) denir. Merkeze yakınsama minimum seviyeye geldiğinde veya durduğunda kümeleme işlemi sona erer.



Şekil 1.37. K-means kümeleme algoritması (a) ilk küme merkezleri, (b) ilk ortalama hesabı, (c) merkeze yansımaya [61]

1) K-means algoritmasının adımları

Algoritmanın ilk adımında öncelikle küme merkezlerini veya diğer bir deyişle küme ortalamasını temsil edecek k adet eleman belirlenir. MacQueen algoritmasında küme merkezleri ilk k adet elemandan seçilir. Ancak elemanların değerleri birbirine çok yakın ise, seçim rastgele yapılır veya birbirinden uzak elemanlar seçilir. Bu noktaların her biri prototip olarak adlandırılır. Belirlenen bu elemanlar tek elemanlı başlangıç kümeleridir ve ilk küme merkezlerini oluştururlar. Kümenin ağırlıklı ortalama değerine sahip olan ya da bu değere en yakın olan elemanı küme merkezi olarak adlandırılır.

İkinci adımda, okunan elemanlar kendilerine en yakın k adet küme merkezinden birine dahil edilir. Elemanların küme merkezine olan yakınlık derecesini bulmak amacıyla çeşitli geometrik yöntemler kullanılır. Bunlardan bir tanesi, kümeler arasındaki sınırları belirleyerek, elemanların hangi küme merkezine daha yakın olduklarını tespit eder. Bunun için önce iki küme merkezi bir doğruyla birleştirilir. Bu doğrunun orta noktasından geçen ve doğruyu dik kesen başka bir doğru daha geçirildiğinde, bu doğru iki kümenin sınırı olarak kabul edilir. Bulunan sınır çizgisi dikkate alınarak, elemanların hangi kümeye dahil edileceği ortaya çıkar.

Noktalar arası uzaklığın hesaplanmasında en çok kullanılan yöntem Öklit bağıntısıdır. İki boyutlu bilgilerde, iki küme merkezinin birleştirilmesinde doğru kullanılırken, boyut sayısı arttığında doğru yerine düzlem kullanılır. Çok boyutlu bilgilerde çok boyutlu düzlemler kullanılır. Algoritmanın geometrik gösteriminde küme sınırları yukarıda anlatıldığı şekilde belirlenmektedir. Bilgisayar programları

ile geliştirilen k-means algoritmalarında ise, düzlemler yerine noktalar arasındaki uzaklıklar hesaplanarak, noktaların merkeze yakınlığı dikkate alınmaktadır [60]. Algoritmanın akış diyagramı Şekil 1.38’de görülmektedir.



Şekil 1.38. K-means algoritmasının adımları

Üçüncü adımda her bir kümeye eklenen yeni eleman ile, küme elemanlarının ağırlıklı ortalaması tekrar hesaplanarak yeni bir küme merkezi bulunur. Ağırlıklı ortalama kümenin her bir boyutundaki bütün elemanların ortalama değerlerinin alınması ile hesaplanır. Algoritmanın başında seçilen elemanlar küme merkezini oluştururken, ikinci döngü sonucunda bulunan yeni küme merkezleri artık bir küme elemanı değil, sadece bir ortalama değerdir. Bundan sonraki seçim işlemlerinde küme merkezini bu yeni eleman temsil eder. Her bir döngüde elemanlar farklı bir kümeye dahil edilebilirler.

Kümeleme işlemi, tüm elemanların tekrar aynı veya farklı bir kümeye dahil edilmesiyle devam eder. Elemanların bir kümeye dahil edilmesi ve küme


merkezlerinin tekrar hesaplanması işlemlerine ait döngü, küme sınırlarının değişimi bitene kadar devam eder. K-means algoritması ile uygulamalarda genellikle birkaç düzine döngü sonrası kararlı bir küme grubu ortaya çıkar.

K-means algoritması bilgisayar programına uygulanırken aşağıdaki adımlar izlenir:

1. Küme sayısı (k) okunur. Bu değer algoritmaya dışardan verilir.
2. k adet rastgele küme merkezi belirlenir. İlk k eleman merkez olabilir.
3. Elemanların merkezlere yakınlıkları hesaplanır
4. Elemanlar yakın oldukları merkezlere göre kümelenir
5. Kümelerin ortalamaları hesaplanarak yeni küme merkezleri belirlenir
6. Kümelenecek başka eleman var mı? Hayır ise(3) e git. Evet ise dur.

2) K sayısının kümelemeye etkisi

Kümeleme algoritmalarında, elemanların birbirlerine olan yakınlıklarına göre oluşturulan kümelerin sayısı k ile gösterilir. K işlem öncesinde bilinen ve kümeleme işlemi bitene kadar değeri değişmeyen sabit bir pozitif tamsayıdır. Şekil 1.39'da bir deste oyun kağıdının k=2 ve k=4 için kümeleme sonuçları gösterilmektedir. Şekilden görüleceği gibi k'nın farklı değerler alması, her biri geçerli olan çok farklı kümeler oluşmasını sağlamaktadır. Hangisinin daha etkili olduğu, hangi kümelemenin kullanılacağına bağlıdır.

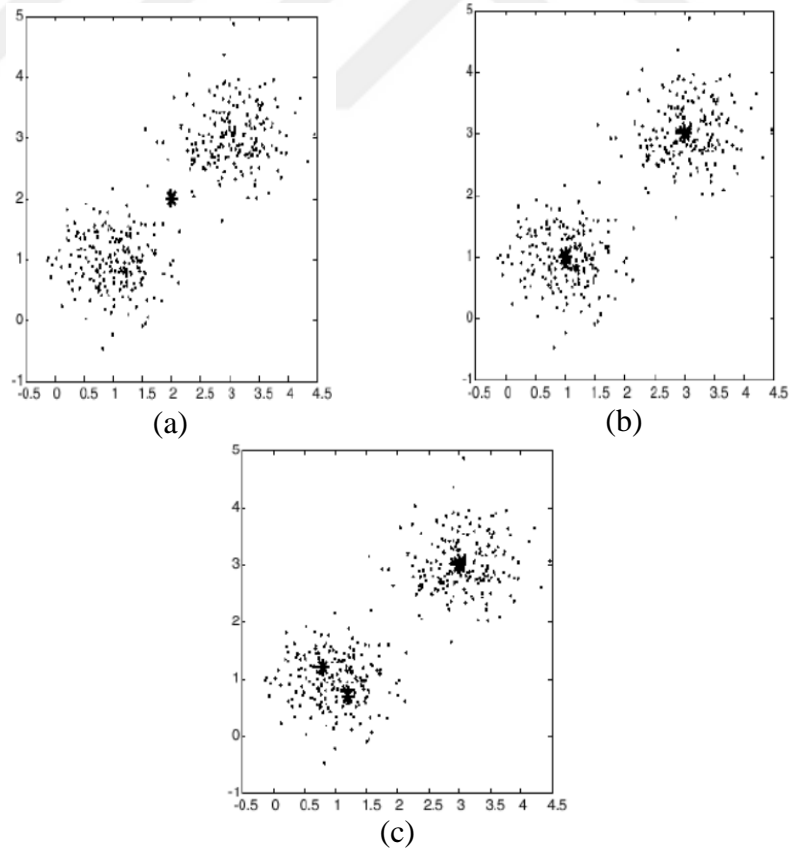


Şekil 1.39. Oyun kağıtlarının k=2 ve k=4 için kümelenmesi

K-means ve benzeri kümeleme algoritmaları k sayısının belirlenmesi konusunda bir çözüm sunmazlar. Ancak birçok durumda, özel bir k değerinin belirlenmesi gerekli olmaz. Analiz aşamasında k değerinin tespiti için ön çalışma yapılır. Tahmini bir

değer kullanılarak kümeleme algoritması çalıştırılır ve alınan sonuçlar değerlendirilir. Değerlendirme sonucunda beklenen kümeleme görülmez ise, başka bir k değeri kullanılarak tekrar kümeleme algoritması çalıştırılır veya veriler üzerinde değişiklik yapılabilir. Algoritmanın her çalıştırılması sonrasında, ortaya çıkan kümelerin etkinliğini hesaplamak için, küme içindeki kayıtların arasındaki ortalama uzaklık ile kümeler arası ortalama uzaklık karşılaştırılır. Hesaplama başka yöntemler de kullanılabilir. Bu yöntemler algoritmaya dahil edilebilir. Ancak ele alınan uygulama açısından sonucun yararlılığının belirlenmesi için kümeler mutlaka daha öznel temelde değerlendirilmelidir.

Aynı veri grubuna ait farklı k değerleri ile k-means algoritması uygulandığında ortaya çıkan sonuç Şekil 1.40'da yer almaktadır. Şekil 1.40 (a)'da k=1 için bütün elemanlar tek bir küme oluşturmuştur. Daha gerçekçi bir kümeleme, Şekil 1.40 (b)'de k=2 için ortaya çıkmıştır. Şekil 1.40 (c)'de k=3 için birbirine daha yakın elemanların yer aldığı grupta üçüncü bir küme oluşmuştur.



Şekil 1.40. Küme sayısına göre K-means algoritmasının sonuçları [62]

Bazı uygulamalarda k-means algoritmasının çalıştırılması sonucunda, verilerin büyük çoğunluğunun aynı kümeye dahil edildikleri görülür. Büyük kümenin çevresinde bir kaç küçük küme de yer alır. Bunun nedeni verilerin büyük çoğunluğunun birbirine yakın özellikler taşıması ve az sayıda verinin farklı özellikte olmasıdır. Bu tipteki uygulamalara örnek olarak, sahtekarlık tespiti ve üretim hataları verilebilir. Her iki uygulamada da önemli sayıda veri, istenen özellikleri taşımaktadır. Gürültü/istisna adı verilen az sayıda veri, istenilen özelliklerin dışında kaldıkları için büyük kümenin dışında konumlanmışlardır. Bu konuya ikinci bölümde, sıradışılık analizinde değinilmiştir.

K-means algoritması ile verileri kümelere ayırmak için geometrik veya aritmetik hesaplama yöntemleri kullanılmaktadır. Bu yöntemler aşağıda örneklerle tanıtılmıştır.

3) K-means kümeleme ile bölütleme

Veri kümeleme kullanarak yapılan görüntü bölütleme örneklerinden birinde hava fotoğraflarından aynı tür arazi örtüsünü içeren tarım bölgeleri kümelenebilir [63]. Kümeleme ile bölütleme yöntemi basit olmasına rağmen işlemsel yükü ağırdır.

Görüntüdeki her piksel koordinatının bir ölçü değerini içeren vektör $x = [x_1, x_2, \dots, x_N]$ olsun. Ölçü değerleri multispektral değerler veya renk bileşeni olabileceği gibi hareketli pencere ortalaması, standart sapma veya mod gibi komşuluk özellikleri de olabilir. Ölçü değerleri doğru seçildiğinde ortak niteliklere göre kümelenecek bir bölgenin içindeki çeşitli piksellerden toplanan veriler benzer olmalıdır. Böylece n boyutlu uzayda veriler iyi bir şekilde kümelenebilir olur. Bir pikselin ölçü vektörü bir ölçü uzay bölgesine düşerse, o piksele bölütlenen bölge isim veya etiketini atanır.

Gri seviyeli ve renkli görüntülerin bölütlenmesi için geliştirilen etkili bir kümeleme algoritması şu adımları içermektedir :

1. İlk aşamada özellikler hesaplanır, özellik vektör dizileri oluşturulur.
2. Kümeleme aşamasında optimum küme sayısı belirlenir, her kümenin özellik uzay merkezi bulunur.

Küme hesaplama algoritması önce iki küme merkezi atar. Görüntünün bütün özellik vektörleri en yakın küme merkezine atanır. Ardından küme merkezi sayısı bir artırılır. Küme sayısı bir artınca yeni küme merkezi en yakın olduğu küme merkezinden en uzak özellik vektörü haline gelir. Kümeleme kalite faktör parametresi (β) en yüksek değeri bulana kadar her iterasyonda hesaplanır [64].

$$\beta = \text{tr}\{S_w\} / \text{tr}\{S_B\} \quad (1.27)$$

$\text{tr}\{ \}$ matrisin izidir. Küme içi dağılım matrisi S_w şöyle hesaplanır:

$$S_w = \frac{1}{K} \sum_{k=1}^K \frac{1}{M_k} \sum_{x_i \in S_k} (x_i - u_k)(x_i - u_k)^T \quad (1.28)$$

Kümeler arası dağılım matrisi S_B şöyle hesaplanır:

$$S_B = \frac{1}{K} \sum_{k=1}^K (u_k - u_0)(u_k - u_0)^T \quad (1.29)$$

K küme sayısı, M_k k . kümenin vektör sayısı, x_i k . kümenin vektör elemanı,

u_k , k . kümenin ortalaması, S_k k . kümenin eleman kümesi, M kümelenecek piksel sayısı, u_0 bütün özellik vektörlerinin ortalamasıdır.

$$u_0 = \frac{1}{M} \sum_{i=1}^M x_i \quad (1.30)$$

b) Bulanık c-means kümeleme

Bir pikselin belirli bir bölgeye atandığı bölütlemelerde genellikle problemler ortaya çıkar. Bölge sınırlarında keskin geçişler olmaması nedeniyle birçok durumda bir pikselin belirli bir bölgeye ait olup olmadığının anlaşılması zordur. Böyle durumlarda bulanık küme algoritmalarıyla bölütleme yöntemlerine başvurulabilir. Bulanık mantık kullanılarak düzgün dağılmayan yoğunluklar tahmin edilir.

Bulanık bölütlemelerde bölgelerin içine bulunan her bir piksele bir üyelik değeri atanır. Eğer bölgelerin özellikleri hesaplanırken üyelikler dikkate alınırsa genellikle bölge özellikleriyle ilgili daha doğru tahminler elde edilir. Bulanık c-means algoritması (Fuzzy c-means-FCM) böyle bir sınıflandırma için bilinen bir tekniktir ve görüntü bölütlemeye başarıyla kullanılmaktadır. Her sınıf için tekrarlayan şekilde (iterative)

bulanık üyelik fonksiyonunu hesaplayan ve ortalama değeri tahmin ederek veriyi kümeleyen otomatik bir algoritmadır. Bulanık üyelik fonksiyonu 0 ve 1 arasında bir değer olarak belli noktadaki veri değeri ile prototip veri değeri (küme merkezi veya sınıf) arasındaki benzerlik derecesini gösterir. Yüksek üyelik değeri o noktadaki veri değerinin belirli bir sınıfın merkezine yakın olduğunu gösterir.

Bu teknik noktasal işlemler içerdiğinden bölgeler arası bağlantıları kapsamaz. Ayrıca gürültüye karşı oldukça duyarlıdır.

C-means kümeleme yöntemi şöyledir;

K-means yöntemi ile veri noktasının kümeye aitliğini ikili değerler (binary) kullanarak belirlenebilir. Bulanık c-means yöntemi uyarlanabilir üyelik değeri kullanır. Bu değer küme içindeki veri noktalarının dağılım istatistiği kullanılarak değiştirilebilir. Bu işlem aşağıdaki hedef fonksiyonu (objective function) minimize ederek yapılır.

$$J_m(U, v) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|x_j - v_i\|^2 \quad (1.31)$$

c küme sayısını, n veri vektörü sayısını, u_{ij} bulanık üyeliği, m bulanıklık indisini temsil etmektedir.

Dağılım istatistiğinde tanımlı kısıtlara göre bulanıklık indisi 1 ile en yüksek bulanıklık değeri (küme içinde izin verilen en yüksek değişim değeri) olarak verilebilecek çok büyük bir değer arasında tanımlanabilir. Bulanık c-means yönteminde üyelik değeri şöyle tanımlanabilir;

$$\text{Bütün } i \text{ ve } j \text{ değerleri için} \quad 0 \leq u_{ij} \leq 1$$

$$\text{Bütün } j \text{ değerleri için} \quad \sum_{i=1}^c u_{ij} = 1$$

$$\text{Bütün } i \text{ değerleri için} \quad 0 < \sum_{j=1}^n u_{ij} < n$$


K-means kümeleme için tanımlanan yöntem, bulanık üyelik değerlerini oluşturarak ve hedef fonksiyonu minimize ederek bulanık c-means kümeleme için kullanılabilir [53].

1.9.3. Bölge tabanlı yöntemler

Bölge tabanlı yöntemler (region based methods) piksellerin benzerliğine bakarak bağlantılı (connected) bölgelerin bulunmasına dayalı bir yöntemlerdir. Amaç mümkün olduğu kadar büyük bağlantılı bölgelerin oluşturulmasını sağlamaktır. Eğer birbirine çok yakın değerlerde pikseller seçilirse görüntü içinde istenmeyen ve gereksiz bölgeler elde edilir. Amaç bir kişinin gözüyle görülen nesnelerin bölge olarak seçilmesidir.

1.9.3.1. Bölge büyütme

Bölge büyütme (region growing) yöntemi aşağıdan yukarı işler. Algoritma bir başlangıç noktası (seed) pikselinin seçilmesiyle başlar, seçilen piksele benzeyen niteliklerde (parlaklık, desen, gradyan, geometrik özellikler gibi) komşu pikseller belirlenip bölgeye eklenir. Komşu piksellerin belirlenmesinde 4 veya 8 bağlantı şekli (connectivity) tanımlanır. Nitelik için değişim değeri tanımlanabilir. Değişim değeri içinde olmayan pikselle karşılaşınca bölge büyütme işlemi durur. Başlangıç noktası otomatik (tercihen) veya elle seçilebilir. Şekil 1.41’de tek noktadan bölge büyütme örneği görülmektedir. Şekil (i)’de başlangıç noktası orijinal görüntünün üst ortasında (ii) ve (v)’de başlangıç noktasından itibaren bölge büyütme adımları görülmektedir.



Şekil 1.41. Tek noktadan bölge büyütme örneği

Seçilen başlangıç noktasındaki bölge ilk olarak bölütlenir. Bu durumun birkaç istenmeyen etkisi bulunur: ilk seçilen bölge genişletme işlemi etkin olur ve köşe ve bitişik bölgelerdeki belirsizlik doğru bir şekilde giderilemeyebilir. Farklı başlangıç noktaları farklı bölütleme sonuçları ortaya çıkarabilir, eğer başlangıç

noktası bir kenarın üzerindeyse problemler oluşabilir. Bunları önlemenin bir yolu başlangıç noktalarını görüntü içinde rastgele dağıtmak ve birkaç başlangıç noktasından eş zamanlı olarak bölge büyütme işlemini gerçekleştirmektir. Genellikle farklı başlangıç noktasıyla oluşan benzer nitelikli bölgeleri birleştirmek için bir birleştirme işlemiyle devam edilir. Bölütme sonucu başlangıç noktasının yerine bağlı olarak değişir.

Bölge büyütme yöntemleri kenarların çok zor tespit edildiği gürültülü görüntülerde genellikle iyi sonuç verir. Çok tepeli (multi-modal) histogramlarda oldukça işe yarar [25].

1.9.3.2. Bölge parçalama yöntemi

Bölge parçalama (Region-Splitting) yöntemleri dağılım, ortalama, varyans, en küçük ve en büyük değerler açısından bütün bölgenin belirli özelliklere göre çeşitliliğini (heterojenliğini) inceler. Eğer bölgede benzerlik koşullarına uymayan, birbirinden farklı çeşitler bulunuyorsa orijinal bölge birden çok bölgeye ayrılabilir. Bölge parçalama işlemi bütün bölgelerin tek tek homojenlik koşulunu sağlamasıyla son bulur.

R bölgesi R_1, R_2, \dots, R_n alt bölgeye ayrılır. Aşağıdaki koşullar ayırma işlemi ifade etmektedir;

(1) Her bölge $R_i; i = 1, 2, \dots, n$

(2) $\bigcup_{i=1}^n R_i = R$

(3) $R_i \cap R_j = 0$ bütün değerler için $i, j; i \neq j$

(4) $H(R_i) = \text{DOĞRU}, i = 1, 2, \dots, n.$

(5) $H(R_i \cup R_j) = \text{YANLIŞ}, i \neq j,$

$H(R_i), R_i$ bölgesinin homojenlik koşulunun mantıksal doğruluğudur.

Bölge parçalama yöntemleri kural tabanlı sistemler veya dörtlü ağaç (quad tree) ile gerçekleştirilebilir. Dörtlü ağaç tabanlı bölge parçalama yönteminde görüntü ağacın

düğümüleri tarafından temsil edilen dört bölgeye ayrılır. Her bölgenin homojenliği kontrol edilir ve mantıksal doğruluğu hesaplanır. Eğer bölge homojen ise düğüm için işlem yapılmaz, değil ise bölge dört bölgeye ayrıştırılır [25].

1.9.4. Diğer yöntemler

Tıbbi görüntüleri anatomik ve patolojik açıdan anlamlı bölgelere ayırma işleminde yukarıdaki bölümlerde yazılanların dışında da değişik yöntemler uygulanmaktadır. Bunların bazıları aktif çevreler, Watershed algoritması, model tabanlı tahmin yöntemleri, kural tabanlı sistemler, sinir ağları tabanlı sınıflandırma, çok seviyeli uyarlanabilir bölütleme (multi level adaptive segmentation) yöntemleridir. Bu çalışmada aktif çevreler, Watershed algoritması incelenmiştir.

1.9.4.1. Aktif çevreler

Aktif Çevreler (Active Contours-Snake) yönteminde genellikle görüntü içinde düz ve sınırları arasında boşluk olmayan nesnelere aranır. Aktif çevre veya yılan sürekli bir çevredir, hedef nesnenin çevresinde elastik şekilde kıvrılır ve kendi üzerinde birleşerek nesneyi kapatır. Yılanın enerji adı verilen fonksiyon ile fiziksel sistemlere benzetilerek kontrol edilmesi mümkündür. Yılan enerjisini azaltmak için sürekli şekilde evrimleşerek aktif kalır. Uygun bir enerji fonksiyonu tanımlanarak düzlük gibi belirli özellikleri olacak şekilde evrimleşen bir yılan tanımlanabilir. Bu yöntem kolayca dinamik görüntü verisine ve üç boyutlu görüntü verisine uygulanabilir.

Bir yılan için enerji fonksiyonu iç ve dış enerjinin toplamından oluşur. İç enerji yılanın uzunluğu ve kıvrımlılığı gibi kendine özgü özelliklerden meydana gelir. Dış enerji ise görüntü yapısı ve belirli kısıtlamaları içerir.

Fiziksel benzetme genişletilebilir ve yılanın hareketi toplam enerjisini azaltacak şekilde etki oluşturacak şekle getirilebilir. Belirli özelliklerde bir yılan tasarlamak için uygun bir enerji fonksiyonu oluşturulup enerjinin azaltılması için gereken kuvvetler hesaplanır.

Eğer yılanın elastik bir bant gibi sallanabilmesi istenirse uzunluğu artıran bir iç enerji fonksiyonu tanımlanır. Kullanıcının tanımladığı eşit aralıklı kontrol noktaları yılanın başlangıç noktasını belirler. İç enerji fonksiyonu, esnekliği temsil etmek için bitişik

kontrol noktalarının arasındaki uzaklıkların karelerinin toplamı olarak alınır. Toplam salınım kuvvetine karşılık gelen ayarlanabilir K sabiti ile çarpılır. Kontrol noktasının (x_i, y_i) indeksi i ile ifade edilir.

$$E_{iç} = k \sum_{i=1}^N d_i^2 \quad (1.32)$$

Yılan bir döngü olduğu için 0 ile N aynı kontrol noktasına karşılık gelir. Kontrol noktası i'ye karşılık gelen kuvvetler enerji fonksiyonunun farkının alınmasıyla elde edilir.

$$F_i(x) = 2K((x_{i+1} - x_i) - (x_i - x_{i-1})) \quad (1.33)$$

$$F_i(y) = 2K((y_{i+1} - y_i) - (y_i - y_{i-1})) \quad (1.34)$$

Bu tür kuvvetler bir kontrol noktasını en yakın iki komşuya doğru çeker. Geometrik olarak kuvvet komşuların ortalama pozisyonlarına doğrudur. Her bir kontrol noktasına uygulanan bu tür kuvvetler yılanı içeri doğru çeker ve kontrol noktalarını art arda çizginin içine çekerek yılanı yumuşatır.

Kontrol noktalarını yılanının konumunu değiştirecek şekilde kuvvetleri ayarlayarak kullanabiliriz. Her kontrol noktasını üzerindeki kuvveti her adımda belirli bir oranda hareket ettirerek yılanın dinamiklerini gerçekleştirebiliriz. Güncellenen denklem şöyledir;

$$x_i + CF_i(x) \rightarrow x_i \quad (1.35)$$

$$y_i + CF_i(y) \rightarrow y_i \quad (1.36)$$


Verilen kuvvet için noktanın ne kadar uzağa gideceğini belirlemek için C sabiti kullanılır. Pratikte güncellemeden önce bütün noktalar için yeni koordinatlar hesaplanır. Aşağıdaki Şekil 1.42'de bu denkleme uyan bir yılan görülmektedir. Bu görüntü en dış çerçeveden başlayıp iç elastik fonksiyon ile hareket ederek yirmi iterasyon sonunda ortaya çıkmıştır. Elastik kuvvet yılanı düzgün ovale doğru büzerek çeker. En dış noktalar en çabuk çekilir. Birkaç nokta, büzülme onlara ulaşmadan önce komşularıyla çizginin içine çekildikleri için dışa doğru hareket eder. Birkaç

iterasyon sonrasında birbirinden eşit uzaklıkta olacak şekilde hareket eden kontrol noktalarının eğrileri görünür.

Aktif çevre/yılan yöntemi kullanıcının başlangıç çevreyi belirlemesini gerektirdiği için yarı otomatiktir. Başlangıç çevresi iyi seçildiğinde son çevreye ulaşmak çabuklaşır. Şekil 1.43'de başlangıç çevresi iyi seçilen bir örnekte 25 iterasyon sonrasında sonuç çerçeve ortaya çıkıyor. Şekil (a)'da başlangıç çevre; (b)'de başlangıcın çevresindeki ara çevre ve (c)'de son çevre yer almaktadır.



Şekil 1.42. Aktif çevreler yöntemi ile oluşan bir görüntü




Şekil 1.43. Başlangıcı iyi belirlenen diğer bir örnek

Yönteminin asıl yararı düzgün sınırları olan uyumlu kapalı alanlar ortaya çıkarır. Dezavantajı nesne içinde keskin kıvrımlar olduğunda çevre belirlenemez ve çoğunlukla istenmeyen çevre döngüleri oluşturabilir. Bu sorunu önlemek için döngüsüz çalışan yılan algoritmaları oluşturulmuştur [25].

1.9.4.2. Watershed bölütlemesi

Watershed (su ayırım hattı) algoritması otomatik bir bölütleme yöntemidir. Üst üste çakışmanın az olduğu, düz dışbükey nesnelere daha iyi sonuç verir.

İlk bölütlenen görüntüde üst üste gelen nesnelerin uzaklık haritası elde edilir. Gri ölçekli görüntü, birbirine değmeyen nesnelere son ikili görüntüde oluşturacak kadar yüksek bir değerle eşiklenir. Uzaklık dönüşümü, yüksekliği temsil eden gri seviyesi içeren üç boyutlu görüntü olarak ele alınabilir. Eşikleme, orijinal nesnelere belirli bir seviyede ayırarak uzaklık dönüşümünde tepeler haline getiren topografik yüzeydeki bir sel gibi düşünülebilir.



Şekil 1.44. Watershed yönteminin ikili görüntüye uygulanması


Gri ölçekli görüntü piksel değerlerinin yükseklik olarak düşünüldüğü topografik yüzey olarak ele alınabilir. Watershed algoritması bu görüntüye doğrudan uygulanarak birbirine yakın nesnelere ayırmada kullanılabilir. İlk başta topografik yüzey tepeleri vadiye çevirecek şekilde tümlenir. Yüzeyin bölgesel en düşük değerlerle (regional minima) delindiği ve bölgenin su ile dolduğu varsayılır. Su, havzalara dolmaya başlar ve bitişik havzalardaki suların karışmaması için setler inşa edilir. Yüzey su ile tamamen dolduğunda setler iki nehir havzası arasındaki setleri oluşturarak sınırları çizer ve görüntüyü istenen bölgelere bölütler. Şekil 1.44’de görüldüğü gibi üst üste gelen nesnelere içeren bir ikili görüntüye uygulanan watershed dönüşümü sonrasında bölgeleri ayıran watershed çizgileri ortaya çıkıyor.

Genellikle görüntünün morfolojik gradyanı bölütlenir. Morfolojik gradyan işlemi aşağıdaki formül ile hesaplanır. Bu işlem sonrası her nesne kenarlarının olduğu yerler tepe noktası haline gelir.

$$MG = \frac{1}{2} (\max(\text{Görüntü}) - \min(\text{Görüntü})) \quad (1.37)$$

Su yüzeyi doldurdukça bu tepelerle karşılaşır ve bu tepeler su ayırım hattı (watershed) olarak işaretlenir. Şekil 1.45’de morfolojik gradyan örneği görülmektedir.

Uygulamada watershed algoritması uygulanan görüntüdeki gürültü ve yerel bozukluklar nedeniyle fazladan bölütlemeler oluşabilir. Bunu önlemek amacıyla çukur noktaların (local minima) sayısını azaltmak için düzleştirme işlemi uygulanır.



Şekil 1.45. Watershed yönteminin bulanık görüntüye uygulanması

Yine de fazladan bölütleme ortaya çıkabilir ve bölütleme uygulanması sonrasında piksellerin benzerliğine dayanarak bölge birleştirme (merge) işlemi gerçekleştirilir. Önceden tanımlanmış setlerle topografik yüzeyin suyla doldurulması da fazladan bölütlemeyi önleyebilir [25]. Şekil 1.45’de bulanık görüntüye uygulanan Watershed yönteminin sonucu görülmektedir. (i)’de orijinal görüntü, (ii)’de gradyen görüntü, (iii)’de gradyen görüntüdeki watershed çizgileri ve (iv)’de orijinal görüntüdeki watershed çizgileri yer almaktadır.

2. AKCİĞER BÖLÜTLEMESİ

Tez çalışması kapsamında bütün akciğer bölgesini ve lob içindeki yapıları bölütlemek için uygulama geliştirilmiş ve literatürden seçilen yayınlarla karşılaştırılmıştır. Geliştirilen histogram tabanlı k-means algoritması ile akciğer bölgesi bölütlenerek loblar elde edilmiştir.

İki farklı makalede önerilen bölütleme yöntemlerinin kodu yazılmış, eldeki görüntülere uygulanmış ve sonuçlar karşılaştırılmıştır. Ayrıca akciğer bölütleme işleminde k-means algoritması kullanan bir makalenin [10] yöntemi uygulanmış ve sonuçlar karşılaştırılmıştır.

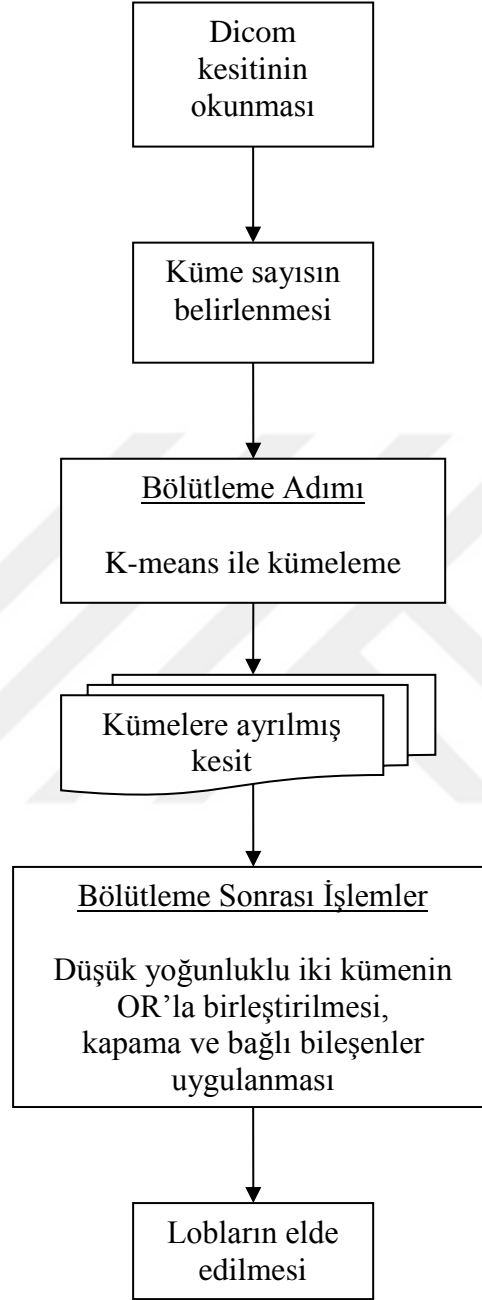
Bölütleme başarısını değerlendirmek için iki değerlendirme fonksiyonu kodlanmıştır. Karşılaştırma amacıyla Fuzzy C-means (FCM) algoritması geliştirilmiştir.

2.1. Histogram Tabanlı K-means ile Bölütleme

Bütün akciğer bölgesini bölütlemek için histogram tabanlı k-means algoritması geliştirilmiştir. Histogram tabanlı k-means algoritmasının tıbbi görüntüler üzerinde uygulandığı az sayıda yayın bulunmaktadır [9, 10]. Histogramdan yararlanan ve k-means algoritmasını kullanan yayın sayısı daha fazladır [65, 66].

Geliştirilen yöntem 3 farklı cihazdan alınmış farklı yoğunluk dağılımındaki görüntüleri ana hatlarıyla bölütleyebilmesi açısından başarılıdır. Bölütleme yöntemi küme sayısının parametrik olması açısından yarı otomatik olarak nitelenebilir. Lobların elde edilmesi aşamasında küme sayısı sabit olarak 4 seçilmiştir. Bölütleme işleminde görüntülere herhangi bir normalizasyon işlemi uygulanmadan kümeleme yapılabilmektedir. Ancak çok dağınık bir yoğunluk dağılımına sahip veri kümesinde verimli bir sonuç için kümeleme işlemi öncesinde normalize edilmesi gerekebilir. Yöntem negatif yoğunluk değerleri ile çalışmamaktadır. İşlem öncesi görüntü değerleri pozitif değerlere ötelenmektedir. Son küme merkezlerinin hesaplanması sonrasında kümeler gerekli durumda görüntüdeki asıl değerlerine çevrilebilir.

Yöntemin ana hatlarıyla işlem akışı Şekil 2.1’de görülmektedir. Tüm işlem adımları birbiri ardından çalışacak şekilde kodlanmıştır.



Şekil 2.1. Dicom kesitten lob bölgesini elde etme işleminin aşamaları

Bu sayede kesitin okunmasından lobların elde edilmesine kadar bütün adımlar otomatikleştirilmiştir. Bölütleme sonrası görüntü işlemleri ve bağlı bileşen uygulaması parametrik değildir.

Geleneksel k-means yönteminde veri değerleri kartezyen düzlemdeki noktalar olarak ele alınmaktadır. K-means algoritması ile bölütleme işleminde görüntüdeki her bir pikselin yoğunluk değeri özellik olarak kullanılabilir. Buna ilaveten komşu piksellerin yoğunluk değerinin ortalaması ve uzamsal özellikler gibi diğer bilgilerle her bir piksel için özellik vektörü oluşturulabilir. Geliştirilen yöntemde veri değerleri olarak alınan görüntüdeki yoğunluk değerleri kartezyen düzlemdeki noktalar olarak alınmak yerine, bir boyutlu sayı serisi olarak ele alınmıştır. Bu sayede, noktalar arası uzaklıklar kartezyen sisteme göre hesaplanmadığı için aralarında bağlantı olmayan ve farklı yerlerde olan aynı tür dokuların aynı kümeye dahil olması sağlanmıştır.

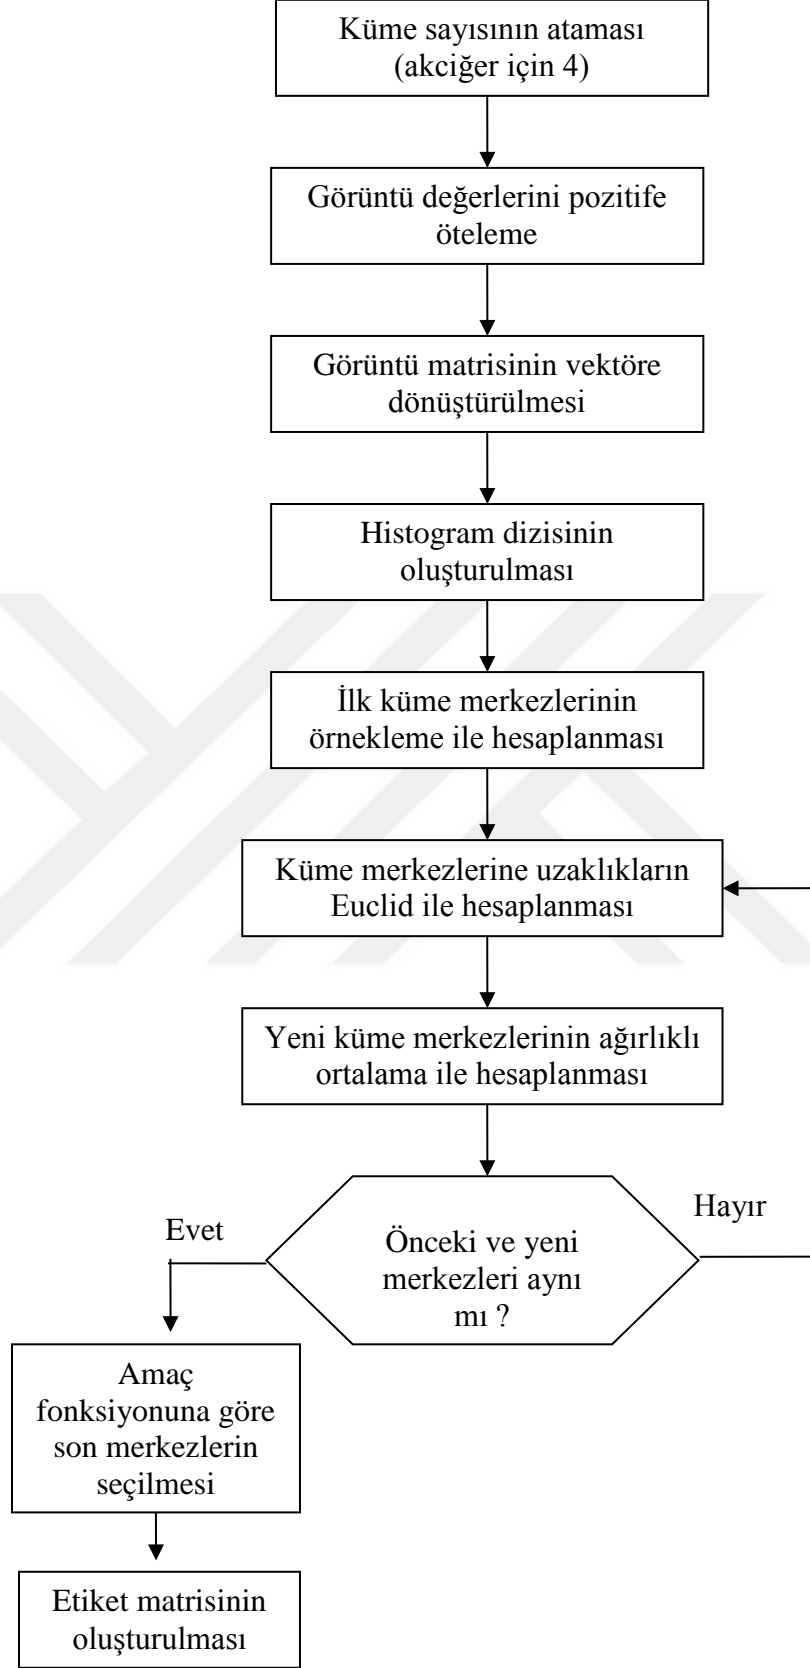
Tek boyutlu sayı serisine yerleştirilen yoğunluk değerlerinin kümeleme işlemleri histogram değerleri üzerinden gerçekleştirilmiştir. Matematiksel anlamda genel olarak histogram, veriyle ilişkili çeşitli kategorilere karşılık gelen eleman adetlerini sayan bir fonksiyondur. Histogramlardan yaklaşık sorgulamalar, veri madenciliği ve eğri basitleştirme gibi birçok alanda yararlanılmaktadır. Geliştirilen yöntemde aşağıdaki denklemle çalışan basit histogramdan yararlanılmıştır.

$$n = \sum_{i=1}^k m_i \quad (2.1)$$

Denklemde n toplam veri sayısını, k toplam aralık sayısını ve m_i histogram fonksiyonunu temsil etmektedir.

Çeşitli görüntü örnekleriyle yapılan denemeler sonucunda başlangıç küme seçiminin uygun yapılmaması durumunda boş küme oluşabilmektedir. Çalışmada boş küme oluşmaması için ilk kümelerin doğru seçilmesi sağlanmıştır.

Bölütleme sonrası oluşan küçük kümelerin nasıl niteleneceği ve kullanılacağı araştırılmıştır. Görüntünün %2'sinden küçük kümelerin başka bir kümeye dahil edilmesi [10] veya görüntünün %1'inden küçük ise silinmesi [67] şeklinde uygulamalar vardır. Çalışmada bölütleme sonrasında görüntünün %1'inden daha küçük kümeler ayrı bir kümeye dahil edilmişlerdir. Bu işlemin karşılaştırmalı sonuçları kısım 2.4'de yer almaktadır. Geliştirilen k-means algoritmasının adımları Şekil 2.2'de yer almaktadır.



Şekil 2.2. Geliştirilen K-means algoritmasının adımları

Kümelemede uygun küme sayısının bulunması için çeşitli algoritmalar kullanılmaktadır. İnsan gözünün bir görüntü içinde ayırt edebileceği parlaklık derecesinin sayısı 25-30 arasındadır. Renk geçişleri açısından ise göz %2-3 arası bir değişikliği ayırt edebilir [25]. Bu açıdan bakıldığında bir görüntüden en fazla 30 küme seçilebileceği düşünülebilir. Aynı şekilde ayırt edilebilir renk aralığı histogram örneklemede bir parametre olarak kullanılabilir. Çalışmada küme sayısı belirlemede verimli sonuç alınabilecek en düşük küme sayısı hedeflenmiştir. Bu sayı işlenecek görüntü türüne göre farklılık gösterebilir. Akciğer temel olarak dört bölgeye ayrıldığından akciğer bölgesi için küme sayısının dört olarak verilmesi yeterli olmuştur. Lob kümelemede ise uygun küme sayısının belirlenmesi için ön çalışma gerekmektedir.

2.1.1. Başlangıç küme merkezlerinin seçimi

Kümeleme işleminde başlangıç küme merkezi seçimi kümeleme başarısını etkileyen bir adımdır. Başlangıç küme merkezlerinin seçiminde aşağıdaki iki yöntem uygulanarak karşılaştırılmıştır. Ayrıca [68] ve [10] makalelerinde kullanılan ilk merkezleri bulma denklemleri de uygulanmıştır ve sonuçlar bölüm 2.4'de açıklanmıştır.

2.1.1.1. Düzgün dağılım yöntemi

Eşit aralıklı dağılmış k adet küme merkezinin seçimi için aşağıdaki denklem kullanılmıştır [69]. En büyük sayıyı da kapsamaları için en yüksek yoğunluk değerinin bir fazlası, küme sayısının birer artan değerleriyle çarpılmıştır. Eşit aralık elde etmek için k+1 sayısına bölünmüştür. Elde edilen küme merkezleri eşit aralıkta düzgün dağılmaktadır. İlk ve son merkezler görüntüdeki en küçük ve en büyük değerlere yakın değerler almaktadır. Bu yöntem yoğunluk değeri dağılımının nispeten homojen olduğu koşullarda, başlangıç küme merkezlerinin seçiminde verimli sonuç verebilir.

$$c_i = \frac{I_{\max} + 1}{k + 1} i \quad (2.2)$$

$I=1..k$, c_i küme merkezleri, k küme sayısı, I_{\max} görüntünün en yüksek yoğunluk değerini temsil etmektedir.

2.1.1.2. Örneklem yöntemi

İlk küme merkezlerini belirlemek amacıyla histogram dizisi aşağıdaki denklem kullanılarak örneklenmiştir. Bu yöntem ile iterasyon sayısı yaklaşık %75 oranında azaltılmıştır.

$$f = \frac{n_c}{k+1} \quad (2.3)$$

f örneklem aralığı, n_c görüntüdeki yoğunluk değeri (renk kodu) adedi, k küme sayısını temsil etmektedir. Bu işlem, deneme yoluyla elde edilen en verimli aralık olarak görülmektedir.

Örneklem aralığındaki orta noktalar belirlenerek, görüntü içinde en çok sayıda bulunan renk kodlarını elde etmek amacıyla küçükten büyüğe sıralanmıştır. Sıralanan bilgiler içinden küme merkezi sayısı kadar yoğunluk değeri seçilerek ilk küme merkezleri olarak atanmıştır.

2.1.1.3. Yöntemlerin karşılaştırılması

Her iki yöntem 20 kesit üzerinde karşılaştırılmıştır. Sonuçta örneklem yönteminin daha az iterasyonla aynı sonuca ulaştığı izlenmiştir. Tablo 2.2’de karşılaştırma sonuçları yer almaktadır. Bilgiler Tablo 2.1’deki kesite aittir.


Tablo 2.1. Karşılaştırılan örnek kesit

kesit	CT000200
renk adedi	2017
örneklem aralığı	403 (2017/(4+1))
küme sayısı	4
renk aralığı	4096


Tablo 2.2. Düzgün dağılım ve örneklem yöntemlerinin karşılaştırılması

İlk küme merkezleri		Son küme merkezleri	
Düzgün dağılım	Örneklem ile	Düzgün dağılım	Örneklem ile
819.4	203	69.3	69,3
1638.8	606	422,7	422,7
2458.2	1009	1025,4	1025,4
3277.6	1412	1297,4	1297,4
İterasyon sayıları		47	13

Her iki yöntem ile son küme merkezleri aynı değerlerle elde edilmiştir. Bu da iki yöntemde verimli olduğu sonucunu vermektedir. Düzgün dağılım yönteminde işlem 47 iterasyon sürerken, örnekleme yönteminde iterasyon sayısı 13'e inmiştir. Tablodaki son küme merkezleri amaç fonksiyonu kullanılmadan, sadece son iterasyonun küme merkezleri alınarak hazırlanmıştır.




Şekil 2.3. Düzgün dağılım ile ilk küme merkezleri



Şekil 2.4. Düzgün dağılım ile son küme merkezleri

Histogram eğrisi üzerinde düzgün dağılım ve örnekleme ile alınan sonuçlar aşağıdadır. Düzgün dağılım ile oluşan ilk küme merkezleri Şekil 2.3’de, son küme merkezleri Şekil 2.4’de yer almaktadır.




Şekil 2.5. Histogram eğrisi üzerinde örnekleme aralığı

Histogram grafiği, negatif ve/veya sıfır değerler içeren görüntünün pozitif değerlere ötelenmiş renk aralığını göstermektedir.


Arka zemin piksel sayısı diğerlerine oranla çok yüksek olduğundan, histogram grafiğinin ayrıntılı görülebilmesi için grafiğe dahil edilmemiştir.

Histogram eğrisi üzerinde örnekleme ile alınan sonuçlar aşağıdaki şekillerde yer almaktadır. Örnekleme aralığı Şekil 2.5’deki grafik üzerinde gösterilmiştir. Örnekleme ile oluşan ilk küme merkezleri Şekil 2.6’da, son küme merkezleri Şekil 2.7’de yer almaktadır.

Örnekleme yöntemi görüntülerin özelliklerinin farklılığı nedeniyle akciğer ve lob bölgelerine farklı şekilde uygulanmıştır. Akciğer görüntüsünde yüksek sayıda olan arka zemin pikselleri hesaplamaya dahil edilmemiş ve örnekleme aralığının orta değeri alınmıştır. Lob görüntüsünde ise örnekleme aralığının en yüksek değeri alınmıştır.



Şekil 2.6. Örnekleme ile ilk küme merkezleri



Şekil 2.7. Örnekleme ile son küme merkezleri

2.1.2. Küme merkezlerine olan uzakların hesaplanması

Çalışmada yoğunluk değerinin en yakın küme merkeziyle ilişkilendirilmesi için Öklid uzaklık ölçüsü kullanılmıştır.

Matematikte Öklid uzaklığı iki nokta arasındaki mesafedir. Öklid uzaklık ölçüsü görüntü matrisine koordinat sistemi uygulanabileceği gibi çeşitli piksel özellikleri üzerinden de uygulanabilmektedir. Her bir piksel için birden çok piksel özelliği bir özellik vektöründe toplanarak uzaklık ölçümü yapılabilir. Bunlar yoğunluk değeri,

çevre piksellerin ortalaması gibi özellikler olabilir. Ayrıca iki görüntü arasındaki Öklid uzaklığı, görüntülerin histogram değerleri üzerinden hesaplanabilmektedir.

İki boyutlu Öklid düzleminde, koordinat sistemi üzerindeki $x=(x_1,x_2)$ ve $y=(y_1,y_2)$ noktaları arasındaki $d(x,y)$ uzaklığı şöyle hesaplanır;

$$d(x,y)=\sqrt{(x_2-x_1)^2+(y_2-y_1)^2} \quad (2.4)$$

Öklid düzleminde gerçek sayılardan oluşan tek boyutlu sayı kümesinde iki sayı arasındaki uzaklık, sayıların farkının mutlak değerine eşittir. x ve y gerçek sayı dizisindeki iki nokta ve bunların arasındaki $d(x,y)$ uzaklığı şöyle hesaplanır [70];

$$d(x,y)=\sqrt{(x-y)^2} = |x - y| \quad (2.5)$$

Bu çalışmada tek boyutlu yoğunluk dizisi ile işlem yapıldığından, yoğunluk değerinin küme merkezlerine olan uzaklıkları için aralarındaki sayısal farklar alınmıştır. Noktalar sayısal farkın en küçük olduğu merkezin kümesine dahil edilmiştir.

2.1.3. Yeni küme merkezlerinin hesaplanması


Bir küme merkezinin en sık ve en etkili sayısal ölçümlemesi aritmetik ortalama (Denklem (2.6)) ile yapılır. Ancak ortalama merkezin ölçülenmesinde her zaman en iyi yol değildir. Ortalama işleminin zayıf tarafı uzak uç değerlere (gürültü) hassasiyetidir. Az sayıda uç değerler bile ortalamayı etkileyebilir [27].

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (2.6)$$

Kümeleme algoritmalarında, yeni küme merkezlerinin hesaplanması sırasında sıkça kullanılan aritmetik ortalama yöntemi ile bu çalışmada verimli sonuç alınamamıştır. Bazı örneklerde hatalı bölütleme, uzun iterasyon adımları ve istemeyen kümelere neden olmuştur.

Yeni küme merkezleri aritmetik ortalama ile hesaplandığında son küme merkezlerinin Şekil 2.8'deki grafikte görüldüğü gibi verimli dağılmadığı gözlenmiştir. Rakamlar Tablo 2.1'de bilgileri verilen kesite aittir.

Ağırlıklı aritmetik ortalamada, sayı kümesindeki her değer bir ağırlıklı değerle ilişkilendirilir. Böylece hesaplanan sonuç ortalamaya, küme içindeki değerlerin katılımı farklı oranlarda gerçekleşir [71]. Ağırlık değeri, ilgili noktanın dizide bulunma sıklığını veya diğerlerine göre önemini ifade eder.



Şekil 2.8. Aritmetik ortalama ile son küme merkezlerinin dağılımı

Eğer bütün ağırlıklar eşitse ağırlıklı aritmetik ortalama ile aritmetik ortalama aynı sonucu verir. x kümedeki elemanları, w elemanların ağırlık değerlerini temsil edecek şekilde, n adet elemanın ağırlıklı aritmetik ortalaması denklemi;

$$\bar{X} = \frac{\sum_{i=1}^n w_i X_i}{\sum_{i=1}^n w_i} \quad (2.7)$$

Küme içindeki değerlerin katılımı vermesi nedeniyle yeni küme merkezlerinin hesaplanmasında ağırlıklı aritmetik ortalama yöntemi kullanılmıştır. Çalışmada kullanılan ağırlıklı aritmetik ortalama denkleminde, küme elemanları yoğunluk değeri ile ağırlık değerleri her bir renk kodunun matraste bulunma sıklığı ile temsil edilmiştir. Eleman sayısı olarak toplam renk sayısı kullanılmıştır. Bu şekilde yeni küme merkezleri ($c_i, i=1..k$) şöyle hesaplanmıştır;

$$c_i = \frac{\sum_{j=1}^t n_j I_{ij}}{\sum_{j=1}^t n_j} \quad (2.8)$$

I yoğunluk değerini, n her bir yoğunluk değerinin matriste bulunma sayısını, t her bir kümedeki toplam renk sayısı temsil etmektedir.

Ağırlıklı aritmetik ortalama ile hesaplanan son küme merkezleri ve grafiksel dağılımı örnekleme ile başlangıç küme merkezlerinin seçimi kısmında yer alan Şekil 2.6'daki sonuçlarla aynıdır.

Aritmetik ortalama ve ağırlıklı aritmetik ortalamasının karşılaştırma sonuçları Tablo 2.3'de yer almaktadır. Aynı ilk değerlere karşılık farklı son küme merkezleri elde edilmiştir. Şekil 2.6'da izlendiği gibi dağılım daha homojendir.

Tablo 2.3. Aritmetik ve ağırlıklı aritmetik ortalamasının karşılaştırılması

İlk küme merkezleri		Son küme merkezleri	
Aritmetik ortalama	Ağırlıklı aritmetik	Aritmetik ortalama	Ağırlıklı aritmetik
203	203	29,3	69,3
1009	1009	40,6	422,7
1412	1412	144,4	1025,4
606	606	628,1	1297,4

2.1.4. Amaç fonksiyonu ile küme merkezlerini doğrulama

Amaç fonksiyonu, problemin içindeki her bir değişkenin, en iyi duruma getirilmek (optimizasyon) istenen değere ne kadar katkıda bulunduğunu ifade eder. Buna göre fonksiyon aracılığı ile bir sayısalın en yüksek değeri veya en düşük değeri elde edilmeye çalışılır. Genel anlamda amaç fonksiyonu aşağıdaki denklemlerle ifade edilir.

$$Z = \sum_{i=1}^n c_i X_i \quad (2.9)$$

Burada c_i , i değişkenine karşılık gelen amaç fonksiyonunun katsayısıdır, X_i ise i . karar değişkenidir. Katsayı ilgili değişkenin bir birimi için amaç fonksiyonunun değerinin katkısını ifade eder. Amaç fonksiyonu içinde her değişkenin bir katsayısı olmayabilir. Fonksiyona katkısı olmayan değişkenlerin katsayısı sıfır olur. Örneğin

amaç fonksiyonu ile bir projenin mevcut değerinin en yüksek derecesi elde edilecekse, X_i proje içindeki i aktivitesi ise c_i katsayısı i aktivitesinin bir birimi ile ortaya çıkan net mevcut değeri verir. Eğer problem belirli bir amaç için maliyetin en aza indirilmesi ise X_i , i 'nin kullandığı kaynak miktarı ve c_i ise i değişkeninin kaynaklarının bir birim kullanılmasıyla ortaya çıkan maliyet olabilir [72].

K-means kümeleme algoritmasına çeşitli amaç fonksiyonları uygulanabilir. Amaç fonksiyonunun benzerlik ve uzaklık ölçümü olarak küme özellik vektörlerinin istenen özellik dağılımını sağlaması hedeflenir. Çalışmada elde edilen küme merkezlerinin kümeleri uygun şekilde temsil ettiğini doğrulamak için toplam kare hatası [54], toplam Manhattan uzaklığı [71], ortalama uzaklığı kareler toplamı [10] ve kök-ortalama-kare uzaklığı (root-means-square-error) [73] amaç fonksiyonu olarak ele alınıp hesaplanmıştır. Amaç fonksiyonunun en küçük değerinde olan küme merkezleri son merkezler olarak seçilmiştir.

Kareler toplamına (sum of squared error) dayanan amaç fonksiyonu sıklıkla kullanılmaktadır ve aşağıdaki denklemlerle ifade edilir. Küme merkezi c_i ve bu kümenin bir elemanı x , küme sayısı k ile temsil edilmektedir.

$$sse = \sum_{i=1}^K \sum_{x \in c_i} |c_i - x|^2 \quad (2.10)$$

Küme merkezlerinin noktalara uzaklığının mutlak değeri (sum of absolute error) Manhattan uzaklığı olarak Denklem (2.11) ile ifade edilir.

$$sae = \sum_{i=1}^K \sum_{x \in c_i} |c_i - x| \quad (2.11)$$

Küme ortalamalarının küme elemanlarından farkının mutlak değeri (sum of mean error), ortalamadan uzaklığın fark toplamı olarak Denklem (2.12) ile ifade edilir.

$$sme = \sum_{i=1}^K \sum_{x_j \in c_i} |x_j - \mu_i|^2 \quad (2.12)$$

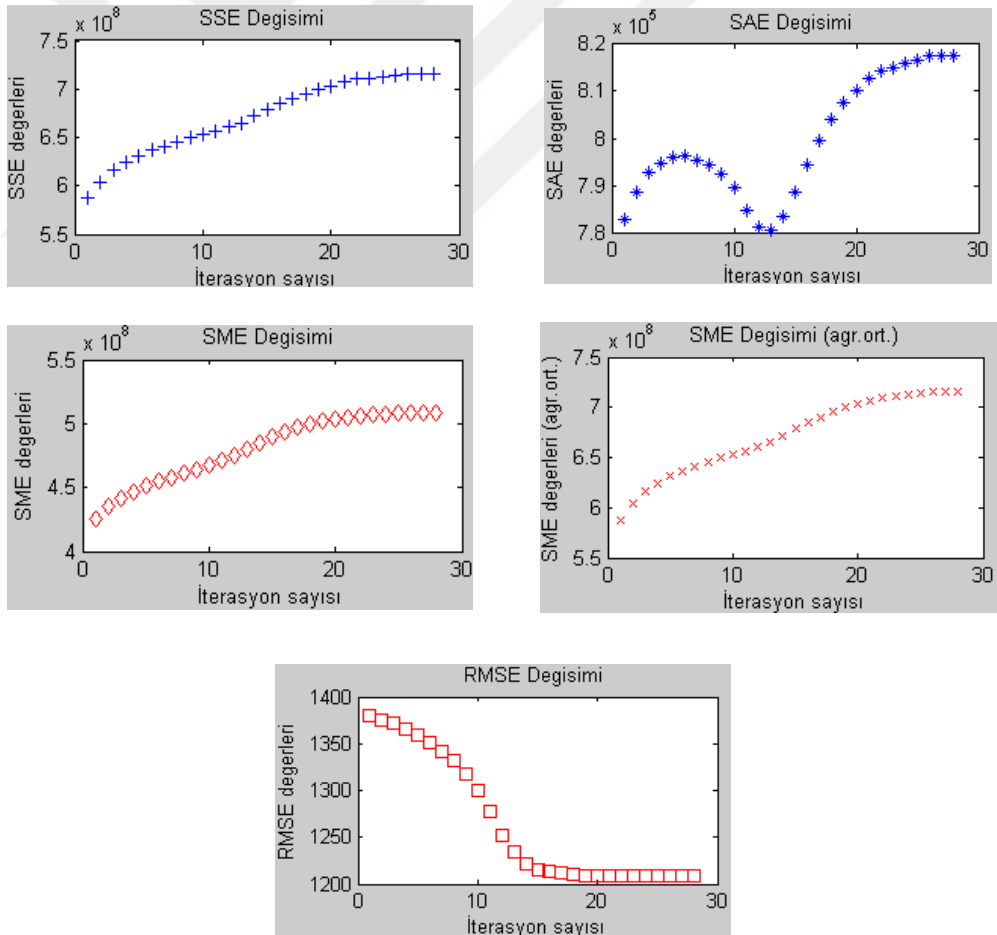
Denklemlerde μ_i , c_i merkezli küme elemanlarının aritmetik ortalamasıdır. Aritmetik ortalama yerine ağırlıklı ortalama kullanıldığında sonuçlar daha verimli olur. Bu denklem SMEA kısaltmasıyla kullanılmıştır.

Değerler arasındaki farkları ölçmede kullanılan diğer bir ölçek kök-ortalama-kare uzaklığıdır. Denklemde n kümenin eleman sayısını temsil etmektedir.

$$rmse = \sqrt{\frac{\sum_{i=1}^k (c_i - x)^2}{n}} \quad (2.13)$$

Kareler toplamı denklemi ile Manhattan uzaklığı denklemi çoğu kez aynı iterasyon sayısında en düşük değere ulaşmıştır. Sme'de aritmetik yerine ağırlıklı ortalama kullanıldığında sonuçlar daha verimli olur.

Amaç fonksiyonlarının seçilen kesitler için aldığı en düşük iterasyon sayıları Tablo 2.4'de yer almaktadır. Çalışmada incelenen kesitlerden birinin amaç fonksiyonlarının grafiksel gösterimine örnek olarak Şekil 2.9'da yer verilmiştir. Aynı kesit kümesi içinde bir uyumluluk görülebilir ancak uyumu bozan kesitler de bulunmaktadır.



Şekil 2.9. CT000050 kesitine uygulanan amaç fonksiyonlarının grafikleri

Tablo 2.4. Amaç fonksiyonlarının min iterasyon sayıları

Kesitler	SSE	SAE	RMSE	SME	SMEA
CT000050	1	13	1	20	1
CT000100	3	3	1	7	3
CT000200	1	1	2	1	1
CT000250	2	2	1	2	2
IMG00060	4	4	1	9	4
EE004437	13	13	13	13	13

2.1.5. Kümeleme doğruluğunun değerlendirilmesi

Kümeleme işleminde önceden tanımlı ve sonuçların karşılaştırılabileceği sınıflar olmadığından ve önceden kaç sınıf olduğu bazen tahmin edilemediğinden sonuçların doğrulanması gerekir. Doğrulama gözle yapılabildiği gibi program aracılığı ile de yapılabilmektedir. Kümeleme sonuçlarının doğrulanmasında gözle kontrol temel bir aşamadır. Burada iki uzmanın görüntü sınırlarını elle belirlemesi ile elde edilen işaretli görüntüler otomatik bölütleme sonuçlarıyla karşılaştırılmaktadır [10][67]. Karşılaştırma yöntemlerinden birinde, sınır pikselleri arasındaki en küçük Öklid uzaklığının ortalaması ile fark rakamsal olarak ortaya çıkmaktadır [67]. Uzmanların çizimlerinin birbiriyle aynı olmadığı makalelerde vurgulanmaktadır.

Ancak kümelerin karmaşık ve gözle ayırt edilememesi durumunda kümelemenin doğruluğunu değerlendirmek zorlaşır. Görsel yardım olmaksızın değerlendirme yapabilme ihtiyacı ortaya çıkar. Bu durumda matematiksel işlemlere başvurulabilir. Rakamsal küme doğrulama uygulamalarında üç yaklaşım kullanılmaktadır [74]. Birincisi veri setinin küme yapısıyla ilgili sezgisel bilgilere dayanarak önceden tanımlanan bir yapıya göre kümeleme algoritmasının sonuçlarını inceleyen dış kriterdir. İkincisi yakınlık (proximate) matrisi gibi veri setinin kendi vektörlerini içeren değerle kümeleme algoritmasının sonuçlarını inceleyen iç kriterdir. Üçüncüsü aynı algoritma ve farklı parametre değerleri kullanarak kümeleme yapısını başka kümeleme şemaları kullanan göreceli kriterdir.

Rakamsal doğrulama için çeşitli algoritmalar kullanılmaktadır. Bu algoritmalarından birisi [73] bağımsız küme doğrulama indisi tanımlayarak kümeleme kalitesini ölçmektedir. Burada göreceli kriter yaklaşımı kullanılmaktadır. Algoritma farklı giriş parametre değerleri için ayrı ayrı çalıştırılarak sonuç kümeler birbiriyle

karşılaştırılmaktadır. Doğrulama indisi kümeleme algoritmasının belirli bir giriş değeri için veri setini en uygun kümelere ayırma ölçüsü olarak kullanılmaktadır. Kümeler arası yoğunluk değişimi dikkate alınmıştır. Önerilen yöntemin k-means algoritmasına uygulanmış sonuçlarına makalede yer verilmiştir. Uygulanan görüntüler farklı olmasına rağmen Tablo 2.5'deki sonuçlara yakın değerler alınmıştır.

Makalede önerilen yöntemde göre, küme içi yoğunluğun düşük olması iyi dağılmış kümeler olduğunu, kümeler arası varyansın düşük olması kümelerin kompakt olduğunu gösterir. Her ikisinin toplamı ise iyi kümeleme kriteri olarak değerlendirilebilir. Uygulanan makalede kullanılan denklemler aşağıda açıklanmıştır.

Sonucun küçük değer alması kompakt kümelerin işaretidir. Küme içindeki ortalamanın dağılımı aşağıdaki denklem ile belirlenmiştir;

$$\text{scat}(k) = \frac{\frac{1}{k} \sum_{i=1}^k \sigma(c_i)}{\sigma(S)} \quad (2.14)$$

Denklemde $\text{scat}(k)$ küme içindeki ortalamanın dağılımı, S veri kümesini, $\sigma(S)$ tüm veri kümesinin varyansını, $\sigma(c_i)$ her bir kümenin varyansını temsil etmektedir.

Küme içi yoğunluğu kullanarak kümeler arasındaki ortalama nokta sayısı aşağıdaki denklem ile bulunmaktadır. Küçük değer alması kümelerin iyi ayrıldığını gösterir.

$$\text{dens}(k) = \frac{1}{k(k-1)} \sum_{i=1}^k \left[\sum_{j=1, i \neq j}^k \frac{\text{density}(u_{ij})}{\max\{\text{density}(v_i), \text{density}(v_j)\}} \right] \quad (2.15)$$

$\text{dens}(k)$ kümeler arasındaki ortalama nokta sayısını, v_i ve v_j , k_i ve k_j kümelerinin merkezlerini ifade eder. Küme merkezlerinin orta noktası u_{ij} değişkenidir. Yoğunluk değerinin hesaplanması şöyledir;

$$\text{density}(u) = \sum_{l=1}^{n_{ij}} f(x_l, u) \quad (2.16)$$

Denklemde n_{ij} , k_i ve k_j kümelerinin eleman sayılarını, x_l ise bu kümelerin elemanını temsil etmektedir. Kümeler u noktasının komşuluğu içindedir. Burada u noktasının komşuluğunun, merkezi u olan ve kümenin standart sapması yarıçapında bir çemberin içinde kabul edilmektedir. Buna göre fonksiyonun hesaplanması aşağıdaki koşullarla yapılmaktadır;

$$f(x_1, u) = \begin{cases} 0, & d(x, u) > \text{std} \\ 1, & \text{diğer} \end{cases} \quad (2.17)$$

Buna göre u değerinin komşuluğunda olan bir noktanın uzaklığı, kümelerin ortalama standart sapmasından küçük olmalıdır. dens(k) denklemindeki küme merkezlerinin yoğunluğu da aynı denklem ile hesaplanmaktadır.

Küme doğrulama indisi SD, iyi kümeleme kriterleri olarak görülen kompakt olma ve iyi dağılım açısından kümelemenin değerlendirme sonucunu verir.

$$SD = \text{scat}(k) + \text{dens}(k) \quad (2.18)$$

Bu değer en küçük sonuç aldığı küme sayısı, veri setinin optimal küme sayısı olarak değerlendirilebilir.

Çalışmada küme sayısının ve amaç fonksiyonunun uygunluğunun değerlendirilmesinde makaledeki küme doğrulama indisi kullanılmıştır. Tablo 2.5’de örnek bir kesitin 3, 4 ve 5 küme sayısı için küme doğrulama indisi değerleri yer almaktadır. En optimal küme sayısının 4 olduğu görülmektedir. Bu inceleme diğer kesitlerde de yapılmış ve çalışılan görüntüler ideal küme sayısının 4 olduğu anlaşılmıştır.


Tablo 2.5. Küme sayısı doğrulama (kesit no : EE004437)

Küme sayısı	3	4	5
Küme içi yoğunluk (dens)	0,417683	0,208333	0,216071
Kümelere arası varyans (scat)	0,000370	0,000258	0,000188
Doğrulama indisi (SD)	0,418053	0,208591	0,0216260

Küme doğrulama indisi uygun amaç fonksiyonunun seçilmesi için her bir fonksiyonun gösterdiği küme merkezlerine uygulanmıştır. Tablo 2.6’de uygulanan kesitlerden bazıları örnek olarak verilmiştir. Diğer kesitlere de uyguladığında kesitin içeriği dikkate alınarak önceden amaç fonksiyonunun belirlenebilir. Böylece belirlenen fonksiyon benzer içerikli kesitlere otomatik uygulanabilecektir. Şekil 2.10’da amaç fonksiyonlarının kesitlere göre grafiksel gösterimi yer almaktadır.

Tablo 2.6. Amaç fonksiyonlarına doğrulama indisinin uygulanması

Kesitler	SSE	SAE	RMSE	SME	SMEA	SDmin
CT000050	1	13	1	20	1	1
CT000100	3	3	1	7	3	1
CT000150	1	1	3	1	1	3
CT000200	1	1	2	1	1	1
CT000250	2	2	1	2	2	2
IMG00060	4	4	1	9	4	4
EE004437	13	13	13	13	13	13



Şekil 2.10. Amaç fonksiyonlarının kesitlere göre grafiksel gösterimi

2.2. FCM Algoritmasının Uygulanması

Çalışmada karşılaştırma amacıyla Fuzzy C-means (FCM) algoritması geliştirilmiştir. K-means ve FCM algoritmaları önce doğruluklarını kontrol amacıyla sentetik basit bir görüntüye uygulanmıştır. Aynı sonuçların alınması üzerine kesitlere uygulanarak sonuçlar karşılaştırılmıştır. Geliştirilen FCM algoritmasındaki adımlar şöyledir;

1. İlk merkezlerin k-means algoritmasındaki yöntem ile bulunması
2. Her bir yoğunluk değeri için merkezlere üyelik derecesinin belirlenmesi,
3. Bulanık küme elemanlarının üyelik derecelerine göre küme merkezlerine atanması,
4. Yeni bulanık küme merkezlerinin hesaplanması,
5. Amaç fonksiyonunun hesaplanması,

6. Yeni küme merkezleri önceki merkezlerden farklı ise 2. adımdan devam edilir, aynı ise işlem sona erer.

FCM algoritmasında aşağıdaki denklemler kullanılmıştır. Her bir yoğunluk değerinin merkezlere üyelik derecesi $M_{jp(x,y)}^m$ şöyle belirlenmiştir;

$$M_{jp(x,y)}^m = \frac{1}{\sum_{i=1}^k \left(\frac{d_{jp(x,y)}}{d_{ip(x,y)}} \right)^{2/(m-1)}} \quad (2.19)$$

Burada $d_{ip(x,y)}$, j. küme merkezinin $p(x,y)$ noktasına olan uzaklığıdır, $d_{kp(x,y)}$ ise $p(x,y)$ noktasının diğer küme merkezlerine olan uzaklığıdır. m bulanıklık indisidir ve çalışmada m için 2 değeri kullanılmıştır [68].

Yeni bulanık küme merkezleri c_j şöyle hesaplanmıştır;


$$c_j = \frac{\sum_{x \in c_j} \sum_{y \in c_j} (M_{jp(x,y)}^m)^m p(x,y)}{\sum_{x \in c_j} \sum_{y \in c_j} (M_{jp(x,y)}^m)^m} \quad (2.20)$$

Denklem (2.20)'de $p(x,y)$ kümenin elemanıdır.

Bulanık kümelemede standart FCM amaç fonksiyonu kullanılmıştır [54].

$$J = \sum_{i=1}^k \sum_{j=1}^n u_{ij}^m \|x_j - c_i\|^2 \quad (2.21)$$

Denklemde j FCM amaç fonksiyonu, k küme sayısı, n toplam eleman sayısı, c_j küme merkezi, x bu kümenin bir elemanı, u bulanık üyelik ve m bulanıklık indisidir.




Şekil 2.11. CT000200 kesitinin amaç fonksiyonunun iterasyona göre değişimi

Şekil 2.11’de CT000200 kesitinin amaç fonksiyonunun grafiği yer almaktadır. Diğer kesitlerde de benzer çıktılar alınmıştır.

FCM algoritmasında bulanık üyelik koşulu şöyledir;

$$\sum_{i=1}^k u_{ij}=1, \forall j, 0 < \sum_{j=1}^n u_{ij} < n, \forall i \quad \text{ve} \quad 0 \leq u_{ij} \leq 1, \forall i, j \quad (2.22)$$



Şekil 2.12. Görüntünün dört kümeye ayrılması (a) Orijinal görüntü (b) K-means ile kümelenecek görüntü (c) FCM ile kümelenecek görüntü (d) Kümeler

2.2.1. Sentetik görüntünün karşılaştırılması

K-means ve fuzzy c-means algoritmaları öncelikle basit sentetik bir görüntü üzerine uygulanarak doğrulukları izlenmiştir. Hazırlanan sentetik görüntü, Şekil 2.12 (a)’de görüldüğü gibi [500,500] boyutlarında ve 5 kümeden oluşmaktadır. Her biri 50 piksel olan sırasıyla 10, 110, 210, 310 ve 410 değerlerini içermektedir.

Sentetik görüntü dört kümeye ayrıldığında şekil 2.12’deki görüntüler elde edilmiştir. Başlangıç küme merkezleri ve son küme merkezleri Tablo 2.7’de listelenmiştir. K-


means sonucu (b), FCM sonucu (c) ve oluşan kümeler (d) seçenekli şekillerdir. Sonuç görüntüler kümelerin birleştirilmiş halidir.

Tablo 2.7. Dört kümenin ilk ve son merkezleri

İlk merkezler	1	150	250	400
Son merkezler				
K-means	10	110	260	410
FCM	10	110	260	410

Sentetik görüntü beş kümeye ayrıldığında Şekil 2.13'deki sonuç alınmıştır. Başlangıç küme merkezleri ve son küme merkezleri Tablo 2.8'de yer almaktadır. K-means sonucu (b), FCM sonucu (c) ve oluşan kümeler (d) seçenekli şekillerdir.

Her iki uygulamada sonuç görüntülerin küme sayıları birbirine eşittir ve sonuç görüntülerin birbirinden farkı sıfırdır. İki algoritma da sadece 1 iterasyonla küme merkezlerini bulmuştur ve tamamen aynı sonuçlar alınmıştır.



Şekil 2.13. Görüntünün beş kümeye ayrılması (a) Orijinal görüntü, (b) K-means ile kümelmiş görüntü, (c) FCM ile kümelmiş görüntü, (d) Kümeler

Tablo 2.8. Beş kümenin merkezleri

İlk merkezler	68,5	137	205	274	400
Son merkezler					
K-means	10	110	210	310	410
FCM	10	110	210	310	410

2.2.2. Kesitlerin karşılaştırılması

K-means ve FCM algoritmaları kesitler üzerinde uygulanıp karşılaştırılmıştır. Bölütleme başarısını değerlendirmede kullanılan fonksiyonlardan [75] [68] bir tanesi aşağıdaki denklemde verilmiştir;

$$F(I) = \sqrt{R} \sum_{i=1}^R \frac{e_i^2}{\sqrt{A_i}} \quad (2.23)$$

Denklemde I görüntüyü, R küme sayısını, A_i i. bölgenin boyutunu, e_i (Denklem (2.25)) bölütlenmiş görüntüdeki bölge ile I görüntüsündeki bölgenin piksel özelliklerinin Öklid uzaklığının toplamını ifade etmektedir. F(I) değerinin küçük olması daha iyi bir bölütleme olduğunu gösterir.

$$e_i = \sum_{i=1} (x_i - \mu_i)^2 \quad (2.24)$$

Bölütlenmiş iki görüntü arasındaki Öklid uzaklığı, görüntülerin histogramları arasındaki fark alınarak veya küme sayıları arasındaki farkla hesaplanabilir. Bu kısımda görüntüler arasındaki farklar için aşağıdaki denklemle hesaplanan küme sayısı dikkate alınmıştır. Öklid uzaklığının küçük olması görüntülerin benzerliği şeklinde yorumlanabilir.

$$Ed = \sqrt{\sum_{i=1}^k (gk_i - gf_i)} \quad (2.25)$$

Burada Ed Öklid uzaklığını, gk k-means ile, gf FCM ile elde edilen görüntünün küme sayılarını temsil etmektedir.


Örnek kesitlerin karşılaştırılma sonuçları Tablo 2.9'dadır. Kümeleme doğruluğunun değerlendirilmesi için 2.1.5. kısımda anlatılan doğrulama indisinin (Denklem (2.18)) aldığı değerlere de tabloda yer verilmiştir. Bütün kesitlerde başlangıç küme

merkezleri her iki yöntem için aynı değerler seçilmiştir. FCM algoritması CT000100 kesitinde 100 olan iterasyon sınırını aşmıştır.

Tablo 2.9. Örnek kesitlerin karşılaştırma sonuçları


Kesit		İterasyon	$F(I)$	Ed	SD
EE004437	k-means	13	1,87	170541	0,208591
	FCM	35	2,54		0,359796
CT000050	k-means	27	4,38	14036	0,361375
	FCM	32	3,37		0,299141
CT000100	k-means	20	2,90	20222	0,361417
	FCM	100*	3,22		0,350172
CT000150	k-means	20	1,94	18068	0,361012
	FCM	57	2,57		0,344468
CT000200	k-means	13	1,87	17642	0,360348
	FCM	46	2,6		0,355798
IMG00060	k-means	9	2,43	119147	0,208107
	FCM	36	9,55		0,360775

Sonuçlar incelendiğinde iterasyon açısından k-means algoritmasının daha verimli olduğu anlaşılmaktadır. Görsel karşılaştırmalarda k-means algoritmasının lob içi bölgelerde daha ayrıntılı bir kümeleme gerçekleştiği izlenmiştir. Bundan dolayı daha dağınık bir kümeleme görüntüsü oluşmakta ve SD indisi FCM'ye oranla daha yüksek değer almaktadır. $F(I)$ fonksiyonu çoğunlukla k-means algoritmasında daha küçük değer almıştır. Bu fonksiyona göre k-means algoritmasının kümeleme başarısı FCM'den daha yüksek çıkmaktadır.




Şekil 2.14. CT000150 kesitinin karşılaştırması (a) FCM, (b) K-means


Örnek olarak CT000150 kesitinin bölütleme sonrası birleştirilmiş görüntüsü Şekil 2.14’de yer almaktadır. FCM algoritması sonucunda lob içi bölgelerde daha az küçük bölge bulunmaktadır.



Şekil 2.15. Kümelenen loblar



(a)



(b)


Şekil 2.16. (a) İlk küme merkezleri, (b) Son küme merkezleri

2.3. Lob Bölütleme Uygulaması

Akciğer bölgesinin bölütlenmesinde kullanılan k-means yöntemi lobları bölütlemek için uygulanmıştır. Örnek olarak seçilen CT000200 kesitinin lob görüntüsü Şekil 2.15'de yer almaktadır. Gereksiz arka zemin pikselleri çıkartılarak matris küçültülmüştür.

Loblar 5 kümeye ayrılmıştır. Loblarda küme sayısı rastgele seçilmiştir ve geliştirilmesi gereken bir konudur. Şekil 2.16'da başlangıç ve son küme merkezleri histogram üzerinde görülmektedir.

Lob içindeki belirli yoğunlukların verilen küme sayısına bağlı olarak ana görüntüden çıkartılabildiği Şekil 2.17'deki gibi gözlenmiştir. Ancak bu bölgelerin istenen emboli bölgeleri olup olmadığı belirlenememiştir.



Şekil 2.17. Lob bölütleme sonuçları (a) Yoğun bölgelerin yerleri, (b) Yoğun bölgeler

2.4. Makale Karşılaştırma ve Uygulama

Bu bölümde yöntemleri uygulanarak kullanılan ve uygulanarak mevcut yöntem ile karşılaştırılan makaleler ve çalışmanın ayrıntıları yer almaktadır.

2.4.1. Uygulanan makaleler

a) Clustering validity assessment: finding the optimal partitioning of a data set

Makalede çok boyutlu verilerin kümelenmesi sonrasında ortaya çıkan kümelerin doğrulanması amaçlanmış ve bunun için denklemler geliştirilmiştir. Doktora çalışmasında bu denklemler tek boyuta indirgenerek görüntü verisine uygulanmıştır.

Çalışılan bütün algoritmalarda kullanılmıştır. Makalenin özeti ve uygulama bilgileri Kümeleme Doğruluğunun Değerlendirilmesi (2.1.5) kısmında yer almaktadır [73].

b) Multiresolution color image segmentation

Renkli görüntü bölütlemesi yapılan makalede, bölütleme başarısını değerlendirmek için bir değerlendirme fonksiyonu geliştirilmiştir. Denklem, [68] makalesinde değerlendirme amaçlı kullanıldığı için, bu makalenin sonuçlarıyla karşılaştırmak için kullanılmıştır. Sonuçlar ve denklem Kesitlerin Karşılaştırılması (2.2.2) kısmında yer almaktadır [75].

2.4.2. Karşılaştırılan makaleler

a) A fast and accurate automatic lung segmentation and volumetry method for mr data used in epidemiological studies

Üç boyutlu otomatik akciğer bölütlemesinin yapıldığı makalede temel bölütleme işleminde k-means algoritması kullanılmıştır. Uygulama 10 tane MR kesit seti üzerinde denenmiştir. Sonuçlar iki radyoloğun elle çizdiği bölütlenmiş görüntülerle karşılaştırılmıştır. Radyologların çizimlerinin birbiriyle aynı olmadığı makalede vurgulanmıştır.

Makalede kullanılan amaç fonksiyonu (Denklem (2.12)) çalışmada uygulanmıştır. Denklemde aritmetik ortalama yerine ağırlıklı ortalama kullanıldığında iterasyon sayısının azaldığı ve kümelemenin daha etkili olduğu görülmüştür.

Makalede uygun küme sayısı deneysel yollarla belirlenerek 4 veya 5 olarak belirlenmiştir ve bütün kesitlere uygulanmıştır. Doktora çalışmasında ise deneysel olarak uygun küme sayısı 4 seçilmiştir.

Başlangıç merkezlerinin seçimi kümeleme sonuçlarını etkilemektedir. Merkezlerin birbirine yakın olmaması için makalede küme merkezleri birbirinden olabildiği kadar uzak noktalarda seçilmiştir. Benzer bir seçim şekli olan düzgün dağılım yöntemi (kısım 2.1.1.1) doktora çalışmasında uygulanmıştır. Diğer taraftan çalışmada geliştirilen örnekleme yöntemiyle karşılaştırıldığında iterasyon sayısının

örnekleme oranla fazla olduğu gözlenmiştir. Bu nedenle çalışmada küme merkezlerinin belirlenmesinde örnekleme daha başarılı bulunmuştur.

Makalede, iterasyonun her bir adımında, tüm görüntü piksel sayısının %2'sinden daha az piksel içeren kümelerin merkezleri, en çok elemanı olan başka bir kümelerle dahil edilmiştir. Doktora çalışmasında geliştirilen k-means algoritmasında, tüm görüntü piksel sayısının %2'sinden daha az piksel içeren küme oluşumuna rastlanmamıştır. Sadece bağlı bileşen aşamasında görüntünün %1'inden daha küçük kümeler ayrı bir kümeye dahil edilmişlerdir.

Makalenin sonuçları üç boyutlu olarak verildiği için doktora çalışmasında elde edilen sonuçlarla görsel karşılaştırılma yapılamamıştır [10].

b) Adaptive fuzzy-k-means clustering algorithm for image segmentation

Makalede görüntüleri bölütleme için AFKM (Adaptive Fuzzy-K-means Clustering) algoritması geliştirilmiştir. Yazarın diğer makalesinden de [2] yararlanılmıştır. Bu algoritma ve başlangıç küme belirleme yöntemlerinin kodu yazılmış, uygulanmış ve sonuçlar karşılaştırılmıştır [68].

Makalede başlangıç kümelerin belirlenmesinde Denklem (2.26) kullanılmıştır;

$$c_j = \min_{p(x,y)} + (2j+1) \frac{\max_{p(x,y)} - \min_{p(x,y)}}{2n} \quad (2.26)$$

Denklemdeki $\min_{p(x,y)}$ ve $\max_{p(x,y)}$ görüntünün en küçük ve en yüksek gri seviye değerleri, j küme merkezinin indisini temsil etmektedir.

Denklem çeşitli küme sayıları için farklı görüntülere uygulandığında, bazı sonuncu küme merkezlerinin görüntünün en yüksek renk sayısını aştığı görülmüştür. Bu durum boş kümelerin oluşumuna neden olmaktadır ve iterasyon sayısını yükseltmektedir. Buradan denklemin başlangıç küme seçimi için verimsiz olduğu şeklinde bir değerlendirmeye varılabilir. Denklem aşağıdaki şekilde değiştirildiğinde en yüksek renk sayısının aşılmadığı görülmüştür;

$$c_j = \min_{p(x,y)} + 2j \frac{\max_{p(x,y)} - \min_{p(x,y)}}{2n} \quad (2.27)$$

Denklemin uygulanma sonuçlarından birine aşağıda yer verilmiştir. Makalede kullanılan Elaine (Şekil 2.18) görüntüsü üzerinde her iki denklemin uygulanması sonucu Tablo 2.10'de yer almaktadır. Görüntünün en yüksek yoğunluk değeri 244'dür. Tabloda görüldüğü gibi Denklem (2.27) ile hesaplanan başlangıç küme merkezlerinin sonuncu değerleri en yüksek renk sayısını aşmıştır.



Şekil 2.18. Elaine.tiff görüntüsü

Tablo 2.10. Elaine görüntüsü için ilk küme merkezleri

Küme Sayısı	1	2	3	4	5
Denklem 2.27	122,5	203,5	284,5	-	-
Denklem 2.28	82	163	244	-	-
Denklem 2.27	92,1	152,8	213,6	274,3	-
Denklem 2.28	61,7	122,5	183,2	244	-
Denklem 2.27	73,9	122,5	171,1	219,7	268,3
Denklem 2.28	49,6	98,2	146,8	195,4	244


Doktora çalışmasında geliştirilen örnekleme yönteminin Elaine görüntüsüne uygulandığında alınan sonuçlar karşılaştırma için Tablo 2.11'de verilmiştir. Küme değerleri en yüksek renk sayısını aşmamıştır ve homojen dağılmıştır.

Tablo 2.11. Örnekleme ile elde edilen küme merkezleri


1	2	3	4	5
113	128	177	-	-
89	128	136	186	-
64	113	128	153	193

Görüntünün dört küme için örnekleme ile elde edilen başlangıç küme merkezlerinin histogram üzerindeki grafiği Şekil 2.19'dedir. Başlangıç küme merkezlerinin

belirlenmesi kısım 2.1.1’de açıklanmıştır. Belirlenen aralıklardaki en yüksek değerler merkez olarak seçilmiştir. Son küme merkezleri ve küme sınırları Şekil 2.20’de yer almaktadır.



Şekil 2.19. Örnekleme ile başlangıç küme merkezleri



Şekil 2.20. Son küme merkezleri ve küme sınırları (açık renkli çizgiler)

Kümeleme başarısını tespit etmek için makalede önerilen AFKM algoritması geliştirilmiş alınan sonuçlar görsel ve fonksiyonlar aracılığı ile karşılaştırılmıştır. Örnek olarak 3 ve 4 kümeye ayrılmış görüntülere Şekil 2.21 ve Şekil 2.22’de yer verilmiştir.

Görsel karşılaştırma için makalenin görsel sonuçları Şekil 2.23’de yer almaktadır. Çok benzer sonuçlar alınmıştır.


Bölütleme başarısını değerlendirmek için makalede kullanılan fonksiyonlardan birisi, $F(I)$ Denklem (2.24)’dür. Diğer fonksiyonların makalelerine ulaşamadım. Makalede denklemin hesaplamasında kullanılan Öklid uzaklığının nasıl hesaplandığı belirtilmemiştir. Bu değer 2.25’de verilen denklem ile hesaplanmıştır.



Şekil 2.21. Görüntünün 3 kümeye ayrılmış sonucu



Şekil 2.22. Görüntünün 4 kümeye ayrılmış sonucu



Şekil 2.23. Uygulanan makalenin görsel sonuçları (a) orijinal, (b) 3 küme, (c) 4 küme

Makalede bölütleme başarısını artırmak için aidiyet derecesini gösteren bir denklemden yararlanılmıştır. Ancak kullanılan aidiyet derecesi denkleminin normalize edilmiş değerinin nasıl hesaplandığı belirtilmemiştir. Çeşitli olası denklemler denemiş ve en uygun olduğu düşünülen denklem ile aşağıdaki şekilde hesaplanmıştır.

$$B_j = 1 - \frac{b_j - \frac{c_j}{n_{c_j} - 0,99}}{10} \quad (2.28)$$

B_j kümesinin aidiyet derecesinin normalize edilmiş değerini, b_j j kümesinin aidiyet derecesini, n_{c_j} j kümesinin eleman sayısını temsil etmektedir.

K-means ve AFKM algoritmalarının karşılaştırılması için makalede kullanılan değerlendirme fonksiyonu $F(I)$ değeri hesaplanmıştır. Kümeleme doğruluğunun değerlendirilmesi için doğrulama indisi SD (Denklem (2.18)) fikir vermesi açısından incelenmiştir.

K-means ve AFKM algoritmaları Tablo 2.11'deki başlangıç küme merkezi değerleri 3,4 ve 5 küme için ile çalıştırılmıştır. Elde edilen son küme merkezleri Tablo 2.12'de listelenmiştir. Küme doğrulama indisi kümeleri dağılımları ve kompaktlığı açısından değerlendirmektedir. Bu açıdan AFKM daha performanslı görünmektedir. K-means algoritmasının $F(I)$ değerinin küçük olması daha iyi bir bölütleme olduğunu göstermektedir.

Tablo 2.12. K-means ve AFKM algoritmalarının sonuçları

	İterasyon	SD	$F(I)$	Son küme merkezleri				
K-means	4	0,419673	5,09	81	137	194	-	-
AFKM	7	0,419619	5,11	72	134	198	-	-
K-means	8	0,363099	4,07	73	118	157	205	-
AFKM	8	0,354053	4,61	45	104	162	218	-
K-means	16	0,328044	3,23	66	103	137	172	215
AFKM	9	0,308439	3,63	39	86	132	177	223

c) Automatic lung segmentation for accurate quantitation of volumetric x-ray ct images

Makalede akciğer bölütlemesi amacıyla optimal eşikleme yöntemi geliştirilmiştir. K-means ile bölütleme işleminin başarısını karşılaştırmak amacıyla bu yöntemi kodu yazılmış, uygulanmış ve sonuçlar karşılaştırılmıştır. Makalede önerilen optimal eşikleme bir otomatik eşik seçme yöntemidir. Burada akciğerin bölütlenmesi için önce optimal eşikleme kullanılmış, kümeleri ayırmak için sonrasında bağlı bileşen algoritması kullanılmıştır.

Son olarak lobların için doldurmak amacıyla topolojik analiz yapılmıştır. Makaledeki gibi bölütleme sonrasında bağlı bileşen algoritması uygulanmış ancak lobların içini doldurmak bölütlemenin gerekli bir adımı olmadığı için bu kısım uygulanmamıştır [67].

Makalede akciğerin bölütlenmesi için yapılan ilk adım eşik değerinin belirlenmesidir. Bu amaçla pikseller akciğer pikselleri ve diğer pikseller olarak iki tipte düşünülmüştür. Bölütleme eşikleme iteratif bir işlem sürecinde seçilmektedir. Her bir adımda akciğer pikselleri ve diğer piksellerin ortalama değerlerinin ortalaması alınır. Elde edilen eşik değeri önceki değer ile aynı ise işlem sona erer. Kullanılan denklem;

$$T^{i+1} = \frac{\mu_b + \mu_n}{2} \quad (2.29)$$

T^{i+1} .(i+1). adımdaki bölütleme eşik değeri, μ_b akciğer piksellerinin yoğunluk ortalaması, μ_n diğer piksellerin yoğunluk ortalamasıdır.

Makalede başlangıç eşik değerinin belirlenmesi için saf havayı temsil eden -1000 HU'ye eşit ve akciğer içini temsil eden 0 HU'dan büyük değerlerle eşiklemenin başlatılması önerilmiştir. Ancak bu değerler sadece CT önekli kesitlerle başarılı olmuştur, IMG ve EE önekli kesitlerde başarısız olmuştur. Bunun nedeni hava değerinin kesit türüne göre değişmesidir.

Doktora çalışmasında kullanılan kesitlerde makalede belirtildiği gibi sadece tek bir hava değeri bulunmamaktadır. Ayrıca arka zemin rengi bazı tür kesitlerde birçok

değer içerebilmektedir. Makalede bu değerlerin tek bir kesit kümesine uygulandığı düşünülmektedir. Bu nedenle makalede önerilen başlangıç eşikleri genellenemez bulunmuştur.

Kesitlerin arka zemin renklerinin çeşitli değerleriyle yapılan denemelerde etkili bir sonuç alınamamıştır. Bu başlangıç eşik değerleri görüntü tipine göre değişken olarak belirlenmelidir. Görüntü tipine göre değişken olan bir yöntem araştırılmıştır. Üç kesit türleriyle yapılan denemelerde her üç tipe uygun olan başlangıç eşik değerlerinin görüntünün aritmetik ortalaması olduğu görülmüştür.

$$T^0 = \frac{\sum_{i=1}^n x_i}{n} \quad (2.30)$$

T^0 başlangıç eşik değeri, x görüntü elemanı, n görüntünün eleman sayısıdır.

CT önekli kesitlerle yöntem k-means ile yakın sonuçlar üretmiştir. Örnek olarak CT000150 kesitinin eşikleme adımları Tablo 2.13’de yer almaktadır.

Başlangıç eşik değerleri $T^0=432$ ’dir. Bir kesiti her iki yöntem üzerinde uygularken kapama işleminin parametresi aynı tutulmuştur.


Tablo 2.13. CT000150 kesitinin eşikleme adımları

Adım	T^{i+1}	T^i	μ_n	μ_b
1	592	574	1084,68	99,17
2	594	592	1086,93	100,27
3	594	594	1087,18	100,40


CT000150 kesitinin optimal eşikleme ve k-means ile bölütleme sonuçları Şekil 2.24’de yer almaktadır. CT000200 kesitinin optimal eşikleme ve k-means ile bölütleme sonuçları Şekil 2.25’de, eşikleme adımları ise Tablo 2.14’de yer almaktadır. Başlangıç eşik değerleri $T^0= 443$ ’dir.

Tablo 2.14. CT000200 kesitinin eşikleme adımları

Adım	T^{i+1}	T^i	μ_n	μ_b
1	591	575	1085,10	97,45
2	593	591	1087,50	98,70
3	593	593	1087,71	98,81



Şekil 2.24. CT00150 kesitinin bölütlenmesi (a) optimal eşikleme, (b) k-means




Şekil 2.25. CT000200 kesitinin bölütlenmesi (a) optimal eşikleme, (b) k-means

Optimal eşikleme IMG ve EE öneki kesitlere uygulandığında k-means algoritmasına oranla daha verimsiz sonuçlar alınmıştır. Şekil 2.26 ve 2.27’de görüldüğü gibi fazla küme oluşumu ve pürüzlü sınırlar ortaya çıkmıştır.


Bölütleme işlemi kesitlere uygulandığında bazı kesitlerde benzer sonuçlar üretirken bazılarında makalenin yönteminin gereksiz ve fazla bölütleme yaptığı izlenmiştir.

Makalede bölütleme sonucunda görüntünün yüzde 1’inden olan küçük kümelerin atıldığı belirtilmiştir. Ancak bu durum lobların küçüldüğü ancak hala izlenebildiği kesitlerde lobların incelen kısımlarının görüntüden çıkmasına neden olduğu tespit edilmiştir. Bu durumu önlemek için kesit kümesinin görüntü ortalaması değerlerinin

yükselme noktasına kadar bu kontrolün yapılmasıdır. Yükselme noktasından sonra lobların küçülmektedir.



Şekil 2.26. IMG00060 kesitinin bölütlenmesi (a) optimal eşikleme, (b) k-means




Şekil 2.27. EE004437 kesitinin bölütlenmesi (a) optimal eşikleme, (b) k-means

Tablo 2.14’de görüldüğü gibi makalenin yöntemi k-means’e oranla daha az iterasyonla sonuca ulaşmaktadır. Ancak her tür kesitte doğrudan uygulanamaması ve başlangıç eşik değerinin belirlenmesi için ön çalışma gerektirmesi yöntemin dezavantajıdır. Diğer taraftan k-means algoritmasında başlangıç değeri verilerek küme sayısı kontrol edilebilmektedir. Optimal eşikleme yönteminde ise sonuçta oluşacak küme sayısı önceden tahmin edilemeyebilir. Bu durum akciğer bölütlemesinde dezavantaj olarak düşünülebilir.

2.5. Lob Girintilerinin Kapatılması


Akciğer tomografisi görüntüleri kontrast madde verilerek çekildiği için kesitlerin bazılarında yansımalar, artifaktlar ve renk farklılıkları ortaya çıkmaktadır. Bu farklar nedeniyle birbirini takip eden kesitler arasında belirgin yoğunluk farklılıkları izlenmektedir. Artifakt ve lob içi doku yoğunluğu nedeniyle bölütleme sonucu oluşan girintilerin giderilmesi için bölütlenen lob ve kümeleme sonrasında oluşan ikinci küme görüntüsü kullanılmıştır. Kesit setinde farklı içerikli görüntüler olması nedeniyle oluşan ikinci kümeler de farklı içerikte oluşmuştur. Bu kesitlere önce ayrı ayrı işlemler uygulayarak sonuç lob görüntüsü elde edilmiştir. Daha sonra yöntemler birleştirilmiştir.




Şekil 2.28. CT000103 kesitinin orijinal görüntüsü

Örnek olarak CT000103, CT000068 ve CT000106 kesitlerine uygulanan sonuçlar aşağıda yer almaktadır. Şekil 2.28'de görülen CT000103 kesiti k-means ile kümelendiğinde Şekil 2.29'daki kümeler oluşmuştur. Kümeleme sonucu oluşan ilk küme (Şekil 2.29 (a)) lob içi hava piksellerini içermektedir. İkinci küme (Şekil 2.29 (b)) ise damar, doku ve artifaktan etkilenen pikselleri içermektedir. Bunlar lob kenarlarındaki beyaz renkli piksellerdir. Üçüncü ve dördüncü kümeler göğüs yapısını içermektedir ve kullanılmamıştır. Bu kesit artifaktan etkilenmeyen grup kesitlere bir örnektir ve bu grup kesitlerde en net kümeleme sonucu elde edilebilmektedir.

Bölütleme sonucunda dört kümenin bir arada renkli görüntüsü Şekil 2.30 (a)'da yer almaktadır.



Şekil 2.29. CT000103 kesitinin 4 kümeye ayrılmış hali (a) 1. küme, (b) 2. küme, (c) 3. küme, (d) 4. küme




Şekil 2.30. CT000103 kesitine kümeleme ve bağlı bileşen uygulanması (a) 4 kümenin bir arada görüntüsü, (b) Bwlabel sonrası görüntü

Lob içindeki pembe alanlar lob içi dokular ve artefaktlar nedeniyle oluşan yoğunluklardır. Artefakt ve lob içi doku yoğunlukları çevre göğüs dokusuna yakın yoğunluk değerlerine sahiptir. Bunlar bağlı bileşen uygulanması sonrasında Şekil

2.30 (b)'de görüldüğü gibi bölütlenen loba dahil olmamıştır. Özellikle lobların kenar pikselleri bölütleme sonucunda yer almamaktadır. Bu durum asıl lob hacminin elde edilememesine neden olmaktadır. İşlem sonrası artefakt ve lob içi doku yoğunlukları çevre göğüs dokusunu içeren gruba dahil edilmektedir.

İkinci küme görüntüsü CT000103 kesiti gibi olan görüntüler için girintileri kapatma ve birleştirme işlemi Şekil 2.31'de görüldüğü gibi kısa bir işlemle gerçekleştirilebilmiştir.



Şekil 2.31. (a-d) ve (b-e) görüntüsü birleştirilerek elde edilen lob (c-f)




Şekil 2.32. Girintileri kapatma işleminin son aşaması (a) Girintileri kapatılan loblar, (b) Boşlukları doldurulmuş loblar

Bağlı bileşen uygulaması sonrası elde edilen loblar ayrı ayrı (Şekil 2.31 a-e) ile ikinci kümeden çıkartılan loblarla (Şekil 2.31 b-f) OR işlemiyle birleştirilerek bütün lob (Şekil 2.31 c-f) dokusu elde edilmiştir.

Girintileri kapatma işleminden sonra lob içi boşluklar doldurularak Şekil 2.32 b'deki gibi tam lob sınırları elde edilmiştir.


CT000068 ve CT000106 kesitlerinde (Şekil 2.33) lob çevresinde başka pikseller de olması nedeniyle yukardaki gibi basit OR işlemi yapılması mümkün olmamıştır. İzlenen yöntem şöyledir;




Şekil 2.33. Farklı işlem gerektiren kesitlere örnek (a) CT000103, (b) CT000068

Bölütlenmiş lobdaki (Şekil 2.34 a) eksik olan sınır piksellerinin elde edilmesi için, lobun kenarları çıkartılarak (d) kenar takibi için başlangıç noktası olarak alınmıştır. Kenarlar (c) görüntüsü üzerinde x ve y ekseninde sağa ve sola doğru taranarak genişletilmiş ve son olarak iç boşluklar doldurularak (f)'deki görüntü elde edilmiştir. İkinci kümenin lobu ile bölütlenmiş lobun kenar farkı (e) kontrol için görüntülenmiş ancak işlemde kullanılmamıştır. Kenarlar arası fark olmayan görüntülerde (a) görüntüsünün iç boşlukları doldurulmuştur.

CT000106 grubundaki kesitlerde (Şekil 2.35 b) lob çevresinde çıkartılacak daha çok piksel mevcuttur. Aynı yöntemle işlenen bu grubun bazı kesitlerinde, bölütlenen lob ile ikinci kümenin lobları aynı boyda olduğu için fark kesiti oluşmamaktadır. Ancak işlem öncesi bu duru belirlenememektedir. Fark kesiti oluşmayan bu kesitlerde iki kümenin birleştirilmesi lob içi boşlukların doldurulmasını sağlamıştır.



Şekil 2.34. CT000068 kesitine uygulanan işlemler (a) Bölütlenmiş lob, (b) İkinci kümenin lobu, (c) a ve b'nin birleştirilmesi, (d) a'nın kenarları, (e) a ve b'nin kenar farkı, (f) c'den elde edilen lob

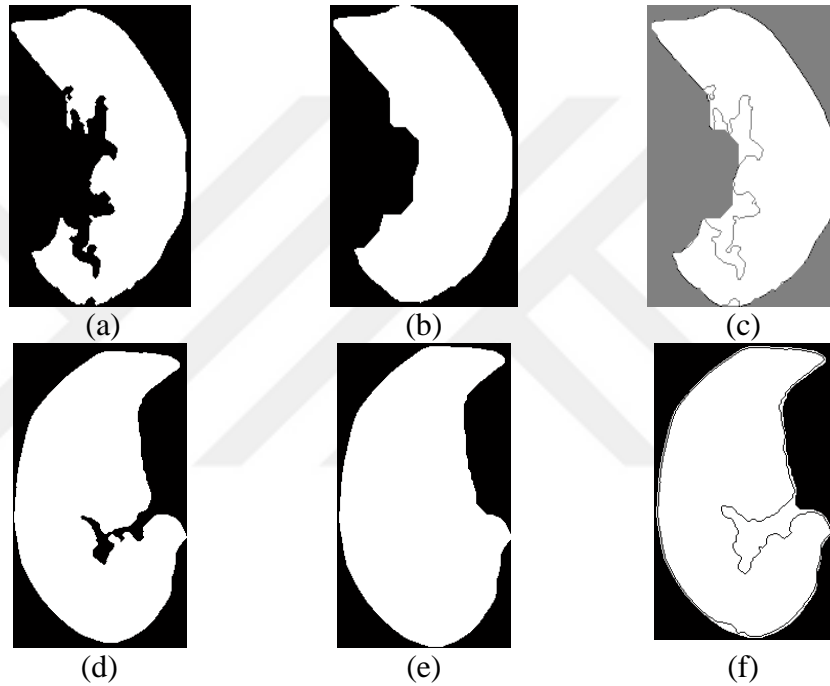


Şekil 2.35. CT000106 kesitine uygulanan işlemler (a) Bölütlenmiş lob, (b) İkinci kümenin lobu, (c) a ve b'nin birleştirilmesi, (d) a'nın kenarları, (e) c'den elde edilen lob

2.5.1. Lob kenarlarının düzleştirilmesi

Ana bronşların lob kümelemesine dahil olmaması nedeniyle özellikle iç kenarlarda oluşan boşluklar ile artefaktlar nedeniyle dış kenarlarda oluşan girintiler morfolojik kapama işlemiyle doldurulmuştur. Bu şekilde tüm lob hacmi elde edilmiştir.


Kapama işlemi için iki morfolojik yöntem denenmiştir. Her iki işlemde de yapıcı parametresi olarak 10 değerinde disk kullanılmıştır. Birinci yöntemde Şekil 2.36'da görülen kesitlere imclose ile kapama işlemi uygulanmış ve etkili sonuç alınmıştır.



Şekil 2.36. Lob kenarlarının düzleştirilmesi (a-b-c) CT000066, (d-e-f) CT000097

İkinci yöntemde Şekil 2.37'de görüldüğü gibi önce (b) kalınlaştırma (imdilata), ardından (d) inceltme (imerode) uygulanmış ve son görüntü ilk görüntü (a) ile birleştirilerek (e) sonuç (f) elde edilmiştir.

Her iki yöntemde de hedeflenen girintilerin kapatıldığı, ancak ikinci yöntemde bazı kesitlerde kenarlarda fazladan kalınlaşma oluştuğu görülmüştür. Bu nedenle birinci yöntem uygulanmıştır.



Şekil 2.37. CT000075 kesitine uygulanan işlemler (a) Bölütlenmiş görüntü, (b) Kenarlar kalınlaştırılır, (c) Eklenen kısımlar ((b)-(a)), (d) görüntü b inceltir (e) a ve d görüntülerini birleştirilmesi, (f) sonuç görüntünün a'dan farkı

3. MERKEZİ PULMONAR EMBOLİ TESPİTİ

Bu tez çalışmasında hesaplama maliyetini düşük tutmak ve sistemin verimli olması amacıyla kural tabanlı bir yaklaşım geliştirilmiştir. Kurallar bilgiyi temsil etmenin etkili bir yoludur ve bilgisayar bilimlerinde, bilgileri yorumlamak için etkili bir yöntem olarak kural tabanlı sistemlere başvurulur. Bu bölümde kural tabanlı programlama kullanarak geliştirilen sistemin ayrıntılarına yer verilmiştir.

3.1. Kullanılan Görüntülerin Özellikleri

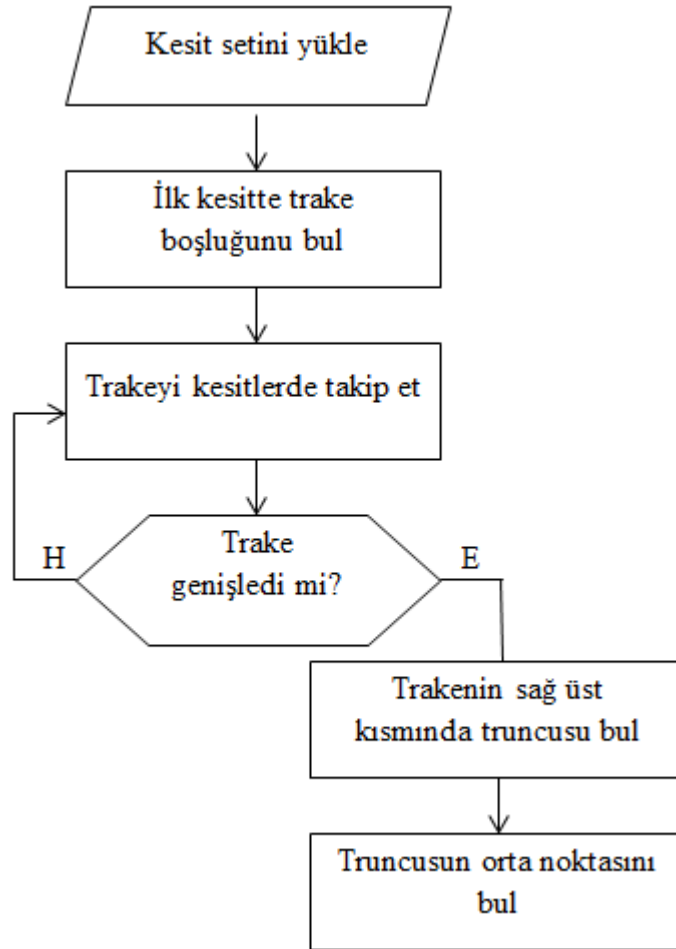
Çalışmada 32 tane merkezi emboli içeren tomografi görüntüsü kullanılmıştır. Görüntüler Kocaeli Üniversitesi Tıp Fakültesi ve Mayo Clinic'den alınmıştır. Veriler üç boyutludur ve Dicom formatındadır. Her bir tomografi çekimi, boyundan başlayıp karaciğerde sonlanan ortalama 600 kesit görüntü içermektedir. Görüntü içindeki emboli bölgelerinin yerleri bir radyolog tarafından tespit edilmiştir. Dicom görüntülerini inceleme aşamasında Radiant Dicom Viewer programından yararlanılmıştır. Dicom veriler Matlab programıyla işlenirken “.mat” formatına dönüştürülmüştür. Kesitler arasında çekimden kaynaklanan nedenlerden dolayı yoğunluk değerleri farklılıkları bulunmaktadır. Bunlar tespit edilip tüm kesitler için aynı eşikleme değerleri kullanılacak şekilde yoğunluk değeri ayarlanmıştır. Kullanılan Dicom formatındaki görüntülerin ortak özellikleri aşağıdaki tabloda verilmiştir.

Tablo 3.1. Görüntülerin özellikleri

Format	DICOM
Genişlik	512
Yükseklik	512
Bit derinliği	12
Renk tipi	Grayscale
Modalite	BT
Kesit kalınlığı	1 mm

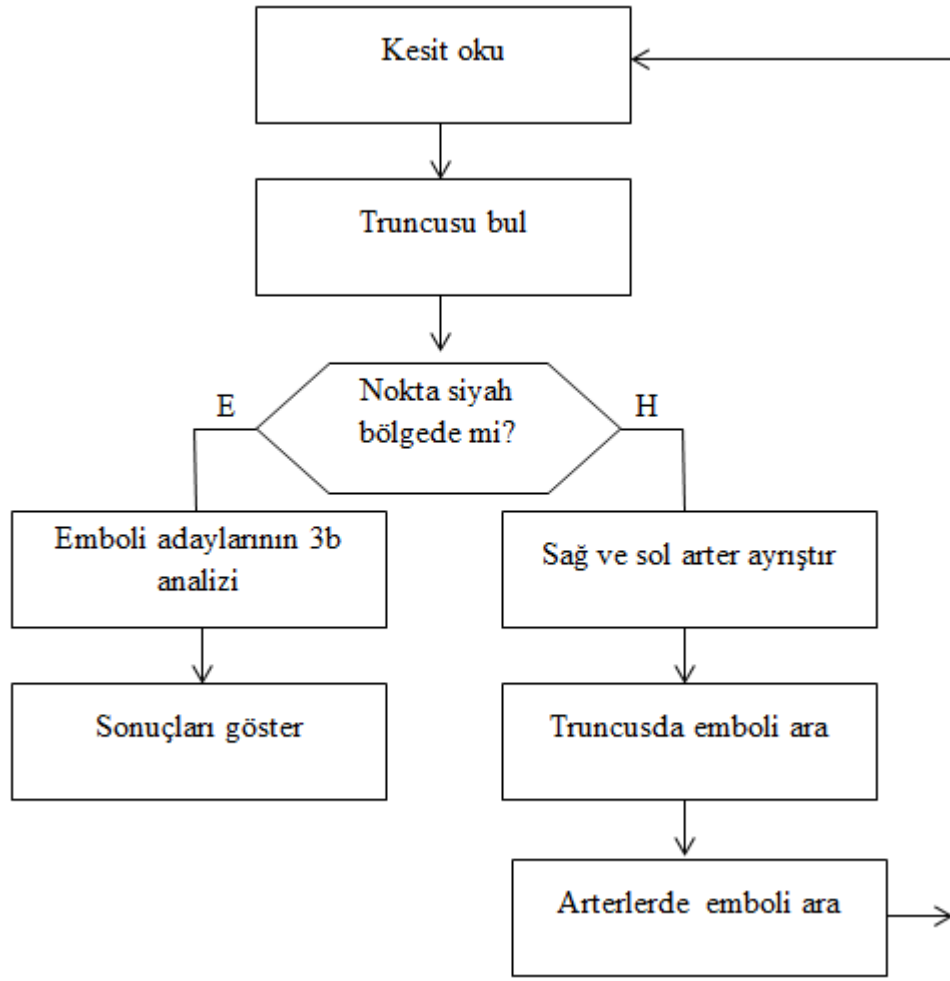
3.2. Geliştirilen Programların Adımları

Çalışmada merkezi pulmonar emboli tespiti için geliştirilen programlar ile otomatik tespit gerçekleştirmektedir. İşlem kesit setinin okunmasıyla başlayıp, emboli adaylarının işaretlendiği kesitlerin görüntülenmesiyle tamamlanmaktadır. Programların ilk kısmı, ilk kesitte trakeyi (soluk borusu) bulup, trake genişleyene kadar kesit serisini okur. Genişleme olduğunda truncusun (ana pulmonar arter) yerini bulup, içindeki orta noktayı seçer. İlk kısmın akış diyagramı aşağıdaki şekildedir.



Şekil 3.1. Truncusun bulunmasının adımları

Programların ikinci kısmında truncus görüntüden çıkana kadar kesit serisi okunarak işlenir. Merkezi embolinin tespit edilebilmesi için öncelikle truncusun tanımlanması ve ana pulmonar arterlerin tespit edilmesi gereklidir. Eşikleme sonrası çevre dokulardan nispeten ayrıştırılan truncus görüntüsü ikili formata dönüştürülmüştür. Her bir kesitte emboli araması yapılmıştır. İkinci kısmın akış diyagramı aşağıdaki şekildedir.




Şekil 3.2. Truncusun taranma işleminin adımları

Akış diyagramlarında özetlenen adımları aşağıdaki kısımlarda ayrıntılı bir şekilde anlatılmaktadır.

3.3. Trake İzlenerek Truncusun Tespiti

Pulmonar emboli tespiti için çekilen tomografi görüntüleri, boyundan başlayıp mideye kadar uzanan yaklaşık 600 tane kesit içermektedir. Doktorlar bu kesitleri truncusun başladığı kesitten incelemeye başlamaktadırlar. Tomografi görüntülerinin program aracılığı ile otomatik işlendiği çalışmalarda pulmonar arterin (truncusun) başladığı kesitin (z_0). bir yöntemle belirlenmesi gereklidir. Bu işlem emboli tespitinden ayrı olarak ele alınarak, farklı bir yöntem uygulanmalıdır. Pulmonary emboli tespiti için geliştirilen algoritmaların yer aldığı makalelerde, başlangıç kesitinin belirlenmesi net belirtilmeyen bir konudur.

Pulmonar truncusun yer aldığı kesitteki koordinatı, oryantasyonu ve biçimi kişiden kişiye ve hatta çekimden çekime farklılık göstermektedir. Çekim sırasında kişinin yatış pozisyonuyla ilişkili olarak görüntü sağa veya sola yatık olabilmektedir. Bu nedenle pulmonar truncusun yerini tam olarak bulmak için tek bir şablona dayalı bir yöntem kullanılamamaktadır.




Şekil 3.3. Kesit kümesinin ilk kesiti ve truncusun bulunduğu kesit, kesit no; (a-b) 3003 (c-d) 3102

Truncusun bulunduğu kesiti otomatik bulmak için önce şu yöntemler denenmiştir; kesitlerden elde edilen energy ve homogeneity değerleri ile üç boyutlu bağlı bileşen yöntemi, üç boyutlu görüntüden truncusun bulunması ve “level set” yöntemi. Bu yöntemler ile istenen sonuca ulaşılamamıştır. Son olarak ilk kesitten itibaren trake izlenerek truncusun bulunduğu kesite ulaşma yöntemi geliştirilmiş ve başarılı bulunmuştur.

Trakenin uzunluğu ve şekli kişiden kişiye değişmektedir. Trakenin dallanma noktasının olduğu kesitte pulmonar truncus görülmeye başlamaktadır. Trakenin dallanma noktası truncusa ulaşmak için anlamlı bir referans noktası oluşturmaktadır. Ancak truncusun başlangıç büyüklüğü de yine kesit kümeleri arasında farklılık göstermektedir. Birçok kesitte başarılı olduğu halde bazı kesitlerde trakeye çok yakın bulunan dokular nedeniyle trake genişlemiş bir şekilde elde edilmiştir. Bu durumlarda truncus zaten görüntüye dahil olduğundan, bu dokular veya lob truncusun elde edilmesine engel oluşturmamıştır.

Şekil 3.3’de iki farklı kesit kümesinin okunan ilk kesiti ve truncusun bulunduğu kesit örneklenmiştir. Öncelikle kesit setinin ilk görüntüsünde trake tespit edilmiştir. Bunun için kesite eşikleme, açma, bağlı bileşen ve boşlukları doldurma işlemleri uygulanmıştır. Genellikle trake görüntü içinde zeminden sonra en büyük ikinci karanlık bölgedir. Bazı kesitlerde başka bölgeler trake yerine seçildiği için karanlık bölgenin merkeze yakınlığı aranmıştır. Takip eden kesitlerde trakenin bulunması için, trakenin bulunduğu kesitte dairesel parça ile onun merkez noktası bulunmuş ve bir sonraki kesitte bu merkez noktayı içeren parça görüntüden küçük bir pencere içinde çıkartılarak takip eden kesitin trakesine ulaşılmıştır. Trakeye çok yakın dokuların olduğu az sayıda kesit kümesinde pencereye bitişik dokular da dahil olmuştur. Trake dallanma noktasına kadar takip edilmiştir. Şekil 3.4’de işlemin adımları görüntülenmiştir.




Şekil 3.4. Trakeden truncusa ulaşma adımları

3.4. Ana Arterlerin Ayrıştırılması

Truncusun bulunduğu kesite ulaşılmasının ardından, truncus ve ana pulmonar arterler görüntü içinden ayrıştırılmıştır. Truncusun başlangıcı ile ayrı matrislere yerleştirilen arterler ayrı ayrı emboli adayı bölge için taranmıştır.

BT kesitleri bacak yönünden boyun tarafına doğru izlendiğinden, kesitin sağ tarafı hastanın sol tarafı olmaktadır. Bu nedenle kesitte sağ tarafta bulunan ana arter sol arter, sol tarafta bulunan ana arter ise sağ arter olarak isimlendirilmektedir. Çalışmada sağ ve sol ana arterler anatomik farklılıkları nedeniyle ayrı ayrı işleme alınmıştır. Şekil 3.5’de bir kesite ait arterler gösterilmiştir. Sol ana arter sağ ana arterden önce sonlanmaktadır.




Şekil 3.5. Sol (a) ve sağ (b) ana pulmonary arterler (3000)

Pulmonar arterlerin ayrı ayrı taranabilmesi için truncusun dallanma noktasından ikiye ayrılmasına gerek duyulmuştur. Bu amaçla truncus üzerinde otomatik olarak belirlenecek bir ayrıştırma noktası seçilmesine karar verilmiştir. Noktanın konumu dallanma noktasının doğru seçilmesine olanak tanıyacak şekilde olmalıdır. Bunun için truncusun alt kenarı bir eğri olarak ele alınıp, tepe noktası üzerindeki orta nokta en uygun ayrıştırma noktası olarak belirlenmiştir. Yöntemin ayrıntıları aşağıda anlatılmıştır;

Truncusun kenar çizgileri çıkartılmış ve alt kenar bir eğri olarak ele alınmıştır (Şekil 3.6, a ve b). Eğrinin tepe noktasının (x_0) y eksenindeki adresi y_1 ve tepe noktasına karşılık gelen y eksenindeki en küçük değer y_2 ise orta nokta y_0 (Şekil 3.6, c ve d). şöyle hesaplanır;

$$y_0 = (y_2 - y_1) / 2 \quad (3.1)$$



Şekil 3.6. Dallanma noktasının tespiti, kesit no; (a-b-c) 3113, (c-d-e) 3115

Şekil 3.7’de bir truncus görüntüsü (a) ve ana arterlerin ayrıştırılma sınırları (b) görülmektedir. Truncus görüntüsünden ayrı ayrı seçilen arterler aşağıdaki şekilde görülmektedir. Sol arter aşağı doğru yönlendirken sağ arter yana doğru biçimlenmektedir. Bu farklılık nedeniyle ayrı ayrı işleme alınmaları gerekmiştir.



Şekil 3.7. Truncusun seçilmesi ve arterlerin işaretlenmesi



Şekil 3.8. Ayrıştırılan a) sol arter b) sağ arter

3.5. Pulmonar Arterin İşlenmesi


Elde edilen (x_0, y_0) noktası truncusun dışında kalana kadar kesit kümesi okunarak truncus 3 boyutlu bir matrise yerleştirilmiştir. Ardından matris okunarak truncus ve arterler ayrı ayrı işlenmiştir. Yatay çizginin üst kısmında kalan truncus da ayrı bir program ile taranmıştır. Okunan kesitlerden secilen arterler üç boyutlu ayrı birer matrise yerleştirilerek işlenmişlerdir. Emboli taraması öncesinde, ele alınan bölgelerin çevre dokularla olan ilişkileri kesmek ve taramayı kolaylaştırmak için görüntülere morfolojik inceltme, açma ve boşlukları doldurma işlemleri uygulanmıştır. Her bir arter dallanma noktasına kadar takip edilmiştir.

İşlenecek bölgeler bağlı bileşen yöntemi ile bitişik yapılardan ayrıştırılmıştır. Ancak bu bütün bitişik dokuları arterler ayırmaya yetmemiştir. Pulmonar artere bitişik dokular ile arterler arasında kalan karanlık bölgeler emboli olarak tespit edilmektedir

ve FP oranını yükseltmektedir. Bunu önlemek amacıyla bitişik dokular aşağıda açıklandığı şekilde arterden ayrıştırılmıştır.

3.6. Bitişik Dokuların Çıkartılması

Sol taraftaki ana arterlerde, truncusa bağlı olmayan ancak konumlarından dolayı truncusa bitişik görünen dokular FP oranının artmasına neden olduğu için görüntüden çıkartılmıştır. Ayrıştırma işlemi için bir kenar takip algoritması geliştirilmiştir. Algoritma birbirini takip eden kesitlerde damarın daralmasını izlenmesi fikrine dayanır. Daralan damar içe doğru yönelmelidir, eğer damar kenarlarına dışa doğru bir artış varsa bu durum ayrıştırılması gereken bir bitişik doku olarak ele alınmıştır. İçe doğru daralan damar kenarlarındaki değişim oranı dikkate alınarak, ayrıştırılan doku yerine yeni kenarlar oluşturulmuştur. Şekil 3.9 (a)'da bir truncusun etrafındaki bitişik duran dokular görülmektedir, a ve b'de işlem öncesi sol arter yer almaktadır, c'de bitişik dokudan ayrıştırılmış arter görülmektedir.



Şekil 3.9. Bitişik dokuların çıkartılması (kesit no: 3129-261)

Dokuların görüntüden çıkartılması için kenar çizgilerde hızlı ve belli bir sayıda devam eden artış olup olmadığı araştırılmıştır. Eğer böyle bir artış bulunmuşsa, kenarlar artış öncesi değerler kadar seçilmiş, üstü görüntüden silinmiştir. Böylece bitişik dokular silinip yerine yeni bir üst kenar çizgisi yerleştirilmiştir. Bunun için

sadece y ekseninde pozitif olarak artan, x ekseninde ise sol arter için artan, sağ arter için azalan değerler dikkate alınmıştır.

Sağ taraftaki ana arterde bitişik dokuların neden olduğu karanlık bölgeler çevrelerindeki piksel değerleri kontrol edilerek ayrıştırılmaya çalışılmıştır. Bitişik dokuların konumları sol taraftan değişiktir, burada karanlık bölgelerin üst veya sağ taraflarında da karanlık bölgeler yer almaktadır. Bu koşul kontrol edilerek FP oranının artışı engellenmiştir.

3.7. Merkezi Embolinin Tespiti

Pulmonar emboli, truncus ve ana arterlerde birden farklı şekilde pozisyon alabilmektedir. Ana arter duvarına tutunabilmekte, dallanma noktasında veya truncusun içinde bulunabilmekte veya arter duvarına tutunup ana arterin ortasına doğru uzanabilmektedir. Merkezi emboli yoğunluk değeri ve konumlanma şekli ile tespit edilir. Truncusun ve ana arterlerin içinde emboliye benzetilebilecek başka bir doku bulunmamaktadır. Ancak çekimden kaynaklanan artifaktlar ve kontrast maddenin yayılım sorunları karanlık bölgeler oluşturmaktadır ve FP oluşumuna neden olmaktadır.


Pulmonary truncus ve ana arterlerde, damar duvarına tutunan veya damar içinde serbest hareket eden karanlık bölgeler aranmıştır. Truncus ve sol arter için soldan sağa doğru iki kenar çizgisi arasındaki bölge kontrol edilirken, sağ arter sağdan sola doğru sanal bir dikey çizgi boyunca taranmıştır. İkili görüntüde, iki kenar arasındaki piksel değeri toplamı, iki kenar arasındaki piksel sayısı ile karşılaştırılmıştır. Eğer aradaki fark 5'den fazla ise emboli adayı bir bölge olabileceği düşünülmüştür. İşlemin denklemi aşağıdaki gibidir;

$$(y_2 - y_1) - \sum_{i=y_1}^{y_2} I(x, y_i) < 5 \quad (3.2)$$

I görüntüsünün içinde, aynı x değerine sahip kenar noktalar y_2 ve y_1 'dir. Kenar noktalar arasındaki fark değeri, kenarlar arasındaki piksel değerinden en az 5 fazla ise, emboli adayı bölge 3 boyutlu analize aktarılır.

3.7.1. Damar duvarına tutunan emboli

Ana arterin içinde bulunan emboli parlak görünen damar çapında daralma olarak izlenmektedir. Buradan yola çıkarak damar çapındaki hızlı daralma tespit edilmiştir. Sol arterde emboli tespiti için, y eksenindeki pikseller en küçük değerinden başlanarak artan değerlere doğru yukardan aşağıya seçilmiş ve her y pikseline karşılık gelen x eksenindeki değerlerin, yani kenar piksellerin farkı hesaplanmıştır. Sağ arter için bunun tersi yapılmış, x eksenini büyük değerden küçüğe doğru azalan sırada seçilmiş ve y eksenindeki kenar piksel değerlerinin farkı hesaplanmıştır. Deneysel olarak kenar pikseller arasındaki fark sol arter için 15, sağ arter için 5 olarak belirlenmiştir. Şekil 3.10'da damar duvarına tutunan iki emboli örneği görülmektedir.



Şekil 3.10. Damar duvarına tutunan emboli (a) patient1, (b) patient5

3.7.2. Damar duvarına tutunmayan emboli

Pulmoner embolinin bir kısmı damar duvarına tutunup kalan uç noktaları damarın ortasında konumlanacak şekilde bulunabilmektedir. Veya çekim sırasında damar içinde ve duvara değmeden bulunabilmektedir. Sağ ve sol ana arterlerin duruşları birbirinden farklı olduğundan ayrı ayrı programlarla işlenmişlerdir. Önce sobel operatörüyle kenarlar seçilmiş ve sol arter için y eksenini, sağ arter için x eksenindeki kenarlar küçükten büyüğe sıralanmıştır. Sıralı veriler küçükten büyüğe tek tek seçilerek sol arter için x eksenindeki sütunlar, sağ arter için y eksenindeki satırlar ele alınmıştır. Sol arter için x eksenindeki satırlar toplanarak, satırın sonu ile başı arasındaki adreslerin farkı ile karşılaştırılmıştır. Sağ arter için ise y eksenindeki satırlar toplanarak, yine aynı şekilde satırın sonu ile başı arasındaki adreslerin farkı ile karşılaştırılmıştır. Burada amaç satır içinde 1'den farklı bir değerin olup

olmadığını tespit etmektir. Toplam ile adres farkı arasında fark varsa bir aday bölgenin bulunduğu varsayılmıştır. Aday bölgeyi kesinleştirmek için volüm (hacim) kontrolü yapılmıştır. Damar duvarına tutunmayan emboli örnekleri Şekil 3.11 b ve d’de yer almaktadır.




Şekil 3.11. Damar duvarına tutunmayan emboli (a) patient5, (b) patient3

3.7.3. Truncusun içindeki emboli

Truncus içindeki emboliyi tespit etmek için y ekseninde yukardan aşağı doğru satırlar ele alınmıştır. Her bir satırın toplam piksel sayısı ile iki kenarın x değerleri arasındaki fark karşılaştırılmıştır. Eğer bu değerler farklı ise bu durumda satırda aday bölge olabileceği düşünülmüş ve emin olmak için volüm kontrolü yapılmıştır. Dallanma noktasına gelindiğinde işlem sonlandırılmıştır. Ancak dallanma noktasını kaplayan ve eğer olarak adlandırılan bir emboli çeşidi bazı kesitlerde tespit edilememektedir.


Şekil 3.12’de görüldüğü gibi (a) ve (c) dallanma noktasına yerleşen emboliye “eğer emboli” adı verilmektedir. Şekil 3.12 (b) ve (d)’de truncus içinde büyük yer tutan ve damarı kapatan tam tıkalı emboli örnekleri görülmektedir. Örnekler (a) patient17, (b) patient8, (c) patient12, (d) patient4’e aittir.



Şekil 3.12. Truncusun içindeki emboli (a-c) “eğer emboli”, (b-d) tam tıkalı

3.7.4. Tam tıkalı ana arter

Ana arterlerin tam tıkalı olması durumu damar sonu ile karıştırılabilmektedir ve FN'lerin başlıca nedenidir. Şekil 3.13'de damarı tam olarak kapatan embolilere örnekler gösterilmiştir. Örnekler (a) patient10-133, (b) patient6-130'a aittir.




Şekil 3.13. Tam tıkalı ana arterler

Tam tıkalı arterler bazı durumda önceki veya sonraki kesitlerde damarın bir kısmını kaplar forma dönüşebilmektedir. Bu durumda, bu kesitler emboli olarak işaretlenebilmektedir. Şekil 3.14'de patient6'nın ilerleyen kesitte (132) işaretlenebilen bir kesiti örneklenmiştir.



Şekil 3.14. İşaretlenebilen tam tıkalı arter



Şekil 3.15. Ana arterde işaretlenen merkezi emboliler

3.7.5. Volüm kontrolü

Çalışmada emboli adayları tespit edilerek 3 boyutlu bir matrise yerleştirilmiştir. Son aşamada adayları kesinleştirmek için volüm kontrolü yapılmıştır. Burada, 2 kesitten daha az kesitte görüntülenen ve dikey ve yatay boyutları 2 pikselden küçük adaylar elenmiştir. Seçilen bölgelerin yoğunluk değerleri de kontrol edilerek, 900-1300 aralığındaki aday bölgeler seçilmiştir. Yoğunluk değerleri bölgelerin aritmetik ortalama değerleri hesaplanmıştır. Aday bölgeyi içeren matris $I(i,j)$, N ve M matris boyutları olarak m aritmetik ortalaması aşağıdaki formülle hesaplanmıştır;

$$m = \frac{\sum_{i=1}^N \sum_{j=1}^M I(i,j)}{N \times M} \quad (3.3)$$

Bu kontrollerden geçen bölge emboli olarak işaretlenmiştir. İşaretleme bölgenin orta noktasına bir noktasına kırmızı artı işareti koyularak yapılmıştır. Görüntü üzerinde işaretlenen bölgelere örnekler Şekil 3.15’da yer almaktadır. Örnekler (a) patient21-170, (b) patient15-187, (c) patient15-177, (d) patient3-207, (e) patient3-188, (f) patient5-150’ye aittir.

3.8. Değerlendirme

Çalışmada elde edilen sonuçların değerlendirilmesinde “doğruluk” yöntemi kullanılmıştır. Tüm veri kümesi içindeki kesitler bir radyolog tarafından incelenmiş, kesitlerdeki emboli bölgelerinin yerleri kaydedilmiştir. Geliştirilen sistemden elde edilen sonuçlar bu bilgilerle karşılaştırılmıştır. Tıbbi açıdan embolinin kaç kesitte görüldüğü ve hacmi dikkate alınmamaktadır. Bunun yerine varlığı ve bulunduğu yer önemsenmektedir. Bu nedenle geliştirilen sistemin doğruluğu incelerken, doktor tarafından belirlenmiş embolilerin buldukları bölgelerin sistem tarafından işaretlenmiş olması doğru tespit olarak değerlendirilmiştir.

Geliştirilen sistemle seçilen emboli adayları yukarıda anlatıldığı gibi volüm kontrolü sırasında kesit sayısı kontrolünden geçmektedir. Belirlenen kesit sayısının altındaki adaylar gürültü veya artefakt kabul edilerek elenmiştir. En uygun hassasiyet oranını tespit etmek için tüm vakalar kesit sayısı değiştirilerek çalıştırılmıştır. Bu amaçla kesit sayısı 1 ile 5 arasında değerler alacak şekilde, her bir vaka 5 kez çalıştırılarak tespit oranları Tablo 3.2’deki sonuç tablosunda listelenmiştir. Her bir kesit sayısı için elde edilen FP/vs (False Positive/vaka sayısı) ile hassasiyet oranları Tablo 3.3’de yer almaktadır.

Alınan sonuçlardan görüldüğü gibi kesit sayısı azaldıkça doğru tespitler 36’dan 56’ya çıkmış ancak yanlış tespit sayısı 33’den 82’ye önemli bir artış göstermiştir. Kesit sayısının artırılması yanlış tespitleri önemli oranda azaltmakta ancak doğru tespit sayısında da azalmaya neden olmaktadır.


Tablo 3.2. Sonuç tablosu

no	5			4			3			2			1		
	TP	FP	FN	TP	FP	FN	TP	FP	FN	TP	FP	FN	TP	FP	FN
1	0	0	1	0	0	1	1	1	0	1	1	0	1	1	0
2	1	4	0	1	4	0	1	4	0	1	4	0	1	5	0
3	1	5	0	1	5	0	1	6	0	1	8	0	1	10	0
4	1	0	1	1	0	1	1	0	1	1	1	1	1	1	1
5	1	2	0	1	3	0	1	3	0	1	3	0	1	4	0
6	1	2	1	1	2	1	1	4	1	1	4	1	2	4	0
7	0	0	2	0	0	2	1	0	1	1	0	1	1	0	1
8	3	1	0	3	1	0	3	2	0	3	2	0	3	4	0
9	2	1	0	2	1	0	2	1	0	2	1	0	2	3	0
10	1	4	0	1	5	0	1	5	0	1	5	0	1	7	0
11	1	2	0	1	2	0	1	3	0	1	3	0	1	4	0
12	1	2	1	1	2	1	1	2	1	1	2	1	2	2	0
13	0	1	2	0	1	2	2	1	0	2	1	0	2	1	0
14	1	0	0	1	0	0	1	0	1	1	0	0	1	1	0
15	1	0	0	1	0	0	1	0	0	1	0	0	1	0	0
16	0	0	2	0	0	2	2	0	0	2	0	0	2	0	0
17	1	1	1	1	1	1	1	2	1	1	2	1	1	2	1
18	1	0	0	1	0	0	1	0	0	1	0	0	1	1	0
19	0	1	1	1	1	0	1	1	0	1	1	0	1	1	0
20	3	0	0	3	0	0	3	2	0	3	2	0	3	3	0
21	3	1	1	3	2	1	3	2	1	3	2	1	4	3	0
22	2	1	0	2	1	0	2	1	0	2	1	0	2	2	0
23	2	1	0	2	1	0	2	1	0	2	1	0	2	2	0
24	0	0	2	0	0	2	1	0	1	1	0	1	1	0	1
25	0	0	2	0	0	2	1	0	1	1	0	1	2	0	0
26	0	0	2	0	0	2	1	0	1	1	0	1	2	0	0
27	0	0	2	1	0	1	2	4	0	2	5	0	2	7	0
28	2	1	1	2	1	1	2	2	1	3	2	0	3	3	0
29	1	0	1	1	0	1	1	1	1	1	1	1	2	2	0
30	2	0	0	2	0	0	2	1	0	2	1	0	2	4	0
31	2	2	0	2	2	0	2	2	0	2	2	0	2	3	0
32	2	1	1	2	1	1	2	2	1	2	2	1	3	2	0
T.	36	33	24	38	36	22	48	53	13	49	57	11	56	82	4

Tablo 3.3. Eşik değerlerine karşılık elde edilen hassasiyet ve FP/vs oranları

Eşik	5	4	3	2	1
FP/vs	1,03	1,13	1,66	1,78	2,56
Hassasiyet	0,60	0,63	0,79	0,82	0,93

Duyarlılık ile veri seti başına düşen yanlış pozitif miktarını gösteren, serbest yanıtli karar işletim karakteristiği FROC (Free-Response Receiver Operating Characteristic) eğrisi Şekil 3.16’da görülmektedir. Eğri, sonuç tablosunda verilen 5 eşik değeri üzerinden hesaplanmıştır. Eşik için seçilen parametre emboli adaylarının kesit sayısıdır ve 1 ile 5 arasında değerler almıştır.



Şekil 3.16. Toplam 32 vakaya ait duyarlılık FROC eğrisi

Bu çalışmada elde edilen sonuç değerler Tablo 3.4’de özetlenmiştir.

Tablo 3.4. Merkezi emboli tespit çalışmasının sonuçları

Veri sayısı	Toplam emboli sayısı	Bulunan emboli sayısı (TP)	Hatalı tespit sayısı (FP)	Bulunamayan emboli sayısı (FN)	FP/vs oranı	Hassasiyet
32	60	56	82	4	2,56	0,93

3.8.1. Literatürdeki çalışmaların verileri

Literatürde merkezi emboli tespitini içeren makaleler 3 gruba ayrılır;

1. Tıbbi açıdan tespit ve araştırma çalışmalarını içeren makaleler,
2. Bilgisayar yazılımı aracılığı (CAD) ile otomatik tespit yapılan makaleler,
 - a. Merkezi, segmental ve subsegmental pulmonar emboli
 - b. Segmental ve subsegmental pulmonar emboli
3. Geliştirilen yazılımların performansını inceleyen makaleler (Philips, Siemens ve R2 tech için)

Tıbbi makalelerden derlenen merkezi embolinin bulunma oranları Tablo 3.5’de listelenmiştir.

Tablo 3.5. Tıbbi makalelerde merkezi embolinin bulunma oranları

Makale	Hasta sayısı	Merkezi emboli bulunma oranı
Vedovati [11]	579	% 60
Sun [12]	88	%64
Kanne [13]	214	% 12,1
Remyjardin [14]	42	%46
Stein [15]	5233	%32
Furlan [17]	635	% 52,4

Kontrast maddenin yayılımına engel oluşturmuyorsa, damar duvarına tutunan ve kısmi tıkanıklığa neden olan büyük merkezi emboliler teşhiste gözden kaçabilmektedir. Tespitte gözden kaçma oranları radyoloji bölümlerinde tutulmamaktadır, ancak araştırma çalışmaları sırasında derlenerek değerlendirme makalelerinde yayınlanmaktadır. Tablo 3.6’da literatürde yayınlanan merkezi embolinin gözden kaçma oranları verilmiştir.

Tablo 3.6. Merkezi embolinin gözden kaçma oranları

Makale	Emboli vaka sayısı	Gözden kaçan merkezi emboli oranı
Blackmon [18]	13	% 15,4
Buhmann [19]	65	%4,6
Lim [20]	329	%0,91

Literatürdeki merkezi emboli tespit çalışmalarının başarı oranları Tablo 3.7’de listelenmiştir. Makalelerde belirtilmeyen sonuçlar tabloda “-“ işaretiyle ifade edilmiştir. Bouma’nın [76] çalışmasında sadece 2 merkezi emboli bulunmaktadır ve bu değerlendirme için düşük bir orandır. Blackmon [18], 13 merkezi emboli ile Bouma’dan sonraki en küçük merkezi emboli içeren veri kümesini kullanmıştır. Çalışmalarında, diğerlerinden farklı olarak hassasiyet dal bazında hesaplanmıştır. Buhman [19] 65 merkezi emboliye karşılık %74 hassasiyet elde etmiş ancak 17 olarak yüksek bir FP/vs oranı bildirmiştir. Engelke’nin [22] hassasiyet oranı %21 olarak çalışmaların içindeki en düşük orandır. En yüksek hassasiyet oranını bildiren Wittenberg’in [23] çalışmasında sadece 23 merkezi emboli içeren veri bulunmaktadır. Tez çalışmasında elde edilen hassasiyet oranı ve doğru tespit (TP) sayısı diğer çalışmalardan daha yüksektir. Bu durumda, çalışmanın doğru tespit açısından diğer çalışmalardan daha başarılı olduğu söylenebilir.

Tablo 3.7. Literatürdeki merkezi pulmonar emboli tespit oranları

Makale	Veri seti	Merkezi emboli sayısı	Hassasiyet oranı	TP sayısı	FN sayısı	FP sayısı	FP/vs oranı
Blackmon [18]	79	13	% 69,2	-	-	-	-
Buhman [19]	40	65	%74	48	17	56	1,4
Engelke [22]	56	72	%21	-	-	-	-
Wittenberg [23]	278	23	%87	20	3	-	-
Bouma [76]	19	2	%50	1	0	1	0,05
Tez çalışması	32	60	%93	56	4	82	2,56

Tablo 3.7’deki çalışmalar çok değişik sayıda veri içermektedir. Kullanılan yöntemle ilgili olarak, veri sayısı çalışma başarısını etkileyebilmektedir. Sınıflandırma veya ağaç kullanan yöntemlerde, doğru bir sonuç için veri sayısının yüksek tutulması tercih edilir. Tablo 3.7’deki çalışmaların içinde Blackmon [18] ve Bouma’nın [76] çalışmaları sınıflandırma yöntemi içermektedir. Bu tez çalışmasında kural tabanlı yöntem kullanıldığı için, veri sayısı başarıyı etkileyen bir faktör olmamıştır.

Diğer taraftan veri seti içindeki görüntülerin artifakt içerip içermemesi, iyi bir çekim olup olmaması tespit başarısını etkileyebilmektedir. Artifaktlardan ve çekimden

kaynaklanan istenmeyen karanlık bölgelerin, deęişen derecelerde deęerlendirmeye etkisi olduęu çeşitli alıřmalarda raporlanmıřtır [19,21].

Pulmonar emboli tespiti yapan bazı alıřmalar merkezi emboliyi de ele almakta ancak tespit oranlarını segmental emboli ile birlikte vermektedir. Fikir verici olması amacıyla bu makalelerdeki oranlara Tablo 3.8’de yer verilmiřtir.

Tablo 3.8. Literatürde merkezi emboliyi ieren alıřmaların tespit oranları

Makale	Veri seti	Emboli sayısı	TP sayısı	Hassasiyet	FP/vs	FP sayısı
Özkan [77]	33	450	428	%95,1	14,4	475
Tsai [78]	16	360	209	%58	3,8	62
Zhou [39]	14	94	63	%67	11,4	160
Engelke	58	1118-72	808	%72,2	4,1	238
Maizlin	104	45	24	%53	0,93	97

3.8.2. FP sayısı için literatürdeki alıřmalardan örnekler

Literatürdeki pulmonar emboli tespiti yapan bazı alıřmaların elde ettięi ve raporlarında açıka yazılan FP sayıları Tablo 3.9’da listelenmiřtir. İtalik font ile yazılan deęerler, makalede verilen dięer veriler üzerinden hesaplanmıřtır. Görüldüęü gibi FP sayısının, veri seti ve emboli sayısından yüksek olduęu alıřmalar mevcuttur.

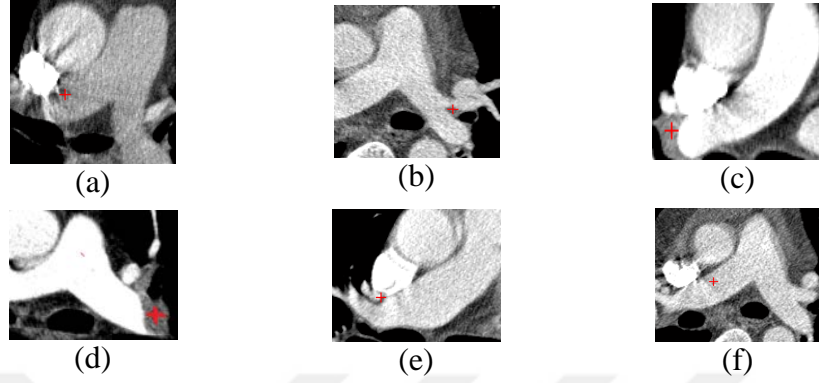
Tablo 3.9. Literatürdeki bazı alıřmaların FP sayıları ve dięer tespitler

Makale	Veri seti	Emboli sayısı	TP sayısı	FP sayısı	FN sayısı	Hassasiyet oranı	FP/vs
Ozkan [77]	33	338	305	448	33	%90,2	13,6
Bouma [76]	19	116	102	1197	14	63%	4,9
Blackmon [18]	79	119	73	258	46	%78	3,27
Buhman [19]	40	212	157	154	55	%74 M, %82	3,85
Dewailly [80]	74	93	80	354	13	%95	5,4
Park [81]	20	44	36	368	8	%81,9	18,4
Wittenberg [23]	278	377	257	1306	120	%87,78,79,61	4,7

3.8.3. alıřmadaki zorluklar


Merkezi emboli tespitinde birkaç zorlukla karşılařılmıřtır. Bunlardan ilki pulmonar arterlerin bazı kesitlerde çeşitli evre dokularla bitişik görülmesidir. Arterlerin bir

parçası gibi görünen bu dokular da emboli taramasına dahil olmakta ve hatalı emboli tespiti oluşabilmektedir. Aşağıdaki Şekil 3.17 (a)'da görülen superior vena cava birden çok kesitte artere bitişik olarak yer almaktadır.



Şekil 3.17. Hatalı tespitlere neden olan bitişik dokulara örnekler-1

İkinci olarak pulmonar arterlerle bitişik yapılar arasında oluşan nispeten karanlık bölgeler hatalı bir şekilde emboli olarak seçilebilmektedir. Bu duruma bir örnek Şekil 3.17 (b)'de ve şekil de görülmektedir. Üçüncü olarak pulmonar arterin çevresindeki lenf nodu gibi bazı dolular emboli ile aynı yoğunluk değerine sahip oldukları için, Şekil 3.17 (c)'de görüldüğü gibi FP oranını artırmaktadır. Arterler emboli ile tam tıkalı olduklarında damar sonu olarak belirlenebilmektedir. Tıkalı damarın Şekil 3.17(d)'de örneği yer almaktadır. Dördüncü olarak damar duvarına yapışan embolinin oluşturduğu daralma ile damarın doğal daralmasının ayırt edilmesi gerekmektedir. Şekil 3.17 (e)'de görüldüğü gibi doğal olarak daralan bir damar emboli olarak seçilmiştir. Son olarak düzgün olmayan çeperler, düşük görüntü kalitesi ve çeşitli artifaktlar FP'lere neden olabilmektedir. Şekil 3.18'de FP'lere neden olan bitişik dokulara örnekler verilmiştir.



Şekil 3.18. Hatalı tespitlere neden olan bitişik dokulara örnekler-2 (a) 3003, (b-c) 3002, (d) 3112

4. SONUÇLAR

Bu tez çalışması birinci bölümde açıklanan ve önemi vurgulanan iki kısımdan oluşmaktadır. İlk kısımda geliştirilen histogram tabanlı k-means algoritması ile akciğer bölütlenerek loblar elde edilmiştir. İkinci kısımda otomatik merkezi pulmonar emboli tespit eden bir sistem geliştirilmiştir.

İlk kısımda bütün akciğer bölgesini otomatik olarak bölütlemek için bölgenin özellikleri dikkate alınarak histogram tabanlı k-means algoritması geliştirilmiştir. Bölütleme sonunda akciğer lobları çevre dokulardan ayrı olarak elde edilmiştir. Bu yöntem akciğer bölgesinin bilgisayar destekli çeşitli analiz işlemlerinde ilk adım olarak kullanılabilir. Çalışmada üç farklı tomografi cihazından alınan toplam 20 kesit seti işlenmiştir. Yöntemin sağladığı kolaylıkla normalizasyon işlemi uygulanmadan görüntüler %96 başarı oranıyla bölütlenebilmiştir.

Geliştirilen yöntem ile elde edilen özellikler ve literatürdeki diğer çalışmalara göre farkları şöyle sıralanabilir:

- Bu yöntem, literatürde ilk defa akciğer bölütlemesinde kullanılmıştır. Diğer çalışmalardan [1-10] farklı olarak Başka yöntemlerle birleştirmeden tek başına akciğer bölgesini verimli olarak bölütleyebilmektedir.
- Noktalar arası uzaklıkları hesaplamak için geleneksel k-means yöntemindeki kartezyen sistem yerine histogram değerleri kullanılmıştır. Böylece aralarında bağlantı olmayan ve farklı yerlerde olan aynı tür dokuların aynı kümeye dahil olması sağlanmıştır.
- Histogram tabanlı k-means algoritması, Fuzzy C-means (FCM) ve optimal eşikleme yöntemleriyle karşılaştırıldığında iterasyon sayısı ve bölütleme doğruluğu açısından daha verimli bulunmuştur.
- Kullanılan ilk küme merkezi belirleme yöntemi ile boş küme oluşumu engellenmiştir ve iterasyon sayısı yaklaşık %75 oranında azaltılmıştır.

- Yöntem üç farklı cihazdan alınmış farklı yoğunluk değerlerine sahip görüntüleri bölütleyebilmesi açısından başarılıdır. Negatif ve farklı renk dağılımdaki görüntülerle çalışabilmektedir.
- Çalışma akciğer bölütleyerek lobları elde etmek için kullanılabilir.
- İşlem öncesi normalizasyon yapılmamıştır.
- Akciğer bölgesinin bölütlenmesinde kullanılan k-means yöntemi lobları bölütlemek için uygulanmıştır. Lob içindeki belirli yoğunlukların verilen küme sayısına bağlı olarak ana görüntüden çıkartılabildiği gözlenmiştir.

İkinci kısımda merkezi pulmonar emboli tespiti için geliştirilen çalışmada 32 vakaya ait veri kümesi kullanılmıştır. Geliştirilen sistem bir radyolog tarafından belirlenen 60 merkezi pulmonar embolinin 56 tanesini doğru tespit etmiş, 4 tanesini bulamamıştır. Tespit edilemeyen emboliler tam tıkalı damarlarda bulunmaktadır.

Merkezi pulmonar emboli tespiti için geliştirilen sistemin literatürdeki diğer çalışmalara göre bazı üstünlükleri ve farkları şu şekilde sıralanabilir:

- Literatürde merkezi emboli tespiti konusunda yapılan çalışmaların içinde en yüksek hassasiyet oranı %87 [23] olarak bildirilmiştir. Bu çalışmada %93 hassasiyet oranı elde edilmiştir. Bu durumda, çalışmanın doğru tespit açısından diğer çalışmalardan daha başarılı olduğu söylenebilir.
- Geliştirilen kural tabanlı algoritma yaklaşımı ile diğer çalışmalardan hesaplama maliyetini açısından daha verimlidir. Diğer çalışmalarda daha karmaşık algoritmalar kullanılmıştır ve bu durum işlem maliyetini ve çalışma süresini artırabilir.
- Pulmonar arterin kısmen tıkalı, tam tıkalı durumları ile truncusun dallanma noktasında olabilecek emboli durumları ele alınmıştır. Diğer çalışmalarda bu detaylar belirtilmemiştir.
- Merkezi emboli tespitinin ilk adımı olarak, kesit kümesi başlangıç kesitinden itibaren okunarak soluk borusu takip edilmiş ve soluk borusunun dallanma noktası içeren kesitte pulmonar otomatik olarak tespit edilmiştir. Kesit setinin okunmasından işaretli embolilerin görüntülenmesine kadar süren işlemler otomatik gerçekleştirilmiştir. Literatürdeki diğer çalışmalarda emboli aramasına

başlanılan kesite ulaşmak için bir yöntem geliştirildiğine dair bir bilgi bulunmamaktadır.

- Düşük görüntü kalitesi ve artefakt içeren kesitler de çalışmaya dahil edilmiştir. Böylece artefaktlardan kaynaklanabilecek hatalı tespitler ele alınmıştır. Literatürdeki bazı çalışmalarda bu tür kesitler çalışmaya dahil edilmemiştir. Artefaktlar geliştirilen yönteme bağlı olarak, yöntemin başarısını düşürebilmektedir.
- Diğer birçok çalışmanın tersine akciğer içinde bölütleme yapılmadan merkezi emboli tespiti gerçekleştirilerek, işlem maliyetinin ve çalışma süresinin düşük olması sağlanmıştır.
- Literatürde pulmonar emboli tespiti yapan çalışmalar çoğunlukla segmental emboli tespiti konusunda geliştirmiştir. Bu tez çalışması literatürde merkezi emboli tespiti içeren altıncı çalışmadır.
- Kullanılan yönteme bağlı olarak, veri sayısı çalışma başarısını etkileyebilmektedir. Bu tez çalışmasında kural tabanlı yöntem kullanıldığı için, veri sayısı başarıyı etkileyen bir faktör olmamıştır.

Merkezi pulmoner emboli tespiti için geliştirilen bu çalışma segmental emboli tespiti yapan bir sistemin bir parçası olarak çalışabilir.

KAYNAKLAR

- [1] Dhawan A., *Medical Image Analysis*, IEEE Press, Nevark, USA, 2003.
- [2] Isa N. A. M., Salamah, S. A., Ngah, U. K., Adaptive Fuzzy Moving K-Means Clustering Algorithm For Image Segmentation , *Consumer Electronics, IEEE Transactions*, 2009, **55**(4), 2145–2153.
- [3] Lee T., Fauzi M. F. A., Komiya R., Segmentation Of CT Brain Images Using K-Means and EM Clustering, *Conference Computer Graphics, Imaging and Visualization*, Malezya, 26 August 2008.
- [4] Wu M. N, Lin C. C, Chang C. C, Brain Tumor Detection Using Color-Based K-Means Clustering Segmentation, *Intelligent Information Hiding and Multimedia Signal Processing. IJHMSP. Third International Conference*, Taiwan, December 2007.
- [5] Ng H. P., Ong S. H., Foong K. W .C., Goh P. S., Nowinski W. L., Medical Image Segmentation Using K-Means Clustering and Improved Watershed Algorithm, *Image Analysis and Interpretation, IEEE Southwest Symposium*, Colorado, USA, 26 March 2006.
- [6] Kawata Y., Niki N., Ohmatsu H., Kusumoto M., Kakinuma R., Mori K., Nishiyama H., Eguchi K., Kaneko M., Moriyama N., Internal Structure Analysis of Pulmonary Nodules in Topological and Histogram Feature Spaces, *Image Processing, 2000. Proceedings. International Conference*, Vancouver, 10 September 2000.
- [7] Li X., A Volume Segmentation Algorithm For Medical Image Based On K-Means Clustering, *Intelligent Information Hiding and Multimedia Signal Processing, International Conference*, China, 15 August 2008.
- [8] Mauldin F. R., Levy J. H., Behler R. H., Nichols T. C., Marron J. S., Gallippi C.M., Blind Source Separation and K-Means Clustering for Vascular Arfi Image Segmentation, in Vivo and Ex Vivo, *Ultrasonics Symposium*, Canada, 6 October 2006.
- [9] Manjon V., Tohka J., Garcia M., Robust MRI Brain Tissue Parameter Estimation By Multistage Outlier Rejection, *Magnetic Resonance in Medicine*, 2008, **59**(4), 866-873.
- [10] Ivanovska T, Hegenscheid K.,Laqua R., Kühn J., Gläser S., Ewert R., Hosten N., Puls R., Völzke H., A Fast and Accurate Automatic Lung Segmentation and Volumetry Method For MR Data Used in Epidemiological Studies, *Computerized Medical Imaging and Graphics*, 2012, **36**(4), 281-293.

- [11] Vedovati M. C., Becattini C., Agnelli G., Kamphuisen P. W., Masotti L., Pruszczyk P., Casazza F., Salvi A., Grifoni S., Carugati A., Konstantinides S., Schreuder M., Golebiowski M., Duranti M., Multidetector CT Scan For Acute Pulmonary Embolism Embolic Burden and Clinical Outcome, *Chest*, 2012, **142**(6), 1417–1424.
- [12] Sun S., Semionov A., Xie X., Kosiuk J., Mesurole B., Detection Of Central Pulmonary Embolism On Non-Contrast Computed Tomography: A Case Control Study,. *The International Journal Of Cardiovascular Imaging*, 2014, **30**(3), 639–646.
- [13] Kanne J. P., Thoongsuwan N., Stern E. J., Detection Of Central Pulmonary Embolism On Computed Tomography Densitometry Images Before Computed Tomography Pulmonary Angiography, *Journal Of Computer Assisted Tomography*, 2003, **27**(6), 907–910.
- [14] Remyjardin M., Remy J., Wattinne L., Giraud F., Central Pulmonary Thrombo Embolism– Diagnosis With Spiral Volumetric CT With The Single Breath Hold Technique–Comparison With Pulmonary Angiography, *Radiology*, 1992, **185**(2), 381–387.
- [15] Stein P. D., Matta F., Musani M. H., Diaczok B., Silent Pulmonary Embolism in Patients With Deep Venous Thrombosis: A Systematic Review, *American Journal Of Medicine*, 2010, **123**(5), 426–431.
- [16] Musani M. H., Asymptomatic Saddle Pulmonary Embolism: Case Report and Literature Review,. *Clinical and Applied Thrombosis/Hemostasis*, 2011, **17**(4) 337–339.
- [17] Furlan A., Aghayev A., Chang C., Patil A, Jeon K. N., Park B., Fetzer D. T., Saul M., Roberts M. S., Bae K. T., Short-Term Mortality in Acute Pulmonary Embolism: Clot Burden and Signs Of Right Heart Dysfunction At CT Pulmonary Angiography, *Radiology* , 2012, **265**(1), 283-293.
- [18] Blackmon K., Florin C., Bogoni L., Mccain J., Koonce J., Lee H., Bastarrika G., Thilo C., Costello P., Salganicoff M., Schoepf U., Computer-Aided Detection Of Pulmonary Embolism At CT Pulmonary Angiography: Can It Improve Performance Of Inexperienced Readers?. *European Radiology*, 2011, **21**(6),1214-1223.
- [19] Buhmann S., Herzog P., Liang J., Wolf M., Salganicoff M., Kirchhoff C., Reiser M., Becker C. H., Clinical Evaluation of A Computer-Aided Diagnosis (CAD) Prototype For The Detection Of Pulmonary Embolism, *Academic Radiology*, 2007, **14**(6), 651-658.
- [20] Lim K., Kligerman S., Lin, C., White C., Missed Pulmonary Embolism on Abdominal CT, *American Journal Of Roentgenology*, 2014, **202**(1), 65-73.
- [21] Wittenberg R., Berger F. H., Peters J. F., Weber M., Van Hoorn F., Beenen L. F., Van Doorn M.M., Van Schuppen J., Zijlstra I. A., Prokop M., Acute

Pulmonary Embolism: Effect Of A Computer-Assisted Detection Prototype On Diagnosis-An Observer Study., *Radiology*, 2012, **262**(1), 305-313.

- [22] Engelke C., Schmidt S., Bakai A., Auer F., Marten K., Computer Assisted Detection Of Pulmonary Embolism: Performance Evaluation in Consensus With Experienced and Inexperienced Chest Radiologists., *European Radiology*, 2008, **18**(2), 298–307.
- [23] Wittenberg R., Peters J., Sonnemans J., Prokop M., Schaefer-Prokop C., Computer-Assisted Detection Of Pulmonary Embolism: Evaluation Of Pulmonary CT Angiograms Performed in An On-Call Setting, *European Radiology*, 2010, **20**(4), 801–806.
- [24] Seutens P., *Fundamentals Of Medical Imaging*, 2nd ed., Cambridge University Press, New York, USA, 2009.
- [25] Dougherty G., *Digital Image Processing For Medical Applications*, Cambridge University Press, New York, USA, 2009.
- [26] Han J., Data Mining For Image/Video Processing:, A Promising Research Frontier, *International Conference On Content-Based Image and Video Retrieval*, Canada, 2008.
- [27] Han J., Kamber M., *Data Mining: Concepts and Techniques*, 2nd ed., The Morgan Kaufmann Series, San Francisco, USA, 2006.
- [28] <http://en.wikipedia.org/wiki/lung>, (Ziyaret tarihi: 12 Kasım 2010).
- [29] <http://www.radiologyinfo.org> (Ziyaret tarihi: 12 Kasım 2010).
- [30] <http://www.tomografi.org> (Ziyaret tarihi: 15 Kasım 2010).
- [31] <http://www.turkrad.org.tr/toplum.php#19> (Ziyaret tarihi: 25 Kasım 2010).
- [32] <http://www.onlinefizik.com> (Ziyaret tarihi: 20 Kasım 2010).
- [33] <http://www.wikiradiography.com/page/ct+anatomy+--+chest> (Ziyaret tarihi: 12 Kasım 2010).
- [34] Ünlüer E., Denizbaşı A., Pulmoner Emboli Olgularında Tedavi Ve Yaklaşım, *Solunum Hastalıkları*, 2002, **13**, 67-72.
- [35] Castañer E., Gallardo X., Ballesteros E., Andreu M., Pallardó Y., Mata J. M., Riera L., CT Diagnosis Of Chronic Pulmonary Thromboembolism, *Radiographics*, 2009, **29**, 31–53.
- [36] Liang J. M., Bi J. B., Computer Aided Detection Of Pulmonary Embolism With Tobogganing and Multiple Instance Classification in CT Pulmonary Angiography, *20th International Conference On Information Processing in Medical Imaging*, Netherlands, 2007, **4584**, 630-641.

- [37] Oya J., Suzuki H., Kawata Y., Niki N., Sugiura T., Tanabe N., Takiguchi Y., Tatsumi Y., Developments of Thrombosis Detection Algorithm Using The Contrast Enhanced CT Images , *Medical Imaging, 2011: Computer-Aided Diagnosis*, Florida, 12 February 2011.
- [38] Furlan A., Patil A., Park B., Chang C. C., Roberts M. S., Bae K. T., Accuracy and Reproducibility Of Blood Clot Burden Quantification With Pulmonary CT Angiography , *American Journal Of Roentgenology* , 2011, **196**(3), 516-523.
- [39] Zhou C., Chan H. P., Patel S., Cascade P. N., Sahiner B., Hadjiiski L. M., Kazerooni E. A., Preliminary Investigation Of Computer-Aided Detection Of Pulmonary Embolism in Three-Dimensional Computed Tomography Pulmonary Angiography Images , *Academic Radiology*, 2005, **12**(6), 782-792.
- [40] Guo, Y., Zhou, C., Chan, H. P., Wei J., Aamer, J. W., Chughtai A., Sundaram B., Hadjiiski L. M., Patel S., Kazerooni E. A., Multiscale Intensity Homogeneity Transformation Method and Its Application To Computer-Aided Detection Of Pulmonary Embolism in Computed Tomographic Pulmonary Angiography (CTPA) , *Medical Imaging 2013: Computer-Aided Diagnosis*, Florida, 9 February 2013.
- [41] Buelow T., Wiemker R., Blaffert T., Lorenz C., Renisch S., Automatic Extraction Of The Pulmonary Artery Tree From Multi-Slice CT Data , *Proc. SPIE 5746, Medical Imaging, Physiology, Function, and Structure From Medical Images*, Canada, 14 April 2005.
- [42] Coursey C. A., Nelson R. C., Boll D. T, Paulson E. K., Ho L. M., Neville A., Marin D., Gupta R., Schindera S., Dual-Energy Multidetector CT: How Does It Work, What Can It Tell Us, and When Can We Use It in Abdominopelvic Imaging , *RadioGraphics*, 2010, **30**, 1037-1055.
- [43] Kanne J. P., Gotway M. B., Thoongsuwan N., Stern E. J., Six Cases of Acute Central Pulmonary Embolism Revealed on Unenhanced Multidetector CT of The Chest , *American Journal Of Roentgenology*, 2003, **180**(6), 1661-1664.
- [44] Quist M., Bouma H., Van Kuijk C., Van Delden O., Gerritsen F., Computer Aided Detection Of Pulmonary Embolism On Multi-Detector CT , *RSNA*, Chicago, USA, 2 December 2004.
- [45] Zhou C., Hadjiiski L. M., Patel S., Chan H. P., Chan B., Computerized Detection Of Pulmonary Embolism in 3D Computed Tomographic (CT) Images, *RSNA*, Chicago, USA, 2 December 2004.
- [46] Masutani Y., Macmahon H., Doi K., Computerized Detection Of Pulmonary Embolism in Spiral CT Angiography Based On Volumetric Image Analysis, *IEEE Trans Med Imaging*, 2002, **21**(12), 1517–1523.

- [47] Hong H., Lee J., MSCT Lung Perfusion Imaging Based on Multi-Stage Registration, *10th Iberoamerican Congress On Pattern Recognition, 2005 Progress in Pattern Recognition, Image Analysis and Applications*, Havana, Cuba, 18 November 2005.
- [48] Bi J., Liang J., Multiple Instance Learning Of Pulmonary Embolism Detection With Geodesic Distance Along Vascular Structure , *IEEE Conference On Computer Vision and Pattern Recognition*, Minneapolis, USA, 17 June 2007.
- [49] Buelow T., Wiemker R., Blaffert T., Lorenz C., Renisch S., Automatic Extraction Of The Pulmonary Artery Tree From Multi-Slice CT Data, *Medical Imaging Conference*, San Diego, USA, 12 February 2005.
- [50] Engelke C., Schmidt S., Auer F., Rummeny E. J., Marten K., Does Computer-Assisted Detection Of Pulmonary Emboli Enhance Severity Assessment and Risk Stratification in Acute Pulmonary Embolism?, *Clinical Radiology*, 2010, **65**(2), 137-144.
- [51] Bowyer K., Validation of Medical Image Analysis Techniques, Editors: Fitzpatrick J. M., Sonka M., *Handbook Of Medical Imaging Volume 2, Medical Image Processing and Analysis*, SPIE Press, USA, 567-700, 2000.
- [52] Kallergi M., Evaluation Strategies for Medical-Image Analysis and Processing Methodologies , Editors: Costaridou L., *Medical Image Analysis Methods*, Taylor and Francis Group, England, 434-464, 2005.
- [53] Farag A. A., Ahmed M. N., El-Baz A., Hassan H., Advanced Segmentation Techniques, Editors: Suri J., Wilson D., Laxminarayan S., *Handbook Of Biomedical Image Analysis, Volume I: Segmentation Models Part A*, Kluwer Academic/Plenum Publishers, New York, USA, 479-499, 2005.
- [54] Dhawan A., Image Segmentation and Feature Extraction, Editors: Dhawan A., Huang H., Kim D., *Principles and Advanced Methods in Medical Imaging and Image Analysis*, World Scientific Publishing Co. Pte. Ltd., Singapur, 197-224, 206-208, 2008.
- [55] Malik A., Choi T., A Novel Algorithm For Segmentation Of Lung Images, *7th International Symposium On Biological and Medical Data Analysis*, Thessaloniki, Greece, 7 December 2006.
- [56] Armato S., Sensakovic F., Automated Lung Segmentation For Thoracic CT, *Academic. Radiology*, 2004, **11**(9), 1011–1021.
- [57] Sluimer I., Schilham A., Prokop M., Ginneken B., Computer Analysis Of Computed Tomography Scans Of The Lung: A Survey, *IEEE Transactions On Medical Imaging*, 2006, **25**(4), 385-405.
- [58] Gonzales R., Woods R., *Digital Image Processing*, 2nd ed., Prentice Hall, New Jersey, USA, 2002.

- [59] Macqueen J., Some Methods For Classification and Analysis Of Multivariate Observations, *The Fifth Berkeley Symposium On Mathematical Statistics and Probability*, USA, 1967.
- [60] Berry M., Linoff D., *Data Mining Techniques: For Marketing, Sales and Customer Relationship Management*, 2nd ed., Wiley Publishing Inc., USA, 2004.
- [61] Böhm, C., Powerful Database Support For High Performance Data Mining, PhD Thesis, Ludwig-Maximilian University Faculty of Mathematic and Informatics, Münih, Germany, 2001.
- [62] Sturn A., Cluster Analysis For Large Scale Gene Expression Studies, Masters Thesis, The Institute For Genomic Research (TIGR), USA, 2000.
- [63] Haralick R. M., Kelly G. L., Pattern Recognition With Measurement Space and Spatial Clustering For Multiple Images, *Proceedings of The IEEE*, USA, 1969.
- [64] Pratt W., *Digital Image Processing*, 4th ed., John Wiley & Sons, Inc., New Jersey, USA, 2007.
- [65] Chen T., Chen Y., Chien S., Fast Image Segmentation Based On K-Means Clustering With Histograms in HSV Color Space, *10th IEEE Workshop On Multimedia Signal Processing*, Australia, 8 October 2008.
- [66] Rodrigues P., Giraldi G., Improving The Non-Extensive Medical Image Segmentation Based On Tsallis Entropy, *Pattern Analysis and Applications*, 2011, **14**(4), 369-379.
- [67] Hu S., Hoffman E., Reinhardt M., Automatic Lung Segmentation For Accurate Quantitation Of Volumetric X-Ray CT Images, *IEEE Transactions On Medical Imaging*, 2001, **20**(6), 490-498.
- [68] Sulaiman S., Isa N., Adaptive Fuzzy-K-Means Clustering Algorithm For Image Segmentation, *IEEE Transactions On Consumer Electronics*, 2010, **56**(4), 2661-2668.
- [69] Hartigan J., Wong M., Algorithm AS136: A K-Means Clustering Algorithm., *Applied Statistics*, 1979, **28**(1), 100–108.
- [70] Kreyszig E., *Introductory Functional Analysis with Applications*, John Wiley, USA, 1989.
- [71] Tan P., Steinbach M., Kumar V., *Introduction To Data Mining*, Pearson International, USA, 2005.
- [72] http://www.courses.psu.edu/for/for466w_mem14/ch11/HTML/sec1/ch11sec1_objfn.htm, (Ziyaret tarihi: 1 Aralık 2015).

- [73] Halkidi M., Vazirgiannis M., Clustering Validity Assessment: Finding The Optimal Partitioning of a Data Set., *IEEE International Conference On Data Mining*, California, USA, 29 November 2001.
- [74] Theodoridis S., Koutroubas K., *Pattern Recognition*, 4th ed., Academic Press, USA, 2008.
- [75] Liu J., Yang Y.H., Multiresolution Color Image Segmentation, *IEEE Transactions On Pattern Analysis and Machine Intelligence*, 1994, **16**(7), 689-700.
- [76] Bouma H., Sonnemans J. J., Vilanova A., Gerritsen F. A., Automatic Detection Of Pulmonary Embolism in CTA Images, *IEEE Transactions on Medical Imaging*, 2009, **28**(8), 1223–1230.
- [77] Özkan H., Osman O., Sahin S, Bos, A., A Novel Method for Pulmonary Embolism Detection in CTA Images, *Computer Methods and Programs in Biomedicine*, 2014, **113**(3), 757-766.
- [78] Tsai H., Chin C., Cheng Y., Intelligent Pulmonary Embolism Detection System, *Biomedical Engineering: Applications, Basis and Communications*, 2012, **24**(6), 471-483.
- [79] Maizlin Z. V., Vos P. M., Godoy M. C., Cooperberg P. L., Computer-Aided Detection of Pulmonary Embolism On CT Angiography: Initial Experience, *Journal Of Thoracic Imaging*, 2007, **22**(4), 324-329.
- [80] Dewailly M., Rémy-Jardin M., Duhamel A., Faivre J. B., Pontana F., Deken V., Bakai A. M., Remy J., Computer-Aided Detection of Acute Pulmonary Embolism With 64-Slice Multi Detector Row Computed Tomography: Impact of the Scanning Conditions and Overall Image Quality in The Detection of Peripheral Clots, *Journal Of Computer Assisted Tomography*, 2010, **34**(1), 23-30.
- [81] Park S., Chapman B., Zheng B., A Multistage Approach To Improve Performance of Computer-Aided Detection of Pulmonary Embolisms Depicted on CT Images: Preliminary Investigation, *IEEE Transaction On Biomedical Engineering*, 2011, **58**(6), 1519-1527.

KİŞİSEL YAYINLAR VE ESERLER

Dincer E., Duru N., Automatic Lung Segmentation By Using Histogram Based K-means Algorithm, *EBBT 2016 Conference, IEEE-EMB (Engineering in Medicine and Biology)*, Istanbul, Türkiye, 27 Nisan 2016.



ÖZGEÇMİŞ

Ş. Esra Dinçer 8/12/1966 tarihinde İstanbul'da doğdu. İlk, orta ve lise öğrenimini İstanbul'da tamamladı. 1983 yılında girdiği Yıldız Üniversitesi, Bilgisayar Bilimleri ve Mühendisliği bölümünden 1988 yılında mezun oldu. Bankacılık sektöründe yazılım uzmanı, proje sorumlusu olarak çeşitli yazılım projelerinin geliştirilmesinde görev aldı. 2004-2006 yılları arasında Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda Yüksek Lisans öğrenimini tamamladı. 2006 yılından bu yana Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda doktora öğrencisidir.

2002-2014 yılları arasında çeşitli vakıf üniversitelerinin Bilgisayar Mühendisliği Bölümlerinde öğretim görevlisi olarak dersler verdi. 2014-2015 yılları arasında Tübitak-BİDEB'den aldığı doktora araştırma bursu ile Arizona State University Biomedical Informatics bölümünde doktora tezinin son kısmını geliştirdi.