

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN VE PEKTORAL KAS BÖLGESİNİN
SÜPERPOZİSYON ETKİSİNİ DİKKATE ALARAK BELİRLENMESİ**

DOKTORA TEZİ

Elektronik Yük. Müh. Hayati TÜRE

**HAZİRAN 2021
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN VE PEKTORAL KAS BÖLGESİNİN
SÜPERPOZİSYON ETKİSİNİ DİKKATE ALARAK BELİRLENMESİ**

Elektronik Yük. Müh. Hayati TÜRE

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)"
Ünvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 19 / 05 / 2021

Tezin Savunma Tarihi : 22 / 06 / 2021

Tez Danışmanı : Prof. Dr. TEMEL KAYIKÇIOĞLU

Trabzon 2021

ÖNSÖZ

Bilgisayar destekli tespit (BDT) sistemleri, teşhis aşamasında radyologlara destek verecek faydalı çıkarımlar sağlaması, karar vermeyi hızlandırması, insan hatasının teşhisteki yerini azaltması ve sağlık sektöründe maliyetleri azaltması gibi avantajlarından dolayı önem kazanmıştır. Bu tez çalışmasında mamografi görüntülerindeki, kitlelerin ve pektoral kas bölgesinin süperpozisyon etkisini dikkate alarak belirleyen bir BDT sistemi geliştirilmiştir.

Tez çalışması süresince bilimsel desteği ve değerli düşünceleriyle bana her konuda ve her aşamada yardımlarını esirgemeyen danışmanım Prof. Dr. Temel KAYIKÇIOĞLU ve yine tez çalışmam süresince değerli katkılarından ötürü Prof. Dr. Ali GANGAL ve Prof. Dr. Cemal KÖSE'ye teşekkür ederim.

Doktora eğitimim boyunca değerli bilgi ve manevi desteğiyle her zaman yanımda olan akademisyen arkadaşlarıma, hoşgörülerinden dolayı mesai arkadaşlarıma şükranlarımı sunarım. Eğitim hayatım boyunca sabır, destek ve sevgileriyle her zaman yanımda olan sevgili aileme çok teşekkür ederim.

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı'nda hazırlanan bu tezin bundan sonraki bu alandaki çalışmalara katkı sağlamasını temenni ederim.

Hayati TÜRE

Trabzon 2021

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Mamografi Görüntülerindeki Kitlelerin ve Pektoral Kas Bölgesinin Süperpozisyon Etkisini Dikkate Alarak Belirlenmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Temel KAYIKÇIOĐLU’nun sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 22/06/2021.

Hayati TÜRE

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ.....	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Meme Anatomisi	3
1.3. Meme Kanseri Tespiti İçin Kullanılan Görüntüleme Yöntemleri	4
1.3.1. Mamografi	4
1.3.2. Tomosentez.....	8
1.3.3. Manyetik Rezonans Görüntüleme	9
1.3.4. Ultrasonografi	9
1.4. Mamografi Görüntü Veri Tabanları	10
1.4.1. DDSM Veri Tabanı	11
1.4.2. CBIS-DDSM Veri Tabanı	11
1.4.3. MIAS Veri Tabanı	12
1.4.4. INbreast Veri tabanı.....	12
1.4.5. Derin Öğrenme İçin Hazırlanan Büyük Veri Tabanları	13
1.4.5.1. Dijital Mamografi DREAM Challenge	13
1.4.5.2. Cohort of Screen-Aged Women Veri Tabanı	14
1.4.5.3. OPTIMAM Tıbbi Görüntü Veri Tabanı	14
1.4.6. Özel Veri Setleri	14
1.5. Mamografi Görüntüleri İçin BDT Sistemleri	15
1.5.1. Ticari Amaçlı BDT Sistemleri.....	19
1.5.1.1. R2 ImageChecker	19
1.5.1.2. Danum International; CyclopusCAD Mammo	20
1.5.1.3. ICAD; SecondLook , PowerLook Tomo Detection	20
1.5.1.4. ScreenPoint Transpara	21
1.5.1.5. Threepalmsoft; CadOne, WorkstaionOne	22

1.5.1.6.	Therapixel; MammoScreen	23
1.5.1.7.	Kheiron Medical Technologies, MIA.....	24
1.5.2.	Akademik Amaçlı BDT Sistemleri.....	25
1.5.2.1.	Pektoral Kas Sınırı Belirleyen Akademik Çalışmalar	25
1.5.2.2.	Şüpheli Bölgeleri Belirleyen Akademik Çalışmalar	30
1.6.	Tezin Amacı ve Kapsamı	34
2.	YAPILAN ÇALIŞMALAR.....	41
2.1.	Önerilen Yöntem	41
2.2.	Görüntü Ön İşleme Adımları	43
2.2.1.	Meme Bölgesi Seçimi ve Arka Plan Çıkarma	43
2.2.2.	Görüntü Normalizasyonu	45
2.2.3.	İki Boyutlu Gabor Süzgeci	45
2.3.	Şüpheli Bölgelerin Belirlenmesi ve Bölütlenmesi.....	48
2.3.1.	Çoklu Eşik Seviye ile İlgili Bölgelerinin Belirlenmesi	48
2.3.2.	İlgili Bölgelerinin Topoğrafik Harita Üzerinden OHS ile Belirlenmesi.....	56
2.3.3.	EEKTS Yöntemi İçin Kural Tablosunun Oluşturulması.....	60
2.3.4.	EEKTS Yöntemi ile Şüpheli Bölgelerin Bölütlenmesi	63
2.4.	Kitlelerin Belirlenmesi	65
2.4.1.	Doku Öznitelikleri Hesaplanması.....	66
2.4.2.	Yuvalama Değeri Tabanlı Öznitelik.....	70
2.5.	EEKTS Yöntemi ile Pektoral Kas Bölütlemesi	71
2.5.1.	Bloklara Ayırma İşlemi	72
2.5.2.	Aday Sınır Parçalarının Belirlenmesi	74
2.5.2.1.	Konum Tabanlı Öznitelikler	76
2.5.2.2.	Geometrik Tabanlı Öznitelikler.....	77
2.5.2.3.	Topoğrafik Tabanlı Öznitelikler	78
2.5.2.4.	Kural Tablosunun Oluşturulması.....	78
2.5.3.	Yanlış Aday Sınır Parçalarını Eleme	80
2.5.4.	Pektoral Kas Parçalarının Birleştirilmesi	86
3.	BULGULAR VE İRDELEME	91
3.1.	EEKTS Yöntemi ile Şüpheli Bölgelerin Belirlenmesi İçin Yapılan Deneyler. 94	
3.1.1.	Niceliksel Sonuçlar ve Değerlendirmesi	94
3.1.2.	Niteliksel Sonuçlar ve Değerlendirmesi	96
3.2.	Kitlelerin Belirlenmesi İçin Yapılan Deneylerin Değerlendirmesi	101
3.3.	EEKTS Yöntemi ile Pektoral Kas Bölütlenmesi İçin Yapılan Deneyler	106
3.3.1.	Blok Sayısının EEKTS Yöntemine olan Etkisinin İncelenmesi.....	107

3.3.2.	Niceliksel Sonular ve Deęerlendirmesi	110
3.3.3.	Niteliksel Sonular ve Deęerlendirmesi	113
3.4.	Pektoral Kas Blgesi ile Sperpozisyon Olan Kitlelerinin İncelenmesi	115
4.	SONULAR.....	122
5.	ÖNERİLER	124
6.	KAYNAKLAR.....	125
ÖZGEÇMİŐ		



Doktora Tezi

ÖZET

MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN VE PEKTORAL KAS
BÖLGESİNİN SÜPERPOZİSYON ETKİSİNİ DİKKATE ALARAK BELİRLENMESİ

Hayati TÜRE

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Temel KAYIKÇIOĞLU
2021, 136 Sayfa

Bu tez çalışmasında, mamografi görüntülerindeki kitleleri ve pektoral kas bölgesini süperpozisyon etkisini dikkate alarak belirleyen yeni bir yaklaşım önerilmektedir. Süperpozisyona uğramış şüpheli bölgelerin belirginliğini artırmak için önce, dört farklı yöndeki Gabor filtreleri kullanılmış ve daha sonra topoğrafik haritaları oluşturulmuştur. Bu haritalar üzerindeki ilgi alanlarını belirlemek için Eş Yükselti Eğrilerinin Kural Tabanlı Sınıflandırılması (EEKTS) yöntemi geliştirilmiştir. Bu yöntemde; ilgi bölgelerini belirlemek için optimum hayat süresi (OHS) içerisinde bulunan eş merkezli yükselti bölgelerinden hesaplanan yuvalama derinliği morfolojik, parlaklık ve doku öznitelikleri kullanılmaktadır. EEKTS yönteminin başarısını süperpozisyon etkisi altında kalan bozulmuş pektoral kas bölgeleri üzerinde artırmak için topoğrafik harita bloklara ayrılmıştır. Bu sayede, bozulmanın etkisi bloklar halinde lokalize edilir ve sağlam olan pektoral kas sınırı parçalarının spesifik desenlerine sahip kontur dizisi ortaya çıkar. EEKTS yöntemi, belirginliği düşük olan kitle ve pektoral kas sınırı örneklerini yüksek doğrulukta tespit etmektedir. Literatürde yer alan pektoral kas bölgesi çıkaran BDT yazılımları, süperpozisyon sonucu bu bölge içerisinde olabilecek kitleleri ihmal etmişlerdir. Bu tez çalışması kapsamında pektoral kas bölgesinin çıkarıldıktan sonra kitle tespit işlemi yapılmasının, EEKTS yönteminin performansına olan etkisi detaylıca incelenmiştir.

Anahtar Kelimeler: Topoğrafik Belirginlik, Süperpozisyon, Eş düzey kontur, Gabor filtre, Minimum yuvalama derinliği, Optimum hayat süresi.

PhD. Thesis

SUMMARY

DETECTION OF MASSES AND THE PECTORAL MUSCLE REGION IN
MAMMOGRAPHY IMAGES CONSIDERING THE SUPERPOSITION EFFECT

Hayati TÜRE

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical-Electronic Engineering Graduate Program
Supervisor: Prof. Dr. Temel KAYIKÇIOĞLU
2021, 136 Pages

In this thesis, a new approach is proposed that determines masses in mammography images and the pectoral muscle region, taking into account the superposition effect. In order to increase the prominence of superpositioned regions, four different directions of Gabor filters are first used, and then topographic maps are formed. In this study, the Rule Based Classification of Isocontour Lines (RBCI) method is developed to determine regions of interest in the topographic maps. In this method, the nesting depth, morphological, intensity, and texture features calculated from the concentric isocontours within Optimum Lifetime (OLT) are used to detect the ROIs. The topographic map is divided into blocks to increase the success of the RBCI method on the distorted pectoral muscle regions under the effect of superposition. In this way, the effect of the distortion is localized in blocks and the sequence of contours with specific patterns of the undistorted pectoral muscle border parts are revealed. The suspicious regions with low prominence are detected with high accuracy using the developed the RBCI method. Studies in the literature that performed pectoral muscle region removal did not take into account the masses that were superpositioned with the pectoral muscle region. Within the scope of this thesis, the performance of the RBCI method in these situations examined in detail.

Keywords: Topographic prominence, Superposition, Isocontour, Gabor filter, Minimum nesting depth, Optimum lifetime.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. Kanser tiplerinin dünya genelinde (a) görülme ve (b) ölüm oranı [1].	1
Şekil 1.2. Birleşik Krallık üzerinden alınan meme kanseri ölüm istatistikleri [10].	3
Şekil 1.3. Meme Anatomisi [6].	4
Şekil 1.4. (a) Mamografi Cihazı [9] (b) ve (c) süperpozisyon projeksiyonları	5
Şekil 1.5. Mamografi görüntüsü üzerindeki anatomik yapılar	7
Şekil 1.6. Farklı yoğunluklardaki memeler için mamografi görüntüleri.	7
Şekil 1.7. Aynı kitlenin (a) Mamografi ve (b) Tomosentez görüntüleri [13].	9
Şekil 1.8. (a) AI sistemi ve (b) radyologlar arasındaki tutarsızlıklar [40].	17
Şekil 1.9. BDT uygulamalarındaki sınırlamalar ve zorluklar [41].	18
Şekil 1.10. (a) Belirgin olmayan bir kitlenin, (b) iyileştirilmiş görüntüsü [54].	21
Şekil 1.11. Bir kitlenin MLO ve CC görünümündeki MammoScreen çıktısı [71].	24
Şekil 1.12. Geleneksel BDT sistemlerinde kullanılan başlıca yöntemler.	31
Şekil 1.13. Belirginliği düşük kitle tipleri	35
Şekil 1.14. Bozulmuş pektoral kas bölgesi tipleri	36
Şekil 1.15. Çalışmanın genel akış şeması.	39
Şekil 2.1. EEKTS yöntemi ile pektoral kas bölütlenmesi için akış diyagramı.	41
Şekil 2.2. EEKTS Yöntemi ile şüpheli bölgelerin belirlenmesi için akış diyagramı	42
Şekil 2.3. Meme bölgesinin belirlenmesi için işlem aşamaları. (a) orijinal görüntü, (b) eşiklenmiş görüntü, (c) en büyük nesne seçimi, (d) kırılmış meme görüntüsü	44
Şekil 2.4. Farklı ölçeklerde ve farklı yönlerde elde edilen Gabor süzgeçleri.	46
Şekil 2.5. (a) 0°, (b) 45°, (c) 90°, (d) 135° için Gabor filtre çıktıları	47
Şekil 2.6. Örnek mamografi görüntüsü için 3B yüzey haritası (a) tüm meme bölgesi (b) kitle, (c) ve (d) benzeri nesnelere	49
Şekil 2.7. Farklı eşiklerdeki ilgi bölgelerinin (a), (b) 2B ve (c), (d) 3B görünümü	50
Şekil 2.8. Gerçek kitle ve Sentetik kitle için sırasıyla (a) , (b) 3B parlaklık dağılımı ve (c), (d) yumuşatılmış görünüşleri	51
Şekil 2.9. Sentetik kitle görüntüsü için (a) 2B ve (b) 3B parlaklık değişimi gösterimi	52
Şekil 2.10. Eşik seviyesi küçülürken ilgi bölgelerinin değişimi.	53
Şekil 2.11. Eşik seviyesi büyürken değişirken ilgi bölgelerinin değişimi	54
Şekil 2.12. Sentetik 4 adet kitle görüntüsü için eşikleme yöntemlerindeki ilgi bölgeleri	55
Şekil 2.13. Sentetik 13 adet kitle görüntüsü için farklı eşikleme yöntemleri ile tespit edilen ilgi bölgeleri	56

Şekil 2.14. Sentetik 4 adet kitle görüntüsü için farklı seviyelerdeki yükselti bölgeleri değişimi ile tespit edilen ilgi bölgeleri	58
Şekil 2.15. Sentetik 13 adet kitle görüntüsü için farklı seviyelerdeki yükselti bölgeleri değişimi ile tespit edilen ilgi bölgeleri	59
Şekil 2.16. DDSM veri tabanındaki kitleler için morfolojik özneliklerin histogram dağılımları.....	61
Şekil 2.17. DDSM veri tabanındaki kitleler için parlaklık özneliklerin histogram dağılımları.....	62
Şekil 2.18. Ön işlenmiş örnek mamografi görüntüsü için (a) 2B görünümü, (b) topoğrafik haritası, (c) EEKTS yöntemi sonucu	64
Şekil 2.19. Örnek bir kitle için (a) 2B görünümü, (b) Gabor 0° (c) Gabor 45° Filtre uygulandıktan sonra Topoğrafik Haritaları	65
Şekil 2.20. Örnek bir görüntü üzerinde gri seviye eş düzey matrisinin oluşturulması; (a) Yönlerin gösterilmesi (b) Görüntü (c) Gri seviye eş oluşum matrisi.....	67
Şekil 2.21. (a) Kitle (b) ve (c) kitle benzeri nesnelere için EEKTS ile bölütlenme sonuçlarının eş merkezli yükselti ile topoğrafik harita üzerinde gösterilmesi.....	71
Şekil 2.22. Bozulmuş pektoral kas sınırı içeren örnek mamografi görüntüsü için (a) 2B görünümü, (b) Topoğrafik harita gösterimi ve (c) bloklara ayrılması	73
Şekil 2.23. Eğri şeklinde Pektoral kas içeren örnek bir mamografi görüntüsü için (a) 2B görünümü, (b) radyolog tarafından çizilen pektoral kas sınırı ve (c) düz çizgi ile bölütleme sonuçları	74
Şekil 2.24. (a) ilk blok, (b) Sıralı konturlar ve (c) aday pektoral kas sınır parçaları	75
Şekil 2.25. Aday sınır parçası ve komşu konturların (a) bir blok için ve (b) tüm bloklar için koordinat sistemi	76
Şekil 2.26. Aday sınır parçalarının bulunması için akış diyagramı	79
Şekil 2.27. (a) Aday sınır parçaları için durum bilgileri ve (b) pektoral kas sınırı.....	81
Şekil 2.28. Pektoral kas bulunmayan blokların ortadan kaldırılması için.....	82
Şekil 2.29. Optimum yol haricinde kalan diğer aday sınırlarının kaldırılması için.....	83
Şekil 2.30. Optimum yol seçimi için akış diyagramı.....	84
Şekil 2.31. Örnek mamografi görüntüsü için aday sınır parçalarının eleme işlemlerindeki (a) Algoritma 1 çıktısı, (b) Algoritma 2 çıktısı, (c) Algoritma 3 çıktısı	85
Şekil 3.1. EEKTS yöntemi ile tespit edilen belirginliği düşük kitleler	98
Şekil 3.2. EEKTS yöntemi ile tespit edilemeyen belirginliği çok düşük kitleler.....	100
Şekil 3.3. Kısmi yansıma görüntüsü eklenen mamografi görüntüleri	101
Şekil 3.4. Tüm öznelikler için farklı sınıflandırıcıları metodlarının ROC Eğrileri.....	102
Şekil 3.5. Farklı boyuttaki çerçeveler ve EEKTS ile belirlenen bölütlenmiş bölge üzerinden alınan doku öznelikleri için ROC Eğrileri.....	103

Şekil 3.6. İstatistiksel özneliklerin gruplandırılması ile oluşturulan ROC Eğrileri	104
Şekil 3.7. Örnek mamografi görüntüleri için tek bir düz çizgi ile pektoral kas bölütlenmesindeki hata oranları. DP, YP ve YN bölgeler sırasıyla kırmızı, mavi ve yeşil renkleri ile gösterilmektedir.....	108
Şekil 3.8. Blok sayısının pektoral kas bölütlenmesine etkisi. Bölütleme hata oranları sırasıyla (YP ve YN) mavi ve yeşil renkleri ile gösterilmektedir. (a) mdb 44, (b) mdb 75, (c) mdb 111, (d) mdb 112, (e) mdb 115, (f) Veri setindeki tüm görüntüler	110
Şekil 3.9. Bölütleme Hata oranları için görüntülerin istatistiksel dağılımları.....	112
Şekil 3.10. (a-l) MIAS ve (m-p) INbreast veri tabanından alınmış bozulmuş pektoral kas örnekleri için EEKTS , Hough ve Gabor yöntemleri ile radyologlara ait bölütleme sonuçları sırasıyla sarı, mavi, yeşil ve kırmızı renkleri ile gösterilmektedir	114
Şekil 3.11. MIAS veri tabanında yer alan pektoral kas ile süperpozisyon.....	116
Şekil 3.12. INbreast veri tabanında yer alan pektoral kas ile süperpozisyon olmuş kitle örnekleri içeren MLO mamografi görüntüleri.....	117
Şekil 3.13. DDSM veri tabanında yer alan pektoral kas ile kısmen süperpozisyon olmuş kitle örnekleri içeren MLO mamografi görüntüleri.....	118
Şekil 3.14. DDSM veri tabanında yer alan pektoral kas ile tümüyle süperpozisyon olmuş kitle örnekleri içeren MLO mamografi görüntüleri.....	119

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Meme yoğunluğunu gösteren BIRADS kategorileri	6
Tablo 1.2. Meme üzerinde bulunan şüpheli bölgeler için BIRADS Sınıflandırması	16
Tablo 1.3. Pektoral kas bölgesi bölütleyen literatürdeki öncü BDT çalışmaları	27
Tablo 1.4. Kitlelerin belirlenmesi üzerine yapılan literatürdeki öncü BDT çalışmaları	32
Tablo 2.1. Farklı boyuttaki sentetik kitleler için parlaklık seviyesi değişimleri	52
Tablo 2.2. EEKTS yöntemi için kural tablosu.....	63
Tablo 3.1. Performans değerlendirmesinde kullanılan metrikler	91
Tablo 3.2. EEKTS yönteminin farklı parametreler için performans değerlendirmesi	95
Tablo 3.3. Belirginliği düşük kitlelerin yer aldığı mamografi görüntüleri	97
Tablo 3.4. Belirginliği çok düşük kitlelerin yer aldığı mamografi görüntüleri	101
Tablo 3.5. Kitle belirleme işlemi yapan BDT sistemlerinin performans sonuçları	106
Tablo 3.6. MIAS veri tabanından seçilen 84 görüntü için EEKTS ve bu alandaki bazı BDT çalışmalarının performans sonuçları	111
Tablo 3.7. INbreast veri tabanı için EEKTS yöntemi ve bu alandaki bazı BDT çalışmalarının performans sonuçları.....	112
Tablo 3.8. Hough, Gabor ve EEKTS yöntemlerinin örnek bozuk pektoral kas görüntülerinin her biri için ayrı ayrı performans sonuçları	113
Tablo 3.9. Hough, Gabor ve EEKTS metotlarının örnek bozuk pektoral kas görüntüleri için performans sonuçları.....	113

SEMBOLLER DİZİNİ

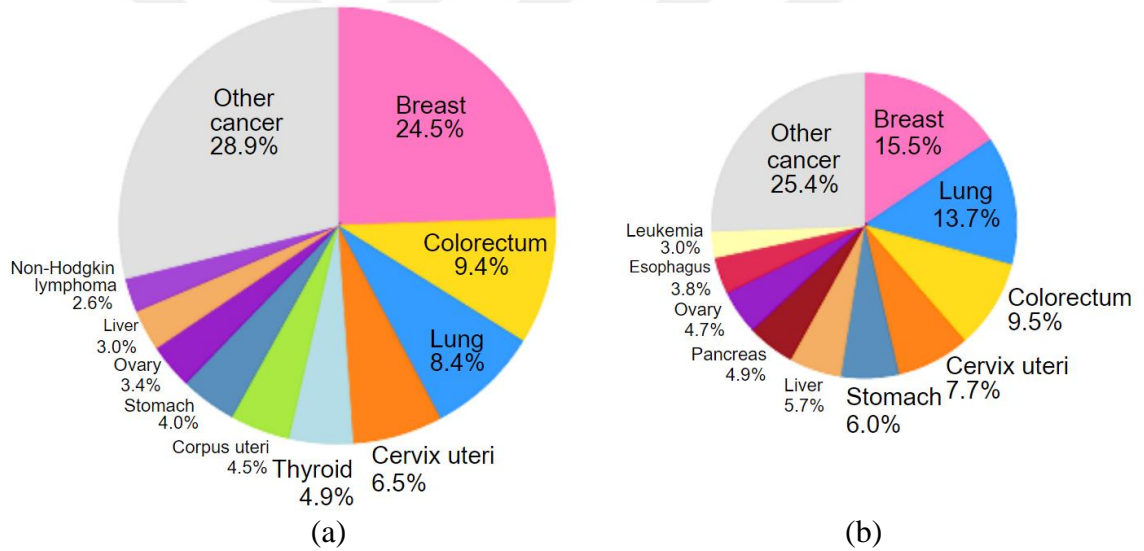
AI	: Artificial Intelligence
AP	: Adaptive Pyramids
ASM	: Aile Sağlığı Merkezleri
AUC	: Area under the ROC Curve
BBE	: Bağlı Bileşen Etiketleme
BDT	: Bilgisayar Destekli Tespit
BIRADS	: Breast Imaging Reporting and Data Systems
CAD	: Computer Aided Detection
CC	: Craniocaudal
CE	: Conformité Européene
CBIS	: Curated Breast Imaging Subset
CSAW	: Cohort of Screen-Aged Women
CNN	: Convolutional Neural Network
DAFL	: Deep Active Learning
DDSM	: The Digital Database for Screening Mammography
DICOM	: Digital Imaging and Communications in Medicine
DL	: Deep Learning
DN	: Doğru Negatif
DOG	: Doğruluk
DP	: Doğru Pozitif
DUY	: Duyarlılık
DVM	: Destek Vektör Makineleri
EKK	: En Küçük Kareler
EEKTS	: Eş Yükselti Eğrilerinin Kural Tabanlı Sınıflandırılması
FCN	: Fully Convolution Network
FDA	: Food and Drug Administration
FPN	: Feature Pyramid Network
GLCM	: Gray Level Co-occurrence Matrix
GSEM	: Gri Seviye Eş oluşum Matrisi
İAB	: İlgi Alan Bölgesi
KES	: Kesinlik

KETEM : Kanser Erken Teşhis, Tarama ve Eğitim Merkezleri
LJPEG : Lossless Joint Photographic Experts Group
MIL : Multiple-Instance Learning
MLO : Mediolateral Oblique
MR : Manyetik Rezonans
MIAS : The Mammographic Image Analysis Society
MST : Minimum Spanning Trees
MND : Minimum Nesting Depth
MYD : Minimum Yuvalama Derinliği
NHS : National Health Service
KNN : K-Nearest Neighbors
HS : Hayat süresi
OKS : Optimum Kontur Seçme
OHS : Optimum hayat süresi
OLT : Optimum life time
OMI-DB : OPTIMAM Medical Image Database
RBCI : Rule Based Classification of Isocontour Lines
RMSE : Root Mean Square Error
ROI : Region of interest
SHM : Sağlıklı Hayat Merkezleri
SPL : Self-Paced Learning
US : Ultrason
USH : Ulusal Sağlık Hizmeti
WHO : World Health Organization
YD : Yuvalama Derinliği
YN : Yanlış Negatif
YP : Yanlış Pozitif
YSA : Yapay Sinir Ağları
YZ : Yapay Zekâ

1. GENEL BİLGİLER

1.1. Giriş

Meme kanseri, Şekil 1.1 'de gösterilen, "The Global Cancer Observatory (GCO)" 2020 yılında yapılan istatistiklere göre, kadınlar arasında en sık karşılaşılan ve en çok ölüme sebep veren kanser türüdür [1]. Ayrıca, önümüzdeki yıllarda gelişmekte olan dünyanın getireceği yaşam süresinin artması, kentleşmenin artması ve batı yaşam tarzlarının benimsenmesi vb. bazı sonuçlar meme kanseri görülme sıklığını daha da artıracaktır [2].



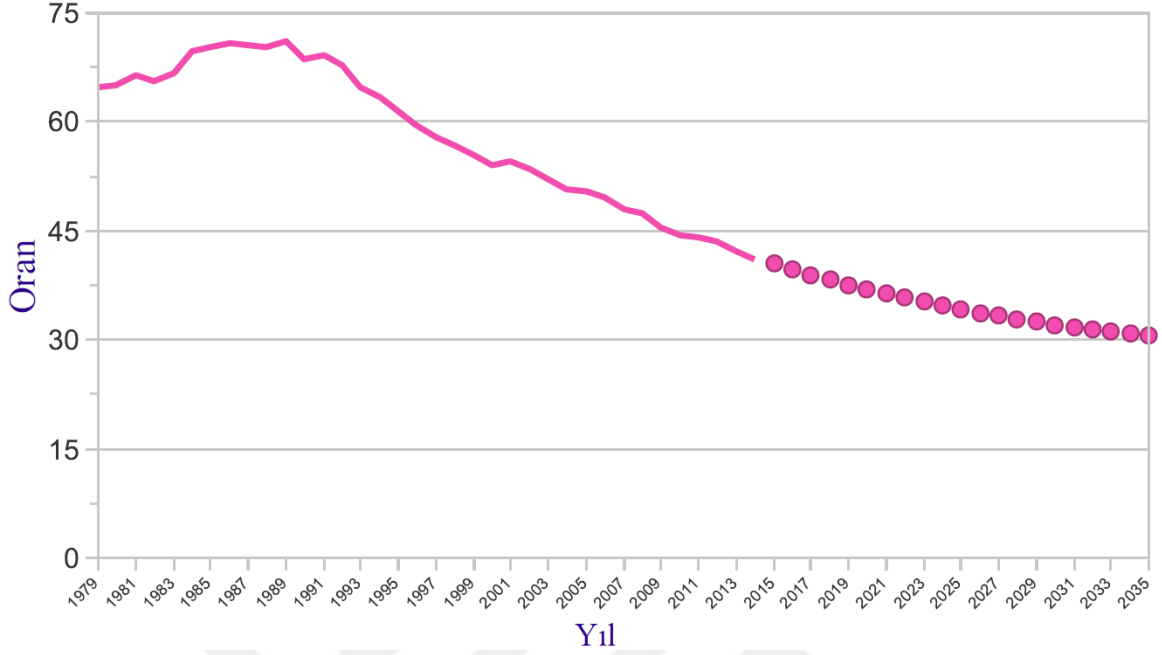
Şekil 1.1. Kanser tiplerinin dünya genelinde (a) görülme ve (b) ölüm oranı [1].

Meme kanserinin erken teşhis edilmesi ile bu hastaların sağ kalım oranları artırılmaktadır. Meme kanseri erken aşamada tespit etmek için dünya çapında en yaygın olarak mamografi görüntüleme yöntemi kullanılmaktadır. Bu yöntem, meme röntgen görüntüleri oluşturmak için düşük enerjili X ışınları kullanan bir teşhis ve tarama aracıdır. Mamografi yönteminin temel amacı, tüm 3 boyutlu memenin anatomik yapısının net bir şekilde görülebilmesi için farklı açılardan alınmış 2 boyutlu X ışını görüntüleri oluşturmaktır. Bu amaçla mamografi görüntüsü çekiminde genel olarak mediolateral oblik (MLO) ve kraniokaudal (CC) gibi iki görünüm kullanılmaktadır. MLO görünümü en fazla miktarda meme dokusunun görüntülenmesine izin vermesinden dolayı en önemli

görünümdür [3]. Meme kanserinin dünya genelinde görülme ve ölüm oranının çok yüksek olmasından dolayı, 40 yaş üstü bayanlar için kontrol amaçlı kamu veya sağlık örgütleri tarafından yürütülen “meme kanseri tarama” programları yapılmaktadır. Bu tarama programlarında kullanılan mamografi görüntüleme yöntemi sayesinde meme kanseri erken teşhis edilebilmektedir [4]. Tarama sırasında, her iki meme için MLO ve CC görüntüleri için iki adet mamografi filmi çekilmektedir. Bağımsız iki farklı radyolog bu filmleri okuyarak, hastalık durumunu değerlendirerek yol haritasını oluşturmaktadır. [4]. Sonuç olarak bu programlar sayesinde erken teşhis işlemi ile meme kanserinden ölüm oranları düşürülmektedir [4]. Erken evrelerde tespit edilen meme kanserlerinin hem tedavileri daha başarılı olmakta hem de hasta yaşam kalitesi önemli ölçüde artırılabilir [8].

Ülkemizde toplum tabanlı kanser taramalarına tüm illerimizde Kanser Erken Teşhis, Tarama ve Eğitim Merkezleri (KETEM) kurularak başlanmış, akabinde bu tarama programlarına Aile Sağlığı Merkezleri (ASM) ve Sağlıklı Hayat Merkezleri (SHM) dâhil edilmiştir [9]. Sözü edilen bu merkezlerde Avrupa Birliği Kalite Standartlarına uygun tarama programları ile son teknoloji dijital mamografi cihazlar ile ücretsiz olarak hizmet verilmektedir [9]. Dünya Sağlık Örgütü'ne göre, meme kanseri ölüm oranlarının önemli ölçüde düşmesi için organize meme kanseri taramasına katılım oranının en az % 70 olması gerekmektedir [2]. Bu amaca ulaşılabilmesi için radyologların, araştırmacıların, mühendislerin ve hastaların gayret göstermesi gerektirmektedir. Ne yazık ki düzenli olarak yapılan bu tarama programları tüm dünyanın 2020 yılından bu yana COVID19 salgını ile mücadele etmesi sonucunda durma noktasına gelmiştir [2]. Bu nedenle, Dünya Kanser Günü'nde, Dünya Sağlık Örgütü (WHO), 2021 yılında başlayan olan yeni bir küresel meme kanseri girişimi oluşturarak bir dizi istişarenin ilkinde ev sahipliği yapmıştır.

Özellikle yoğun olarak yürütülen meme kanseri tarama programlarının sonucunda radyologlar için tanı koyulması için bekleyen oldukça fazla mamografi görüntüsü sürekli açığa çıkmaktadır [3]. Bu kadar fazla sayıdaki görüntünün değerlendirilmesi radyologlar için büyük bir iş yükü ile birlikte yorgunluk oluşturmaktadır. Ayrıca radyoloji uzmanlarının sahip oldukları deneyim ve yetenek seviyeleri de değişkenlik göstermektedir. Bu nedenlerden dolayı, radyologlar bazı durumlarda meme kanseri teşhis aşamasında hatalar yapabilmektedir [4]. Bilgisayar Destekli Tespit (BDT) yazılımları, radyoloji uzmanlarına ikinci bir gözden geçirme imkânı ile hataları azaltmaktadır [5]. Sonuç olarak, BDT sistemlerinin başarısı özellikle meme kanseri teşhisi ve tedavisi alanında büyük önem arz etmektedir.



Şekil 1.2. Birleşik Krallık üzerinden alınan meme kanseri ölüm istatistikleri [10].


Şekil 1.2 'de Birleşik Krallık üzerinde yapılan meme kanseri ölüm istatistiklerinin sonuçları gösterilmektedir [10]. Erken teşhiste kazanılan avantajların sonucunda tedavi yönünden önemli üstünlükler kazanılarak, son yıllarda ölüm oranları ciddi oranda düşmüştür. Ayrıca, bu şekilden de görüleceği üzere ilerideki yıllar içinde ölüm oranların daha da düşeceği öngörülmektedir [10].

1.2. Meme Anatomisi

Meme süt salgılayan bir dış salgı bezi olup, içerisinde farklı anatomik yapılar bulunmaktadır [6]. Meme üzerinde yer alan bu anatomik yapılar Şekil 1.3' de gösterilmiştir. Meme deri dokusunun altında yağ dokusu ve onun hemen altında da süt bezleri yer almaktadır. Süt bezleri lübüller halinde bulunur ve bunların bir araya gelmesinin sonucunda "lob" adı verilen adalar meydana gelir [7]. Bir memede yaklaşık 15-20 adet lob bulunur ve her bir lobun kendine ait süt kanalı vardır. Tüm süt kanalları birleşerek meme başına kadar uzanır.

Meme dokusunda yer alan hücrelerin kontrolsüz çoğalması sonucunda ortaya çıkan yapıya meme kanseri denilmektedir. Meme kanseri genellikle lübüllerde gelişir ve oradan

da sırasıyla süt kanallarına, yakın çevresine ve yakınındaki lenf bezlerine yayılarak devam etmektedir [7].




Şekil 1.3. Meme Anatomisi [6].

1.3. Meme Kanseri Tespiti İçin Kullanılan Görüntüleme Yöntemleri


Meme kanserinin erken tespit edilmesi amacıyla tıbbi görüntüleme teknikleri yaygın olarak kullanılmaktadır. Bu görüntüleme metotlarının kendi aralarında farklı açılardan avantaj ve dezavantajları bulunmaktadır. Aşağıda alt başlıklar altında bu metotlar hakkında bilgi verilerek, tercih edilme sebepleri, güçlü ve zayıf olduğu yönleri anlatılacaktır.

1.3.1. Mamografi

Meme üzerindeki şüpheli bölgelerin teşhis etmek amacıyla X ışınları ile oluşturulan görüntüleme metoduna mamografi denir. Şekil 1.4 (a) 'da meme kompresyon düzeneğinde meme benzeri bir nesnenin yer aldığı mamografi cihazı gösterilmektedir. Bu cihaz en basit manada X ışını kaynağı, meme sıkıştırma düzeneği ve X ışını dijital belirleyicisinden oluşmaktadır.



(a)



(b)

(c)

Şekil 1.4. (a) Mamografi Cihazı [9] (b) ve (c) süperpozisyon projeksiyonları

Mamografi cihaz düzeneğinde kompresyona uğratılmış 3 boyutlu memeye ait farklı doku tiplerinin X ışınına karşı gösterdiği zayıflatma miktarınca parlaklık değişimi gösteren 2 boyutlu olan bir görüntü ortaya çıkmaktadır [9]. Ancak, mamografi çekim tekniğinde tek açıdan X ışığı kaynağının olmasının dezavantajının bir sonucu olarak üst üste binen farklı doku tiplerinin projeksiyonları aynı görüntü üzerine düşerek süperpozisyon durumu oluşmaktadır [13]. Bu durum Şekil 1.4 (b) 'de gösterilmektedir.


Şekil 1.3'te gösterilen memenin anatomik bileşenleri Şekil 1.5 'de mamografi görüntüsü üzerinde işaretlenerek gösterilmiştir. X ışını ile elde edilen tıbbi görüntüleme metotlarında ortaya çıkan görüntünün tersi alınmaktadır. Sonuç olarak bu şekilde de görüleceği üzere pektoral kas, damar, şüpheli bölgelerin vb. yoğun bileşenlerin X ışınlarını fazla soğurduğu için açık tonlarda olduğu; tersi durumdaki yağ dokusunun ise koyu tonlu olduğu gözükmemektedir.

Hasta yaşı ve memesinin anatomik yapısına bağlı olarak mamografi görüntüleri farklı yoğunluklarda olabilir. Özellikle 40 yaş altındaki bayanların memelerinin yoğun olmasından dolayı mamografi görüntüleri de yüksek parlaklık göstermektedir. Sonuç olarak bu tip görüntülerde şüpheli bölgelerin belirginliği düşmektedir. Tablo 1.1'de mamografi görüntüleri için BIRADS meme yoğunluk kategorileri gösterilmiştir. BIRADS 1-4 arasındaki yoğunluk kategorilerinde yer alan memeler sırasıyla Şekil 1.6'da gösterilmektedir.


Mamografi görüntüsünde yer alan süperpozisyon durumunu azaltmak için farklı açılardan meme görüntüsü alınmaktadır. Bunlardan en yaygın olanları yandan eğimli (mediolateral oblique-MLO) görünümü ve üstten aşağıya (craniocaudal-CC) görünümü olanlardır. MLO görünümü ile diğer görümlere göre maksimum düzeyde meme miktarının görüntülenmesini sağlamaktadır. Bu görünüm sayesinde radyolojik açıdan pek çok amaç için kullanılan pektoral kas bölgesinin büyük bir kısmı da görüntülenebilmektedir. Ayrıca pektoral kas bölgesinin aşağı kısmında kalan kitleler de bu görünüm üzerinde görülebilmektedir. Bu sebeplerden dolayı MLO görünümü teşhis aşamasında radyologlar tarafından en çok tercih edilen görünümdür [15].

Tablo 1.1. Meme yoğunluğunu gösteren BIRADS kategorileri

BIRADS I Yağlı meme	Meme dokusu çoğunlukla yağdan oluşur ve glandüler doku toplam meme dokusunun % 25' inden daha azını oluşturur.
BIRADS II Dağınık fibroglandüler doku meme	Fibroglandüler doku, toplam meme dokusunun % 25-50' ini oluşturur.
BIRADS III Heterojen yoğun meme	Fibroglandüler doku, toplam meme dokusunun % 50-75' ini oluşturur.
BIRADS IV Yoğun meme	Yoğun meme Fibroglandüler doku, toplam meme dokusunun % 75' inden fazlasını oluşturur ve sıklıkla tanı duyarlılığının azalmasına neden olur.



Şekil 1.5. Mamografi görüntüsü üzerindeki anatomik yapılar




Şekil 1.6. Farklı yoğunluklardaki memeler için mamografi görüntüleri.

1.3.2. Tomosentez

Tomosentez görüntüleme yönteminde meme pozisyonu sabit iken bilgisayarlı tomografi yöntemine benzer olarak X ışını kaynağı farklı yönlerden kesitler halinde gönderilerek görüntü dizisi oluşturulmaktadır. Alınan bu çok sayıda görüntülerin bilgisayar sistemiyle yönteme özel algoritmalar ile birleştirilmesi ile meme görüntüsü elde edilir. Ayrıca mm düzeyinde elde edilen bu kesit görüntüleri peş peşe video formatında izlenebilir.

Tomosentez görüntüleme yöntemi ile 3 boyutlu bir memenin X ışınları altında 2 boyutlu görüntülenmesi esnasında ortaya çıkan üst üste binme yani süperpozisyon etkileri azaltılmaktadır. Bu yöntem ile farklı yönlerden gelen X ışını demetleri ile süperpozisyon probleminin nasıl çözüm bulunduğu şematik olarak Şekil 1.4 (c) 'de gösterilmektedir. Belirgin olmayan bir kitlenin yer aldığı mamografi görüntüsü ve aynı kitlenin tomosentez görüntüleme yöntemi ile elde edilen görüntüsü sırasıyla Şekil 1.7 (a) ve (b) 'de gösterilmektedir. Bu şekilden de görüleceği üzere, tomosentez yöntemi ile süperpozisyon probleminin etkilerinin azaltılmasının sonucunda kitlenin belirginliği artmıştır. Tomosentez ve mamografi yöntemlerinden elde edilen görüntüler üzerinde yapılan radyolojik değerlendirmelerin teşhisteki başarımlarını performansını olan etkisini pek çok çalışma incelemiştir [13-15]. Bu çalışmalara göre elde, tomosentez görüntülemesinin kullanılması durumunda kanser yakalama oranının ciddi oranda arttığı ve yalancı pozitif oranın da düştüğü gözlemlenmiştir. Bunun yanında mamografi yöntemlerinde elde edilen görüntülerde şüpheli görülebilen yalancı kitle dokularını biyopsiye gerek kalmadan bu yöntem ile teşhis edilebilmekte ve iyi yâda kötü huylu olup olmadığına karar verilebilmektedir [16].

Tomosentez cihazlarının maliyetlerinin yüksek olmasından dolayı, gelişmekte olan ülkelerdeki sayısı fazla değildir. Hatta az gelişmiş ülkelerdeki hastaların bu cihazların erişimi oldukça zordur. Ayrıca bir hasta için tomosentez görüntüleri sayısı oldukça fazladır ve bunları değerlendirecek radyologlar için oldukça iş yükü gerektirir. Sonuç olarak, dünya genelinde meme kanser taramasında en uygun radyolojik yöntem, birçok parametre göz önünde bulundurularak, mamografi olarak seçilmiştir [17].



Şekil 1.7. Aynı kitlenin (a) Mamografi ve (b) Tomosentez görüntüleri [13].

1.3.3. Manyetik Rezonans Görüntüleme

Manyetik Rezonans (MR) görüntüleme yönteminde güçlü bir manyetik alan ortamında bulunan doku üzerindeki hidrojen atomu çekirdekleri uyarılarak ortaya çıkan yansıma işlemi kullanılmaktadır. Bu yöntemde X ışınları kullanılmadığından sağlık açısından daha az risklidir ve genellikle yumuşak dokuların görüntülenmesinde kullanılır.

Mamografi üzerinde tespit edilen şüpheli bölgelerin detaylıca incelenmesi açısından MR görüntüleme metodu oldukça fazla tercih edilmektedir [17]. Sonuç olarak şüpheli bölgenin MR görüntüsü üzerinde incelenmesi ile iyi yâda kötü huylu olup olmadığına karar verilerek gereksiz biyopsinin önüne geçilmektedir. Ancak erken evredeki meme kanserleri MR görüntüleme yöntemi ile teşhis edilememektedir. Ayrıca bu yöntemin uygulanabilirliği ve kişi başına düşen cihaz yaygınlığı mamografi cihazlarına göre oldukça düşüktür.

1.3.4. Ultrasonografi

Ultrasonografi görüntüleri, X ışınları içermeyen, 1MHz ile 10 MHz frekansları arasındaki ses dalgalarının dokular üzerinden enerjinin geriye yansıması yoluyla oluşturulmaktadır. Meme üzerinde yer alan aynı karakteristikteki farklı dokuların ses dalgalarını soğurma oranının yakın olmasından dolayı birbirinden ayırt edilebilme hassasiyeti düşmektedir [11].

Özellikle 40 yaş altındaki genç bayanlarda meme dokusu yoğun olduğundan dolayı mamografi görüntülerinde hassasiyet düşmektedir [12]. Bu durumlarda, ultrasonografi görüntüleri sayesinde mamografi üzerinde gizlenmiş şüpheli kısımlar saptanabilmektedir [12]. Ayrıca mamografi üzerinde tespit edilen şüpheli bir bölgenin biyopsisine başvurmadan önce, ultrasonografi altında incelenerek iyi yâda kötü huylu olup olmadığı incelenebilmektedir.

1.4. Mamografi Görüntü Veri Tabanları

BDT sistemleri alandaki yapılan ilk çalışmaların performanslarını inceleyen bazı araştırmacılar özellikle standart bir görüntü setini içeren ortak bir veri tabanlarının o yıllarda olmamasının dezavantajlarından bahsetmişlerdir. Sonuç olarak bu alandaki bir çalışmada ölçülen performansının test veri tabanına güçlü bir şekilde bağımlı olması nedeniyle, bir BDT sisteminin doğruluğunu güvenilir bir şekilde tahmin etmek zordur. İlerleyen yıllarda, bu sorunlara olası çözümler için, bazı araştırmacılar ortak bir veri tabanı oluşturmuşlardır. Böylece, standart bir görüntü seti üzerinde yapılan karakterize işlemler ile detaylandırılarak bu alandaki tüm araştırmacıların kullanımına sunulması hedeflenmiştir.

Meme kanseri üzerinde radyologlara teşhis işleminde yardımcı olacak BDT sistemlerinin geliştirilmesi ile uğraşan araştırmacılar genellikle yaygın olarak kullanılan veri tabanlarını kullanmaktadır. Ayrıca, bu veri tabanlarında bulunan görüntüler için uzman radyologlar tarafından yapılan şüpheli bölge bölütlemesi ve teşhis bilgilerinin yer alması, araştırmacılara hem büyük bir kolaylık ve standardizasyon sunmaktadır. Bir veri tabanı içerisinde yer alan görüntülerin bazı karakteristik değişkenlere göre BDT sistemlerinin performans sonuçları da farklı çıkabilmektedir [18]. Bir veri tabanı araştırmacılar tarafından yaygın olarak kullanılıp performans sonuçları da spesifik bir biçimde yayınlanmışsa, aynı veri tabanını aynı şartlar altında mukayese etmek isteyen diğer araştırmacılar için avantaj teşkil etmektedir.

Aşağıdaki alt başlıklarda BDT sistemlerinde kullanılan en yaygın veri tabanları hakkında özet bilgiler ile kendi aralarındaki avantaj ve dezavantajları sunulmaktadır.

1.4.1. DDSM Veri Tabanı

Digital Database for Screening Mammography (DDSM) veri tabanı [19] özellikle içermiş olduğu fazla sayıda şüpheli bölgelerin olmasına bağlı olarak, mamografi görüntüleri üzerine yapılan BDT çalışmalarında en yaygın olarak kullanılan veri tabanı türüdür. Yaklaşık 2500 adet kişiye ait her iki memenin MLO ve CC görüntüleri mevcuttur.

Bu veri tabanı içerisinde; şüpheli bölgelerin konumu, yaklaşık sınır maskeleri, hasta hakkında etiket ve meme yoğunluğu bilgisi (1-4 arasında) yer almaktadır. Ayrıca şüpheli bölgelere ait belirginlik durumu 1 ile 5 arasında kategorize edilerek, şekil ve kenarlarının karakteristik özellikleri (“irregular”, “spiculated”, “obscured” vb. gibi) verilmektedir. Son olarak şüpheli bölgelere ait biyopsi sonuçları da (iyi “benign” yâda kötü huylu “malignant”) bu veri tabanı ile sunulmaktadır.

1.4.2. CBIS-DDSM Veri Tabanı

DDSM veri tabanı literatürde oldukça fazla kullanılmasına rağmen bazı dezavantajları bulunmaktadır. Özellikle bu veri tabanının kullanılabilmesi için kayıt edildiği LJPEG (Lossless Joint Photographic Experts Group) sıkıştırılmış görüntü formatından standart DICOM biçimine dönüştürülmesi gerekmektedir [20]. Fakat bu işlem için PYTHON yâda benzeri bir platformda yapılması gerekenler çoğu araştırmacı için işlem yükü oluşturmaktadır. Ayrıca bu veri tabanında yer alan şüpheli bölgelerin radyologlar tarafından işaretlenmiş maskeleri sunulmamaktadır. DDSM veri tabanında bulunan bu dezavantajları ortadan kaldırmak için CBIS (Curated Breast Imaging Subset)-DDSM [21] veri tabanı hazırlanmıştır. Bu veri tabanı içerisinde tüm şüpheli bölgelerin hem radyologlar tarafından hem de bazı popüler bölütleme algoritmaları [23-25] tarafından oluşturulan ilgi bölgelerinin maskeleri yer almaktadır.

BDT sistemi geliştirmek isteyen araştırmacılar, CBIS-DDSM veri setine internet üzerinden ilgili sayfasından [21] kolaylıkla erişebilir. Şüpheli bölgeleri bölütleme yapan araştırmacılar bu veri setinden bulunan maskeler ile çalışmalarını test ederek harici bir radyoloğa ihtiyaç duymayacaklardır. Aynı zamanda bu standart veri setini kullanan tüm araştırmacılar çalışmalarını aynı şartlar altında aynı kesin referans bölütleme sonuçları ile mukayese edebilmektedir. Sonuç olarak 2017 yılı içinde hazırlanan bu veri seti, yukarıda

bahsetmiş olduğumuz avantajlarından dolayı son yıllarda oldukça fazla literatürde tercih edilmektedir.

1.4.3. MIAS Veri Tabanı

Mammography Image Analysis Society (MIAS) veri tabanı [25], DDSM veri tabanından sonra literatürde en sık olarak kullanılmaktadır. Bu veri tabanında toplam 161 hastaya ait sağ ve sol memelerin yalnızca MLO görünümlü görüntüleri yer almaktadır. Veri tabındaki her bir görüntü için toplam 7 sütundan oluşan etiket numarası, meme yoğunluğu kategorisi, şüpheli bölgelerin tipi ve koordinatları gibi bazı bilgiler yer almaktadır. Örneğin, “mdb058 D MISC M 318 359 27” görüntüsü için “58” referans numarasını ve “D” (dense-yoğun) meme yoğunluğunu göstermektedir. Aynı görüntüde yer alan diğer bilgiler “MISC” (Other, ill-defined masses) olduğu ve kanser türünün de “M” (malignant-kötü huylu) olduğunu ve son üç rakamsal değer (“318 329 27” sırasıyla ilgili bölgenin x, y koordinatları ve yarıçapı göstermektedir.

1.4.4. INbreast Veri tabanı

Hem MIAS ve hem de DDSM veri tabanları, oluşturulduğu tarih itibari ile dijital mamografi cihazlarının olmaması sebebiyle, analog mamografi görüntü çıktılarının dijital tarayıcılar ile sayısallaştırılması sonucu oluşturulmuştur. Oysaki INbreast [26] veri tabanı bir grup araştırmacı tarafından, tümüyle dijital bir mamografi cihazından alınan sonuçların derlenmesi ile bir araya getirilerek hazırlanmıştır. Ayrıca bu veri tabanı üzerinde dijital ortamda çalışan uzman radyologlar şüpheli bölgelerin ve pektoral kas sınırlarına ait koordinatları kaydedip veri tabanına XML formatında eklemiştirler. Çok yaygın olarak kullanılan DDSM ve MIAS veri tabanlarında sunulmayan şüpheli ölge sınırlarının koordinat bilgileri bu veri tabanında yer almaktadır. Sonuç olarak bu veri tabanını kullanan tüm araştırmacılar başarımlarını aynı kesin referans bölütleme sonuçlarını kullandıklarından dolayı kendi aralarında aynı şartlar altında mukayese edebilirler.

1.4.5. Derin Öğrenme İçin Hazırlanan Büyük Veri Tabanları

Son yıllarda özellikle yüksek işlem gücüne sahip veri işleme merkezlerinin artması ile birlikte BDT sistemlerinde de derin öğrenme algoritmaları ile ilgili çalışmalar oldukça artmıştır. Ancak, bu algoritmaların eğitilerek test edilmesi için büyük veri tabanlarına ihtiyaç vardır. Yukarıda bahsi geçen ve tüm araştırmacılara açık bulunan veri tabanlarındaki görüntü sayısı özellikle derin öğrenme algoritmaları geliştirmek için yetersizdir.

Aşağıdaki alt başlıklarda, son yıllarda hazırlanmış derin öğrenmede kullanılabilecek başlıca mamografi veri tabanları açıklanmaktadır.

1.4.5.1. Dijital Mamografi DREAM Challenge

Derin öğrenme algoritmalarında kullanılması için bazı kuruluşlar büyük veri tabanları hazırlamışlardır. Bu amaç için Dijital Mamografi DREAM Challenge [27] etkinliği kapsamında büyük bir veri tabanı, araştırmacılara sunulmuştur. DREAM Challenge, çok çeşitli bilim ve mühendislik alanlarından katılımcıları bir araya getirerek çeşitli istatistiksel ve makine öğrenimi yöntemlerini karşılaştırmalı olarak değerlendirip, hesaplama yöntemlerini geliştirmeyi amaçlayan bir kar amacı gütmeyen işbirliğine dayalı organizasyondur. Bu amaç için açık kaynak kod üzerinden Python paketi olan DREAM Tools [28] ve Synapse platformunu [29] araştırmacılara sunulmuştur.

DREAM Challenge katılımcılarının, biyoloji ve biyotıp alanında önde gelen dergilerde çok sayıda yayını bulunmaktadır. Bu organizasyonun meme kanseri tespitini iyileştirmek için topladığı büyük veri tabanında 80.000 kadından 640.000'den fazla mamografi görüntüsü yer almaktadır. Bu veri tabanını kullanan araştırmacıların bir kısmı algoritmalarını açık bilim kaynaklı bir yaklaşım ile sunarken bir kısmı da ticari amaçlı BDT sistemleri ile piyasaya sunmuştur. Ayrıca bu algoritmalar sayesinde, diğer organlardaki kitle görüntülerinde kullanılan BDT sistemlerine potansiyel olarak fayda sağlaması da hedeflenmiştir. Sonuç olarak bu Dream Challenge etkinliğine katılan araştırmacılar böyle bir büyük veri tabanı üzerinde algoritmalarını eğiterek meme kanseri tespitine yönelik birçok yeni yaklaşımın geliştirilmesini sağlamışlardır.

1.4.5.2. Cohort of Screen-Aged Women Veri Tabanı

Bu alandaki diğer önemli büyük veri tabanı, “Cohort of Screen-Aged Women” (CSAW) [30], 2008 ile 2015 yılları arasında İsveç'in Stockholm bölgesinde bir taramaya davet edilen 40 ila 74 yaş arasındaki tüm kadınlardan oluşan yaklaşık 2 milyon mamografi görüntüsünden oluşmaktadır. Mamografi görüntüleme alanında derin sinir ağlarının eğitimi ve değerlendirilmesi için tanımlanan bu büyük veri tabanı şimdilik yalnızca belirli araştırmacılar [31] için kullanıma açılmıştır.

1.4.5.3. OPTIMAM Tıbbi Görüntü Veri Tabanı

Yaklaşık 2 milyon gibi çok fazla görüntüden oluşan OPTIMAM Medical Image Database- Tıbbi Görüntü Veri tabanı (OMI-DB) [32], National Health Service - Ulusal Sağlık Hizmeti (NHS) kurumu tarafından meme tarama merkezlerinden alınan görüntülerin toplanmasıyla oluşturulmuştur. Bu veri tabanındaki görüntüler için radyolojik, klinik ve patolojik veriler PACS sistemlerinde yer almaktadır. Ayrıca bazı zor görüntüler üzerinde yapılan okuma işlemi için uzaktaki uzman radyologlardan tele-tıp uygulamasıyla yardım alınmaktadır.

Cancer Research-UK tarafından finanse edilen OPTIMAM araştırma projesinin ana amacı meme kanserinin erken tespit edebilecek BDT sistemlerini tasarlanmasına olanak sağlamaktır. Bu veri tabanına erişmek isteyen araştırma grupları / kurumlar bir takım özel izinler, prosedürler ve sınırlandırmalar ile birlikte OMI-DB verilerine sahip olabilmektedir.

1.4.6. Özel Veri Setleri

Meme kanseri üzerine geliştirilen BDT sistemlerinin kendi aralarında aynı şartlar altında mukayese edilmesi zor bir işlemdir. BDT sistemlerinin belirgin olmayan kitleleri içeren görüntüler üzerindeki başarı oranlarının ne olacağı ve mukayesesi genellikle sunulmamaktadır. Bazı araştırmacılar zor görüntüleri seçerek küçük veri setleri oluşturarak bunlar üzerinde başarı performansını sunmuşlardır. Fakat bu tip sonuçların mukayese edilmesi konusunda standart olmayan veri seti kullandıkları için bu zorluklarla karşılaşılır. Özellikle, süperpozisyon sonucu bir kısım yâda tümüyle yoğun bölge içerisinde kalan şüpheli bölgelerin tespit edilmesi ve bölütlenmesi bu alanda BDT sistemleri için en zor işlemler arasında yer almaktadır. Bu konuyu daha da ileriye taşırsak

pektoral kas bölgesi içerisinde kalan şüpheli bölgeleri çoğu BDT sistemi bu bölgedeki yanlış pozitifleri azaltmak için çıkardıkları için ihmal etmektedir. Ayrıca pektoral kas bölgesi içerisinde yer alan şüpheli bölgeler yoğun bir bölge içerisinde olduğundan dolayı, süperpozisyon sonucu ayıt edilmesi zor nesnelere arasındadır. Bu tip belirlenmesi zor olan şüpheli bölgelerin sayısı çok olmasa da hiçbir araştırmacı BDT sistemleri performansını bunlar üzerinde test etmemiştir. Sonuç olarak bu tip zor görüntüler için özel veri setleri hazırlanarak kategorize edilerek standardize edilmesi durumunda aynı veri setini kullanan araştırmacıların daha detaylı bir şekilde mukayese etme imkânı bulabileceklerdir.

1.5. Mamografi Görüntüleri İçin BDT Sistemleri

Mamografi görüntüleri meme üzerinde şüpheli bölgelerin incelenmesi esnasında radyologlara pek çok avantajlar sunarak erken teşhis avantajını sunmaktadır. Bu görüntüler üzerinde yapılan radyolojik incelemeler dünya genelinde belirlenen ortak bir standart kavram olan Tablo 1.2 'de yer alan BIRADS (Breast Imaging Reporting and Data Systems) sınıflandırılması ile değerlendirilmekte ve tedavi yolu belirlenmektedir.

Dünya çapında pek çok meme kanseri tarama programları yapıldığından dolayı ortaya pek çok sayıda mamografi görüntüsü radyologlar üzerinde ciddi bir yük oluşmaktadır [33]. Ayrıca radyologların mamografi görüntüleri değerlendirme performansı uzmanlık derecelerine, yeteneklerine ve yorgunluk düzeylerine vb. nedenlere göre değişkenlik göstermektedir [34]. Radyologların yapacakları hatalar ile erken teşhisi mümkün vakalar kaçırılmaktadır [35]. Ayrıca yanlış teşhis edilen sağlam dokular üzerinde yapılan işlemler ile hem sağlık hizmetleri açısından maddi hem de hasta açısından manevi kayıplar oluşturmaktadır [36]. Bu nedenlerden dolayı mamografi görüntüleri üzerinde radyologlara ikinci göz olarak yardımcı olacak bir takım Bilgisayar Destekli Teşhis (BDT) yazılımları geliştirilmektedir [37]. Bu yazılımların sayesinde hem radyologların iş yükü hem de hata oranları azaltılması amaçlanmaktadır.

BDT sistemi ile mamografi görüntüsü değerlendiren bir radyolog genel olarak aşağıdaki adımları takip eder [38].

- Radyolog, mamografi görüntüsü üzerindeki şüpheli bölgeleri kaydederek ilk okumasını gerçekleştirir.
- BDT sistemi ile mamografi görüntüsü taranır ve şüpheli bölgeler ve özellikleri tespit edilir.

- Radyolog daha sonra ilk okuması ile BDT sistemi çıktısını mukayese ederek şüpheli herhangi bir alanın işaretlenmiş olup olmadığını analiz eder. Böylece BDT sistemi radyologları daha fazla analiz gerektiren alanlara karşı uyarabilir. Radyolog, bu analiz sonucunlarına göre son değerlendirmesine karar verir.


Tablo 1.2. Meme üzerinde bulunan şüpheli bölgeler için BIRADS Sınıflandırması

BIRADS 0	Yapılan inceleme yetersiz, ilave görüntüleme yöntemlerine ihtiyaç var
BIRADS 1	Normal Meme yapısı
BIRADS 2	İyi huylu bulgular
BIRADS 3	Muhtemelen iyi huylu bulgular
BIRADS 4	Farklı derecelerde şüpheli bulgular (4A:hafif, 4B: orta, 4C:ileri)
BIRADS 5	Yüksek olasılıkla kötü huylu bulgular
BIRADS 6	Biyopsi ile kanıtlanmış kötü huylu olgular

Özellikle son yıllarda yaşanan teknolojik gelişmelerin sonucunda, meme kanseri tahmininde uzman radyologları bile geride bırakabilen BDT sistemleri sunulmuştur [39]. Bu sistemlerin birbirine göre mukayese ederek, avantaj ve dezavantajlarını açıklayan ayrıca onlar için ortaya çıkan sınırlamaları ve zorlukları ön gören özet çalışmalar [42-46] bulunmaktadır. Ayrıca bu alanda ülkeler arası işbirliği ile detaylı çalışmalar da yapılmaktadır, örneğin Birleşik Krallık ve ABD' den büyük bir zenginleştirilmiş veri seti üzerinde yüksek performans gösteren bir BDT sistemi oluşturulmuştur [40]. Bu BDT sistemi altı radyoloğun bağımsız değerlendirmelerinden daha iyi bir performans göstermiştir. Bu çalışmanın bir amacı da bu BDT sisteminin İngiltere'den ABD'ye genelleme yeteneğine dair kanıt sağlamasıdır. Şekil 1.8 ' de bu çalışma kapsamında radyologların kaçırıp BDT sisteminin yakaladığı veya tam tersi durum için oluşan vakalar sırasıyla gösterilmektedir. Bu şekilden de görüleceği üzere, her ne kadar radyologlardan daha iyi bir performans gösteren bir BDT sistemi olsa da, bazı durumlardaki radyologların yakalayabildiği vakaları kaçırabilmektedir.

BDT sistemlerinin performansı gelişen görüntü işleme yöntemleri ile sürekli bir artış göstermesine rağmen, ulusal düzenlemelere bağlı olarak radyologların teşhis esnasındaki başvuracakları ikinci göz konumunda olup son değerlendirme işlemi için kullanılmamaktadır [41]. Ayrıca, BDT alanındaki gelişen teknolojik alt yapı ve

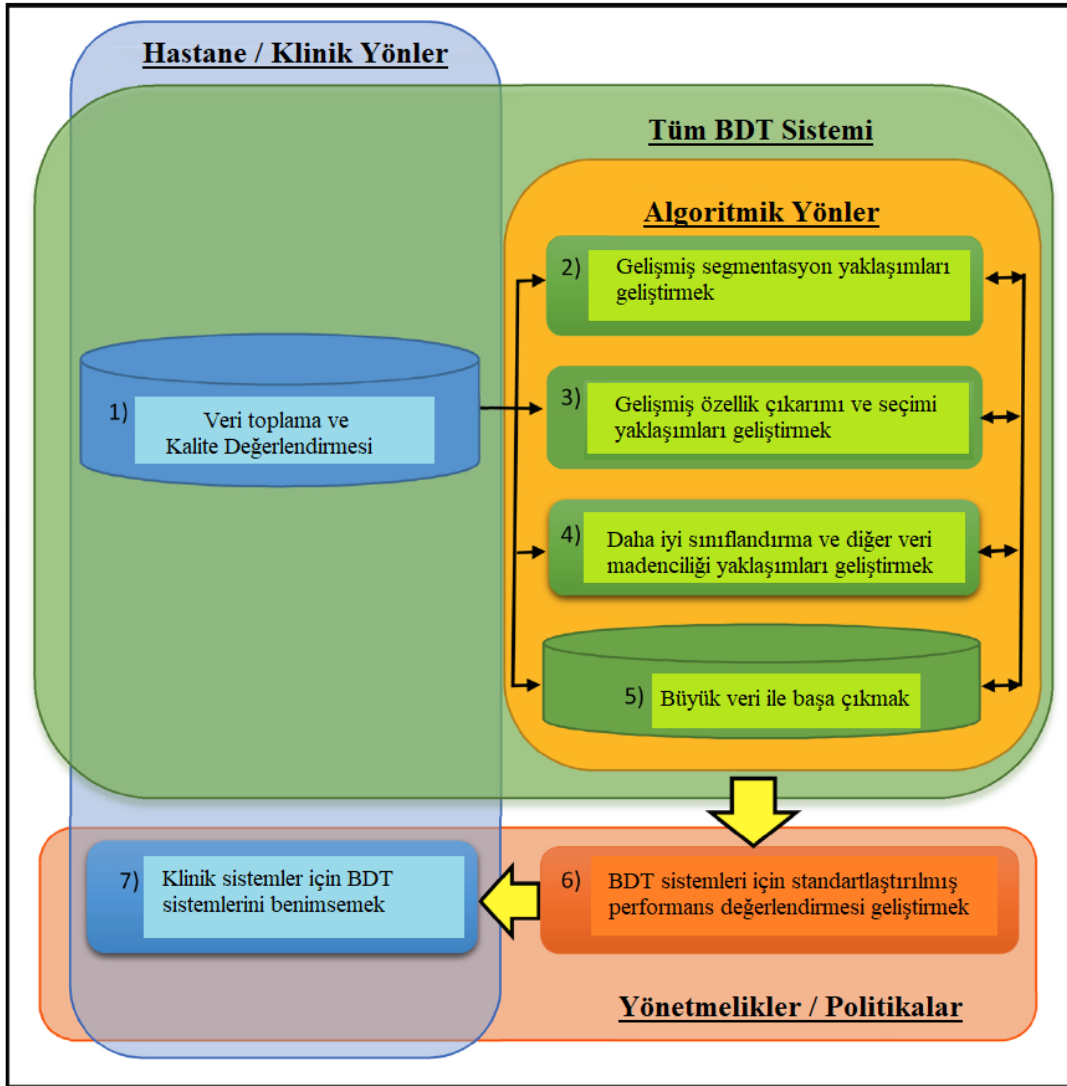
algoritmalarla rağmen, ilerleyen zamanlarda ortaya çıkacak en önemli 7 anahtar zorluk Şekil 1.9 ' de gösterilmektedir.



Şekil 1.8. (a) AI sistemi ve (b) radyologlar arasındaki tutarsızlıklar [40].

Şekil 1.9' da yer alan 6. ve 7. başlıklarda, algoritmalar arasındaki klinik etkinin mevcut karşılaştırılması kullanılan veri tabanlarındaki, genel test yöntemlerindeki farklılıklar ve sınırlı sayıda bağımsız etkinliklerin değerlendirilmesi vb. gibi nedenlerden dolayı bazı dar boğazlar oluşmaktadır. Son birkaç yıl öncesinde araştırmalarda yaygın olarak kullanılan mevcut veri kümeleri küçük boyutludur ve standart kurum ve görüntüleme makinası satıcılarından gelmektedir. Dolayısıyla bu durum da araştırmacıların tasarladıkları algoritmaların aşırı uyarlanması için bir potansiyel tehdit oluşturmaktadır [41]. Sonuç olarak eğitim, doğrulama ve sonraki testler için kullanılan veriler, daha önce görülmemiş bir veri setiyle bağımsız testlere izin vermek için geliştirilen her bir BDT sistemi için şeffaf olmalıdır. Ayrıca bu sistemlerin eğitim aşamasında tekrarlanan vakalar kullanılması ile potansiyel önyargı oluşmasından da kaçınılmalıdır.

Meme kanseri tahmini için uzun yıllar içerisinde geliştirilen BDT sistemleri ile radyologlar arasındaki performans karşılaştırması için oldukça fazla akademik çalışma [33-39] yapılmıştır. Bu çalışmaların çoğu tarama mamografilerinden oluşturulmuş özel veri tabanları ile özel kliniklerde gerçekleştirilmiştir. Bu çalışmalarda özellikle BDT sistemlerinin radyologlar üzerinde ikinci göz olarak yaptıkları performans artışından bahsedilmiştir.



Şekil 1.9. BDT uygulamalarındaki sınırlamalar ve zorluklar [41].

Son yıllarda gelen teknolojik ilerlemelerinin sonucunda, yapay zekâ devriminin gelmesi, büyük sayıda görüntüden oluşan veri tabanları ve yüksek kapasiteli işlemci gücü vb. etkenler derin öğrenme modellerini geliştirmenin önünü açmıştır. Yaşanan bu gelişmelerin sonucu olarak, mamografi görüntüleri üzerinde tasarlanan BDT sistemlerinde derin öğrenme algoritmalarının kullanılması sağlanmıştır. Bu BDT sistemleri için açıklanan ve yayınlanan performanslara rağmen, çoğu zaman tedavi edilecek görüntü ve vakaların çeşitliliğiyle karşı karşıya kalınmaktadır. Yapay zekâ, eğitimlerinin istatistiksel doğasının bir sonucu olarak, öğrenme tabanında bulunmayan bazı şüpheli vakaları kaçırmalarına neden olabilmektedir [39].

Meme kanseri üzerine yapılan BDT sistemleri; ticari ve akademik amaçlı olarak iki alt konu başlığında aşağıda detaylıca açıklanacaktır.

1.5.1. Ticari Amaçlı BDT Sistemleri

Ticari amaçlı BDT sistemleri genellikle patentli yapay zekâ ve örüntü tanıma algoritmaları kullanmaktadır. Bu yazılımların başlıca yaptıkları işler; meme sınırı, meme yoğunluğu, meme ucu pozisyonu, pektoral kas sınırı, kitle sınırı ve benign/malign tipi belirlemektir. Sonuç olarak radyologlar için bu yazılımlar ikinci göz konumunda potansiyel hem faydalar sunmakta ve hem de işlerini kolaylaştırmaktadır.

BDT yazılımlarının çoğu ortaya çıkan yeni büyük veri tabanları ve büyük hesaplama hacimleri sayesinde kural tabanlı algoritmalarından, Derin Öğrenme 'ye dayalı algoritmalara geçiş göstermiştir. Bu alanda yaşanan büyük gelişmelere rağmen YZ araçlarının klinik uygulamada gerçek performansını keşfetmede büyük bir boşluk bulunmaktadır.

Yaygın olarak kullanılan ticari BDT sistemlerini birbirine göre mukayese ederek, avantaj ve dezavantajlarını açıklayan ayrıca onlar için ortaya çıkan sınırlamaları ve zorlukları ön gören özet çalışmalar [42-44] bulunmaktadır. Yaklaşık 8805 mamografi görüntüsü üzerinde belli başlı 3 adet ticari BDT yazılımlarının performansını inceleyen bu alandaki en detaylı yapılan bir çalışmanın [45] sonuçlarına göre; BDT yazılımı ve bir radyolog ile yapılan okuma sonuçları, herhangi bir BDT yazılımı kullanmadan iki radyolog ile teşhis yapılan sonuçlara göre daha başarılı olmaktadır.

Mamografi görüntülerini değerlendiren başlıca ticari BDT sistemleri aşağıdaki alt başlıklarda anlatılmaktadır.

1.5.1.1. R2 ImageChecker

“R2 ImageChecker”, meme kanseri alanındaki FDA (Food and Drug Administration) tarafından 1998 yılında onaylanan ilk ticari amaçlı BDT sistemidir [46]. Bu ticari yazılım aslında daha önce Chicago Üniversitesi'nde akademik amaçla geliştirilen bir prototipe dayanmaktadır.

Bu yazılım, kötü huylu mikrokalsifikasyonların ve kötü huylu kitlelerin olasılığını hesaplayarak ve radyologlar için sabit bir olasılık eşliğinin üzerindeki bölgeleri vurgulamaktadır. Bu yazılım ile radyologlar tarafından teşhis sonuçlarının mukayese eden

bazı çalışmalar [47-49] yapılmıştır. Bu çalışmalara göre özetle, bu yazılım yanlış pozitif sayısını artırmamasının yanında bazı zor görüntülerde de yanlış negatifler oluşturmaktadır. Klasik bilgisayarla görme tekniklerini kullanan bu yazılım, alanında ilk ticari yazılım olmasına rağmen teknolojik gelişmelere rağmen güncel kalamamıştır ve sonuç olarak hayatı sona erdirilmiştir [50].


1.5.1.2. Danum International; CyclopusCAD Mammo

CyclopusCAD Mammo, CE "Conformité Européene - Avrupa'ya Uygunluk " belgesi bir BDT sistemidir. Bu sistem, Avrupa, Orta Doğu ve Afrika'daki bağımsız PACS sistem entegratörlerine pazarlanması amacıyla Danum International şirketi ile anlaşma yapmıştır. Bu şirketin Hipax ve Alma Mammo görüntüleyicilerine CyclopusCAD Mammo sistemi mamografi okuma iş akışına entegre edilerek, kullanıma hazır bir paket olarak sunulmaktadır.

1.5.1.3. ICAD; SecondLook , PowerLook Tomo Detection

ICAD firması derin öğrenme algoritmaları geliştirmeden önce mamografi görüntüleri için tasarlamış olduğu SecondLook isimli BDT sistemini tasarlamıştır. Derin öğrenme algoritmalarının gelişmesine paralel olarak, ICAD firması tasarlamış olduğu ve CE belgesi almaya hak kazanarak PowerLook Tomo Detection isimli BDT sistemini tomosentez sonuçlarını değerlendiren kliniklerin hizmetine sunmuştur. SecondLook ve aynı mimaride tasarlanan R2 ImageChecker ve CyclopusCAD Mammo için performans karşılaştırmaları da yapılmıştır [51-53].

Radyolojik görüntüleme cihazları alanında en büyük üreticilerden Siemens, GE ve Hologic firması da bu BDT sistemine uyumlu tomosentez cihazları üretmektedir [54]. PowerLook Tomo Detection, tomosentez kesitlerindeki her bir mamografi görüntü düzlemlerini hızla tarayarak şüpheli dokuları tanımlamaktadır. Daha sonra her bir düzlemden çıkarılan yumuşak doku yoğunlukları, bir sentetik 2D görüntü üzerinde harmanlanarak birleştirilir.



Şekil 1.10. (a) Belirgin olmayan bir kitlenin, (b) iyileştirilmiş görüntüsü [54].

Sonuç olarak, bu 2D görüntüde tespit edilen bölgeler, radyologlar için okuma süresini kısaltmak ve performansını iyileştirmek için verimli ve etkili bir gezinme aracı oluşturmaktadır [54]. Şekil 1.10 (a) 'da bir mamografi görüntüsü üzerinde süperpozisyon sonucu görülemeyen şüpheli bölgenin, bu BDT sistemi üzerindeki 2-D sentetik görüntü çıktısı Şekil 1.10 (b) 'de gösterilmektedir. Bu şekilden de görüleceği üzere, şüpheli bölgenin sınırları belirginleşmiştir. Sonuç olarak bu BDT sisteminin kullanılmasıyla, tek bir geliştirilmiş sentetik görüntüyü kullanarak tomosentez hacmine kolayca incelenebildiği ve dolayısıyla okuma süresinde ortalama % 29,2 azalma ile kötü huylu kitlelerin % 90 'dan fazlası tespit edilebildiği gözlemlenmiştir [54]. Bazı çalışmalar, bu BDT sistemini performansını diğer ticari BDT sistemleri ile mukayese etmiştir [55-58].

1.5.1.4. ScreenPoint Transpara

ScreenPoint firması, yirmi yılı aşkın süredir meme kanseri üzerine BDT sistemleri konusunda akademik araştırma yapan Profesör Nico Karssemeijer ve Profesör Sir Michael

Brady tarafından kurulmuştur [59]. ScreenPoint firmasına ait Transpara BDT sistemi, makine öğrenimi algoritmaları hakkında kapsamlı deneyime sahip birinci sınıf araştırmacılar ve mühendisler ile klinik araştırma konularında deneyimli radyologlar tarafından oluşturulmuştur. Bu bahsi geçen potansiyel ekip, akademik alandaki çalışmalardan başlayarak derin öğrenme ile çalışan FDA tarafından onaylı ticari bir BDT sistemi geliştirmiştir [59].

Derin öğrenme teknolojisini kullanarak 1 milyondan fazla görüntü üzerinde eğitilen Transpara yazılımı, daha hızlı ve daha doğru sonuçlar ürettiğinden dolayı, şu anda dünya çapında yaklaşık 20 ülkede kullanılmaktadır. Ayrıca ticari manada kazandıkları bu popülerliğin yanında ekibin içerisinde olan akademisyenlerin de etkisiyle oldukça fazla akademik çalışmalar [60-64] yapmışlardır. Bu çalışmalarda, Transpara yazılımını kullanan radyologların iş yükünün azalmasının yanında kanser tespitindeki başarının ne derece arttığını gösteren klinik sonuçlar yer almaktadır.

ScreenPoint firması, radyologlarla yakın işbirliği içerisinde olup ürünlerinin klinik ihtiyaçları karşılama, yoğun bir tarama uygulamasının iş akışına uymasını ve üstün bir performans elde etmeyi amaçlamaktadır. Bu firma bu amaçla, dünyanın farklı yerlerindeki öncü görüntüleme merkezleri ile işbirliği içerisinde çalışmaktadır.

Türkiye'nin radyolojik alandaki görüntüleme ve tanı merkezlerinin arasında önde gelen Radiologica kliniği [67], Transpara sistemini mamografi ile meme kanseri taramasında hem kullanarak hem de geliştirilmesine etiketlenmiş veri seti vererek katkıda bulunmaktadır. Bu klinik yılda 5.000'den fazla hastanın mamografi filmlerini teşhisleri için bu sistemi kullanmaktadır.

Transpara sisteminin başlıca avantajları; birçok kadın için gereksiz biyopsileri ve endişeyi azaltmaya yardımcı olması, bazı kanserleri daha erken tespit etmesi ve böylece bu kadınların tedaviye daha erken başlayarak, uygulanacak tedavinin potansiyel olarak daha iyi bir sonuç ortaya çıkarmasıdır [67]. Bu sebeplerden dolayı bu BDT sistemini dünya çapında pek çok radyolog tercih etmektedir.

1.5.1.5. Threepalmssoft; CadOne, WorkstaionOne

Threepalmssoft firması mamografi görüntülerinde BDT işlemi için CADOne isimli sistemi geliştirmiştir. Bu sistem yalnızca "CE" onayı değil ayrıca dünyanın çeşitli yerlerinde satılması için gerekli izinlere de sahiptir. Bu sebeplerden dolayı dünya genelinde

yoğun olarak kullanılmaktadır [68]. Bu sistemin raporlarında; meme ve pektoral kas sınırı, meme ucu pozisyonu, kütle yoğunluklarının ve kireçlenmelerin ana hatları vb. gibi radyologların yerleşik iş akışına katkı sağlayacak bilgiler yer almaktadır.

Three Palm Software'in iş istasyonu ürünü, WorkstationOne ile kurumsal bütünleşme sunularak iş akışı stilleri değiştirilebilmektedir. Bu sistemin kullanıcı arayüzü, radyologların verimliliğini en üst düzeye çıkarmak için tek düğme ve fare tekerleği stilinde çalıştırma yeteneklerine sahip olan patent almış bir ürün de sunmaktadır [69]. Ayrıca bu yazılım ince radyografik anormallikleri daha yüksek başarı ile bulabilmek için sistematik görüntüleme maskesi tekniklerini içeren uzman görüntüleme patentini de içermektedir [70]. Three Palm Software firması kendi alanında pek çok radyolojik görüntü üreticisi ve yazılım firmaları ile işbirliği kurmuştur. Bunun sonucunda "WorkstaionOne" yazılımı geliştirilirken 15 'ten fazla satıcı için özelleştirilmiştir [71].

1.5.1.6. Therapixel; MammoScreen

Therapixel, tıbbi görüntüler üzerinde yapay zekâ tabanlı BDT sistemlerini tasarlayan ve bunları ticari olarak satışa sunan uzmanlaşmış bir yazılım şirkettir. Bu şirketin, mamografi görüntüleri üzerinde geliştirmiş olduğu "MammoScreen" BDT sistemi [71], Yapay Zekâ ile meme kanseri tespit eden küresel rekabet etkinliğinde (Dijital Mamografi DREAM Challenge 2017) birinci olarak, büyük bir üne sahip olmuştur. MammoScreen sistemi, bu etkinlik kapsamında yarışmacılara sunulan 640 bin mamografi görüntüsü üzerinde derin öğrenme algoritmaları kullanılarak geliştirilmiştir. MammoScreen yazılımının diğer BDT sistemleri olan performans karşılaştırmaları akademik çalışmalarda da [72-74] sunulmuştur.

MammoScreen yazılımı, kullanıcı dostu tasarımı ile potansiyel lezyonların tespiti, potansiyel lezyonların malignitesinin karakterizasyonu ve lezyonların çoklu görünümünden eşleştirilmesi vb. sonuçları bir ara yüz ile bir radyoloğun ihtiyacı olabilecek bilgileri tek seferde ek tıklama olmadan sunabilmektedir. Ayrıca, bu yazılım tarafından belirlenen şüpheli bölgeler, şüphe seviyesine göre 1 ile 10 arasında puan verilmektedir. Bu BDT sisteminin şüpheli bir kitle üzerindeki değerlendirme sonucu (şüphe seviyesi 10) Şekil 1.11' de gösterilmektedir. Sonuç olarak bu yazılımı kullanan bir radyolog; teşhisinde şüphelendiği ve daha fazla ilgilenilmesi gereken vakalar için hızlı ve güvenilir bir onay alabilmektedir.



Şekil 1.11. Bir kitlenin MLO ve CC görünümündeki MammoScreen çıktısı [71].

1.5.1.7. Kheiron Medical Technologies, MIA

Kheiron Medikal Teknolojilerine ait MIA (Mammography Intelligent Assessment - Mamografi Akıllı Değerlendirme) yazılımı [75], İngiltere Hükümeti tarafından 2020 yılında yapılan “Artificial Intelligence (AI) in Health and Care Awards” alanında ödül kazanmıştır. MIA yazılımı, “Proud winner of Best New Radiology Software in the 2019 AuntMinnie Europe Awards” ve “Best AI Product In Health at the CogX 2019 Innovation Awards” olmak üzere iki adet daha ödül almıştır. Bu yazılımın; “İngiltere hükümeti Meme Görüntüleme” hizmetinde tarama programlarında yoğun bir şekilde kullanılması planlanmaktadır. Bu sayede daha hızlı ve verimli klinik araştırmaların yapılacağı tahmin edilmektedir. Bu projenin ölçeği ve derinliği, yapay zekânın sağlık hizmetlerine klinik olarak titiz ve güvenli bir şekilde sunulması söz konusu olduğundan benzeri görülmemiş bir boyuttadır. Sonuç olarak bu projeni, İngiltere hükümeti için bu alandaki mihenk taşı konumundadır. Ayrıca, bu firma yalnızca İngiltere’de değil, İskoçya, ABD ve Macaristan

gibi ülkelerde de iş ortakları bulunmaktadır. Bu yazılım üzerine uğraşan araştırmacılar akademik alanda yaptıkları çalışmaların bir kısmını [76-78] yayınlamışlardır.

1.5.2. Akademik Amaçlı BDT Sistemleri

Araştırmacılar, popüler bir konu olan mamografi görüntüleri üzerindeki BDT sistemleri hakkında yaklaşık 30 yıldır akademik çalışma yapmaktadır. Bu çalışmalar yaptıkları işe göre kategorize edildiğinde genel olarak 5 alt başlığa ayrılmaktadır:

- Pektoral kas sınırının belirlenmesi
- Şüpheli bölgelerin belirlenmesi ve bölütlenmesi
- Şüpheli Bölgelerin iyi/kötü huylu olarak sınıflandırılması
- Meme yoğunluğunun hesaplanması
- Meme ucunun ve dış sınırının belirlenmesi

Bu tez çalışmasında yalnızca ilk iki başlık hakkında derinlemesine çalışmalar yapılmıştır. Bu başlıklar hakkındaki literatür araştırması aşağıda verilmektedir.

1.5.2.1. Pektoral Kas Sınırı Belirleyen Akademik Çalışmalar

MLO mamografi görüntülerinde pektoral kas; üst köşe konumu, yüksek parlaklık, kabaca üçgen şekli vb. gibi bazı ayırt edici özellikleri ile ön planda olan bir bölgedir [79]. Bu nedenlerden dolayı; bu bölge genellikle kayıt amaçlı, 3 boyutlu yeniden yapılandırma işleminde ve karşılaştırma sürecinde referans bölge olarak yaygın olarak kullanılmaktadır [80]. Pektoral kasın yoğunluğu ve dokusu anormal bölgelere benzediğinden dolayı, BDT sistemlerinde YP değerlerinin artmasına sebep olmaktadır [81]. Ayrıca parlaklık düzeyi yüksek olan bu bölgenin varlığı meme dokusunun yoğunluğunu hesaplayan BDT sistemlerini de olumsuz olarak etkilemektedir. Sonuç olarak, pektoral kasın doğru tespiti ve çıkarılması, BDT sistemlerinin performansını iyileştirmek için önemli bir ön işleme adımıdır [82]. Bu nedenlerden dolayı literatürde pek çok otomatik pektoral kas tespit yöntemi önerilmiştir. Bu BDT çalışmalarının fazlaca olması sebebiyle bazı araştırmacılar bu çalışmaları [79-82] gözden geçirerek sistematik ve kapsamlı bir genel bakış sağlamıştır. Bu özet çalışmalarda, bu alandaki yöntemlerin nitel ve nicel sonuçları mukayese edilerek bu çalışmaların avantajları ve dezavantajları geniş bir şekilde gözden

geçirilmiştir. Bu alandaki bazı öncü çalışmalar kullandıkları yöntemlere göre kategorize edilerek Tablo 1.3 'de sunulmaktadır.

MIAS ve DDSM veri tabanları içinde tecrübeli radyologlarca işaretlenmiş pektoral kas bölütleme sonuçları bulunmamaktadır. Sonuç olarak bu alanda çalışma yapan bazı araştırmacılar kesin referans maskesini elde etmek için kendi radyologları ile pektoral kas bölütlemesi yapmışlardır. Fakat kesin referans veri setinin araştırmacılar arasında farklı olması, hazırlanan çalışmaların mukayese edilmesini imkânsız hale getirmektedir.

Ferrari vd. [85] pektoral kas sınırı tespit eden yöntemlerinin performansını ölçmek için MIAS veri tabanından 84 adet görüntü seçmişlerdir. Bu görüntülerdeki pektoral kas sınırları, iki uzman radyolog tarafından özel okuma prosedürleri ve bazı güçlendirme süreçleri kullanarak manuel olarak tespit edilmiştir. Ferrari vd. [85] radyologlara ait bölütleme sonuçları ile kendi yöntemlerinin bölütleme sonuçlarını her bir görüntü için ayrı ayrı isteyen araştırmacılara sunmaktadır. Bu nedenden dolayı Ferrari vd. [85] yapmış oldukları bu çalışma literatürde yaygın olarak kullanılmaktadır.

Tablo 1.3 'de sunulan çoğu çalışma [86-89,92,96,101,103] Ferrari vd. [85] çalışmalarına ait kesin referans bölütleme sonuçlarını kullanmaktadır. INbreast veri tabanı pektoral kas bölütleme maskeleri ile birlikte sunulmaktadır. Dolayısıyla INbreast veri tabanını kullanan çalışmalar [99-103] aynı kesin referans değerlerini kullanarak aynı şartlar altında performans değerlerini mukayese edebilmişlerdir.

Pektoral kas sınırı belirleyen çalışmalar temelde iki ardışık süreçten oluşmaktadır; pektoral kas sınırının kabaca tahmin edilmesi ve sonra bu kaba sınır üzerinden doğru ve kesin sınırın tespit edilmesi. Bazı çalışmalarda tahmin işlemi için çoğunlukla düz bir çizgi kullanılmıştır. Kwok vd. [83] Hough Dönüşümü ile düz çizgi tahmin ettikten sonra Uçurum Algılama Algoritması ile bu çizgi üzerinden pektoral kas sınırını belirlemişlerdir. Kinoshita vd. [94] önce Radon alan bilgisini kullanarak yüksek eğimli düz çizgi adaylarını tespit etmişlerdir ve daha sonra bu adaylar arasından en uzun düz çizgi adayını pektoral kas sınırı kabul etmişlerdir.

Tablo 1.3. Pektoral kas bölgesi bölütleyen literatürdeki öncü BDT çalışmaları

Geliştiren Araştırmacılar	Yöntem Adı	Veri tabanı	Performans Değerleri (%)
Kwok vd. [83]	Yinelemeli eşikleme ve uçurum algılama	MIAS	94 DOG
Kwok vd. [84]	Hough dönüşümü ve uçurum algılama	MIAS	88.8 DOG
Ferrari vd. [85]	Hough Dönüşümü	MIAS	1.98 YP 25.19 YN
Ferrari vd. [85]	Gabor Filtresi	MIAS	0.58 YP 5.77 YN
Ma vd. [86]	Grafik-kesim Değişken Piramit (AP)	MIAS	3.71 YP 5.95 YN
Ma vd. [86]	Grafik-kesim Minumum Yayılan Ağaç (MST)	MIAS	2.55 YP 11.68 YN
Camilus vd. [87]	Watershed	MIAS	0.85 YP 4.88 YN
Li vd. [88]	Doku Özellikleri	MIAS	1.45 YP 5.52 YN
Chen vd. [89]	Bölge Büyütme	MIAS	1.02 YP 5.63 YN
Raba vd. [90]	Bölge Büyütme	MIAS	86 DOG
Hazarika vd. [91]	Bölge Büyütme	MIAS	92 DOG
Mustra vd. [92]	Polinom Uydurma / Eğri Tahmini	MIAS	89.69 DOG
Mughal vd. [93]	Topoğrafik harita üzerinde gradyan dağılımı	MIAS	0.99 YP 5.67 YN
Kinoshita vd. [94]	Radon alan tabanlı hat tahmin	MIAS	8.99 YP 9.13 YN
Rampun vd. [95]	Kontur Büyütme	MIAS	98.1 DOG
Türe vd. [96]	Optimum Kontur Seçme	MIAS	3.5 YP 5.2 YN
Yin vd. [97]	Geometrik özellikler	-----	1.71 YP 5.2 YN
Maitra vd. [98]	Geometrik özellikler	MIAS	95.7 DOG
Taghanaki vd. [99]	Geometrik özellikler	MIAS INbreast	95 DOG 96 DOG
Shen vd. [100]	Genetik Algoritma ve Morfolojik Seçim	INbreast	1.35 YP 1.27 YN
Shi vd. [101]	Gradyan Ağırlık Haritası	INbreast	2.42 YP 13.61 YN
Rampun vd. [102]	Değiştirilmiş Bütünsel Olarak iç içe geçmiş Kenar Algılama Ağı	INbreast	0.3 YP 5.7 YN
Türe vd. [103]	Bloklara ayrılmış Eş düzey haritası üzerinden Kontur Belirleme	MIAS INbreast	0.92 YP, 1.26 YP 2.34 YP, 1.15 YP

Yin vd. [97], Maitra vd. [98] ve Taghanaki vd. [99], pektoral kas sınırının kabaca tahmin etmek için sırasıyla dikdörtgen ve bazı belirli şekillere dayalı geometrik kurallar tanımlamışlardır. Bu çalışmalar kesin sınırı tespit etmek için yinelemeli eşik yöntemini kullanmışlardır. Ancak bu çalışmalarda kaba sınır tahmin etme sürecinde, pektoral kas bölgesinin anatomik ve geometrik özellikleri için bazı kısıtlamalar kullanılmıştır. Bozulmuş pektoral kas için ilk tahmin süreci oldukça zorlu bir görevdir. Ayrıca bu ilk aşamadaki yanlış tahmin, sonraki adımları olumsuz yönde etkilemektedir.

Ferrari vd. [85] çalışmalarında Hough dönüşümü ve Gabor dalgacıklarına dayalı iki farklı yöntem önermişlerdir. Bu çalışmada, Hough dönüşüm yöntemi pektoral kas sınırının düz çizgi ile kabaca tahmin işlemi için kullanılmıştır. Fakat bu yöntem pektoral kas sınırına ait anatomik ve geometrik kısıtlamalara dayanmaktadır. Bu araştırmacılar [85] düz çizgi hipotezinin sınırlamasının üstesinden gelmek için Gabor dalgacık filtre bankasını kullanmışlardır. Bu yöntemde; pektoral kas sınırı, özel olarak tasarlanmış bazı Gabor filtreleri kullanılarak güçlendirilerek, büyüklük ve faz görüntüleri önce bir vektör toplama prosedürü kullanılarak hesaplanmıştır. Bu işlemlerin ardından her pikselin büyüklük değeri fazın yönüne bağlı olarak yayılmıştır. En son aşamada tüm sonuçları birleştirilerek pektoral kas sınırını tespit etmişlerdir.

Camilus vd. [87] pektoral kas bölgesi adaylarını saptamak için Watershed bölütleme yöntemini kullanmışlardır. Elde ettikleri pektoral kas bölgesine ait aday bölgelerini geliştirdikleri algoritma ile birleştirmişlerdir. Ancak, hem aşırı bölütlenmiş bölge adayları hem de birleştirme kriterlerinin hatalı olması durumunda yöntemleri başarısız olmaktadır. Ma vd. [86] geliştirdikleri Adaptive Pyramids (AP) ve Minimum Spanning Trees (MST) yöntemlerine dayanarak pektoral kas sınırını tespit etmişlerdir. Fakat bu yöntemler deri katlaması vb. sebeplerden dolayı oluşan çok katmanlı ve küçük boyutlu pektoral kas bölgelerinde hatalı sonuçlar vermektedir. Li vd. [88] pektoral kas sınırının kabaca tahmin edilmesinde görüntünün homojen dokusunu ve yüksek yoğunluklu sapma özelliklerini kullanmıştır. Chen vd. [89] şekle dayalı bir geliştirme filtresi kullanarak aday çekirdek noktaları ile kabaca ilgili bölgeyi tahmin etmişlerdir. Ancak bu noktaların şekil özelliklerine bağlı olarak seçilmesinden dolayı, şekilsel olarak bozulmuş pektoral kas örneklerinde hatalı sonuçlar ortaya çıkmaktadır.

Tablo 1.3 'den görüleceği üzere, bazı çalışmalar [89-91] pektoral kası tespit etmek için bölge büyütme algoritmasını kullanmışlardır. Bu algorithmada en önemli işlem bölge büyütme aşamasındaki durdurma kriterinin doğru seçilmesidir. İlk tohum, boyut

sınırlandırma ve vb. gibi bazı kısıtlamaların kullanılmasının sonucunda, bu yöntemler özellikle süperpozisyon etkisine bağlı olarak hatalı sonuçlar ortaya çıkarmaktadır.

Hong vd. [114] mamografi görüntülerindeki pektoral kas sınırı, memenin dış hat sınırı, meme ucu sınırı ve şüpheli dokular gibi belirgin bölgeleri tanımlamak için çok ölçekli yaklaşımla oluşturulan bir topoğrafik harita üzerindeki eş yükseltilerin ilişkisine dayalı bir yöntem önermişlerdir. Belirgin bir bölgenin konturları genellikle yoğun, yarı-eş merkezli bir kontur modeli oluşturur. Bu durumun bir sonucu olarak, belirgin bölgelerin sınırı, topoğrafik haritadan en dış kontur ile kolayca temsil edilebilir. Bu araştırmacılar [114] bir bölgenin belirginliğini ölçmek için yalnızca ardışık yarı-eş merkezli konturların yuvalama derinliğini kullanan bir yöntem geliştirmişlerdir. Hong vd. çalışmalarında [114] bu yöntem ile pektoral kas ve meme sınırı için kapsamlı bir şekilde uygulama yapmalarına rağmen bazı anatomik bilgiler kullanılarak bu sınırların belirgin bölgelerden kolaylıkla belirlenebileceğini iddia etmişlerdir. Türe vd. [96] pektoral kas sınırını belirlemek için Hong vd. [114] çalışmalarından ilham alarak topoğrafik harita üzerinde çalışan Optimum Kontur Seçme (OKS) yöntemi geliştirmişlerdir. OKS yöntemi yuvalama bilgisine ilaveten ek bazı geometrik özellikleri kullanmasına rağmen bozulmuş pektoral kas sınırları için hatalı sonuçlar vermektedir.

MLO mamografi görüntülerinde pektoral kas sınırının anatomik özelliklerinin sonucu olarak genelde diğer bölgelere göre belirgindir. Fakat bazı durumlarda pektoral kas bölgesinin diğer bölgeler ile süperpozisyon sonucu bozulduğu vakalar da ortaya çıkmaktadır. Bu bozucu durum haricinde deri katlanması, dış etkenler ve çekim hataları vb. gibi başka nedenlerden dolayı da bozulmalar ile karşılaşılabilir. Tablo 1.3 'de yer alan çalışmalar; Türe vd. [103] hariç özellikle bozulmuş pektoral kas sınırı tespit işlemi ve bunun üzerinde performans ölçümü yapmamışlardır. Ayrıca, bozulmuş pektoral kas sınırlarına sahip mamografi görüntülerinin seçilerek hazırlanan bir veri seti üzerinde performans sonuçlarının yer aldığı bir çalışma da literatürde yer almamaktadır.

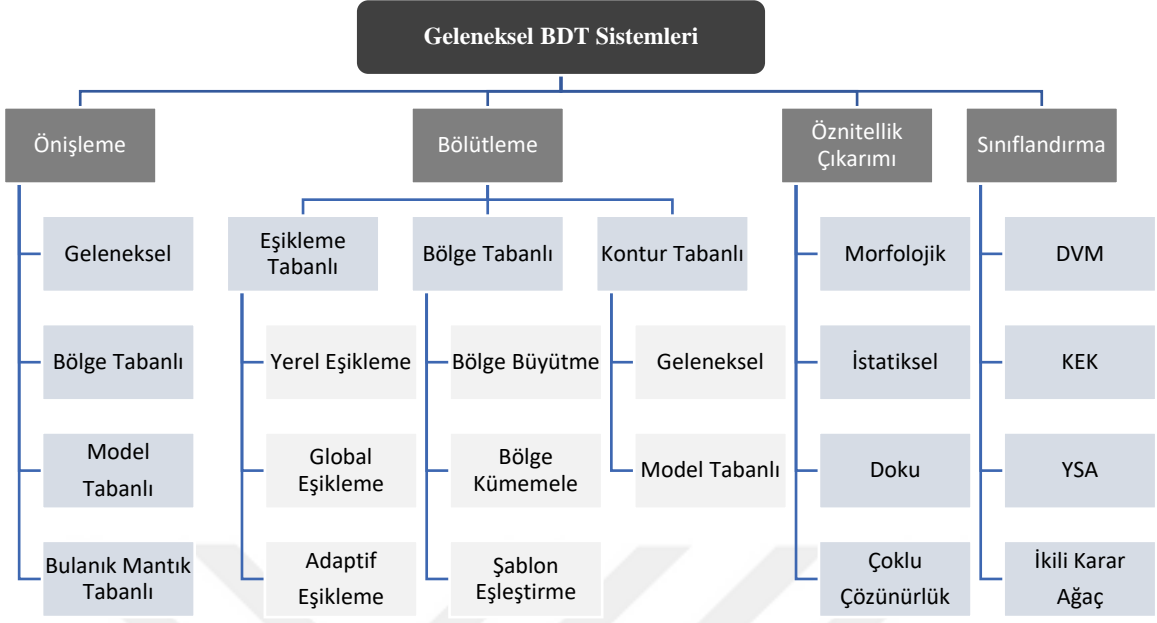
Sonuç olarak bu alanda birçok yöntem geliştirilmiş olmasına rağmen, bozulmuş pektoral kas sınırının doğru tespit edilmesi zorlu bir görevdir. Ayrıca, literatürde yer alan bu yöntemler, bozulmuş pektoral kas görüntülerine kapsamlı bir şekilde özel olarak değinmemiştir. Türe vd. [103] bozulmuş pektoral kas sınırlarının doğru tespiti için otomatik ve sağlam bir yöntem geliştirilmeyi amaçlamışlardır. Geliştirdikleri yöntem Hong vd. [114] 'nın kullanmış olduğu topoğrafik harita üzerinden alınan özelliklere dayanmaktadır. Hong vd. [114] tüm görüntü topoğrafik haritasını ve yalnızca belirgin

bölgelerin ayırt edici özelliği olan yuvalama derinliğini kullanmışlardır oysaki Türe vd. [103] bu haritayı bloklara ayırarak hem bozuk parçaları bloklara lokalize edip hem de pektoral kasın kenarları için yeni güçlü özelliklerin ortaya çıkmasını hedeflemiştir. Türe vd.[103] geliştirdikleri yöntemi bozulmuş pektoral kas bölgelerinden oluşan bir veri seti üzerinde test ederek oldukça başarılı bir performans elde etmişlerdir.

1.5.2.2. Şüpheli Bölgeleri Belirleyen Akademik Çalışmalar

Mamografi görüntüleri üzerine akademik olarak geliştirilen BDT sistemlerinin büyük bir kısmı şüpheli bölgelerin belirlenmesi ve bölütlenmesi hakkındadır. Bu kadar çalışmanın sonucu olarak özellikle bu alandaki çalışmaları mukayese etmek için pek çok araştırmacı özet çalışma [104-113] hazırlamıştır. Bu alandaki çoğu akademik çalışmanın avantajları, dezavantajları ve performans sonuçları bu özet çalışmalarda [104-113] sunulmaktadır. Özet çalışmaların yayınlandığı tarihlere bakıldığında yaklaşık 15 yıldır hazırlandığı fakat son yıllarda bu alandaki çalışmaların sayısının artmasıyla daha fazla sayıda özet çalışması için araştırmacıların motive olduğu görülmektedir. Bazı özet çalışmalar [104-107] bu alandaki çalışmaları incelerken geleneksel ve derin öğrenme temelli BDT sistemleri olmak üzere olarak iki ana başlığa ayırarak kendi aralarında mukayese etmiştir.

Şekil 1.12'de Geleneksel BDT Sistemleri için en çok kullanılan yöntemler ile birlikte bir blok diyagram üzerinde gösterilmektedir. Bazı özet çalışmalar [104-107] özellikle sistematik açıdan bu alandaki çalışmaları bu şekilde kategorize etmişlerdir.



Şekil 1.12. Geleneksel BDT sistemlerinde kullanılan başlıca yöntemler

Bu alandaki BDT sistemleri bir veri tabanındaki farklı görüntüler üzerinde ve farklı kesin referans sonuçları kullanarak deneysel çalışmalar yapmış olmalarıdır [105]. Bu durumda olan çalışmaların niceliksel mukayesesi de zor yâda imkânsız olmaktadır. Ayrıca literatürde, mamografi görüntülerindeki tespit edilmesi zor şüpheli bölgeleri kategorize ederek araştırmacıların kullanımına açık standart bir veri seti bulunmamaktadır [106]. Bu durumu öngören Oliver vd. [106] inceledikleri çalışmaları öncelikle sistematik olarak kategorize ettikten sonra öncü çalışmalarını belirleyerek performans değerlendirmesi için kendileri testler yapmışlardır. Bu test çalışmalarında MIAS veri tabanını kullanmışlardır. Öncelikle kitle içeren görüntüler için meme yoğunluğu, kitlelerin morfolojik özellikleri ve kitle boyutları olmak üzere 3 gruba ayırmışlardır. Daha sonra belirledikleri bu öncü çalışmalar için bu kategoriler için hepsi için ayrı ayrı performans değerlendirmeleri yapmışlardır. Sonuç olarak bu çalışma sayesinde farklı kategoriler için aynı şartlar altında belirledikleri öncü yöntemlerin performans değişimini mukayese edilebilmişlerdir. Bu çalışmaya benzer şekilde yaygın kullanılan veri tabanlarının kendi içinde kategorize edilmesi ile araştırmacılara zor görüntüler üzerinde aynı şartlar altında performans karşılaştırmalarına olanak sağlanabilir.

Tablo 1.4. Kitlelerin belirlenmesi üzerine yapılan literatürdeki öncü BDT çalışmaları

Geliştiren Araştırmacılar	Yöntem Adı	Veri tabanı	Performans Değerleri
Hong vd. [114]	Topoğrafi Haritası/Yuvalama Derinliği	DDSM	100% DUY 3.1 YP
Quelleg vd. [115]	Topoğrafi Haritası/Multiple-Instance Learning	DDSM	0.94 AUC
Mudigonda vd. [116]	Topoğrafi Haritası/Hiyeraşik Gruplama	MIAS	81% DUY 2.2 YP
Eltonsy vd. [117]	Eş merkezli Katmanlar/Geometrik Özellikler	DDSM	92% , 61.6% DUY 5.4, 5.1 YP
Gao vd. [118]	Eş merkezli Katmanlar / MCA+CMM	DDSM	91.3% DUY 10.4 YP
Liu vd. [119]	Eş merkezli Katmanlar/Dar Tabanlı Aktif Kontur	DDSM	82.4% DUY 5.3 YP
Agrawal vd. [120]	Eş merkezli Katmanlar/ Belirginlik Tabanlı	MIAS	0.89 AUC
Dominguez vd. [121]	Çoklu Eşikleme/ Bölge Sıralama Sistemi	MIAS	80% DUY 2.3 YP
Choi vd. [122]	Çoklu Eşikleme/Wavelet Model Tabanlı	DDSM	90% ,85.4%DUY 15, 4.5 YP
Chakraborty [123]	Çoklu Eşikleme/Radyal Bölge Büyütme	DDSM	85% DUY 1.4 YP
Casti vd. [124]	Gabor Filtre Faz Tepkisi Analizi	DDSM	82% DUY 11.86 YP
Sampaio vd. [125]	Hücrel Sinir Ağları/Doku ve Geostatik Özellikler	DDSM	80% DUY 0.84 YP
Masotti vd. [126]	Gri Düzey İnvaryant Ranklet Doku Özellikleri	DDSM	70% DUY 0.82 YP
Tai vd. [127]	Kompleks Doku Özellikleri	DDSM	90% DUY 4.8 YP
Dong vd. [128]	Vector Field Convolution	DDSM	94.78% DUY 0.95 YP
Jen vd. [129]	Abnormality Detection Classifier	DDSM	86% DUY 84% KES
Hu vd. [130]	Adaptif Eşikleme/ Çoklu çözünürlük	MIAS	91.73% DUY 0.71 YP
De Sampio vd. [131]	CNN/Mikro Genetik Algoritması	DDSM	83.17% DUY 0.19 YP
Shen vd. [132]	Deep Active Learning /Self-Paced Learning	DDSM	90% DUY 2 YP
Jung vd. [133]	RetinaNet + Feature Pyramid Network	INbreast	94% DUY 1.5 YP
Shen vd. [134]	Adversarial Learning+FCN	INbreast	87% DUY 0.5 YP
Agarwal vd. [135]	Faster R-CNN	INbreast	98% DUY 1.67 YP
Ribli vd. [136]	Faster R-CNN+Deep-CNN-s	INbreast	90% DUY 0.3 YP

Mamografi görüntülerindeki kitlelerin belirlenmesi üzerine yapılan belli başlı BDT çalışmaları kullanmış oldukları yöntemler, veri tabanlarına göre kategorize edilerek performans sonuçları ile birlikte Tablo 1.4 'de sunulmuştur. Fakat aynı veri tabanlarında bile araştırmacıların farklı görüntüleri ve sayıları seçmesinin bir sonucu olarak bu çalışmaların performans sonuçlarını aynı şartlar altında mukayese etmek oldukça zordur.

Tablo 1.4'de gösterilen bazı çalışmalar [114-123] kitleleri belirlemek için çoklu ölçekteki eşiklemeye dayalı eş düzey haritalama yöntemi ile belirgin bölgelerde ortaya çıkan aynı eş merkezli katmanların topoğrafik özelliklerini kullanmışlardır. Daha sonra belirledikleri belirgin bölgeler için seçtikleri bazı öz nitelikler ile sınıflandırma işlemi yaparak kitleleri belirleme işlemi yapmışlardır.

Hong vd. [114] kitle adaylarını belirlemek için topoğrafi görüntüsü üzerinden konturlar arasındaki çevrili sınırlar içindeki ilişkisini gösteren içerme ağacı ile sunulan hiyerarşik betimleme yöntemi kullanmışlardır. Bu çalışmada kitle tespit işlemi; belirgin bölgeler üzerinden topolojik olarak tanımlanan Minimum Nesting Depth (MND, Minimum Yuvalama Derinliği) kullanılarak gerçekleştirilmiştir. Eltonsy vd. [118] iç içe geçmiş eş merkezli bölgeleri morfolojik açıdan eleme işlemi yaparak kitleleri belirleme işlemi yapmışlardır. Bu çalışmalara [114,118] benzer olarak Dominguez vd. [121] ise çoklu eşikleme yöntemi ile kitle aday bölgelerini bulduktan sonra morfolojik ve parlaklık özellikleri ile kitleleri belirlemişlerdir.


Türe vd. [137] ilgi alanlarının belirlenebilmesi için kitlerin hayat süresi olarak minimum yuvalama derinliği eşiği belirlemişlerdir. Bu eşik ile belirledikleri yükselti bölgelerini morfolojik ve parlaklık özelliklerini kullanarak kural tabanlı elemişlerdir. Daha sonra iç içe geçmiş çoklu ölçekteki sınır desenleri arasındaki ilişki durumunun ölçülmesi esasına dayalı kural tabanlı bölge büyütme işlemi ile kitle adaylarını bölütlemişlerdir. Son olarak bu bölütlenmiş bölgeler üzerinden doku özelliklerini destek vektör makineleri (DVM) kullanılarak sınıflandırmıştır. Fakat hayat süresinin tek bir değer üzerinden belirlenmesi anında oluşan ilgi bölgesinin kitle özellikleri göstermeme ihtimali bulunmaktadır. Bu durumda olan kitleler geliştirdikleri yöntemdeki kural tabanlı elendiğinden dolayı YN'ler ortaya çıkarmaktadır. Bu durumu ortadan kaldırmak için diğer çalışmalarında [138] tek bir eşik yerine "optimum hayat süresi" tanımlayarak belirli bir aralıktaki yükselti bölgelerini kullanmışlardır. YN sayısını düşürmelerine rağmen, süperpozisyon etkisinde kalan kitlerin belirginlikleri ve eş merkezli katmanları bozulduğundan dolayı onları belirlemede başarısız olmuşlardır.

Son yıllardaki akademik amaçlı çalışmalarda; mamografi görüntüleri için büyük veri tabanları ve yüksek başarılı bilgisayarların da varlığı nedeniyle derin öğrenmeye dayalı yöntemler sıklıkla kullanılmıştır. Derin öğrenmeye dayalı yöntemleri kullanarak geliştirilen literatürdeki belli başlı BDT çalışmaları [131-136], Tablo 1.4 'de gösterilmektedir.


1.6. Tezin Amacı ve Kapsamı

Bu tez çalışması kapsamında mamografi görüntüleri üzerinde yer alan kitleleri ve pektoral kas sınırını belirleyen bir BDT sistemi geliştirilmiştir. Mamografi görüntüsündeki nesnelere belirginliği konumu, meme anatomisi, süperpozisyon vb. etkenlere bağlı olarak değişime uğramaktadır. BDT sistemleri için bu tip nesnelere belirlenmesi zor bir görevdir. Belirginlik durumunu etkileyen bu faktörler aşağıda kategorize edilerek, Şekil 1.13'de gösterilmiştir. Bu tez çalışması kapsamında özellikle belirginliği düşük bu kitle tiplerinin yüksek doğrulukla tespit edilmesi amaçlanmış olup deneysel çalışmalar da bu amaca göre organize edilmiştir.

- Pektoral kas ile kısmen süperpozisyon olan kitleler (a),
- Pektoral kas ile tümüyle süperpozisyon olan kitleler (b),
- Filmin dışında kaldığından bir kısmı gözükmeyen kitleler (c),
- Süt kanalları vb. gibi nesnelere ile süperpozisyon olmuş kitleler (d),
- Filmin arka planına yakın olan kitleler (e),
- Yoğun bir meme içerisinde süperpozisyon olan kitleler (f).



Şekil 1.13. Belirginliği düşük kitle tipleri



Şekil 1.14. Bozulmuş pektoral kas bölgesi tipleri

MLO mamogram görüntülerindeki pektoral kas bölgesinin belirginliği; görüntü üzerindeki konumu, meme anatomisi, süperpozisyon vb. etkenlere bağlı olarak bozulmaya uğramaktadır. BDT sistemleri için bu tip bozulmuş pektoral kas bölgelerinin belirlenmesi zor bir görevdir. Bozulma durumuna göre ortaya çıkan pektoral kas örnekleri aşağıda kategorize edilerek, Şekil 1.14'de gösterilmiştir. Bu tez çalışması kapsamında özellikle bozulmuş pektoral kas bölgelerinin yüksek doğrulukla tespit edilmesi amaçlanmış olup deneysel çalışmalar da bu amaca göre organize edilmiştir.

- Küçük boyutlu pektoral kas örnekleri (h), (i), (p),
- Kitleler ile süperpozisyon olmuş pektoral kas örnekleri (m), (n),
- Çok katmanlı pektoral kas örnekleri (b), (d), (e), (f), (j), (l),(n),(o),
- Komşu dokular ile süperpozisyon olan pektoral kas örnekleri (a) - (h), (m) - (p),
- Heterojen dağılımlı parlaklık gösteren pektoral kas örnekleri (a), (d), (e), (h), (i), (p).

MLO mamografi görüntülerinde büyük bir kısmı gözükten pektoral kas bölgesi; üst köşe konumu, yüksek yoğunluklu ve üçgen şekli gibi bazı ayırt edici özelliklere sahip ana işarettir. Ayrıca bu bölge doku ve yoğunluk özellikleri açısından anormal bölgelere benzemektedir. Bu bölgenin bölütlenmiş maskesi radyolojik değerlendirme aşamasında pek çok amaçla kullanılmaktadır. Pektoral kasa ait bölütlenmiş bölgenin BDT sistemlerindeki başlıca kullanım yerleri aşağıda maddeler halinde özetlenmektedir;

- Maske, 3-D rekonstrüksiyon aşamasında ana referans bölgesi olarak kullanılmaktadır.
- Maske, meme çiftlerinin iki taraflı kaydı işleminde karşılaştırma bölgesi olarak kullanılmaktadır.
- Bu bölge yüksek yoğunluğa sahip olmasından dolayı, meme yoğunluğu hesaplayan BDT sistemlerinin doğruluğunu artırmak için bu bölge çıkarılmaktadır.
- Doku ve parlaklık özellikleri bakımından kitleye benzemesinden dolayı BDT sistemlerinin yanlış pozitif sayısını düşürmek için bu bölge çıkarılmaktadır.

MLO mamografi pektoral kas bölgesi doku ve yoğunluk özellikleri açısından anormal bölgelere benzemektedir. Bu nedenle bu bölgenin varlığı BDT sistemleri üzerinde YP sayısının artması ile performans düşüşüne sebebiyet vermektedir. Fakat süperpozisyon sonucunda kitlelerin konumu pektoral kas bölgesi sınırında hatta içerisinde bile olabilmektedir. Sonuç olarak pektoral kas bölgesi çıkarılması işlemi ile YP düşürme bakımından performans artışı olurken, YN artışı ile tersi bir durum oluşabilmektedir. Literatürde yer alan pektoral kas bölgesi çıkarıcı BDT yazılımları, bu gölge içerisinde olabilecek kitleleri ihmal etmişlerdir. Bu tez çalışması kapsamında pektoral kas bölgesinin çıkarıldıktan sonra kitle tespit işlemi yapılmasının BDT sisteminin YP/YN performansına olan etkisinin incelenmesi de amaçlanmıştır.

Tezin ilk bölümünde ilk olarak meme anatomisi ve meme kanseri tanıtılmış daha sonra meme kanseri görüntüleme yöntemlerinden en çok kullanılanlardan biri olan

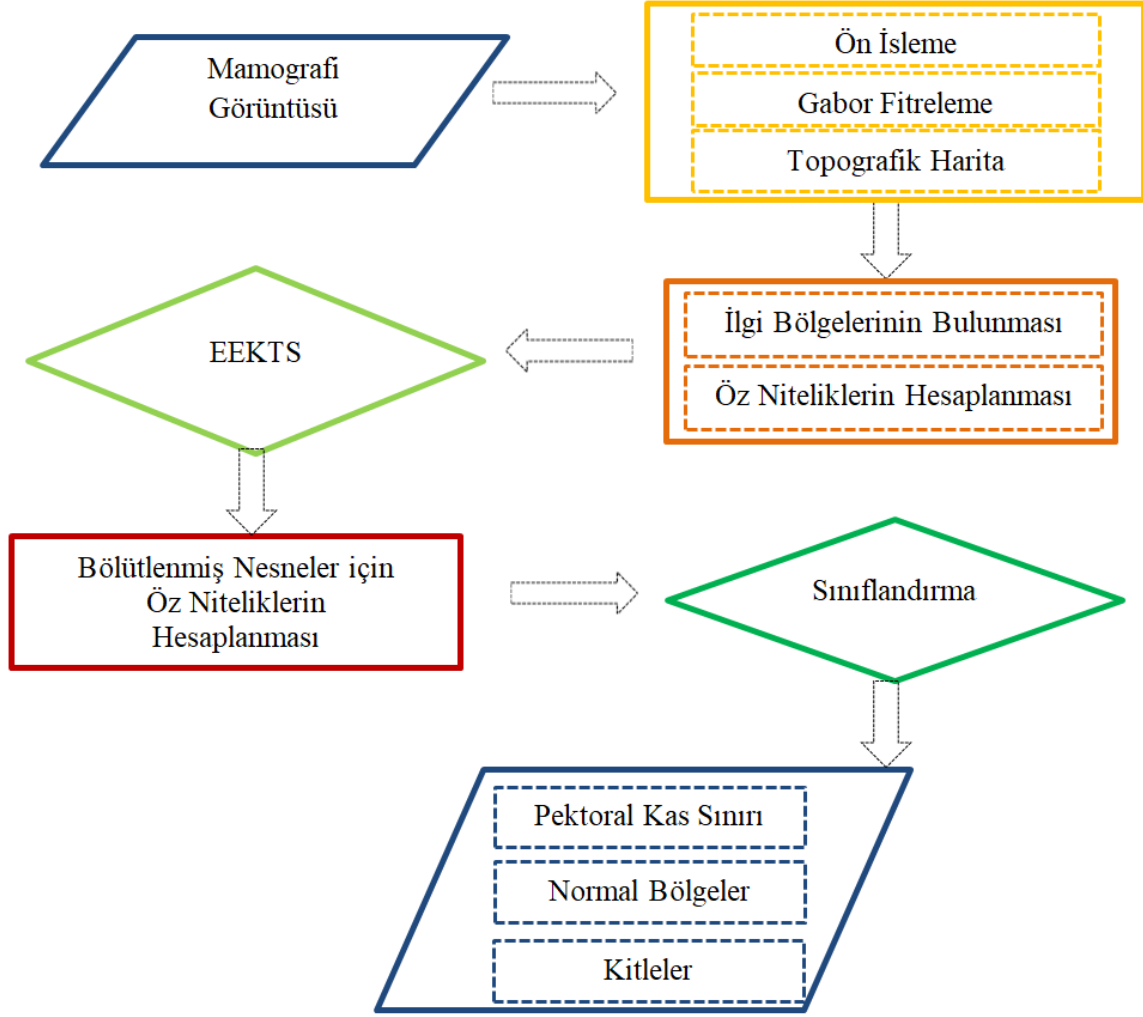
mamografi ve diğerk tamamlayıcı yaygın görüntüleme yöntemleri tanıtılmıştır. Daha sonra dünya çapında en yaygın ve ayrıca derin öğrenme için son yıllarda hazırlanmış olan mamografi veri tabanları hakkında özet bilgiler verilmiştir. Mamografi üzerinde yapılan radyolojik değerlendirmeler sunulduktan sonra bu alandaki BDT sistemleri incelenerek hem ticari hem de akademik olarak sistematik bir biçimde sunulmuştur.

Şekil 1.15’de bu tez çalışması için genel akış şeması verilmektedir. Tezin ikinci bölümü bu akış şemasına göre organize edilmiştir. Öncelikle ilk aşamada mamografi görüntülerinde meme bölgesi belirlenmiştir. Daha sonra kitleleri üzerindeki süperpozisyon etkisini azaltmak için 4 farklı açı Gabor filtre kullanılmıştır. Bu çıktıların eş düzey haritaları oluşturularak, topoğrafik belirginlik esaslı Optimum Hayat Süresi (OHS) üzerinden yapılarak eş yükselti eğrileri seçilmiştir. Daha sonra Eşyükselti Eğrilerinin Kural Tabanlı Sınıflandırılması (EEKTS) yöntemi ile ilgi bölgeleri belirlenerek kabaca bölütlenmiştir. Bir sonraki aşamada bu ilgi bölgeleri üzerinden doku öznitelikleri hesaplanmıştır. Ayrıca bu ilgi bölgelerine ait yuvalama derinliği, morfolojik ve parlaklık öz nitelikleri kullanılarak kitle ve normal bölgeler sınıflandırılmıştır.

Tezin ikinci bölümünün son kısmında bozulmuş pektoral kas bölgelerinin yüksek doğrulukla bölütlenebilmesi için topoğrafik harita bloklara ayrılmıştır. Güncellenen EEKTS yöntemi her bir blok için aday sınır parçalarını bulmuştur. Son aşamada yanlış pozitif aday sınır parçaları ortadan kaldırılır ve daha sonra EEKTS tarafından tespit edilemeyen sınır parçaları için eğri uydurulması ile pektoral kas sınırı tespit edilmiştir.

Tezin üçüncü bölümünde öncelikle EEKTS yönteminin belirginliği düşük kitle tipleri belirlemedeki performansını değerlendirmek için bazı parametrelerin değiştirilmesiyle elde edilen deneysel bulgular niceliksel olarak sunulmuştur. Ayrıca belirginliği düşük kitleleri içeren görüntü örnekleri üzerinde, EEKTS yönteminin niteliksel sonuçları sunulmuştur. Daha sonra kabaca bölütlenen ilgi bölgelerinden elde edilen özniteliklerin sınıflandırma işlemine olan etkisi deneysel olarak incelenmiştir. EEKTS yöntemi ile bozulmuş pektoral kas tiplerinin belirleme üzerine detaylı deneyler yapılmış olup sonuçlar hem niceliksel hem de niteliksel olarak sunulmuştur. Bu tez çalışmasında elde edilen deneysel bulgular, literatürde yer alan bu alandaki öncü çalışmalarla karşılaştırılarak tablo ve grafikler ile sunulmuştur. Bu bölümün son aşamasında; pektoral kas bölgesinin çıkarıldıktan sonra kitle tespit işlemi yapılmasının, bu tez çalışmasında geliştirilen BDT sisteminin YP/YN performansına olan etkisi incelenmiştir.

Dördüncü ve beşinci bölümlerde bu tez çalışmasında elde edilen sonuçlar ve bu tez çalışmasından sonra yapılabilecek gelecek çalışmalar hakkında bilgiler verilmiştir.

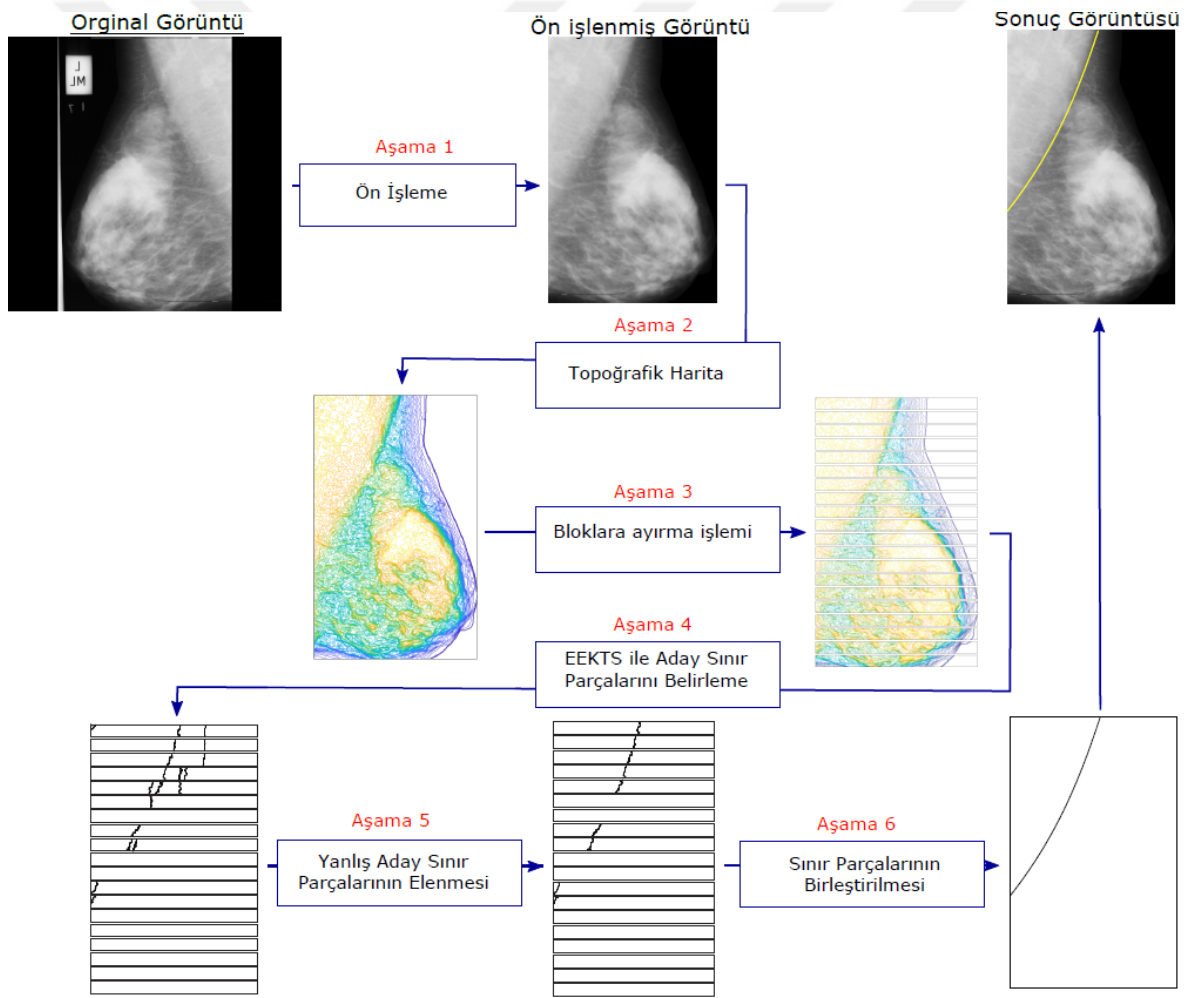


Şekil 1.15. Çalışmanın genel akış şeması

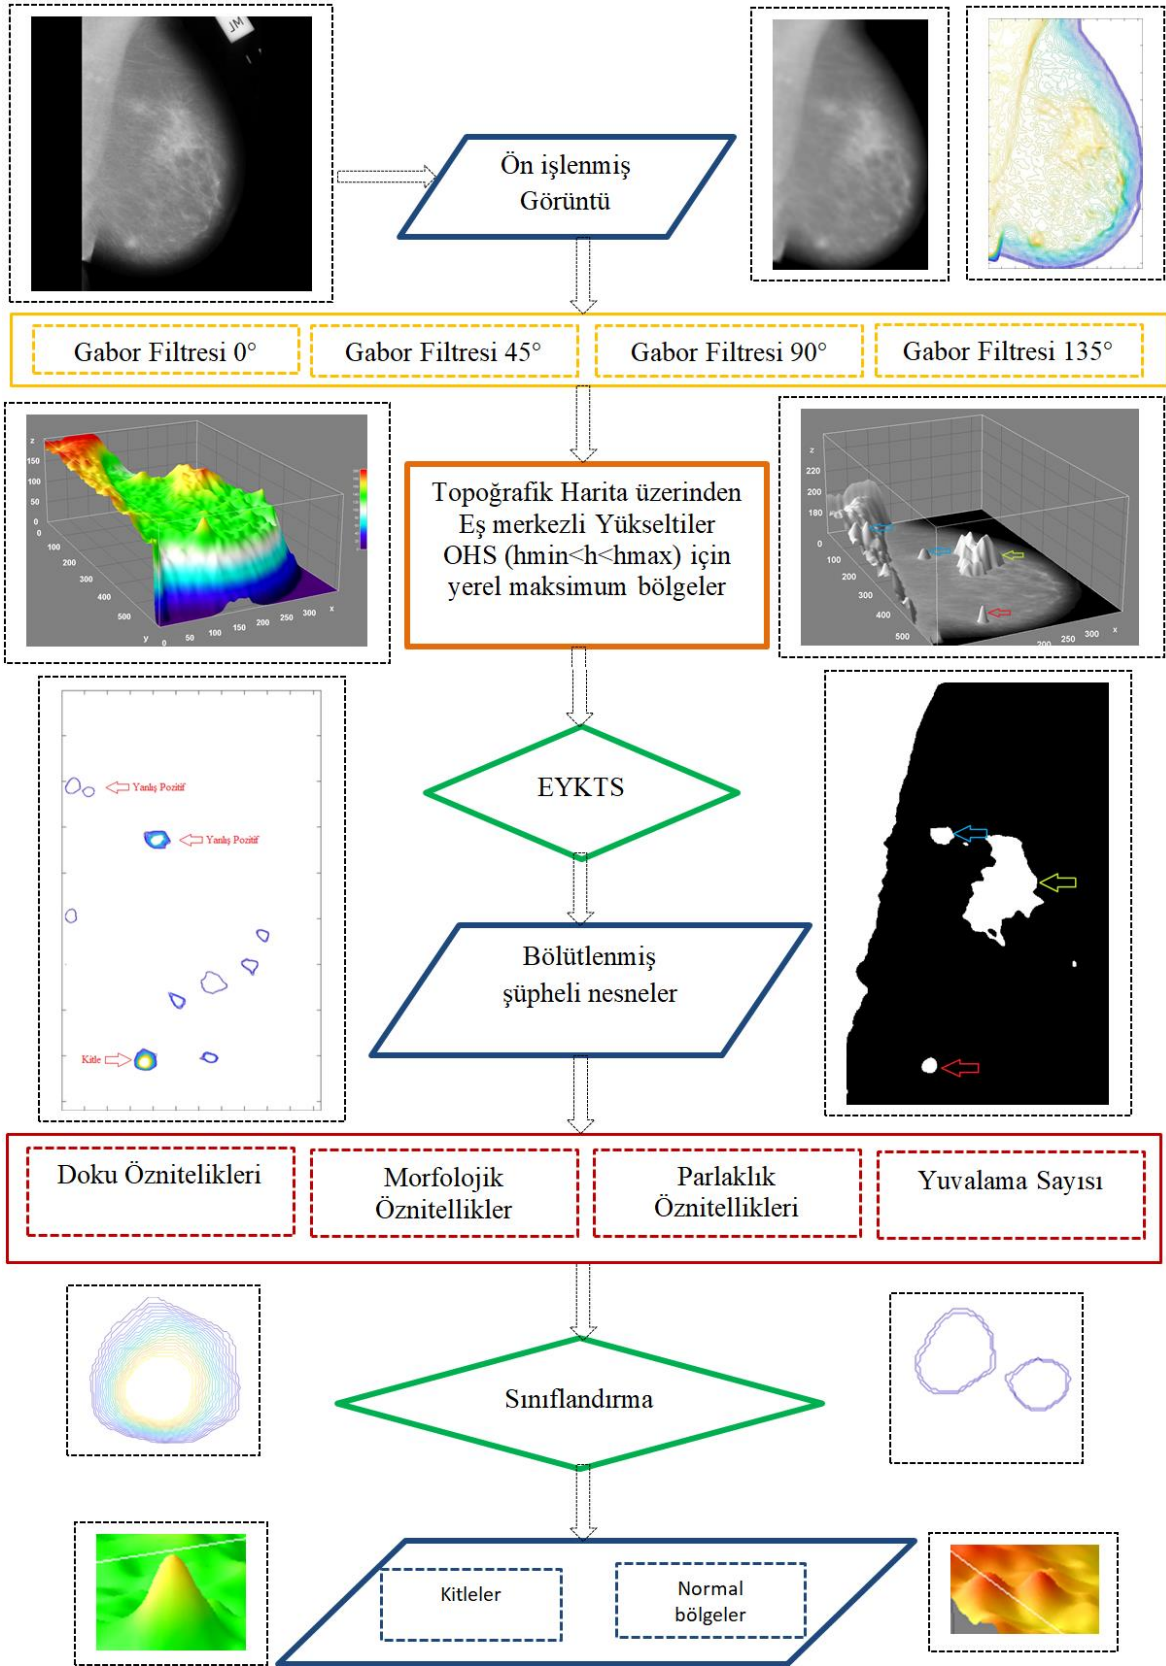
2. YAPILAN ÇALIŞMALAR

2.1. Önerilen Yöntem

Bu tez çalışması kapsamında önerilen EEKTS (Eş Yükselti Eğrilerinin Kural Tabanlı Sınıflandırılması) yöntemi ile kitleler ve pektoral kas sınırı belirlenmektedir. Bu yöntemle ait akış diyagramları Şekil 2.1 ve Şekil 2.2 'de sırasıyla gösterilmektedir. Bu akış diyagramlarındaki her bir aşama sırasıyla başlıklar halinde aşağıda sunulmaktadır.



Şekil 2.1. EEKTS yöntemi ile pektoral kas bölütlenmesi için akış diyagramı



Şekil 2.2. EEKTS Yöntemi ile şüpheli bölgelerin belirlenmesi için akış diyagramı

2.2. Görüntü Ön İşleme Adımları

Bu tez çalışmasında geliştirilen yöntemlerin farklı mamografi veri tabanları için otomatik olarak çalışması amaçlanmıştır. Bundan dolayı öncelikle bazı görüntü ön işleme adımları ile tüm veri tabanları için geçerli standardizasyon işlemi yapılması gereklidir. Bu yapılan işlemler aşağıdaki alt başlıklarda sırasıyla anlatılmaktadır.

2.2.1. Meme Bölgesi Seçimi ve Arka Plan Çıkarma

Tipik bir mamografi görüntüsü genellikle başlıca iki farklı bölgeyi içerir, X ışınlarına maruz kalan göğüs bölgesi ve maruz kalmayan hava arka planı (göğüs olmayan). Ayrıca, hava arka plan bölgesinde etiketler, işaretçiler ve vb. gibi nesnelere yer alabilmektedir. Arka planda yer alan bu bozucu etkilerin ortadan kaldırılması ve döndürme işlemi için toplam 4 aşamadan oluşan bir yöntem önerilmiştir. Bu aşamaların çıktıları örnek bir mamografi görüntüsü üzerinde sırasıyla adım adım Şekil 2.3 'de gösterilmektedir.


1. Eşikleme: Bu aşama, bir mamografi görüntüsündeki göğüs bölgesini ve hava arka planını ayırmak için kullanılır. Deneysel olarak belirlenen 20 gri seviyesi ile eşikleme işlemi gerçekleştirilir. Bu işlemin sonucunda, genellikle meme görüntüsü ve diğer bozucu etkenlere ait farklı boyutlarda oluşan beyaz renk kodunda nesnelere oluşur, en büyük nesne göğüs bölgesi olarak tanımlanır.

2. Morfolojik İşlemler: İlk aşamanın sonucunda bazı durumlarda bozucu etkenlere ait nesnelere meme bölgesi ile birleşik kalabilir. Bağlı nesnelere ayırmak için bir erozyon işlemi uygulanır. Daha sonra Bağlı Bileşen Etiketleme (BBE) algoritması kullanılarak meme bölgesi seçilir. Bu işlemden sonra, ortaya çıkan ikili görüntü yalnızca göğüs bölgesini temsil etmektedir. Son olarak, yapılan erozyon işlemini telafi etmek için bu görüntüye aynı miktarda bir genişletme işlemi gerçekleştirilir.

3. Çıkarma: Son ikili görüntü, orijinal görüntüdeki meme bölgesini çıkarmak için kullanılır. Orijinal görüntü ile bu ikili görüntü çarpılarak meme bölgesine ait kısım temiz bir şekilde oluşturulur. Son olarak nesnenin sınırlayıcı kutusu kullanılarak meme bölgesi kırılır. Bu adım sonucunda pektoral kasın yanında yer alan siyah bantlı kısım da çıkarılır ve böylece pektoral kas görüntüsünün köşesine yerleşir.

4. Döndürme: Sol ve sağ yöndeki memelerin mamografi görüntülerindeki yön farklılığını ortadan kaldırmak için, pektoral kası her zaman görüntünün sol üstünde olacak

şekilde sağ mamografi görüntülerine döndürme işlemi yapılmaktadır. Bu işlem için, 50x50 piksel boyutundaki bir maske penceresi görüntünün en üst sağ ve en üst sol noktasına konumlandırılarak, maske içindeki ortalama yoğunluk hesaplanır ve karşılaştırılır. Bu sonuca göre sağ üstteki değer sol üstteki değerden büyük ise görüntünün sağ memeye ait olduğuna karar verilir ve ardından ilgili görüntü dikey olarak döndürülür.



Şekil 2.3. Meme bölgesinin belirlenmesi için işlem aşamaları. (a) orijinal görüntü, (b) eşiklenmiş görüntü, (c) en büyük nesne seçimi, (d) kırılmış meme görüntüsü

2.2.2. Görüntü Normalizasyonu

Bu tez çalışmasında geliştirilen yöntemde alan, çevre vb. gibi bazı metrik ölçüler öznitelik olarak kullanılmaktadır. Dolayısıyla farklı veri tabanlarındaki boyut farklılıklarının standardize edilmesi gerekmektedir. MIAS veri tabanında yer alan görüntülerde yükseklik boyutu (1024 piksel), DDSM ve INbreast veri tabanı görüntülerine göre en düşük değerdir. Bu nedenden dolayı diğer veri tabanlarındaki görüntüler bu değer üzerinden normalize edilerek ölçekleme işlemi yapılmıştır.

2.2.3. İki Boyutlu Gabor Süzgeci

Bir mamografi görüntüsü üzerinden alınan bir kitlenin 3 boyutlu parlaklık dağılımı Şekil 2.8 (a) 'da gösterilmektedir. Bu şekil üzerinde oldukça fazla küçük boyutlu tepeler yer almaktadır. Bu tepeler, ilgi bölgelerinin belirlenmesi aşamasını olumsuz açıdan etkilemektedir. Literatürde bu gürültüleri ortadan kaldırırken kitle kenar şekillerini ciddi oranda bozmayacak olan Gauss, ortalama değer, medyan ve anizotropik vb. filtreler oldukça fazla kullanılmıştır. Şekil 2.8 (c) 'de Gauss filtresi ile yumuşatılmış kitlenin 3B görüntüsü gösterilmektedir. Bu şekilden de görüleceği üzere, bu filtre ile yalnızca küçük tepeler değil aynı zamanda kitleye ait kenar şekillerinde detaylar da ortadan kalkmıştır.

Gabor filtresi, görüntü işleme alanında belirli yönlerdeki bileşenlerin belirgin hale getirerek özellikle yönlü doku analizinde öz nitelik çıkarmak için oldukça fazla kullanılan bir yöntemdir. Bu filtrelere ait frekans ve yönelim temsillerinin, birçok araştırmacı tarafından insan görsel sistemine benzer olduğu iddia edilmektedir. Bazı araştırmacılar, memeli beyinlerinin görsel korteksindeki basit hücrelerin Gabor fonksiyonları ile modellenebileceğini iddia etmişlerdir. Gabor filtresi, görüntü işleme alanında belirli yönlerdeki bileşenlerin belirgin hale getirerek özellikle yönlü doku analizinde öz nitelik çıkarmak için oldukça fazla kullanılan bir yöntemdir. Bu tez çalışmasında süperpozisyon sonucu belirginliği azalmış şüpheli bölgelerin belirlenmesi amaçlandığından Gabor filtresi kullanılmasına karar kılınmıştır.

Bir Gabor filtresi, iki boyutlu Gauss fonksiyonu ile harmonik bir fonksiyon olan trigonometrik kosinüs fonksiyonunun çarpılmasından elde edilir. Buradaki harmonik fonksiyon, karmaşık Gabor fonksiyonunun reel bileşenidir. Gabor filtresinin denklemi Eşitlik 2.1 'te verilmektedir.


$$gabor(s, x, y; \lambda, \theta, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2 s^2}\right) * \cos\left(2\pi \cdot \frac{x'}{\lambda s^2}\right) \quad (2.1)$$

$$x' = x \cdot \cos\theta + y \cdot \sin\theta \quad (2.2)$$


$$y' = -x \cdot \sin\theta + y \cdot \cos\theta \quad (2.3)$$

Bu denklemlerde x ve y değerleri görüntüdeki piksellerin yatay ve dikey koordinatlarını, γ gabor çekirdeğinin en/boy oranını, σ aranan örüntünün ölçeğini (Gauss zarfının genişliğini), λ ise gabor çekirdeğinin dalga boyunu göstermektedir. Dönme işlemi için x ve y koordinatlarının farklı θ açılarında döndürülmüş halleri Eşitlik (2.2) ve (2.3)'te verildiği gibi hesaplanmaktadır.

Gabor süzgecinde istenen parametreler (λ , σ , θ , γ) ayarlandığında mamografi görüntülerindeki süperpozisyona uğramış şüpheli bölgeler belirginleştirilmektedir. Sabit ölçekli gabor süzgeci denkleminde Eşitlik 6'daki gibi ölçek parametresi s de eklenerek çok ölçekli gabor çekirdeği ile ölçek değişiminin süperpozisyona olan etkisi incelenmektedir. Ölçek parametresi de eklenerek elde edilen farklı yönlerdeki (0° , 45° , 90° , 135°) ve farklı ölçeklerdeki örnek Gabor çekirdekleri Şekil 2.4'de gösterilmektedir.



Şekil 2.4. Farklı ölçeklerde ve farklı yönlerde elde edilen Gabor süzgeçleri



Şekil 2.5. (a) 0° , (b) 45° , (c) 90° , (d) 135° için Gabor filtre çıktıları

Yukarıda belirtilen gabor fonksiyonu denkleminin parametrelerinin değerleri yöntem üzerindeki etkileri incelenerek belirlenmiştir. Bahsi geçen parametreler için 7. seviye üzerinden deneysel olarak bulunmuş parametre değerleri ile oluşturulan Gabor filtrelerinin uygulanmasının sonucunda ortaya çıkan genlik çıktıları Şekil 2.5 'de 4 farklı açı için sırasıyla gösterilmektedir. Bundan sonraki aşamada bu 4 görüntünün her biri için ilgi bölgesi belirleme ve bölütleme işlemi yapılmaktadır. Bu işlemler bittiğinde tüm belirlenen ilgi bölgelerinin topoğrafik haritaları birleştirilir. Birleştirilmiş topoğrafik harita bölütlenen nesnelerin kontur bilgilerini içermektedir.

2.3. Şüpheli Bölgelerin Belirlenmesi ve Bölütlenmesi


Bu tez çalışması kapsamında önerilen BDT sistemi için ilgi bölgelerinin belirlenmesi ve kabaca bölütleme işlemleri bu aşamada gösterilmektedir.

2.3.1. Çoklu Eşik Seviye ile İlgi Bölgelerinin Belirlenmesi


Literatürdeki çoğu BDT sistemi, ilgi bölgelerini eşikleme yöntemleri ile belirlemişlerdir. Fakat bu yöntemlerin pratikte kullanılmasına ilişkin bazı dezavantajlar bulunmaktadır. Bunlar, eşik seviye değeri işlemi görüntüden görüntüye değişebilmektedir ayrıca görüntüde bile tek bir eşik seviyesi ile tüm şüpheli bölgelerin belirlenebilmesi mümkün değildir. Bundan dolayı çoğu çalışma tek bir eşik değer yerine çoklu eşik seviye ile ilgi bölgelerini belirlemişlerdir.

Şekil 2.3 (d)' de yer alan ön işlenmiş mamografi görüntüsüne ait parlaklık değişiminin renkli yüzey haritası yumuşatılmış olarak Şekil 2.6 (a)'da gösterilmektedir. Bu şekilden de görüleceği üzere, kitle ve kitle benzeri nesnelere morfolojik olarak yüksekliği ve yüzey alanları değişkenlik gösteren tepeler şeklindedir. Bu nesnelere Şekil 2.6 (b-d)'de sırasıyla gösterilmektedir.


Kitle ve kitle benzeri nesnelere ortaya çıktığı farklı 2 eşik seviyesi için ilgi bölgeleri Şekil 2.7 (a) ve (b) 'de sırasıyla gösterilmektedir. Ayrıca bu eşik seviyeleri için yüzey haritaları 2.7 (c) ve (d) 'de sırasıyla gösterilmektedir. Bu eşik seviyelerinin değerleri bazı önemli nesnelere gösterebilmek için özellikle seçilmiştir. Bu şekiller üzerinde kitle, kitle benzeri nesnelere ve glandular dokular sırasıyla kırmızı, mavi ve yeşil renkli oklar ile işaretlenmiştir. Bu şekillerden de görüleceği üzere bazı şüpheli bölgeler farklı eşik değerlerinde ortaya çıkmakta ve hayat süresinin bitmesi ile kaybolmaktadır.



(a)



(b)

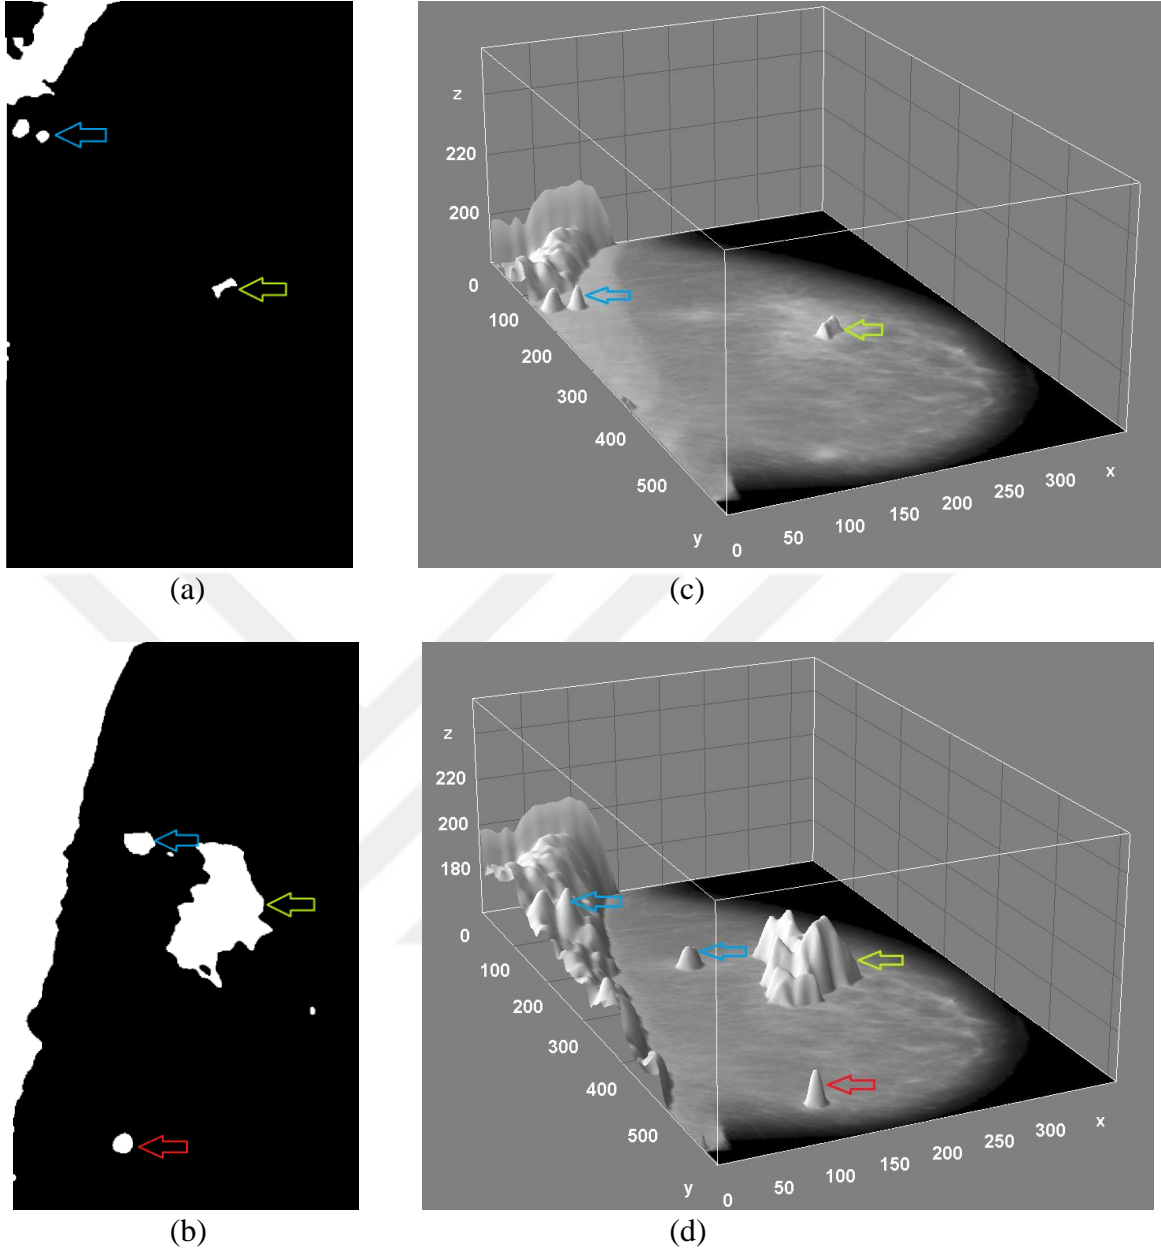


(c)



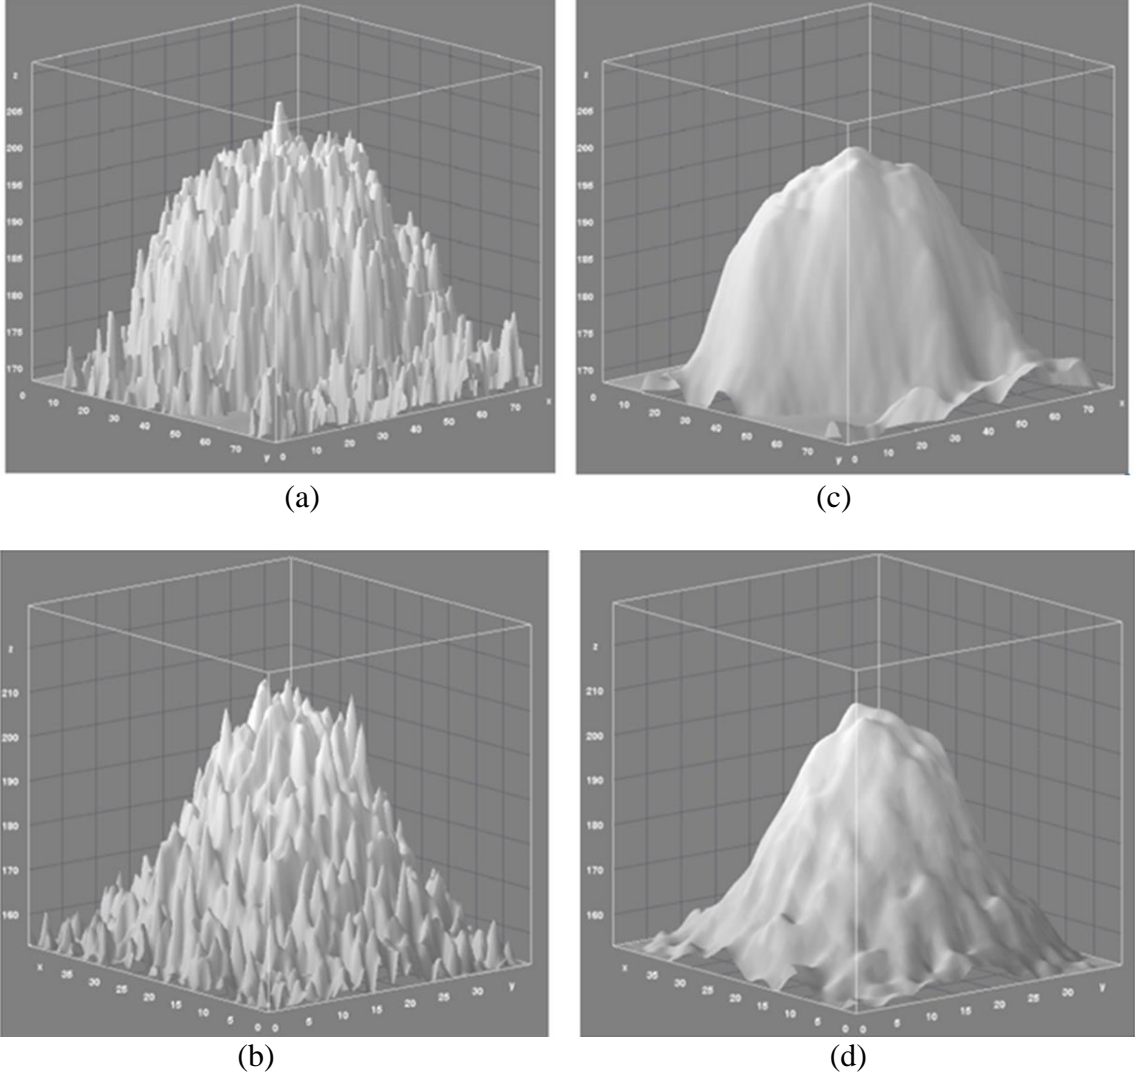
(d)

Şekil 2.6. Örnek mamografi görüntüsü için 3B yüzey haritası (a) tüm meme bölgesi (b) kitle, (c) ve (d) benzeri nesnelere



Şekil 2.7. Farklı eşiklerdeki ilgi bölgelerinin (a), (b) 2B ve (c), (d) 3B görünümü

Bir kitleye ait 3B parlaklık dağılımı ve yumuşatılmış görünümü Şekil 2.8 (a) ve Şekil 2.8 (c) 'de sırasıyla gösterilmektedir. Bu tez kapsamında yapılan deneysel çalışmalarda kullanılmak üzere Gauss filtresi ile sentetik kitle görüntüsü oluşturulmuştur. Bu sentetik görüntünün kitleye benzerliğini sağlamak için normal kitlede bulunan gürültülere benzer olacak şekilde “tuz biber” gürültüsü eklenmiştir. Şekil 2.8 (b) ve (d)'de sentetik bir kitleye ait 3B parlaklık dağılımı ve yumuşatılmış görünümü sırasıyla gösterilmektedir.



Şekil 2.8. Gerçek kitle ve Sentetik kitle için sırasıyla (a) , (b) 3B parlaklık dağılımı ve (c), (d) yumuşatılmış görünümleri

Bu tez çalışmasında çoklu eşikleme yöntemi ile mamografi görüntülerindeki şüpheli bölgelerin belirlenmesi işlemindeki hataları gösterebilmek farklı ebatlardaki sentetik kitlelerin yer aldığı iki adet test görüntüsü oluşturulmuştur. Daha sonra bu görüntüler üzerinde; hayat süresi, eyer (birleşme), oluşum noktası vb. gibi bazı temel tanımlamalar şekiller ile açıklanarak gösterilmiştir. Daha sonra bu görüntüler üzerinde farklı eşikleme yöntemleri ile tespit edilen ver kaçırılan ilgi bölgeleri detaylıca şekiller üzerinde gösterilmiştir.

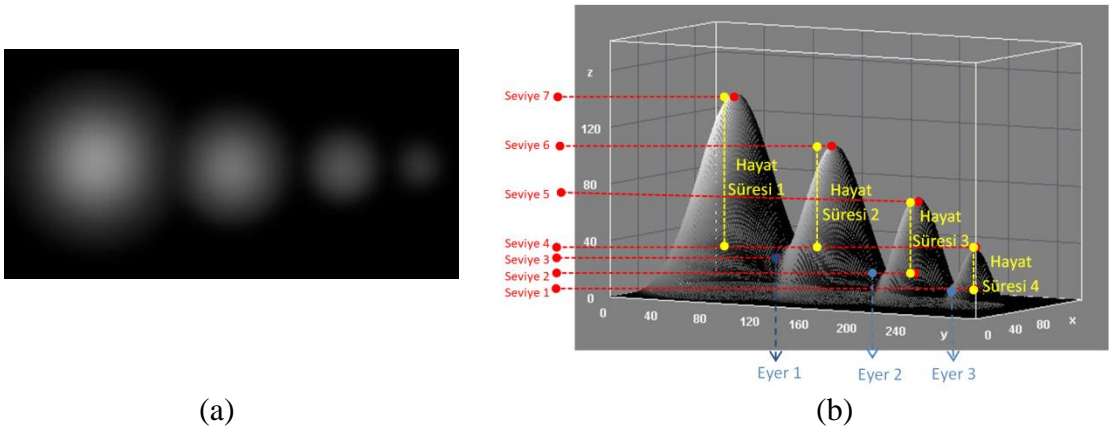
Çoklu eşik seviyesi ile ilgi bölgesi belirleme işlemi için Tablo 2.1’de gösterilen farklı Gauss filtre standart sapma değerleri ve farklı parlaklık seviyeleri kullanılarak farklı ebatlarda olacak şekilde 4 adet sentetik kitle oluşturulmuştur. Bu kitleler birbirlerine yan

yana bitişik durumda büyük ebatlıdan küçük ebatlı olana doğru sıralanarak Şekil 2.9 (a)'da gösterilen test görüntüsü oluşturulmuştur. Bu görüntüye ait 3B görünümü Şekil 2.9 (b)'de gösterilmektedir. Bu şekilden de görüleceği üzere her bir kitlenin yüzey alanı ve yükselti seviyesi farklıdır.

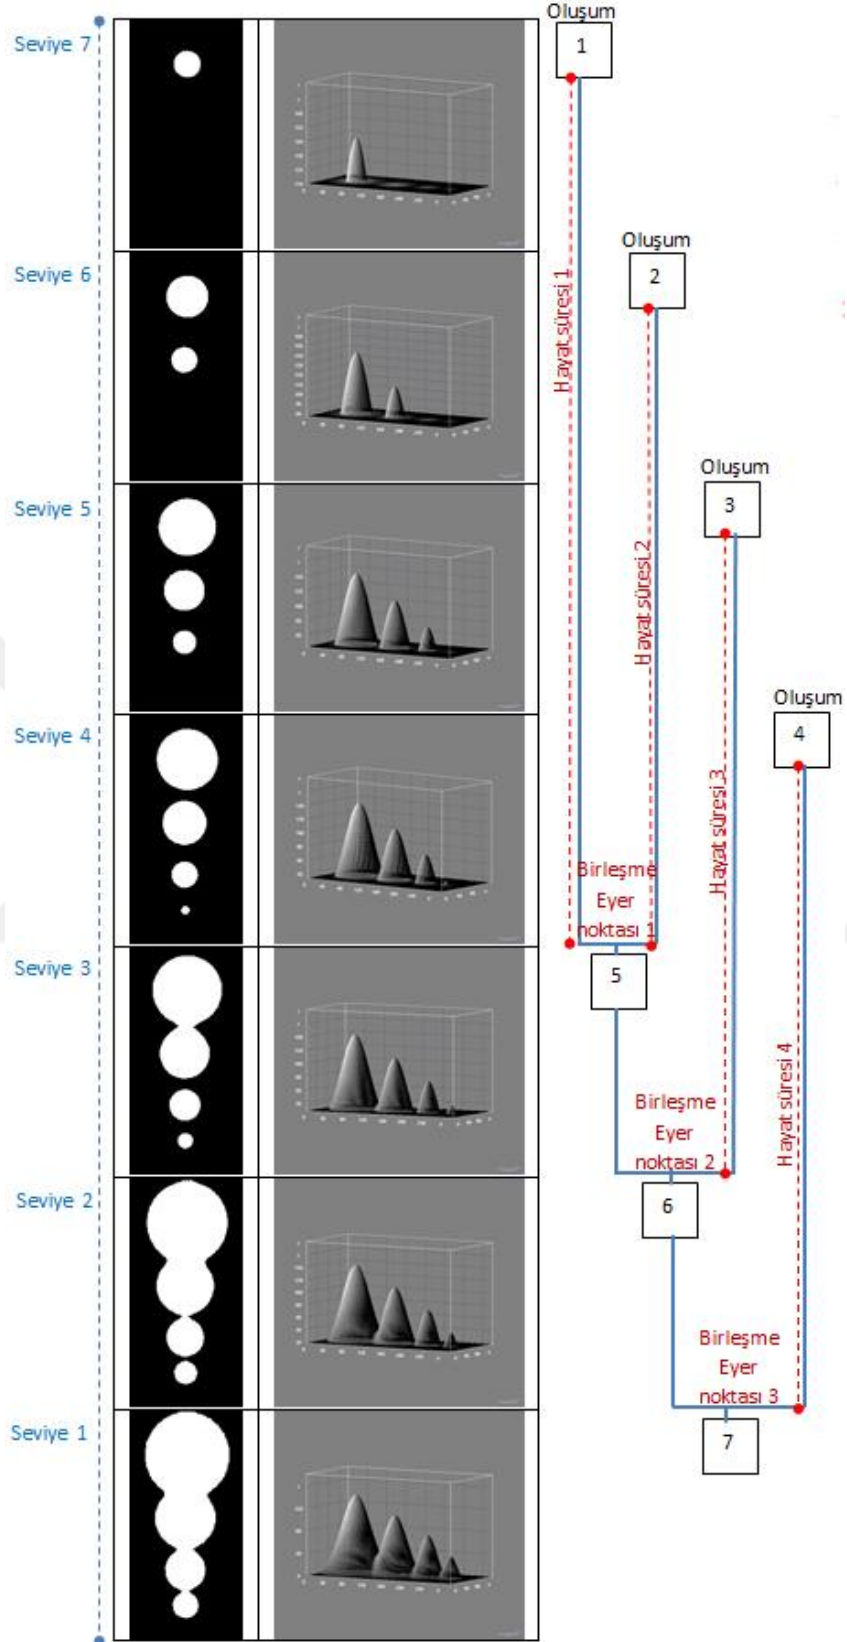
Çoklu eşikleme işleminde eşik seviyesinin büyükten küçüğe doğru seçilmesi durumunda ilgi bölgelerinin ilk ortaya çıktığı an “oluşum (appearing)” ve başka bir ilgi bölgesi ile birleştiği an “eyer (merging)” düzeyi olarak adlandırılır. Çoklu eşikleme işleminde eşik seviyesinin küçükten büyüğe doğru seçilmesi durumunda birleşmiş ilgi bölgelerinden bir ilgi bölgesinin ilk koptuğu an “ayrılma (split)” ve ortadan kaybolduğu an “kaybolma (annihilation)” düzeyi olarak adlandırılır. Bu düzeyler arasındaki fark o ilgi bölgesinin “Hayat Süresi” (HS) ’ni göstermektedir. Yapılan bu tanımlamalar eşik seviyesi büyükten küçüğe için Şekil 2.10 ‘da ve tersi durum için ise 2.11 ‘de sırasıyla detaylıca gösterilmektedir.

Tablo 2.1. Farklı boyuttaki sentetik kitleler için parlaklık seviyesi değişimleri

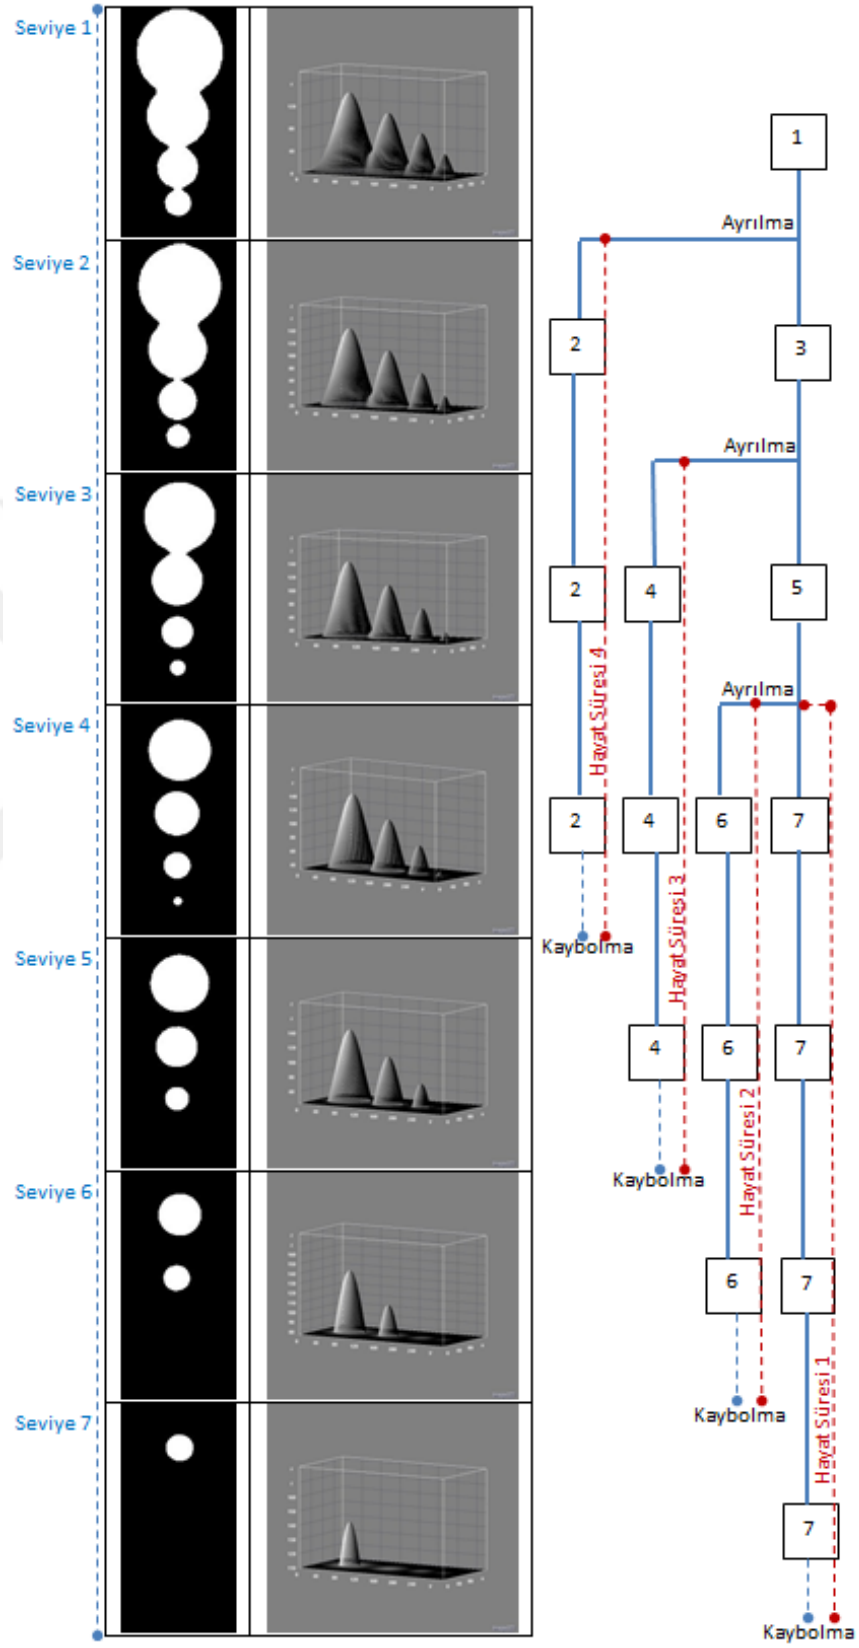
İkili İmge	Gauss Filtre Standart Sapma	Maksimum Parlaklık Seviyesi	Tepe noktaları Parlaklık Seviyesi	Sentetik Kitlelerin Hayat Süresi
1	25	150	144	112
2	20	120	113	81
3	15	90	80	66
4	10	60	48	39



Şekil 2.9. Sentetik kitle görüntüsü için (a) 2B ve (b) 3B parlaklık değişimi gösterimi

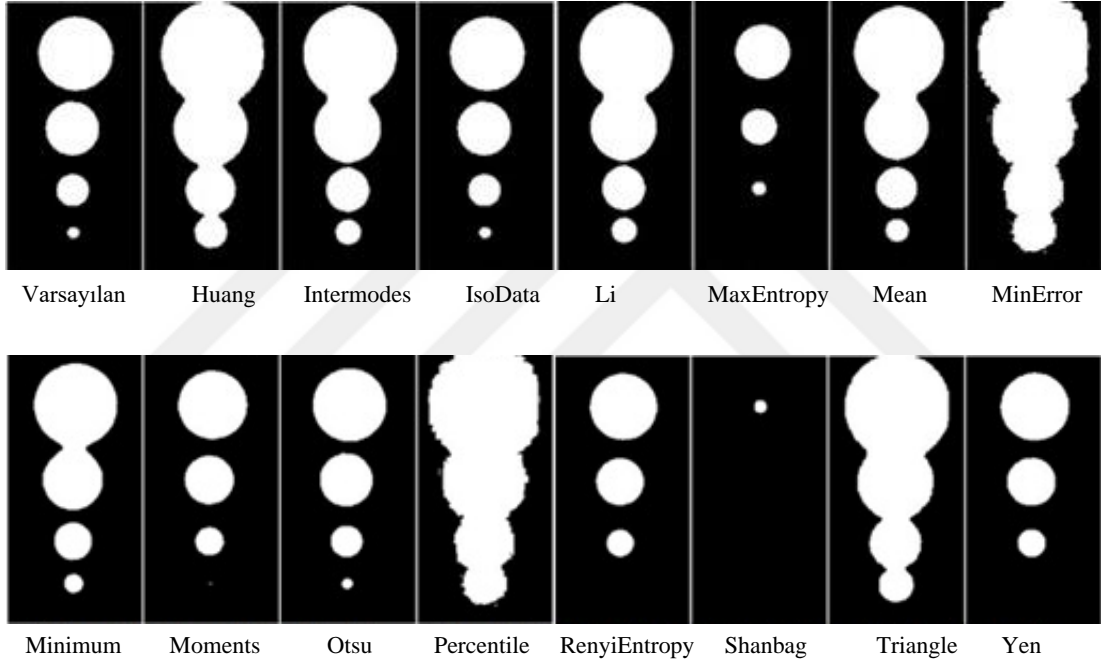


Şekil 2.10. Eşik seviyesi küçülürken ilgi bölgelerinin değişimi



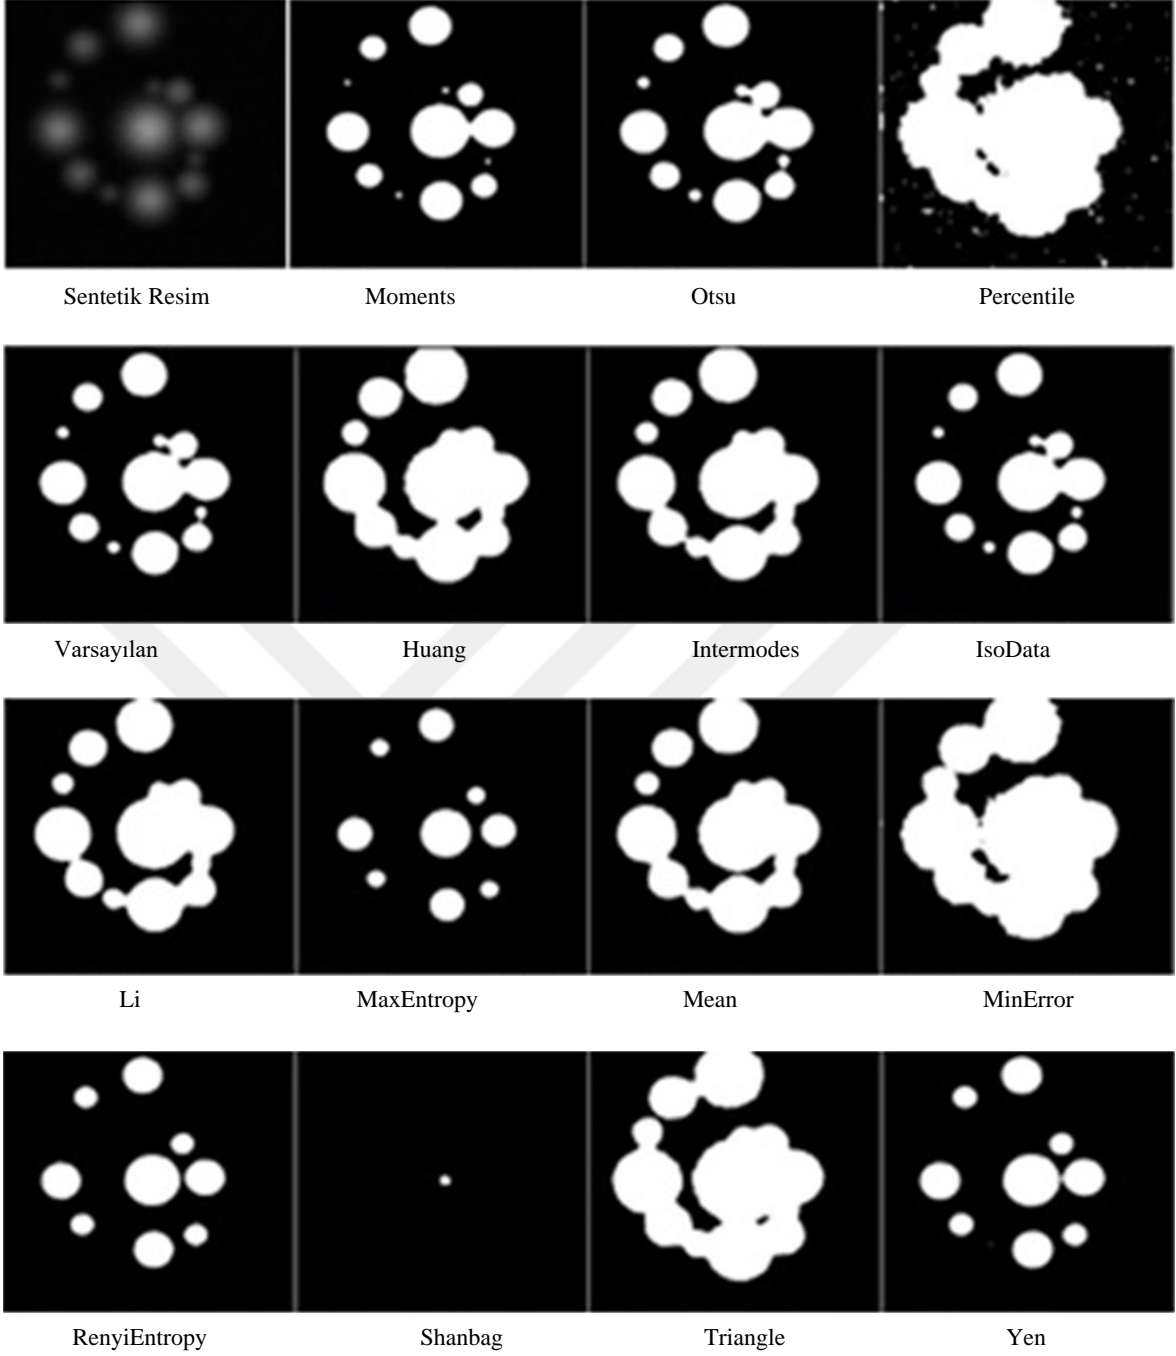
Şekil 2.11. Eşik seviyesi büyürken değişirken ilgi bölgelerinin değişimi

Şekil 2.10 ve Şekil 2.11 'den görüleceği üzere, farklı eşik seviyelerinde birleşme ve ayrılma durumları ile ilgi bölgeleri ortadan kaybolmakta yâda oluşmaktadır. Sonuç olarak tüm ilgi bölgelerini belirlemek için uygun eşik seviye belirleme işlemi oldukça zordur. Literatürde yaygın olarak kullanılan eşikleme yöntemleri için ilgi bölgelerinin değişim sonuçları Şekil 2.12'de gösterilmektedir. Bu şekilden görüleceği üzere bazı yöntemler bu ilgi bölgelerinin tümünü belirleyebilmektedir.



Şekil 2.12. Sentetik 4 adet kitle görüntüsü için eşikleme yöntemlerindeki ilgi bölgeleri

Bu tez çalışmasında çoklu eşikleme yöntemi performansını detaylıca test etmek için ilk sentetik görüntüye göre daha fazla sayıda, farklı HS 'leri ve ebatlarda olan 13 adet sentetik kitlenin yer aldığı bir sentetik görüntüsü daha oluşturulmuştur. Bu sentetik görüntü ve yaygın olarak kullanılan eşikleme yöntemlerinin sonuçları Şekil 2.13'de sırasıyla gösterilmiştir. Bu şekilden de görüleceği üzere bu eşikleme yöntemleri ile ilgi bölgelerinin hepsi aynı anda tespit edilememektedir. Bu test işlemi tüm eşik değerleri için tekrarlanarak ilgi bölgelerinin değişimi araştırılmıştır. Sonuç olarak bu sentetik test görüntüsünde tek bir eşik seviyesinde tüm ilgi bölgelerinin ortaya çıkmadığı görülmüştür.



Şekil 2.13. Sentetik 13 adet kitle görüntüsü için farklı eşikleme yöntemleri ile tespit edilen ilgi bölgeleri

2.3.2. İlgi Bölgelerinin Topoğrafik Harita Üzerinden OHS ile Belirlenmesi

Topoğrafik harita, coğrafik alanda 3B nesnelerin morfolojik yapısının belli bir ölçekte eşyükselti eğrileri ile 2B üzerinde göstermek için kullanılan harita türüdür. Şekil 2.6 'da gösterilen 3B yüzey haritasındaki nesnelere ve dağ, tepe, vadi, akarsu vb. coğrafik nesnelere benzerlik göstermektedir. Sonuç olarak bu 3B harita üzerinde olan nesnelerin

kesitlerinden hem morfolojik özellikler hem de belirginlik bilgisi elde edilebilir. Bu nedenlerden dolayı bu tez çalışmasında mamografi üzerindeki ilgi bölgelerinin belirlenmesi ve bölütlenmesi aşamasında topoğrafik harita kullanılmaktadır. Daha sonra bu harita üzerinden topoğrafik belirginlik esaslı ilgi bölgelerini belirleme işlemi yapılmaktadır.

Görüntü işleme alanında bir topoğrafik haritanın oluşturulması aşamasında kullanılan terminolojiler aşağıda detaylıca açıklanmıştır.

t: parlaklık değeri

$R(t)$: “t” parlaklık değerinden yüksek olan kısımları gösteren bağlantılı bölge

$\Gamma(t)$: “t” parlaklık değerindeki eş yükselti eğrisi $R(t)$

N: örnekleme seviyesi

I: Görüntü

Bir görüntü için “N” örnekleme seviyesindeki bağlantılı bölgeler $R_N(I)$ ve eş düzey haritası $M_N(I)$ Eşitlik (2.4) ve (2.5)’de gösterilmiştir.

$$R_N(I) = \{R(t_i) | i = 1, 2, \dots, N\} \quad (2.4)$$

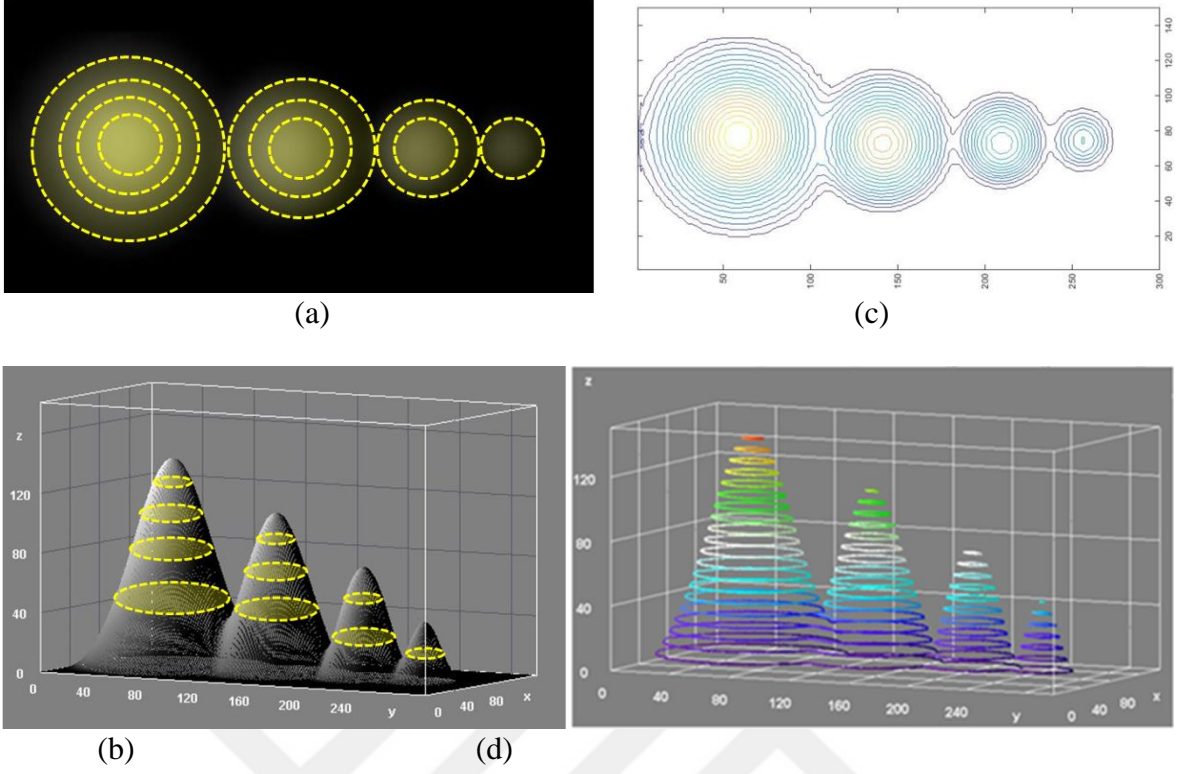
$$M_N(I) = \{\Gamma(t_i) | i = 1, 2, \dots, N\} \quad (2.5)$$

Bir eş düzey haritası her bir parlaklık seviyesi t_i için hesaplanan $\Gamma(t_i)$ eş düzey eğrilerinin bir araya gelmesinden oluşur. N örnekleme seviyesi Eşitlik (2.7)’de t_{min} ve t_{max} minimum ve maksimum parlaklık değerleri ile hesaplanmaktadır.

$$t_i = t_{min} + (i - 1)\Delta t \quad , \quad \Delta t = \frac{t_{max} - t_{min}}{N-1} \quad (2.6)$$

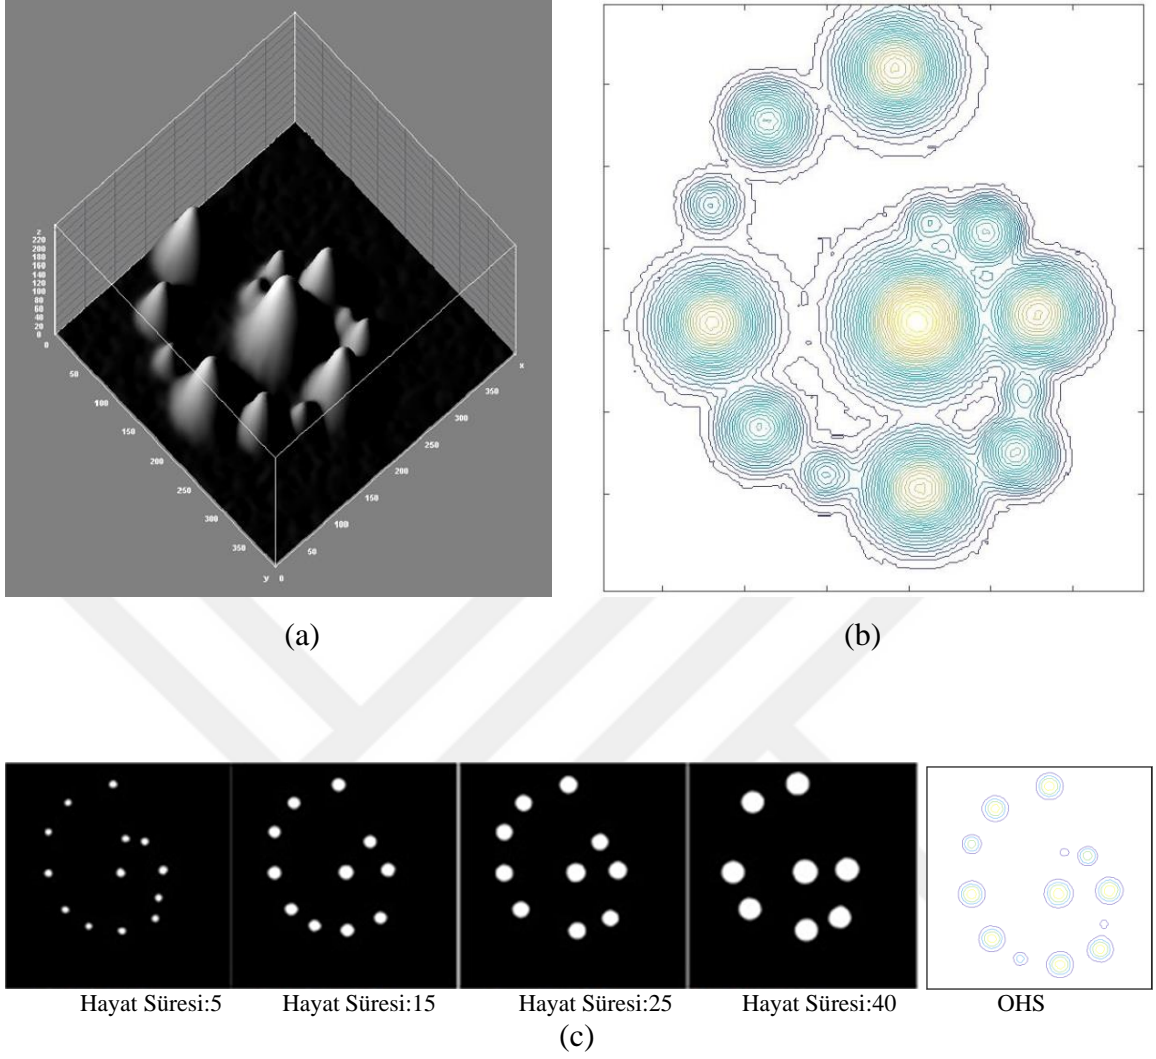
$$N = t_{max} - t_{min} + 1, \quad \Delta t = 1 \quad (2.7)$$

Çoklu ölçekleme yöntemi ile oluşturulan topoğrafik haritalarda kullanılan N örnekleme değeri ile nesnelere üzerinden alınacak kesit miktarı optimize edilir. Her bir parlaklık değerinden kesit alınacaksa N değeri ona göre tüm parlaklık seviyelerine göre hesaplanır.



Şekil 2.14. Sentetik 4 adet kitle görüntüsü için farklı seviyelerdeki yükselti bölgeleri değişimi ile tespit edilen ilgi bölgeleri

Şekil 2.14 (a)'da sentetik görüntüde yer alan her bir kitlenin hayat süresi içerisindeki taban konturlarına ait yükselti bölgeleri gösterilmiştir. Bu bölgelere ait kesitler Şekil 2.14 (b)'de 3B görünümünde de gösterilmiştir. Ayrıca bu sentetik görüntünün topoğrafik haritası 2B ve 3B olarak Şekil 2.14 (c) ve (d) 'de gösterilmektedir. Bu haritalardan da görüleceği üzere, bir objenin eş düşey eğrisi şekilleri obje sınırları ile benzerdir. En önemli desenlerden birisi iç içe geçen konturların sayısını gösteren yuvalamadır. Belirgin bir obje üzerindeki izokonturlar genellikle yoğun iç içe geçen bir desen oluşturur. Konturların sıklaşması topoğrafyada dik bir eğime karşılık gelirken, seyrek konturlar nispi olarak daha düşük eğimli bir yüzey şeklini ifade eder.



Şekil 2.15. Sentetik 13 adet kitle görüntüsü için farklı seviyelerdeki yükselti bölgeleri değişimi ile tespit edilen ilgi bölgeleri

Şekil 2.15 (a)'da 13 kitleden oluşan sentetik görüntü için 3B görünümü gösterilmiştir. Bu sentetik görüntünün topoğrafik haritası Şekil 2.15 (b)'de gösterilmektedir. Ayrıca bu görüntü için hayat süresi seviyeleri 5, 15, 25 ve 40 seçilerek ortaya çıkan yükselti bölgeleri ve bu bölgelere ait topoğrafik harita Şekil 2.15 (c)'de sırasıyla gösterilmektedir. Bu sentetik görüntüdeki her bir kitlenin topoğrafik belirginlik miktarı da farklıdır. Bir bölgenin belirginlik ölçüğü “hayat süresi” nin büyüklüğü ile doğru orantılıdır.

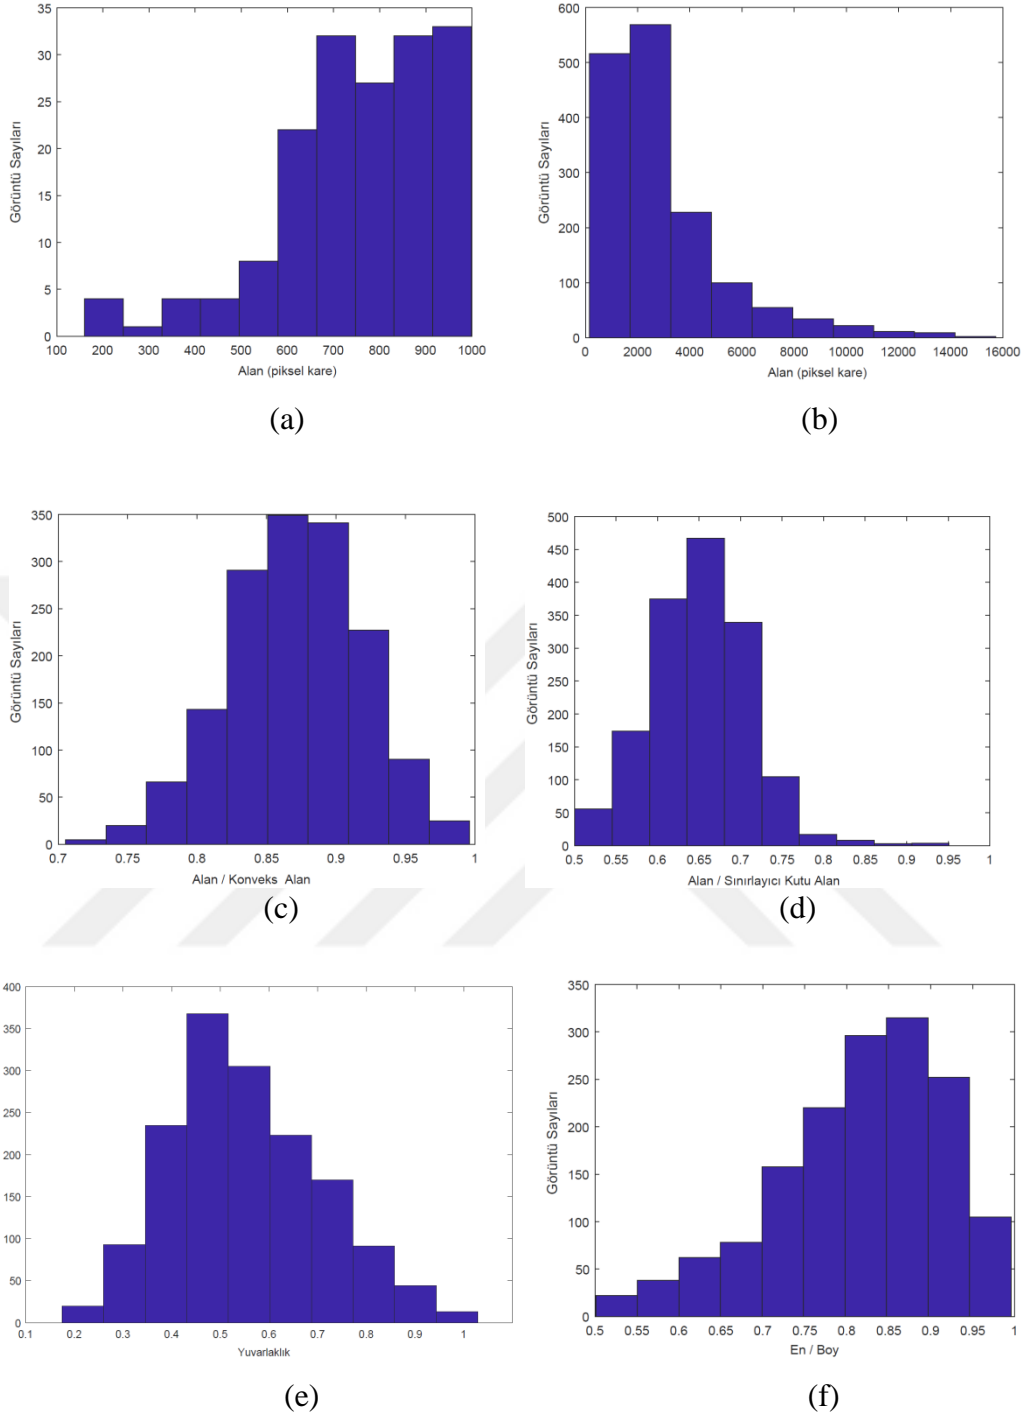
Hayat süresi küçük bir nesne üzerinde eğer yükselti bölgesi eşik değeri büyük seçilirse, ilgili nesneye ait ilgi bölgesi tespit edilemez. Sonuç olarak bu yöntem de uygun “hayat süresi” (yuvalama derinliği) seçme işlemi önemlidir. Aksi durumda ilgi bölgeleri kaçırılabilir.

Çoklu eşikleme yöntemi ile mamografi görüntülerinde ilgi bölgesi belirleme ve bölütleme işleminin yukarıda anlatılan bazı dezavantajlarından dolayı bu tez çalışmasında alternatif bir yöntem olan “Optimum Hayat Süresi (OHS)” yada “Optimum Yuvalama Derinliği (OYD)” tanımı yapılarak bu aralıkta olan eş merkezli yükselti bölgeleri üzerinden ilgi bölgeleri belirlenmiştir. Daha sonra bu ilgi bölgelerinin her biri kabaca bölütleme işlemini gerçekleştirebilmek için bu tez çalışması kapsamında geliştirilen EEKTS yöntemi ile sınıflandırılmıştır. Bu yöntem esasında şüpheli bölgelerin belirginlik esasına göre yerel yükselti bölgelerinin bulunmasına dayanmaktadır. Fakat belirlenecek olan bu yükselti bölgelerin “hayat süreleri” nin uzunluğu ve kısalığı belirlenecek ilgi bölge sayısını değiştirmektedir. Bu tez çalışmasında OHS seçimi yanlış negatif oluşturmayacak ve yanlış pozitif sayısını minimize edecek şekilde yapılan detaylı deneysel çalışmaların sonucunda tespit edilmiştir.

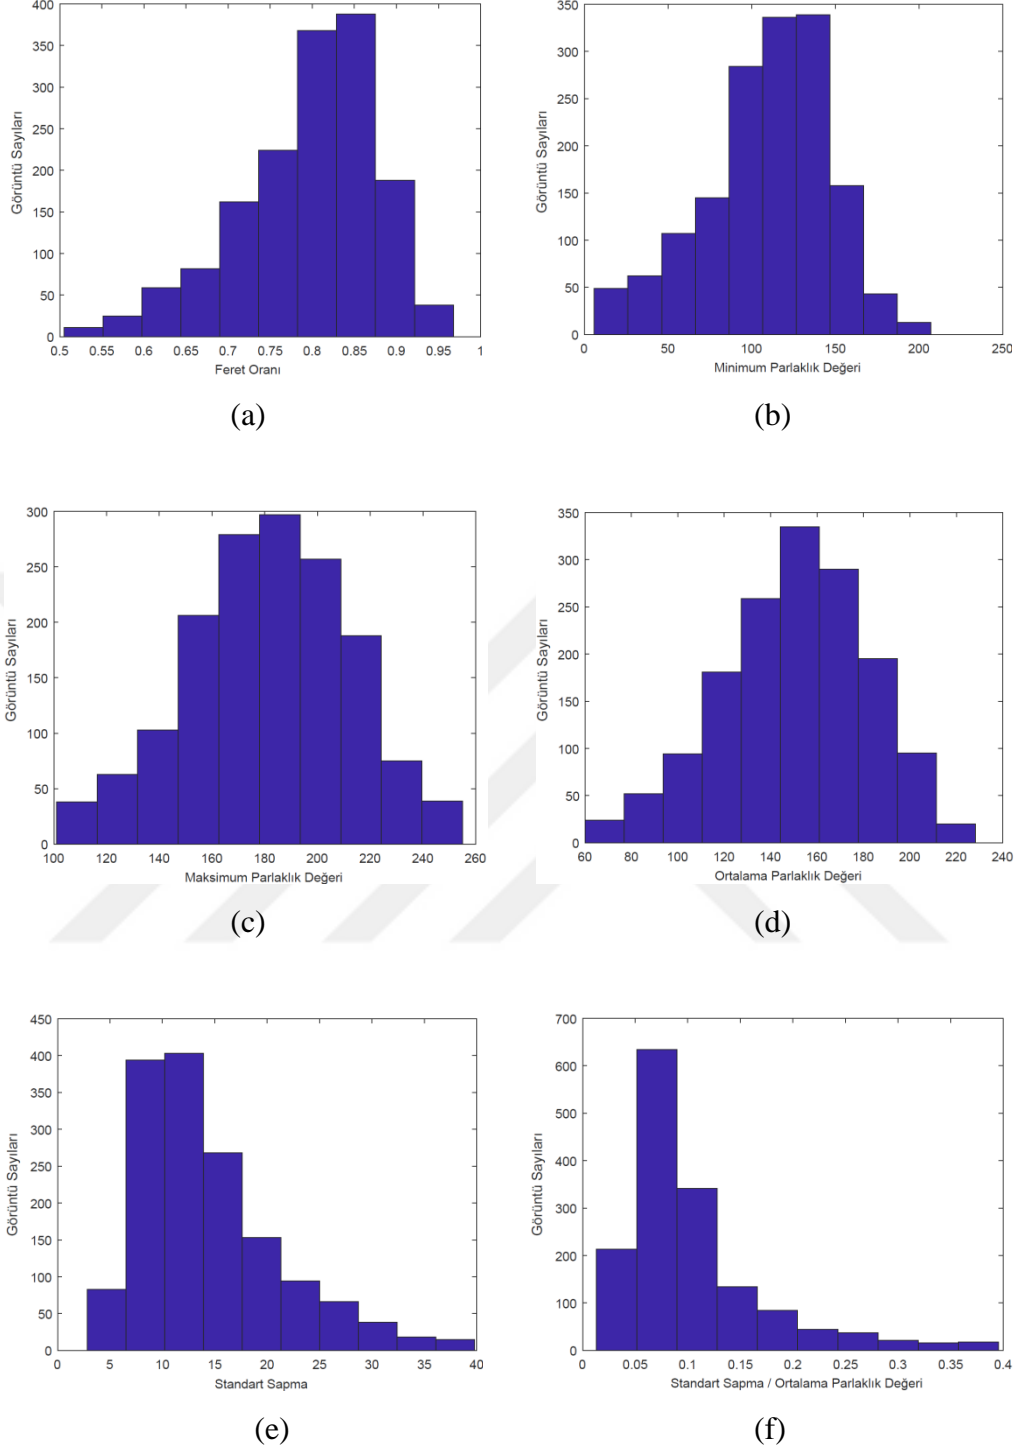
2.3.3. EEKTS Yöntemi İçin Kural Tablosunun Oluşturulması

Bu tez çalışması kapsamında geliştirilen EEKTS yöntemi kullanılan kuralların parametrelerini belirlemek için farklı kitle tiplerine ait karakteristik özelliklerin bilinmesi gereklidir. Bu amaç için CBIS-DDSM veri setinde yer alan 1484 adet kitlenin radyologlar tarafından hazırlanmış bölütleme maskeleri kullanılmıştır. Bu maskeler üzerinden hesaplanan morfolojik ve parlaklık özniteliklerinin histogram dağılımı için Şekil 2.16 ve Şekil 2.17’de sırasıyla gösterilmektedir. Bu veri seti içerisinde oldukça fazla sayıda kitle bulunmasının bir sonucu olarak farklı karakteristik özellikteki kitle tipleri için istatistiksel inceleme yapılabilmesini mümkün kılmıştır.

Morfolojik ve parlaklık istatistiksel grafikleri, Gauss dağılımına benzerlik göstermiştir. Ayrıca bazı özniteliklerde özellikle belli değerlerdeki aralıklarda yığılmalar olmaktadır. Küçük kitlelerin sayısının daha iyi anlaşılabilmesi için kitlelerin alan dağılımı istatistiği iki grafik olarak sunulmuştur. Küçük ebatlı kitleler için oluşturulan 1000 piksel kare dağılımdan da görüleceği üzere özellikle 500 piksel kare ‘den küçük kitle sayısı tüm veri setinin yaklaşık % 1’i civarındadır. Ayrıca 500-1000 piksel kare arasındaki aralıkta da yaklaşık % 10 civarında kitle bulunmaktadır.



Şekil 2.16. DDSM veri tabanındaki kitleler için morfolojik özniteliklerin histogram dağılımları



Şekil 2.17. DDSM veri tabanındaki kitleler için parlaklık özniteliklerin histogram dağılımları

EEKTS yöntemi kurallarında kitle alanı ile ilgili kurala ait eşik değeri değiştirilerek çok az bir DP kaybı ile çok yüksek miktarda YP eleme imkânı bulunmaktadır. Sonuç olarak özellikle alan tabanlı bu eşik değerlerinin değişiminin EEKTS yönteminde

performansını ölçmek için 6 farklı kural tablosu oluşturulmuştur. Standart sapma ve standart sapma / ortalama parlaklık değeri dağılımları için de az bir DP kaybı ile yüksek miktarda YP eleme imkânı bulunmaktadır. Bahsi geçen bu durumları dikkate alarak histogram grafikleri üzerinden belirlenen kurallar Tablo 2.2’de gösterilmektedir. Bu parametrelerin EEKTS yönteminin performansı üzerine olan etkisi deneysel olarak bulgular aşamasında gösterilmektedir.

Tablo 2.2. EEKTS yöntemi için kural tablosu


Bölütleme Yöntemi	Alan (piksel kare)>	Alan/ Konveks Alan>	Alan/ Kutu Alan>	Yuvarlaklık>	Feret Oranı>	En/ Boy Oranı>	Maks. Parlaklık Değeri>	Min. Parlaklık Değeri<	Ortalama Parlaklık Değeri>	Standart Sapma<	Standart Sapma/ Ortalama Parlaklık dereğeri <
EEKTS-1	300	0.7	0.5	0.35	0.5	0.5	100	210	90	40	0.4
EEKTS-2	500	0.7	0.5	0.35	0.5	0.5	100	210	90	40	0.4
EEKTS-3	1000	0.7	0.5	0.35	0.5	0.5	100	210	90	40	0.4
EEKTS-4	300	0.7	0.5	0.35	0.5	0.5	100	210	90	30	0.3
EEKTS-5	500	0.7	0.5	0.35	0.5	0.5	100	210	90	30	0.3
EEKTS-6	1000	0.7	0.5	0.35	0.5	0.5	100	210	90	30	0.3

2.3.4. EEKTS Yöntemi ile Şüpheli Bölgelerin Bölütlenmesi

Bir kitleye ait ilgi bölgeleri OHS içerisinde eş merkezli yükseltlerden oluşur ve diğer nesnelere ile olan birleşme anına kadar, kitlenin konturları devam eder. Bu birleşme anına kadar kitlenin eşyükselti eğrilerinin merkezden dışa doğru büyümektedir. Bu durumda aşağı (under) ve aşırı (over) bölütlemenin önemi bir sonraki aşamada bölütlenmiş bölgeden alınacak özneliklerin sınıflandırmaya olan katkısı için önemlidir. Bu tez çalışmasında bu nedenlerden dolayı ilgi bölgesinin bölütleme işlemine önem verilerek, morfolojik ve parlaklık öz niteliklerini kullanarak eşyükselti eğrilerinin kural tabanlı sınıflandıran (EEKTS) bir yöntem önerilmiştir. EEKTS yöntemi ile ayrıca kitlenin eşyükselti eğrilerinin sayısı kitle sınıflandırma aşamasında en önemli özneliklerden birisi olan yuvalama derinliği de tespit edilir.

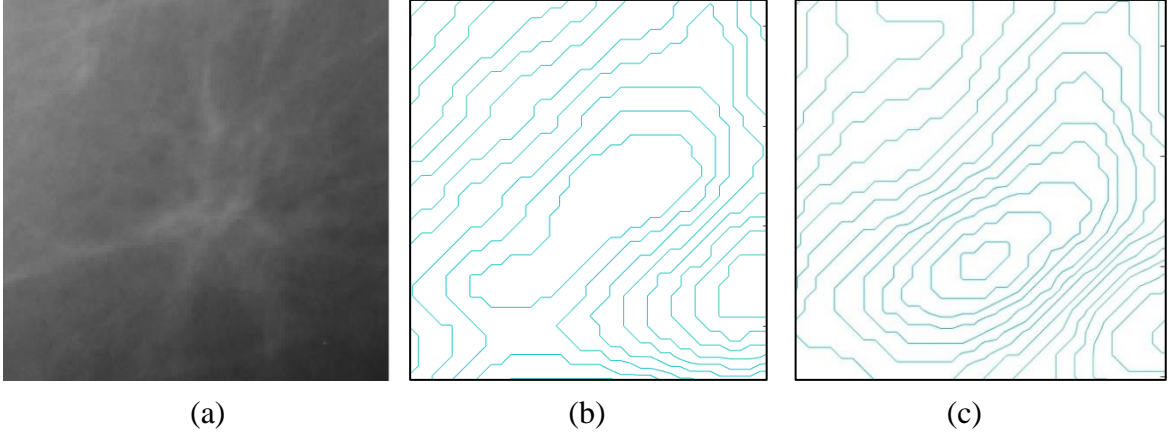
Şekil 2.18 (a)’da gösterilen ön işlenmiş mamografi görüntüsünün Gabor 0° filtre çıktısı için topoğrafik harita Şekil 2.18 (b)’de gösterilmektedir. Bu harita üzerinde konturların seçilebilmesi için örnekleme seviyesi N=50 olarak seçilmiştir. Harita üzerinden

görülebileceği üzere belirgin bölgeler doğrudan konturların sıklığı ile ilişkilidir. Bir nesnenin şeklini belirleyen etken de bu sık konturların en dıştaki olanlarıdır. OHS içerisinde yer alan kitlelere ait eş merkezli yükselti için morfolojik ve parlaklık öznitelikleri deneysel çalışmalar sonucunda kural tabanlı olarak belirlenmiştir. Bu deneyler yaklaşık 1500 kitle üzerinde ve radyoloji uzmanlarının yapmış olduğu bölütleme sonuçları ile belirlenmiştir. Belirlenen kural tabloları üzerinden alınan sonuçlar bulgular aşamasında detaylıca verilmiştir. Şekil 2.18 (c)'de EEKTS yönteminin sonuçları gösterilmektedir. Tespit edilen kitle ve yanlış pozitif nesnelerin bir kısmı yuvalama derinliklerinin daha iyi görülebilmesi için Şekil 2.21 'de sırasıyla gösterilmektedir.



Şekil 2.18. Ön işlenmiş örnek mamografi görüntüsü için (a) 2B görünümü, (b) topoğrafik haritası, (c) EEKTS yöntemi sonucu

Şekil 2.19 (a)'da gösterilen komşu dokuların süperpozisyonu nedeniyle belirginliği bozulmuş bir kitle gösterilmektedir. Şekil 2.19 (b) ve (c) 'de sırasıyla Gabor 0° ve Gabor filtre 45° çıktısı yer almaktadır. Bu iki şekil mukayese edildiğinde Şekil 2.19 (c)'de eş merkezli yükselti bölgelerinden yuvalama derinliğinin büyüdüğü ve kitleye ait belirgin olmayan konturların da ortaya çıktığı görülmektedir.



Şekil 2.19. Örnek bir kitle için (a) 2B görünümü, (b) Gabor 0° (c) Gabor 45° Filtre uygulandıktan sonra Topoğrafik Haritaları

Bu tez çalışmasında süperpozisyon sonucu bozulan kitlelerin tespit edilebilmesi amaçlanmıştır. Bu amaç için 0°, 45°, 90° ve 135° yönlerindeki gabor filtresi uygulandıktan sonra EEKTS yöntemi ile ilgi bölgeleri bölütlenmiştir. Farklı derinliklerde ortaya çıkan her bir eş yükselti bölgesi için tanımlanmış öz nitelikler için belirlenen eşik değerleri açısından kural tabanlı elemeye tabi tutularak tüm Gabor filtre yönleri için bölütlenmiş konturların birleştirilmesi ile sonuç görüntüsü oluşturulmaktadır. Sonuç olarak, Gabor filtrelerinden geçirilmiş görüntülerdeki OHS 'deki derinliklerde ortaya çıkan yükseltilere uygulanan eleme kural tablosuna göre kalan eş yükseltilerin toplamı bölütlenmiş mamografi görüntüsünü oluşturmaktadır. Bulgular aşamasında yapılan detaylı deneysel çalışmalar sonucunda Gabor filtre ile süperpozisyon etkisinin azaltılarak tespit edilebilen kitleler gösterilmektedir.

2.4. Kitlelerin Belirlenmesi

Bu aşamada EEKTS yöntemi ile bölütlenen nesnelerin kitle ve normal olarak sınıflandırma işlemi yapılmaktadır. Bu sınıflandırma işlemi için bölütlenen nesnelere ait doku analizi, yuvalama derinliği, morfolojik ve parlaklık öz nitelikleri gibi bazı öz nitelikler kullanılmaktadır. EEKTS sonucunda aşırı/aşağı (over/under) bölütlenme durumları şüpheli bölge üzerinden alınacak bu öz nitelikleri etkilemektedir. Sonuç olarak EYKYS aşamasının başarısı bu kısmın başarısını doğrudan etkilemektedir.

Aşağıda detayları verilecek olan bu öz nitelikler gruplara ayrılarak ayrı ayrı ve hepsi bir arada farklı sınıflandırıcılar için farklı parametrelerde test edilerek bulgular aşamasında detaylıca ROC grafikleri ile birlikte sunularak mukayese edilmiştir.

2.4.1. Doku Öznitelikleri Hesaplanması

Doku öz nitelikleri, görüntüde birbirine göre belirlenen konumlardaki parlaklık değişiminin istatistiksel dağılımından hesaplanmaktadır. Bu istatistikler birinci dereceden, ikinci dereceden ve daha yüksek dereceden olabilmektedir. Bu tez çalışması kapsamında Haralick vd. [140] tarafından önerilen ikinci dereceden Gri Seviye Eş oluşum Matrisi (GLCM; Gray Level Co-occurrence Matrix) kullanılarak oluşturulan doku öznitelikleri kullanılmaktadır. Aşağıda detayları gösterilecek olan doku öznitelikleri hesaplanırken oluşturulan eşitlikler ve notasyon gösterimleri için bu alandaki öncü çalışmalar [141-142] kullanılmaktadır.


GLCM bir görüntüdeki gri seviye düzeyleri kadar satır ve sütun sayısı olan belli bir yönde (θ) ve aralarında belli bir uzaklık ($\Delta x, \Delta y$) bulunan çift gri seviyeli piksellerin birbirlerine göre oluşma sıklıklarını ifade eden matristir. Eşitlik'de $P(i, j | \Delta x, \Delta y)$ GLCM matrisinin oluşturma aşamalarını gösteren eşitlikler yer almaktadır. "i" ve "j" indisleri görüntüde yer alan parlaklık değişimi kombinasyonu göstermektedir. "M" ve "N" görüntünün satır ve sütun sayısını göstermektedir. "m" ve "n" sıklığı hesaplanacak piksellerin satır ve sütun indislerini göstermektedir.

Şekil 2.20'de 8 seviyesi bulunan örnek bir görüntü için GLCM matrisi gösterilmektedir. Bu matris " $\Delta x = 1, \Delta y = 0, \theta = 0^\circ$ " parametrelerine göre hesaplanmıştır. Örnek görüntü üzerinde bir kısım aynı tür ikili geçişler farklı renkler ile gösterilmiştir. Bunların sıklığını gösterildiği GLCM matrisinde de görüntüdeki aynı renkler ile gösterilmektedir.

$$P(i, j | \Delta x, \Delta y) = \frac{1}{(M-\Delta x)(N-\Delta y)} Q(i, j | \Delta x, \Delta y) \quad (2.8)$$

$$Q(i, j | \Delta x, \Delta y) = \sum_{n=1}^{N-\Delta y} \sum_{m=1}^{M-\Delta x} A \quad (2.9)$$

$$A = \begin{cases} 1 & \text{eğer } f(m, n) = i \text{ ve } f(m + \Delta x, n + \Delta y) = j \\ 0 & \text{diğer durumlarda} \end{cases} \quad (2.10)$$



1	3	2	4	1	3
4	5	4	6	7	1
7	1	8	2	5	4
2	1	7	1	8	3
5	4	6	7	1	5

(b)

	1	2	3	4	5	6	7	8
1	0	0	2	0	1	0	1	2
2	1	0	0	1	1	0	0	0
3	0	1	0	0	0	0	0	0
4	1	0	0	0	1	2	0	0
5	0	0	0	3	0	0	0	0
6	0	0	0	0	0	0	2	0
7	4	0	0	0	0	0	0	0
8	0	1	1	0	0	0	0	0

(c)

Şekil 2.20. Örnek bir görüntü üzerinde gri seviye eş düzey matrisinin oluşturulması; (a) Yönlerin gösterilmesi (b) Görüntü (c) Gri seviye eş oluşum matrisi

$$P_x(i) = \sum_{j=0}^{G-1} P(i, j) \quad (2.11)$$

$$P_y(j) = \sum_{i=0}^{G-1} P(i, j) \quad (2.12)$$

$$\mu_x = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} iP(i, j) = \sum_{i=0}^{G-1} iP_x(i) \quad (2.13)$$

$$\mu_y = \sum_{i=0}^{G-1} i \sum_{j=0}^{G-1} jP(i, j) = \sum_{i=0}^{G-1} jP_y(j) \quad (2.14)$$

$$\sigma_x^2 = \sum_{i=0}^{G-1} (i - \mu_x)^2 \sum_{j=0}^{G-1} P(i, j) = \sum_{i=0}^{G-1} (P_x(i) - \mu_x(i))^2 \quad (2.15)$$

$$\sigma_y^2 = \sum_{j=0}^{G-1} (j - \mu_y)^2 \sum_{i=0}^{G-1} P(i, j) = \sum_{j=0}^{G-1} (P_y(j) - \mu_y(j))^2 \quad (2.16)$$

Eşitlik 2.11 ve 2.12’de $P_x(i)$ ve $P_y(j)$ marjinal olasılık dağılımını hesaplayan eşitlikler gösterilmektedir. “G” görüntüde kullanılan gri düzeylerin sayısıdır. μ_x, μ_y ve σ_x, σ_y sırasıyla bu olasılık dağılımlarına ait ortalama değer ve standart sapmaları Eşitlik (2.13), (2.14), (2.15) ve (2.16) ‘de sırasıyla gösterilmektedir. Her bir bölütlenmiş nesne için

GLCM üzerinden hesaplanan bu öz nitelikler aşağıda gösterilen eşitlikler ile hesaplanmaktadır.

Bir görüntünün homojenliğini gösteren ölçü değeri ASM (Angular Second Moment) Eşitlik 2.17'de hesaplanmaktadır.

$$ASM = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{P(i, j)\}^2 \quad (2.17)$$

Bir görüntünün yerel yoğunluk değişimini gösteren kontrast ölçü değeri değeri Eşitlik 2.18'de hesaplanmaktadır

$$KONTRAST = \sum_{n=0}^{G-1} n^2 \{ \sum_{i=1}^G \sum_{j=1}^G P(i, j) \}, |i - j| = n \quad (2.18)$$

Bir görüntünün yerel homojenliğini gösteren ölçü değeri IDM (Inverse Difference Moment) Eşitlik 2.19'de hesaplanmaktadır

$$IDM = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{1}{1+(i-j)^2} P(i, j) \quad (2.19)$$

Bir görüntünün entropi gösteren ölçü değeri *ENTROPİ* Eşitlik 2.20'de hesaplanmaktadır. Bir görüntüdeki homojen olmayan kısımlar düşük entropiye sahipken, homojen bir kısımlar yüksek entropiye sahip olmaktadır.

$$ENTROPİ = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j) \times \log (P(i, j)) \quad (2.20)$$

Birbirlerine göre belirtilen konumlarda pikseller arasındaki gri düzeyde doğrusal bağımlılığın bir ölçü değeri olan korelasyon ve varyans ölçü değeri sırasıyla Eşitlik (2.21) ve Eşitlik (2.22)'de hesaplanmaktadır.

$$KORELASYON = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{\{i \times j\} \times P(i, j) - \{\mu_x \times \mu_y\}}{\sigma_x \times \sigma_y} \quad (2.21)$$

$$VARYANS = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i - \mu)^2 P(i, j) \quad (2.22)$$

Ortalama ve entropi ölçü değerlerinin toplamı sırasıyla Eşitlik (2.23) ve (2.24)'de hesaplanmaktadır.

$$AVER = \sum_{i=0}^{2G-2} iP_{x+y}(i) \quad (2.23)$$

$$SENT = -\sum_{i=0}^{2G-2} P_{x+y}(i)\log(P_{x+y}(i)) \quad (2.24)$$

Fark entropisi ve hareketsizlik ölçü değerleri Eşitlik (2.25) ve (2.26)'de hesaplanmaktadır.

$$FENT = -\sum_{i=0}^{G-1} P_{x+y}(i)\log(P_{x+y}(i)) \quad (2.25)$$

$$INERTIA = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{i-j\}^2 \times P(i,j) \quad (2.26)$$

Görüntü üzerindeki piksel dağılımlarının oluşturacağı kümeleme durumunu ölçen öznitelikler Eşitlik (2.27) ve (2.28)'de hesaplanmaktadır.

$$SHADE = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{i+j-\mu_x-\mu_y\}^3 \times P(i,j) \quad (2.27)$$

$$PROM = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{i+j-\mu_x-\mu_y\}^4 \times P(i,j) \quad (2.28)$$

Unser vd. [143] doku tanımlaması için kullanılan normal GLCM matrisinin, doğrudan görüntüden tahmin edilebilen toplam ve fark histogramları ile değiştirilmesini önermişlerdir. Eşitlik (2.29) ve (2.30)'da hesaplanan histogram dağılımları üzerinden yukarıda hesaplanan doku öznitelikleri için farklı ölçü değerleri verecek yeni öznitelikler oluşturulmaktadır. Hesaplanan bu öznitelikler Eşitlik (2.31)-(2.38)'de gösterilmektedir.

$$H_s(i | \Delta x, \Delta y) = WCard \{(m, n) \in D, s_{\Delta x, \Delta y}(m, n) = i\} \quad (2.29)$$

$$H_d(j | \Delta x, \Delta y) = WCard \{(m, n) \in D, d_{\Delta x, \Delta y}(m, n) = j\} \quad (2.30)$$

$$W = \frac{1}{(M-\Delta x)(N-\Delta y)}$$

$$s_{\Delta x, \Delta y}(m, n) = f(m, n) + f(m + \Delta x, n + \Delta y) \quad (2.31)$$

$$d_{\Delta x, \Delta y}(m, n) = f(m, n) - f(m + \Delta x, n + \Delta y)$$

$$SHADE = \sum_{i=0}^{2G-2} (i - 2\mu)^3 H_s(i | \Delta x, \Delta y) \quad (2.32)$$

$$PROMINENCE = \sum_{i=0}^{2G-2} (i - 2\mu)^4 H_s(i | \Delta x, \Delta y) \quad (2.33)$$

$$KONTRAST = \sum_{j=0}^{2G-2} j^2 H_d(j | \Delta x, \Delta y) \quad (2.34)$$

$$HOMOJENLİK = \sum_{j=0}^{2G-2} \frac{1}{1+j^2} H_d(j | \Delta x, \Delta y) \quad (2.35)$$

$$CORRELATION = \frac{1}{2} \left(\begin{array}{c} \sum_{i=0}^{2G-2} (i - 2\mu)^2 H_s(i | \Delta x, \Delta y) \\ - \sum_{j=0}^{2G-2} j^2 H_d(j | \Delta x, \Delta y) \end{array} \right) \quad (2.36)$$

$$SHADE = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{i + j - \mu_i - \mu_j\}^3 \times P(i, j | \Delta x, \Delta y) \quad (2.37)$$


$$PROM = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{i + j - \mu_i - \mu_j\}^4 \times P(i, j | d) \quad (2.38)$$

2.4.2. Yuvalama Değeri Tabanlı Öznitelik

EEKTS yönteminin sonucunda ortaya çıkan bölütlenmiş nesne üzerinde yuvalama yapan konturların sayısı o kitlenin belirginliğini KTS sonucunda ortaya çıkarmaktadır. “yuvalama derinliği” kitle ve normal görüntüleri sınıflandırılma aşamasında kullanılmaktadır. Şekil 2.18’de örnek mamografi görüntüsü için EEKTS sonuçlarını gösterilmektedir. Bu şekil üzerinden de görüleceği üzere bölütlenmiş nesne iç içe geçen eş yükselti eğirilerinden oluşmaktadır. Bir nesneyi oluşturan tüm konturlar Eşitlik (2.39)’da gösterildiği üzere $P_{1,n}$ ile ifade edilmektedir. Bu eşitlikte yer alan konturlar iç içe geçme durumuna göre $i < j$ ise $\Gamma_i \subset \Gamma_j$ alt kümesi olacak şekilde sıralanmaktadır. Nesneyi oluşturan konturların sayısı " $L(P_{1,n})$ " ilgili nesnenin yuvalama derinliğini göstermektedir.

$$P_{1,n} = (\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_{n-1}, \Gamma_n) \quad (2.39)$$

Şekil 2.21’de bu nesnelerin yuvalama derinliğinin miktarı görülmektedir. Bu öz niteliğin sınıflandırmaya olan katkısının deneysel sonuçları bulgular aşamasında detaylıca gösterilmektedir.



Şekil 2.21. (a) Kitle (b) ve (c) kitle benzeri nesneler için EEKTS ile bölütlenme sonuçlarının eş merkezli yükselteler ile topoğrafik harita üzerinde gösterilmesi

2.5. EEKTS Yöntemi ile Pektoral Kas Bölütlemesi

Bu tez çalışması kapsamında önerilen pektoral kas bölütleme işlemi yapan EEKTS yönteminin akış diyagramı Şekil 2.1 ’de gösterilmektedir. Bu blok diyagramda, örnek mamografi görüntüsü için tüm aşamaların çıktıları sırasıyla karşılık gelen bloğun yanında gösterilmektedir. Ön işleme ve topoğrafik harita oluşturulması aşamaları önceki kısımlarda açıklanmıştır. Diğer aşamalar alt başlıklarda ayrıntılı olarak açıklanacaktır.

MLO mamografi çekimi esnasında konumlandırma hatası, diğer bozulma etkileri yâda meme anatomisine bağlı olarak pektoral kasa ait boyut, parlaklık, şekil ve doku vb. gibi bazı karakteristik özellikler değişkenlik gösterir. Ayrıca, pektoral kas sınırı kitleler, yapısal bozukluklar, deri kıvrımları ve süperpozisyon (örtüşen) dokular ve bunun gibi nedenlerle de bozulma olabilir. Yaygın olarak karşılaşılan bozulmuş pektoral kas tipleri Şekil 1.14’de farklı örnekler halinde gösterilerek bozulma durumları kategorize edilmiştir. Bu şekil üzerinden de görüleceği üzere bir veya birden fazla bozulma tipi aynı örnek görüntü üzerinde bulunabilmektedir.

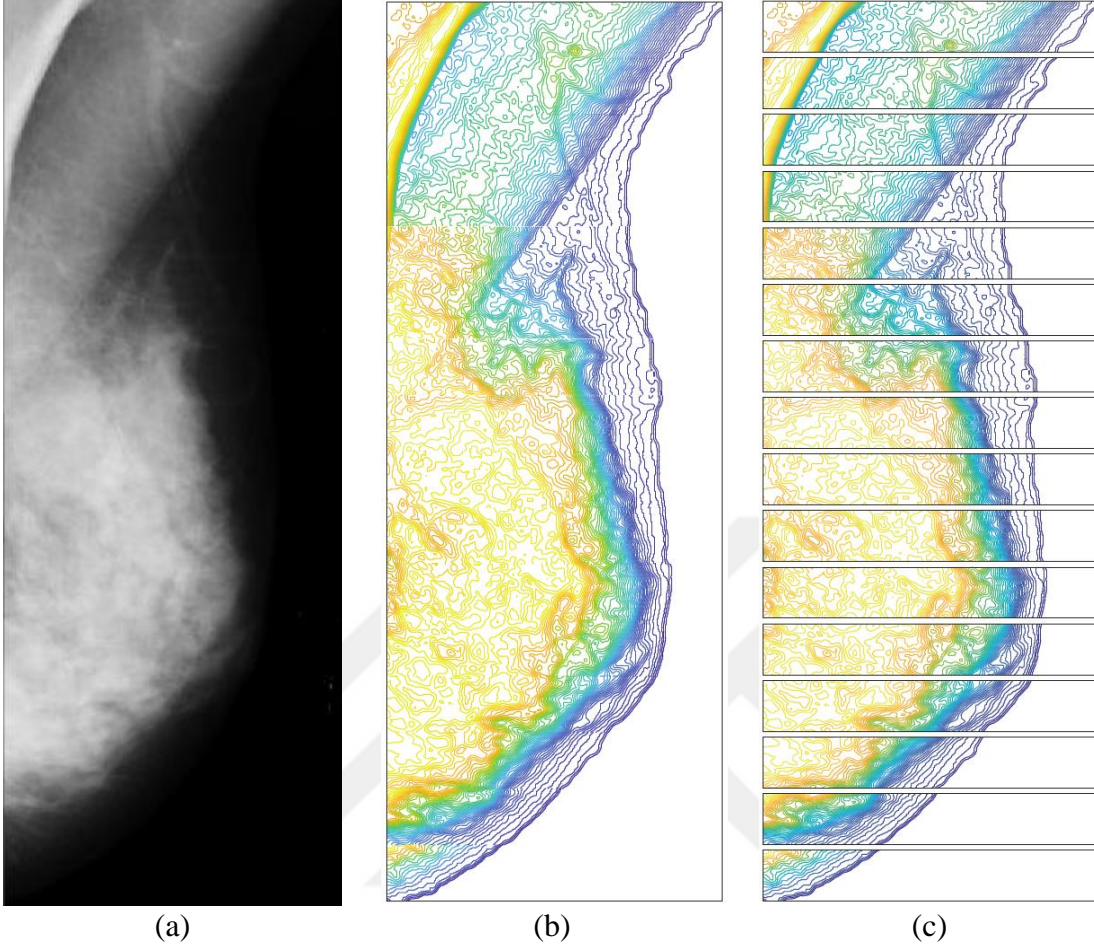
EEKTS yöntemi konturlar arasındaki ilişkiyi ortaya koyan topoğrafi haritasını kullanmaktadır. Pektoral kasın birbirini izleyen konturları arasındaki ilişki, genellikle lokasyon, geometrik ve topoğrafik bilgilere dayalı bazı ayırt edici özelliklere sahip bazı spesifik kalıplar gösterir. Ancak bu özellikler, yukarıda bahsedilen bozulma etkilerinden dolayı bazen kararsız ve verimsiz olabilir. Bu nedenle, topoğrafi haritası, bu bozulma etkilerini sınırlandırmak için küçük yatay bloklara bölünmüştür. Sonuç olarak, bloklarda bulunan pektoral kasın konturları daha istikrarlı ve verimli spesifik modeller haline gelir. Ayrıca, bölünmenin bir sonucu olarak; bir eğri sınır, düz çizgi benzeri sınır parçalarına dönüştürülür.

2.5.1. Bloklara Ayırma İşlemi

MIAS veritabanından seçilen bozulmuş bir pektoral kas sınırı içeren Mdb 40 görüntüsü için Şekil 2.1 'deki blok diyagramına göre ilk 3 adımı Şekil 2.22'de sırasıyla gösterilmektedir. Şekil 2.22 (b) 'de topoğrafik harita üzerinden de görüleceği üzere pektoral kas konturları bozulmuş durumdadır ve herhangi bir desen göstermemektedir.

Topoğrafi haritasındaki pektoral kas konturları genellikle konumları, geometrik ve topoğrafik yapıları ile ilişkili bazı ayırt edici özelliklere sahip olsa da, yukarıda bahsedilen bozulma etkilerinin bir sonucu olarak, bu özellikler bazen kararsız ve verimsiz olabilir. Dolayısıyla pektoral kas sınırı tek bir sürekli konturla temsil edilemez ve bu tip sınırların doğru tespiti zor bir görev haline gelir. Bu çalışmada, bu zor görevin üstesinden gelmek için, topoğrafi haritasını Şekil 2.22 (c)'de gösterildiği üzere yatay bloklara bölünmesi önerilmiştir. Bu yaklaşımın iki önemli amacı vardır; çarpık kontur parçaları, sağlam kontur parçaları birbirinden ayrılır ve tüm sınır konturu eğri bir çizgi olsa bile, kontur parçaları bloklarda ardışık düz çizgi parçalar haline gelir.


İçbükey ve dışbükey eğrilerin bileşkesinden oluşan bir pektoral kasına sahip bir mamografi görüntüsü Şekil 2.23 (a) 'da gösterilmektedir. Radyolog tarafından çizilen pektoral kas sınırı Şekil 2.23 (b) 'de kırmızı renk ile gösterilmiştir. Bu pektoral kas sınırının başlangıç ve bitiş noktaları arasındaki düz bir çizgi çizilerek Şekil 2.23 (c) 'de gösterilmiştir. Bu örnek için düz çizgi benzetimi ile pektoral kas sınırı belirlendiğinde ortaya çıkacak olan doğru bölütleme (kırmızı bölge), aşırı bölütleme (mavi bölge) ve aşağı bölütleme (yeşil bölge) alanları bu şekil üzerinde gösterilmektedir.



Şekil 2.22. Bozulmuş pektoral kas sınırı içeren örnek mamografi görüntüsü için (a) 2B görünümü, (b) Topoğrafik harita gösterimi ve (c) bloklara ayrılması

Bu tez çalışması kapsamında en uygun blok sayısını belirlemek için pek çok deneysel çalışma yapılmıştır. Detayları bulgular aşamasında verilen sonuçlara göre blok sayısının 16 olmasına karar verilmiştir. Normalizasyon aşamasında tüm veri tabanları için görüntü yüksekliği 1024 piksel olarak ölçeklenmiştir. Bu tez çalışmasında blok yüksekliği 50 piksel belirlenerek ayırma işlemi yapılmaktadır. Sonuç olarak bu blok yüksekliği ile en küçük memelerde bile blok sayısının en az 16 olması sağlanabilmektedir. Ayrıca deneysel çalışmalarda bozulma miktarının pektoral kas bölgesinin dörtte birini geçmediği görülmüştür. Bu istatistikler neticesinde küçük pektoral kas bölgeleri için bile 16 bloklü bölünme işlemi yapılırsa, çarpık kısımlar ve sağlam kısımlar birbirinden ayrılabilir. Şekil 2.22 (c)' de gösterilen 50 piksel yüksekliğindeki bloklardan görüleceği üzere, çarpık ve sağlam parçalar ağırlıklı olarak farklı bloklara ayrılmış ve özel bir desen gösteren konturların ardışık dizilimi ortaya çıkarılmıştır. Düz çizgi benzerliği, topoloji ve eksen

kesişim noktaları ile ilgili özel desen gösteren karakteristik özellikler bir sonraki adımda detaylı olarak açıklanacaktır.




Şekil 2.23. Eğri şeklinde Pektoral kas içeren örnek bir mamografi görüntüsü için (a) 2B görünümü, (b) radyolog tarafından çizilen pektoral kas sınırı ve (c) düz çizgi ile bölütleme sonuçları

2.5.2. Aday Sınır Parçalarının Belirlenmesi

Bu tez çalışmasında aday sınır parçalarının tespiti için kitle tespitinde kullanılan EEKTS yöntemi uyarlanmıştır. Bozulmaya uğramış pektoral kas sınır parçaları bloklar içerisine lokalize edilmesi ile sağlam parçalar için bazı ayırt edici örüntüler kendini gösterir. EEKTS yöntemi her blok için ayrı ayrı çalıştırılmaktadır bundan dolayı herhangi bir blok içinde bulunan bozulmuş pektoral kas parçası diğer sağlam bloklardaki parçalardan olumsuz etkilemez. Ancak bazı durumlarda meme sınırı, deri kıvrımları ve pektoral kasa benzeyen bazı dokular da pektoral kas sınır parçalarına benzer örüntüler göstermektedir. Bu nedenlerden dolayı, EEKTS yöntemi bazen yanlış sınır parçalarını da tespit edebilir ve bunun yanında gerçek sınır parçaları da kaçırabilir. EEKTS yöntemi ile aday sınır parçaları tespit edildikten sonra ilk olarak, hatalı sınır parçaları ortadan kaldırmak için sırasıyla uygulanacak üç adet algoritma önerilmiştir, son olarak eğri

uydurma işlemi ile kaçırılan sınır parçaları tespit edilerek, pektoral kas sınırının tümü tespit edilmiş olur.

Test görüntüsü mdb 40 için 1. Blok Şekil 2.24 (a) 'da gösterilmektedir. Bu şekilden görüleceği üzere, pektoral kas sınır parçasına ait konturlar peş peşe gelen ardışık doğru parçalarından benzeyen bir örüntü göstermektedir. Bir örüntüde yer alan konturlardan en dışta yer alan kontur parçası o nesnenin sınırını temsil etmektedir. Bu örüntüye benzer şekilde deri kıvrımı, göğüs sınırı ve nadiren süt kanalı gibi bazı dokular da bu tip örüntüler gösterebilmektedir. Pektoral kas sınır parçasına benzer bir şekilde deri kıvrımı ve meme sınırına ait örüntüler bu şekil üzerinde yer almaktadır. EEKTS yöntemi, pektoral kas sınır parçalarını konum, geometrik ve topoğrafik tabanlı özellikler için kural tabanlı bir algoritma kullanmaktadır. Bir blok içerisinde pektoral kas sınır parçasına benzer örüntüler de olacağından dolayı EEKTS yöntemi ile bu aday sınır parçalarının hepsi bu aşamada tespit edilememektedir. Sonuç olarak, bir blokta bir veya daha fazla aday sınır parçaları da olabilir. EEKTS yöntemi her blok için aday sınır parçalarını sırayla tespit etmektedir, bu algorithmada kullanılan öznitelikler ve karar ağacı kuralları alt başlıklarda açıklanmaktadır.



(a)



(b)




(c)

Şekil 2.24. (a) ilk blok, (b) sıralı konturlar ve (c) aday pektoral kas sınır parçaları

2.5.2.1. Konum Tabanlı Öznitelikler

Bölünme işleminden sonra memenin anatomik yapısının bir sonucu olarak pektoral kas sınır parçasına ait konturlar konum tabanlı bazı özellikler göstermektedir. Bu konturların her bir üst ve alt eksenini kesmektedir ve peş peşe dizi şeklinde devam etmektedir. Bu sıralı konturların matematiksel olarak temsil edilebilmesi için önce blok için bir koordinat sistemi oluşturulur ve ardından konturlar bu noktalara göre sıralı bir dizi ile temsil edilir. Şekil 2.24 (a)'da gösterilen 1. blok görüntüsüne ait pektoral kas parçasının bir konturu C_n^m , Şekil 2.25 (a)'da gösterilmektedir. Bu aşamanın ana amacı sıralı bir şekilde giden bu kontur dizisini ifade etmek ve diğer özniteliklerin hesaplanma aşamasında bu notasyonu kullanmaktır.



Şekil 2.25. Aday sınır parçası ve komşu konturların (a) bir blok için ve (b) tüm bloklar için koordinat sistemi

Şekil 2.25 (b)'de trp_n^m ve brp_n^m ile sırasıyla sağ üst ve sol üst için en uç eksen kesişim noktalarını göstermektedir. Bu şekilden de görüleceği üzere, bu noktalar y eksenini kesmektedir fakat pektoral kasa ait olan son blok için brp_n^m değeri y ekseninden x eksenine geçiş yapar.

MLO yönündeki mamografi görüntüsü çekim işleminde meme pozisyonu bakımından teknisyen bir hata yapmamış ise, meme anatomisinin bir sonucu olarak pektoral kas sınırı hiçbir zaman görüntünün köşegenine ulaşamaz. Sonuç olarak, pektoral kas konturlarına ait uç noktalar, blokların üst ve alt taraflarını kesen Şekil 2.25 (c)'de gösterilen köşegenin y eksenli koordinatları ile sınırlıdır. Bu aşamadaki alınan konum tabanlı özneliklerin diğer amacı da bu köşegen sınırının ötesinde kalan uç noktalara ait kontur dizisini ortadan kaldırmaktır. Sonuç olarak bu sayede köşegenin ötesinde kalan pektoral kas sınırına benzeyen meme sınırı yâda damar vb. gibi nesnelere ait örüntüler bu sayede ortadan kaldırılır.

Üst ve alt köşegen için uç noktalar sırasıyla, tdp_n^m ve bdp_n^m ile gösterilir. Bu koordinatlar aşağıdaki Eşitlik (2.41) ve (2.42) ile hesaplanır;

$$m = 1 \dots \frac{h}{50} \quad (2.40)$$

$$tdp^m = w - \frac{50}{h} \cdot w \cdot (m - 1) \quad (2.41)$$

$$bdp^m = w - \frac{50}{h} \cdot w \cdot m \quad (2.42)$$

Eşitlik (2.45)'de gösterilen C_{1,N_m}^m sıralı bir dizi, Eşitlik (2.43) ve (2.44) ile sınırlanan ardışık şekilde artan uç noktalara sahip konturlar içerir.

$$tdp_n^m = 1 \dots tdp^m \quad (2.43)$$

$$bdp_n^m = 1 \dots bdp^m \quad (2.44)$$

$$C_{1,N_m}^m = \{C_n^m \mid n = 1, 2, \dots, N_m\} \quad (2.45)$$

2.5.2.2. Geometrik Tabanlı Öznelikler

Bloklara ayırma işleminin sonucunda, pektoral kas parçalarına ait konturların düz çizgi benzerliğini artmaktadır. Bu nedenle, EEKTS yöntemi öznelik olarak pektoral kas

parçalarının konturlarının düz çizgiye olan benzerliğini kullanmıştır. Düz çizgi benzerliğini ölçmek için, doğrusal regresyonun en basit ve en yaygın şekilde uygulanan şekli olan Kök-Ortalama-Kare-Hata (RMSE) tekniği kullanılmaktadır. RMSE değeri hesaplanırken her veri noktası için hataların karesi alındıktan sonra karekök değerlerinin ortalaması alınır. Kontur ile düz çizgi arasındaki benzerlik arttıkça, RMSE değeri azalır.

Şekil 2.25 (a)'da bir kontur için kestirim yapılan düz çizgi (L_n^m) ve eksen kesişim açısı (θ_n^m) gösterilmektedir. Bir blok içerisinde yer alan sıralı dizideki konturların RMSE ve eksen kesişme açıları sırasıyla aşağıdaki Eşitlik (2.46) ve (2.47) de gösterilmektedir.

$$RMSE_{1,N_m}^m = \{RMSE_n^m | n = 1, 2, \dots, N_m\} \quad (2.46)$$

$$\theta_{1,N_m}^m = \{\theta_n^m | n = 1, 2, \dots, N_m\} \quad (2.47)$$

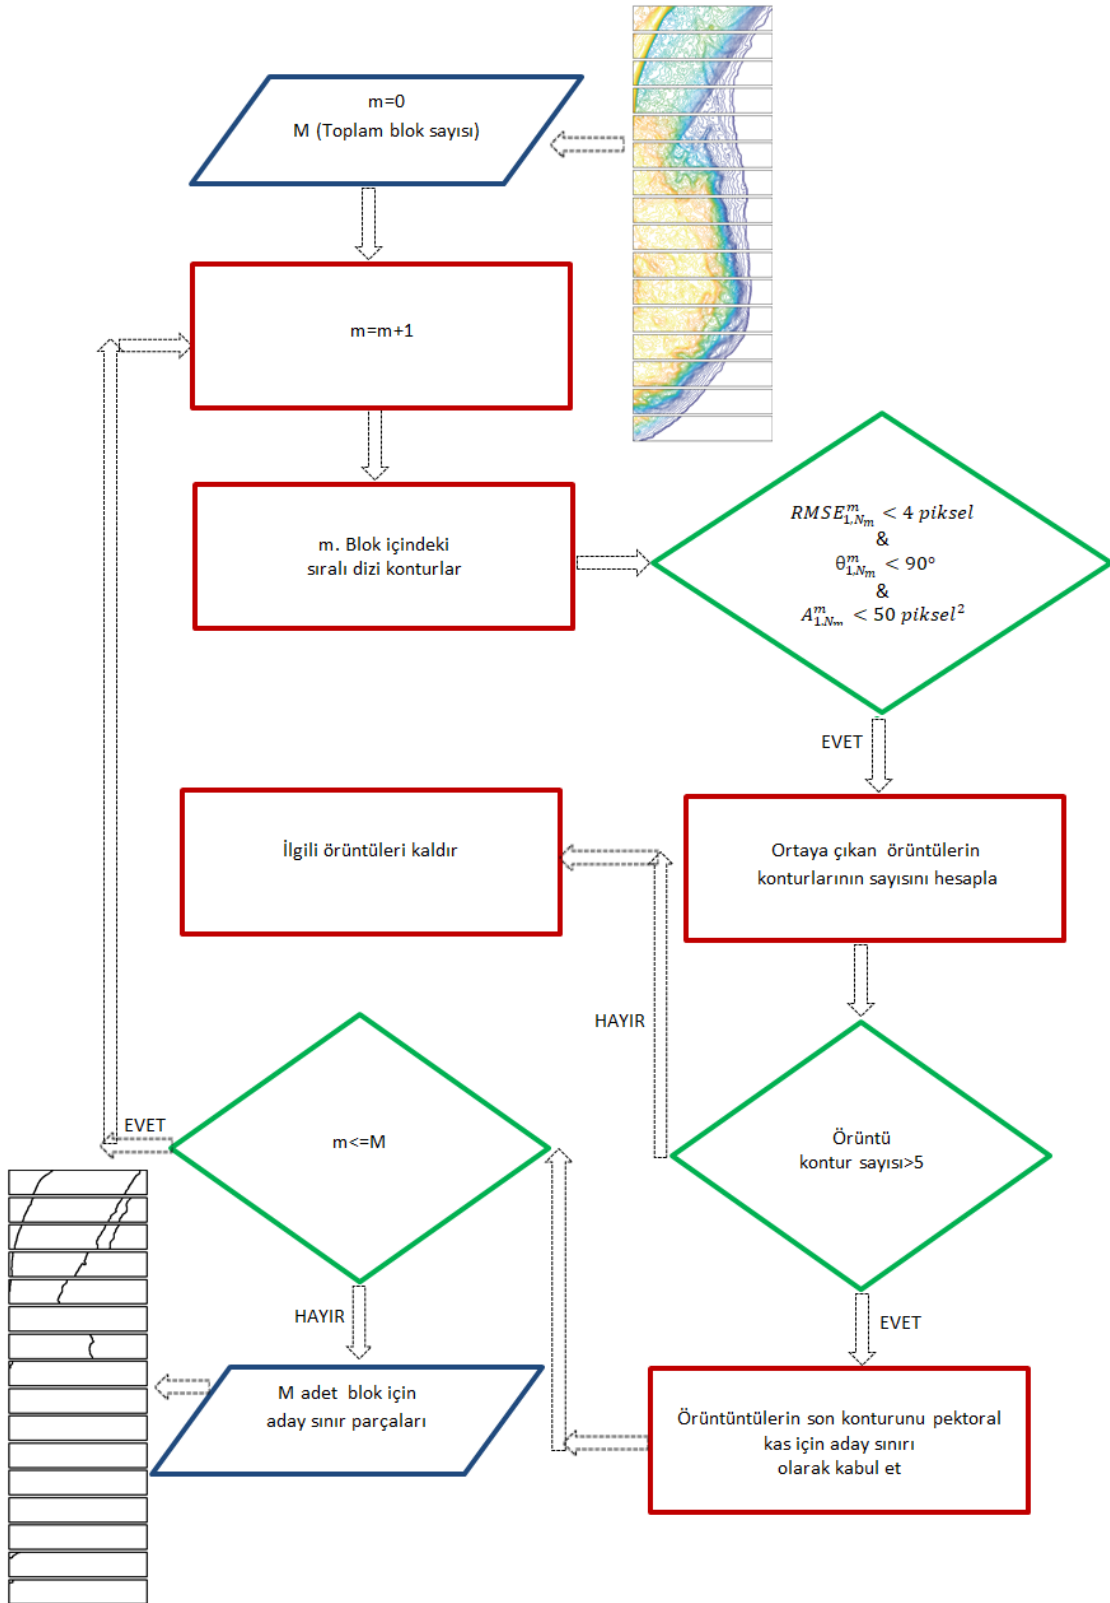
2.5.2.3. Topoğrafik Tabanlı Öznitelikler

MLO mamografi görüntülerinde yer alan pektoral kas bölgesi anatomik yapısının bir sonucu olarak tıpkı şüpheli bölgeler gibi genellikle belirginliği yüksektir. Belirginliği yüksek olan nesnelerin topoğrafik haritadaki ardışık konturlar arasındaki alan, düşük belirginlikteki nesnelere göre çok daha küçüktür. Konturlar arasındaki topolojik ilişki, ardışık konturlar arasındaki alan analiz edilerek belirlenebilir. Bir bloktaki sıralı dizide yer alan konturlar arasındaki alan, Eşitlik (2.48) 'de gösterilmektedir. Sonuç olarak bu alan değerlerinin küçük ve artmadan devam etmesi o nesnenin belirginliğinin şiddetini göstermektedir.

$$\Delta A_{1,N_m}^m = \{\Delta A_n^m | n = 1, 2, \dots, N_m\} \quad (2.48)$$

2.5.2.4. Kural Tablosunun Oluşturulması

Pektoral kas parçalarına ait belirli desenli konturların tespit eden EEKTS yöntemine ait akış diyagramı Şekil 2.26'da gösterilmiştir. Bu yöntem, yukarıda tanımlanan özniteliklere ait karar ağacı kurallarından oluşmaktadır. Bu kuralların eşik değerleri deneysel olarak yapılan çalışmaların sonucunda bulunmuştur.



Şekil 2.26. Aday sınır parçalarının bulunması için akış diyagramı

Sıralı dizideki farklı dokuların spesifik desenli konturları, her biri için ayrı ayrı gruplandırılır. Herhangi bir dokunun belirginliği, dokuya ait spesifik desenli konturların sayısı ile ölçülür. Bu sayı bir çıkıntı dokusunda büyük iken, ince bir dokuda düşüktür. Bu çalışmada, aday sınır parçalarının sayısını kontrol etmek için çok düşük çıkıntılı dokular ihmal edilmiştir. Sonuç olarak belirli desenli konturların minimum sayısı "5" olarak deneysel olarak seçilmiştir. Belirli desenli konturların en dıştaki konturu o nesnenin aday sınır olarak kabul edilmiştir.

EEKTS yöntemi, tüm bloklar için ayrı ayrı yürütülerek tüm aday sınır parçaları bulunur. Bu algoritmanın Şekil 2.24 (a) 'de yer alan ilk blok için çıktıları Şekil 2.24 (b) ve (c) 'de gösterilmektedir. Bu şekilden de görüleceği üzere hem pektoral kas sınırına hem de benzer dokulara ait sınırlar elde edilmektedir. Dolayısıyla bu yanlış sınırları elemek için bazı ilave algoritmalara ihtiyaç vardır. Bu algoritmalar bir sonraki alt başlıkta açıklanmaktadır.

2.5.3. Yanlış Aday Sınır Parçalarını Eleme


EEKTS yöntemi her bir blokta pektoral kas, meme sınırı, deri kıvrımları ve diğer benzer dokulara ait pektoral kas için aday sınır parçaları tespit eder. Dolayısıyla bu yöntem tarafından tespit edilen aday sınırları, pektoral kas parçalarının yer aldığı bloklarda olabileceği gibi pektoral kasın yer almadığı meme dokusuna ait bloklarda da görülebilmektedir. EEKTS yöntemi, bozulma etkilerine bağlı olarak bazı sınır parçalarını tespit edemeyebilir. Bu bahsedilen ihtimallerin sonucunda, bu yönteminin çıktılarını 6 farklı durumda aşağıdaki gibi kategorize edilmektedir.

- Durum 1: Herhangi bir pektoral blokta yalnızca gerçek sınır parçası olması.
- Durum 2: Herhangi bir pektoral blokta bir veya daha fazla yanlış sınır parçası ve gerçek sınır parçası olması.
- Durum 3: Herhangi bir pektoral blokta bir veya daha fazla yanlış sınır parçası ve gözden kaçan sınır parçası olması.
- Durum 4: Herhangi bir pektoral blokta gözden kaçan sınır parçası olması.
- Durum 5: Herhangi bir meme bloğunda hiç bir aday sınır parçası olmaması.
- Durum 6: Herhangi bir meme bloğunda bir veya daha fazla yanlış sınır parçası olması.

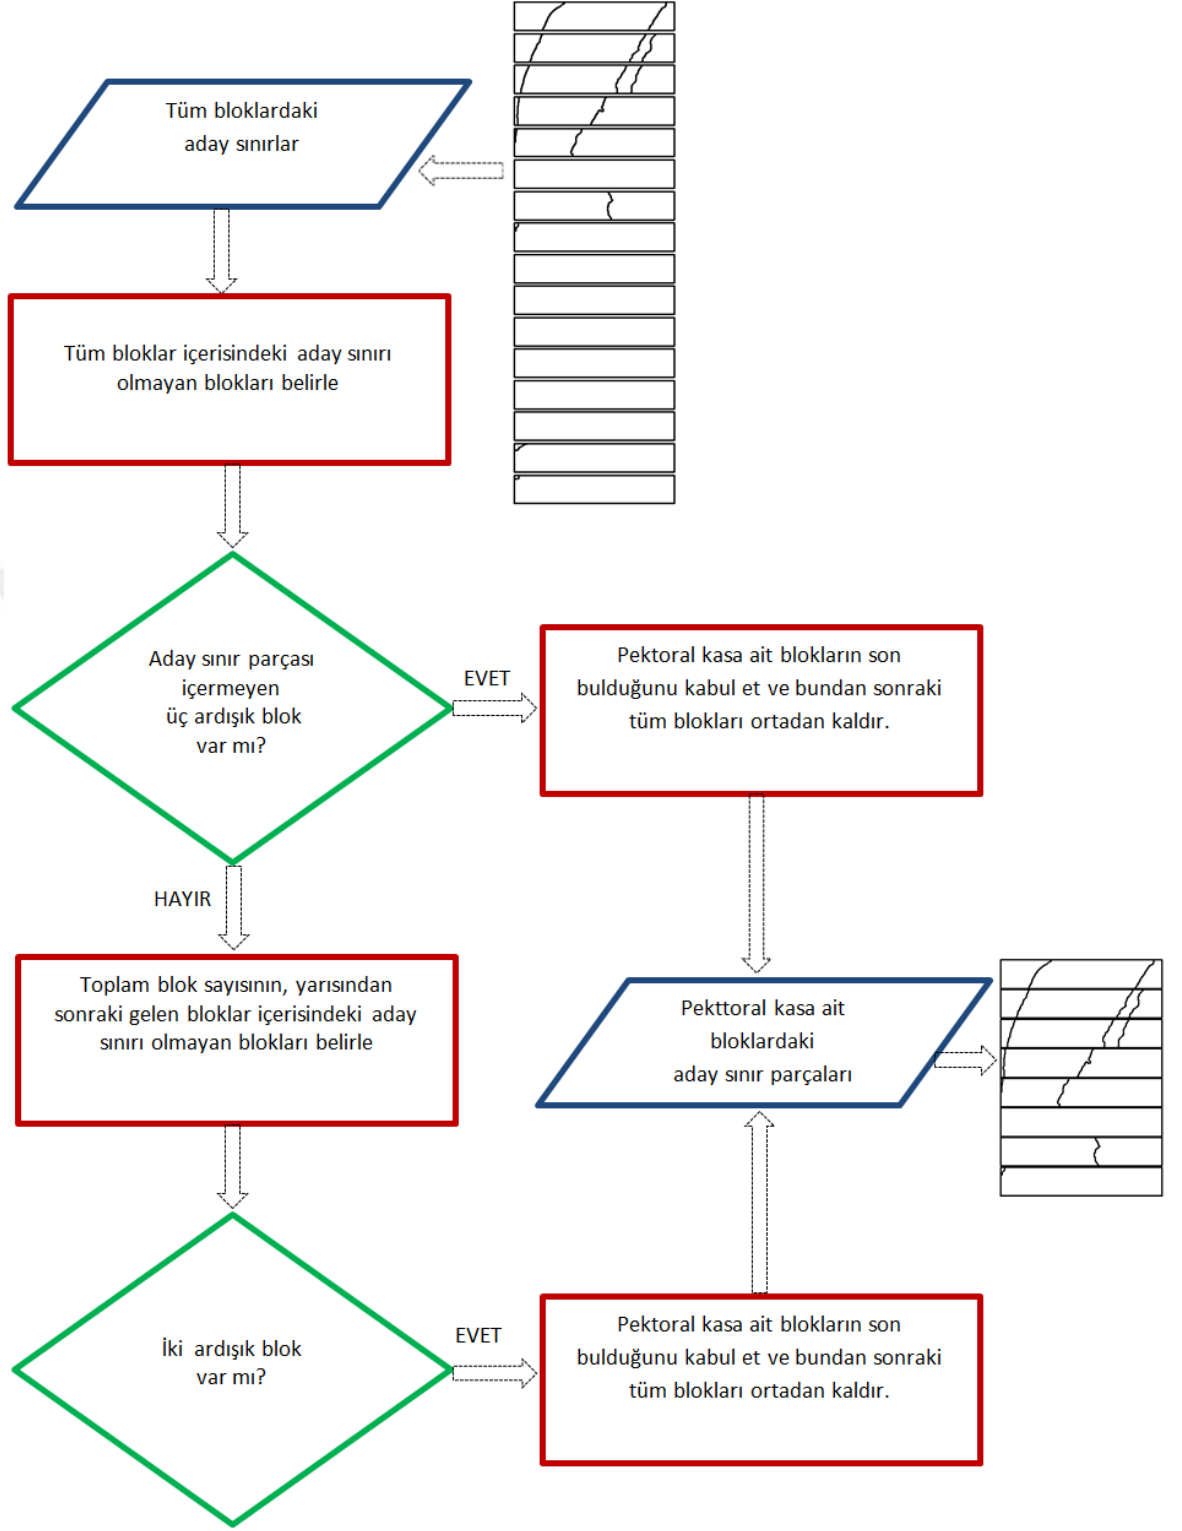
Şekil 2.27 (a)' da EEKTS yönteminin sonuçları ile yukarıda kategorize edilen durumlar ilgili blok içerisinde farklı renkler ile temsil edilerek gösterilmiştir. Bu aşamada,

yanlış sınır parçalarını ortadan kaldırmak için bazı algoritmalar önerilmiştir. Bu algoritmalar temel olarak pektoral kas sınırına ait aşağıda verilen bazı bilgilere dayanmaktadır:

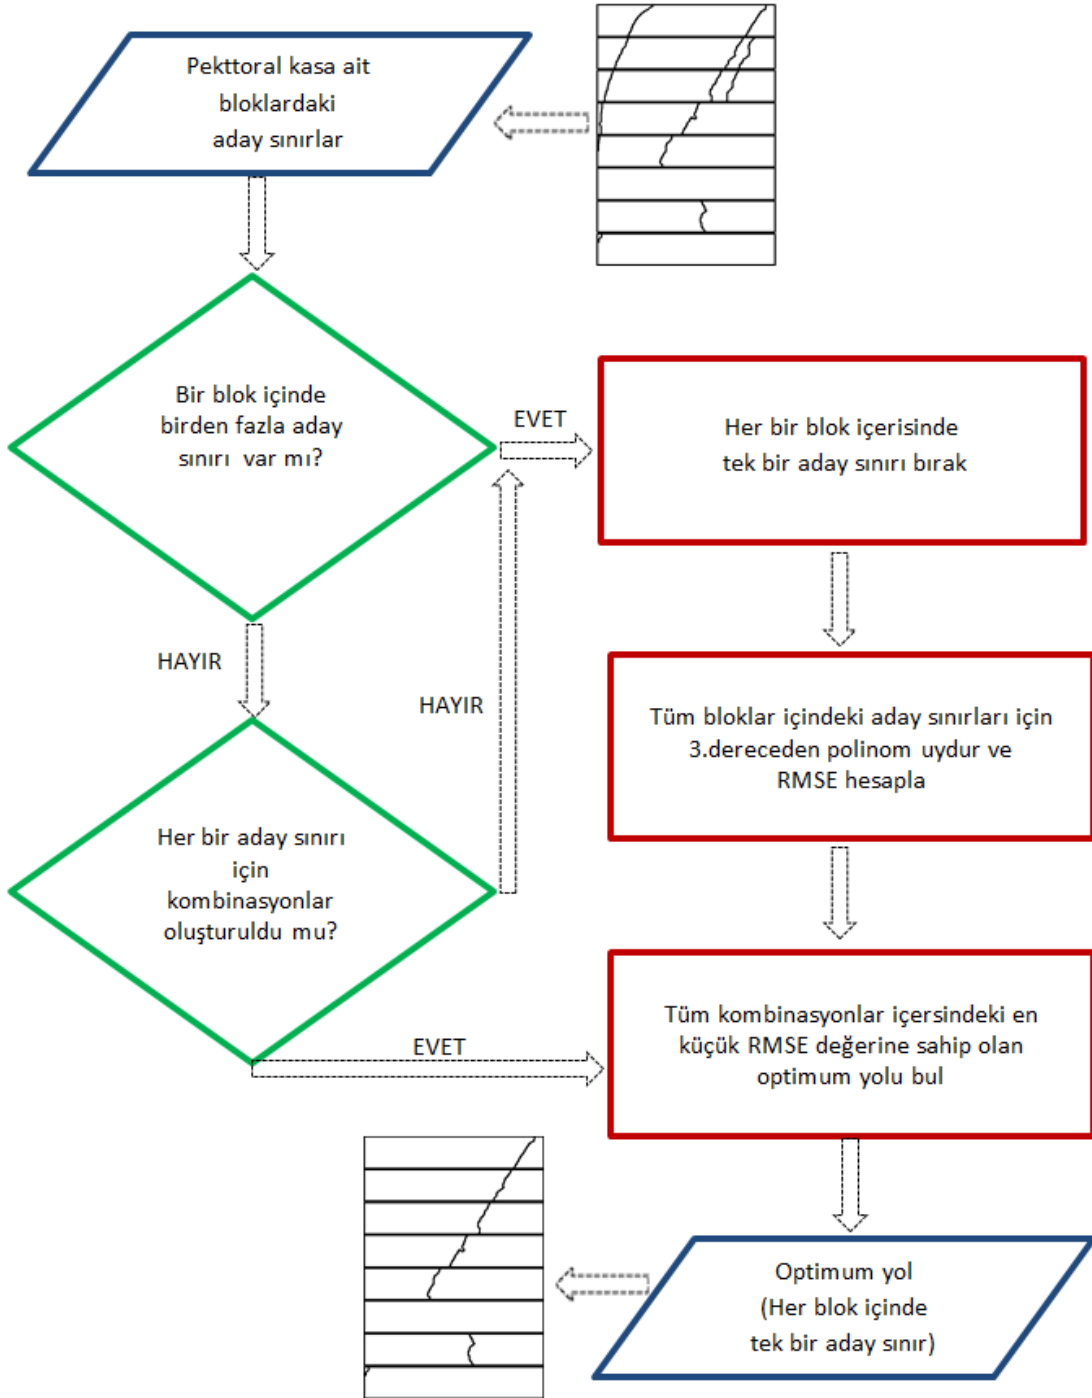
- Pektoral kas sınırı, içbükey, dışbükey, düz çizgi veya bunların bir karışımı olabileceği için üçüncü derece polinom ile temsil edilebilir.
- Görüntünün üst kenarından (y eksenini) başlar ve sol kenarında (x eksenini) biter.
- Yukarıdan aşağıya azalarak sürekli bir şekilde devam eder.



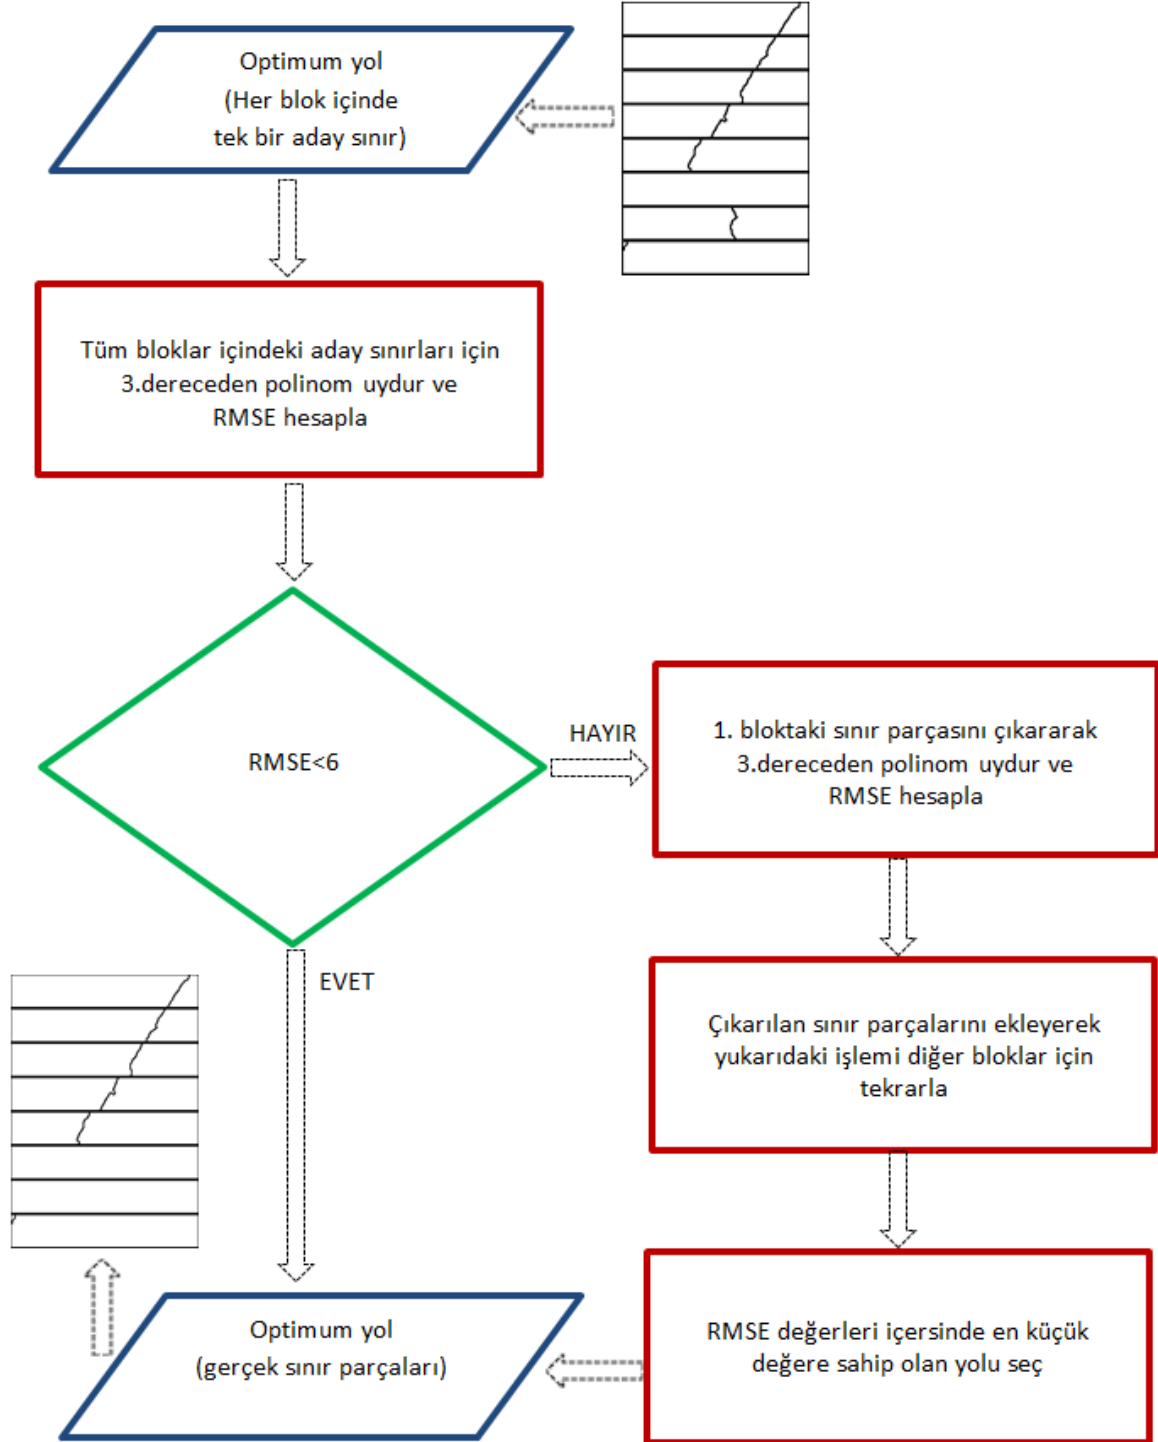
Şekil 2.27. (a) Aday sınır parçaları için durum bilgileri ve (b) pektoral kas sınırı



Şekil 2.28. Pektoral kas bulunmayan blokların ortadan kaldırılması için akış diyagramı




Şekil 2.29. Optimum yol haricinde kalan diğer aday sınırlarının kaldırılması için akış diyagramı



Şekil 2.30. Optimum yol seçimi için akış diyagramı

“Durum 6” ' dan da gösterildiği üzere, yanlış pozitif sınır parçaları sadece pektoral bloklarda değil aynı zamanda pektoral kas ait olmayan meme bloklarında da ortaya çıkar. Bu nedenle, “Durum 6” olarak ortaya çıkan aday sınır parçalarını ortadan kaldırmak için pektoral kasın yer aldığı son bloğu tespit eden bir algoritma önerilmiştir. Bu algoritmanın akış diyagramı Şekil 2.28 ‘de gösterilmektedir.

Pektoral kas sınırına benzer dokuların olmasının bir sonucu olarak bir blokta birden fazla aday sınır parçası görülebilir. Bu durumda doğru sınır parçasını tahmin ederek diğerlerini ortadan kaldırma işlemi yapılması gerekmektedir. Bu işlem için Şekil 2.29 ‘ de akış diyagramı gösterilen algoritma önerilmiştir. Bu algortmada tüm sınır parçalarının farklı kombinasyonları için tüm alternatif yollar oluşturulur. Her bir yol için üçüncü dereceden polinom uydurulur. Bu yollara ait RMSE değerlerinin arasında en küçüğüne sahip sınır yolu optimum yol olarak seçilir. Bu yol dışında kalan aday sınır parçaları ortadan kaldırılır.



Şekil 2.31. Örnek mamografi görüntüsü için aday sınır parçalarının eleme işlemlerindeki (a) Algoritma 1 çıktısı, (b) Algoritma 2 çıktısı, (c) Algoritma 3 çıktısı

Herhangi bir bloktaki optimum sınır parçası haricindeki yanlış sınır parçaları, optimum yol seçilerek ortadan kaldırılır. Ancak, optimum sınır parçalarının da tümü doğru olmayabilir. Ayrıca, bozulma etkileri nedeniyle bazı sınır parçaları gözden kaçmış da olabilir. Kaçırılan sınır parçalarının en iyi şekilde tahmin edilmesi için, optimum sınır yolundaki yanlış sınır parçaları ortadan kaldırılmalıdır. Bu işlem için Şekil 2.30 ‘da akış diyagramı verilen algoritma geliştirilmiştir. Optimal sınır parçalarının doğruluğu, sınır

uydurma işlemi ile test edilir. Doğruluk koşulu olarak deneysel olarak belirlenen RMSE değeri 6 kullanılır. Bu koşul karşılanana kadar, eleme ve eğri uydurma süreci yinelemeli bir şekilde devam eder.

Şekil 2.31 'de sırasıyla, bu üç algoritmanın çıktıları göstermektedir. Bu şekilden görüldüğü gibi; tüm YP sınır parçaları bu algoritmaların uygulanması ile ortadan kaldırılmıştır.

2.5.4. Pektoral Kas Parçalarının Birleştirilmesi

Yanlış pozitif aday sınır parçaları, önceki aşamalarda önerilen algoritmalarla ortadan kaldırılsa da, EEKTS yönteminin bozulmanın etkisine bağlı olarak tespit edemediği sınır parçaları olabilir. Şekil 2.31 (c)' den görüleceği üzere bozulma durumunun yüksek olduğu 6 ve 7. bloklardaki pektoral kas sınır parçaları tespit edilememiştir. Ayrıca, tespit edilen sınır parçaları genellikle pürüzlüdür ve bazı durumlarda sürekliliği de olamayabilir. Bu aşamada, eğri uydurma işlemi hem kaçırılan sınır parçalarını tespit etmek hem de pürüzlü olan aday sınırlarını düzleştirme işlemi için kullanılmıştır.

Bu tez çalışmasında yapılan deneysel çalışmaların sonucunda, pektoral kas sınırının genellikle düz doğru, iç ve dış bükey eğrilerin kombinasyonundan oluştuğu görülmüştür. Bu nedenle; pektoral kas sınırı eğri uydurma işleminde, 3. Dereceden bir polinom kullanılmıştır. Bu işlemden sonra pektoral kas sınırının eksik kalan parçaları tamamlanarak sürekliliği olan pürüzsüz bir eğri elde edilmiş olur. Bu tez çalışması kapsamında geliştirilen pektoral kas sınırı tespit eden yöntemin, mdb40 görüntüsü için çıktısı Şekil 2.27 (b) 'de gösterilmektedir.

3. BULGULAR VE İRDELEME

Bu tez çalışması kapsamında geliştirilen EEKTS yönteminin mamografi görüntüleri üzerindeki şüpheli bölgeleri ve pektoral kas sınırını belirlemesi üzerine yapılan deneylerin sonuçları verilmiştir. Bu performans deneylerinde özellikle belirginliği düşük şüpheli bölgeler ve bozulmuş pektoral kas bölgeleri için de bulgular hazırlanmıştır. Elde edilen bu performans sonuçları aşağıda detayları verilen ölçüm kriterleri üzerinden niceliksel alt başlıklarda sunulmaktadır. Bu sonuçların değerlendirilmesi ve önerilen yöntemlerin özellikle başarılı olduğu ve başarısız olduğu görüntülerde niteliksel olarak aşağıdaki alt başlıklarda verilmektedir. En son olarak bu tez çalışmasında geliştirilen yöntemlerin niceliksel sonuçları ve literatürdeki öncü BDT çalışmalarına ait sonuçlar ile mukayese edilerek irdelenmiştir.

Literatürdeki BDT sistemleri performans değerlendirilmesi için yaygın olarak Tablo 3.1'de gösterilen Hata Matrisi (Confusion Matrix) üzerinde yer alan temel değerleri kullanmıştır.

Tablo 3.1. Performans değerlendirmesinde kullanılan metrikler

		Kesin Referans	
		Pozitif	Negatif
Test Sonuçları	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Bu hata matrisinde kullanılan temel metriklerin anlamları pektoral kas sınırı ve kitle belirleme işlemleri için ayrı ayrı aşağıda açıklanmaktadır.

Doğru pozitif (DP):

- Gerçekte pektoral kas pikseli olup bölütleme sonucunda da pektoral kas olarak sınıflandırılan piksellerin sayısıdır.

- Gerçekte anormal bölgeye ait ilgi bölgesi olup sınıflandırma sonucunda da anormal bölge olarak sınıflandırılan ilgi bölgelerinin sayısıdır.

Doğru negatif (DN):

- Gerçekte meme bölgesine ait bir piksel olup bölütleme sonucunda da meme bölgesi pikseli olarak sınıflandırılan piksellerin sayısıdır.
- Gerçekte anormal bölgeye ait ilgi bölgesi olup sınıflandırma sonucunda anormal bölge olarak sınıflandırılan ilgi bölgelerinin sayısıdır.

Yanlış Pozitif (YP):

- Gerçekte meme bölgesine ait bir piksel olup bölütleme sonucunda pektoral kas olarak sınıflandırılan piksellerin sayısıdır.
- Gerçekte normal bölgeye ait ilgi bölgesi olup sınıflandırma sonucunda da anormal bölge olarak sınıflandırılan ilgi bölgelerinin sayısıdır.

Yanlış Negatif (YN):

- Gerçekte pektoral kas pikseli olup bölütleme sonucunda meme bölgesi pikseli olarak sınıflandırılan piksellerin sayısı
- Gerçekte anormal bölgeye ait ilgi bölgesi olup sınıflandırma sonucunda da normal bölge olarak sınıflandırılan ilgi bölgelerinin sayısıdır.

Bu tez çalışması kapsamında elde edilen şüpheli bölgeler arasından anormal bölgelerin belirlenmesi sonuçlarını değerlendirmek için kullanılacak bazı temel performans metrikleri çeşitli eşitliklere göre hesap edilmektedir. Bu temel metrikler; doğru pozitif oranı (duyarlılık, sensivity), doğru negatif oranı (özgüllük, specificity) ve doğruluk (accuracy); sırasıyla Eşitlik (3.1), (3.2) ve (3.3)'de hesaplanmaktadır.

$$DUY = \frac{DP}{DP+YN} \times 100 \quad (3.1)$$

$$KES = \frac{DN}{DN+YP} \times 100 \quad (3.2)$$

$$DOG = \frac{DP+DN}{DP+DN+YP+YN} \times 100 \quad (3.3)$$

Sınıflandırma işlemlerinde, metotlar kesinlik (yanlış pozitifleri eleme kabiliyeti) ve hassasiyet (doğru pozitifleri tespit etme kabiliyeti) arasındaki dengeyi kurmakla uğraşmaktadır. İkili sınıflandırma sistemlerinde ayırım eşik değerinin farklılık gösterdiği durumlarda, hassasiyetin kesinliğe olan oranı ROC grafikleri ile gösterilmektedir. Bir ikili sınıflandırıcının başarısı ROC eğrisinin alanı (AuC) ile ölçülmektedir. Bu değer ne kadar yüksek olursa sınıflandırma işlemi o kadar başarılı olmaktadır. Bu tez çalışması kapsamında elde edilen sınıflandırma performansları ROC grafikleri ile sunulmaktadır

Bu tez çalışması kapsamında elde edilen pektoral kas bölgesinin bölütlenmesi sonuçlarını değerlendirmek için kullanılacak olan bazı temel performans metrikleri çeşitli eşitliklere göre hesap edilmektedir. YP, kesin referans bölgesi dışında kalan piksel sayısının kesin referans bölgesindeki piksel sayısına oranıdır. Benzer şekilde YN, kesin referans bölgesi içinde bulunmayan piksel sayısının kesin referans bölgesindeki piksel sayısına oranıdır. Tespit edilen bölgedeki piksel seti ve kesin referans bölgesindeki piksel seti sırasıyla D ve R olarak belirtilir. Bu ölçümler Eşitlik (3.4) ve (3.5)'de verilen eşitlikler ile hesaplanmaktadır.

$$YP = 100 \times \frac{|D \cup R| - |R|}{|R|} \quad (3.4)$$

$$YN = 100 \times \frac{|D \cup R| - |D|}{|R|} \quad (3.5)$$

YP_m ve YN_m , N sayıda görüntü için tüm YP ve YN değerlerinin ortalamasını gösterir. Bu ölçümler Eşitlik (3.6) ve (3.7)'de hesaplanmaktadır. Burada m ve i alt yazıları sırasıyla ortalamayı ve görüntünün indeksini belirtir.

$$YP_m = \sum_{i=1}^N \frac{YP_i}{N} \quad (3.6)$$

$$YN_m = \sum_{i=1}^N \frac{YN_i}{N} \quad (3.7)$$

Bu tez çalışması kapsamında yapılan deneysel çalışmalar yukarıda açıklanan performans metrikleri ve ROC grafikleri ile aşağıda alt başlıklar halinde detaylıca verilmektedir.

3.1. EEKTS Yöntemi ile Şüpheli Bölgelerin Belirlenmesi İçin Yapılan Deneyler

Bu kısımda EEKTS yönteminin performansı bazı parametreler ve filtre tipleri değiştirilerek deneysel olarak incelenmiştir. Bu deneysel çalışmaların sonuçları niceliksel ve niteliksel olarak aşağıda alt başlıklar altında sunulmaktadır.

Literatürde şüpheli bölgelerin belirlenmesi için en çok MIAS ve DDSM veri tabanları kullanılmıştır. Fakat MIAS veri tabanında yalnızca 56 adet görüntüde kitle bulunmaktadır. Sonuç olarak bu kadar az sayıda bir veri üzerinde eğitim ve test işlemi yaparak sınıflandırma performansını ölçmek zor bir görevdir. Bu tez kapsamında kullanmak için DDSM veri tabanı üzerinde kitle içeren 1484 adet görüntüye erişim sağlanabilmiştir. Ayrıca CBIS-DDSM veri setinde bu görüntüler için radyoloji uzmanları tarafından hazırlanmış kitlelere ait bölütleme maskeleri de yer almaktadır. Bu nedenlerden dolayı bu aşamadaki deneysel çalışmalar DDSM veri seti üzerinde gerçekleştirilmiştir.

3.1.1. Niceliksel Sonuçlar ve Değerlendirmesi

Bu tez çalışmasında, geliştirilen EEKTS yönteminin özellikle süperpozisyon etkisi altında kalan belirginliği düşük kitleler üzerinde başarı sağlanması hedeflenmiştir. Bu nedenle özellikle “OHS” , filtre tipleri ve bazı istatistikî öznitelikler vb. gibi bazı parametreler değiştirilerek performansa olan etkisi niceliksel olarak detaylıca incelenmiştir. Bu sonuçlar Tablo 3.2 ‘de beş kısım halinde sunulmaktadır.

İlk kısımda 5 farklı genişlikteki ortalama değer filtreleri için OHS=5-35 seçilerek EEKTS-1 yöntemine ait elde edilen DP, YN ve YP sonuçları gösterilmektedir. Bu sonuçlardan görüleceği üzere en küçük YN değeri, Yumuşatma Filtre 2 (15x15 ortalama değer filtresi) kullanılarak elde edilmektedir. Elde edilen sonuçlara göre, yumuşatma miktarının artması YP sayısını düşürmektedir. Fakat bu işlem ile ne yazık ki YN sayısı da artmaktadır.

İkinci kısımda Yumuşatma Filtre 2 (15x15 ortalama değer filtresi) kullanılarak 5 farklı OHS için DP, YN ve YP sonuçları gösterilmiştir. Bu sonuçlardan görüleceği üzere OHS için eşik değeri aşağı düşürüldükçe DP sayısı da artmaktadır. Fakat YN sayısını düşürmek için yapılan bu işlem, YP sayısında ciddi bir artış oluşturmaktadır.

Üçüncü kısımda farklı genişliklerdeki Gabor filtreleri için OHS=5-35 seçilerek EEKTS-1 yöntemine ait elde edilen DP, YN ve YP sonuçları gösterilmektedir. Bu

sonuçlardan görüleceği üzere en küçük YN değeri, Gabor Filtre 4 kullanılarak elde edilmektedir. Gabor Filtre genişliğinin belli bir seviyeye kadar artırılması YN değerini düşürmektedir. Bu işlemin YP sayısı üzerine ciddi bir etkisi bulunmamaktadır.

Tablo 3.2. EEKTS yönteminin farklı parametreler için performans değerlendirmesi

EEKTS Bölütleme Yöntemi	DP	YN	YP	DUY %	YP _m
Ortalama Değer Filtre, farklı filtre boyutları ile					
10x10, OHS= 5-35, EEKTS-1	1228	259	11218	82.75	7.56
15x15, OHS= 5-35, EEKTS-1	1233	254	10418	83.09	7.02
20x20, OHS= 5-35, EEKTS-1	1213	274	7872	81.74	5.30
25x25, OHS= 5-35, EEKTS-1	1173	314	5532	79.04	3.73
30x30, OHS= 5-35, EEKTS-1	1118	369	3842	75.34	2.59
Ortalama Değer Filtre, farklı OHS aralıkları					
15x15, OHS= 25-35, EEKTS-1	594	893	373	40.03	0.25
15x15, OHS= 20-35, EEKTS-1	761	726	820	51.28	0.55
15x15, OHS= 15-35, EEKTS-1	955	532	1922	64.35	1.30
15x15, OHS= 10-35, EEKTS-1	1121	366	4544	75.54	3.06
15x15, OHS= 5-35, EEKTS-1	1233	254	10418	83.09	7.02
4 yönde Gabor Filtre, farklı filtre boyutları ile					
10x10, OHS= 5-35, EEKTS-1	1249	238	14029	84.16	9.45
15x15, OHS= 5-35, EEKTS-1	1291	196	16642	86.99	11.21
20x20, OHS= 5-35, EEKTS-1	1336	151	18257	90.03	12.30
25x25, OHS= 5-35, EEKTS-1	1372	115	18949	92.45	12.77
30x30, OHS= 5-35, EEKTS-1	1321	166	17354	89.02	11.69
4 yönde Gabor Filtre, farklı OHS ile					
25x25, OHS= 25-35, EEKTS-1	828	659	1278	55.80	0.86
25x25, OHS= 20-35, EEKTS-1	986	501	2369	66.44	1.60
25x25, OHS= 15-35, EEKTS-1	1152	335	4659	77.63	3.14
25x25, OHS= 10-35, EEKTS-1	1291	196	9238	86.99	6.23
25x25, OHS= 5-35, EEKTS-1	1372	115	18949	92.45	12.77
4 yönde Gabor Filtre, farklı EEKTS'ler ile					
25x25, OHS=5-35, EEKTS-2	1322	165	12454	89.08	8.39
25x25, OHS=5-35, EEKTS-3	1201	286	6261	80.93	4.22
25x25, OHS=5-35, EEKTS-4	1337	150	16233	90.09	10.94
25x25, OHS=5-35, EEKTS-5	1287	200	10845	86.73	7.31
25x25, OHS=5-35, EEKTS-6	1135	352	4873	76.48	3.28

Dördüncü kısımda Gabor Filtre 4 kullanılarak faklı OHS 'ler için DP, YN ve YP sonuçları gösterilmiştir. Bu sonuçlardan görüleceği üzere OHS eşik değeri aşağı düşürüldükçe DP sayısı artmaktadır. Fakat YN sayısını düşürmek için yapılan bu işlem YP sayısında ciddi bir artış oluşturmaktadır.

Bu tez çalışması kapsamında Tablo 2.2 'de EEKTS kural tablolarının bazı eşik değerleri değiştirilerek, EEKTS yönteminin performans sonuçları gösterilmektedir. Mamografi veri tabanlarında kitlelere ait alan özneliliğinin değişimi incelendiğinde, ebatları küçük kitle sayısının oldukça düşük olduğu görülmektedir. Oysaki küçük ebatlı kitleleri belirlenme işlemi esnasında aşırı sayıda YP ile de karşılaşılmaktadır. Bu kısımdaki deneylerin sonuçlarına göre özellikle küçük ebatlı kitleler için YN oluşturulması durumunda çok sayıda YP 'in ortadan kaldırılabilirdiği görülmüştür.

3.1.2. Niteliksel Sonuçlar ve Değerlendirmesi

Bu tez çalışması kapsamında Gabor filtre ve ortalama değer filtresi kullanımının EEKTS yöntemindeki başarımlarını incelenmiştir. Bu inceleme sonucunda Gabor filtrenin kullanılması ile belirginliği düşük kitlelerin tespit edilebildiği görülmüştür. Bu kitlelerin yer aldığı görüntülerin ismi Tablo 3.3'de gösterilmektedir. Ayrıca bu görüntülerin bir kısmı Şekil 3.1 'de gösterilmektedir. Bu şekilden de görüleceği üzere bu kitlelerin çoğu yoğun bölgeler içerisinde süperpozisyon sonucu bazı kısımları görülmemektedir. Ancak ön işleme aşamasında uygulanan 4 farklı açıdan Gabor filtresi sonucunda, süperpozisyon etkisi azaltılarak bu tip kitlelerin EEKTS yöntemi ile belirlenmesi ve kabaca bölütlenme işlemi gerçekleştirilebilmiştir.


EEKTS yönteminin süperpozisyon etkisine rağmen özellikle başarılı olduğu belirginliği düşük kitle tipleri 4 gruba ayrılarak aşağıda detaylandırılmıştır:

- Pektoral kas bölgesine bitişik durumda yada bir kısmı süperpozisyon olan kitleler (Şekil 3.1. (a) ve (b)). Bu durumda olan kitlelerin yoğun bölge olan pektoral kas ile bir kısmı örtüştiğinden dolayı belirginliği düşmektedir.
- Pektoral kas ile tümüyle süperpozisyon olan kitleler (Şekil 3.1 (c) ve (d)). Bu durumda olan kitleler yoğun bölge olan pektoral kas ile örtüştiğinden dolayı belirginliği düşmektedir. Bu tip kitleler göğüs duvarına yakın olursa kitlenin bir kısmı filmde yer almayacağından dolayı morfolojik özelliklerini kaybedeceğinden kaçırılma ihtimali olabilmektedir.

- Meme içerisinde yoğun olan bir doku ile süperpozisyon olmuş kitleler (Şekil 3.1 (e) ve (d)). Bu durumda olan kitlelerin yoğun bölge olan pektoral kas ile bir kısmı örtüştüğünden dolayı morfolojik özellikleri değişebilmektedir.
- Meme içerisinde bulunan süt kanalları, damar vb. doku tipleri ile süperpozisyon olan kitleler (Şekil 3.1 (g) ve (h)). Süperpozisyon miktarı, karşılaştığı doku tipi ve kendi büyüklüğüne bağlı olarak belirginliği değişkenlik göstermektedir.

Tablo 3.3. Belirginliği düşük kitlelerin yer aldığı mamografi görüntüleri

00037_RIGHT_CC	00018_RIGHT_MLO	00673_RIGHT_MLO	01398_LEFT_CC
00056_LEFT_MLO	00076_LEFT_MLO	00698_RIGHT_CC	01398_LEFT_MLO
00066_LEFT_CC	00090_LEFT_CC	00764_RIGHT_CC	01418_RIGHT_CC
00159_RIGHT_MLO	00092_RIGHT_CC	00775_LEFT_MLO	01430_RIGHT_MLO
00173_LEFT_CC	00096_RIGHT_MLO	00778_RIGHT_CC	01433_LEFT_MLO
00200_RIGHT_MLO	00119_LEFT_CC	00781_RIGHT_MLO	01452_RIGHT_CC
00359_LEFT_MLO	00122_RIGHT_MLO	00814_LEFT_CC	01498_RIGHT_MLO
00391_LEFT_MLO	00149_LEFT_MLO	00816_RIGHT_MLO	01504_LEFT_CC
00409_RIGHT_MLO	00169_RIGHT_MLO	00818_RIGHT_MLO	01514_LEFT_MLO
00433_LEFT_CC	00187_LEFT_CC	00841_RIGHT_MLO	01517_LEFT_MLO
00490_RIGHT_CC	00206_RIGHT_MLO	00865_RIGHT_MLO	01532_LEFT_MLO
00500_RIGHT_MLO	00207_LEFT_MLO	00892_LEFT_CC	01553_RIGHT_MLO
00544_LEFT_CC	00224_LEFT_CC	00917_RIGHT_MLO	01565_RIGHT_MLO
00544_LEFT_MLO	00224_RIGHT_MLO	00927_LEFT_CC	01621_RIGHT_MLO
00615_RIGHT_MLO	00231_LEFT_MLO	00939_RIGHT_CC	01632_LEFT_MLO
00641_RIGHT_MLO	00236_RIGHT_MLO	00939_RIGHT_MLO	01635_LEFT_CC
00718_RIGHT_MLO	00240_RIGHT_MLO	00959_RIGHT_MLO	01635_RIGHT_CC
00738_RIGHT_CC	00241_RIGHT_CC	00976_LEFT_CC	01638_RIGHT_MLO
00738_RIGHT_MLO	00281_LEFT_MLO	00978_RIGHT_CC	01649_LEFT_CC
00766_LEFT_CC	00303_LEFT_MLO	00982_RIGHT_MLO	01653_RIGHT_MLO
00813_RIGHT_MLO	00328_RIGHT_CC	01000_RIGHT_CC	01687_RIGHT_CC
00820_RIGHT_CC	00396_LEFT_MLO	01009_RIGHT_CC	01698_RIGHT_CC
00837_RIGHT_MLO	00413_LEFT_CC	01036_RIGHT_MLO	01701_LEFT_MLO
00893_LEFT_MLO	00421_LEFT_CC	01051_RIGHT_CC	01720_RIGHT_MLO
00951_RIGHT_CC	00487_RIGHT_MLO	01086_LEFT_MLO	01737_RIGHT_CC
01044_LEFT_MLO	00488_LEFT_CC	01103_RIGHT_CC	01744_LEFT_MLO
01323_LEFT_CC	00519_RIGHT_CC	01138_RIGHT_MLO	01749_LEFT_CC
01331_LEFT_CC	00534_LEFT_CC	01152_RIGHT_MLO	01776_RIGHT_CC
01333_LEFT_CC	00534_LEFT_MLO	01179_LEFT_MLO	01780_LEFT_CC
01416_RIGHT_CC	00545_LEFT_MLO	01238_RIGHT_CC	01817_RIGHT_MLO
01599_LEFT_MLO	00554_LEFT_MLO	01264_LEFT_MLO	01821_LEFT_CC
01677_RIGHT_MLO	00564_RIGHT_CC	01270_LEFT_MLO	01822_LEFT_MLO
01690_LEFT_MLO	00572_RIGHT_CC	01305_LEFT_CC	01850_RIGHT_CC
01716_RIGHT_CC	00626_LEFT_CC	01349_LEFT_MLO	01850_RIGHT_MLO
01716_RIGHT_MLO	00630_LEFT_MLO	01360_LEFT_MLO	01853_LEFT_MLO
01719_RIGHT_CC	00640_RIGHT_MLO	01367_LEFT_MLO	01876_LEFT_MLO
01795_LEFT_CC	00653_LEFT_MLO	01379_LEFT_CC	01887_LEFT_MLO
01800_RIGHT_CC	00659_RIGHT_MLO	01389_RIGHT_MLO	01888_RIGHT_MLO




Şekil 3.1. EEKTS yöntemi ile tespit edilen belirginliği düşük kitleler

Gabor filtre kullanılmasına rağmen EEKTS yöntemi bazı görüntülerde yer alan belirginliği çok düşük kitleleri tespit edememiştir. Bu görüntüler Tablo 3.4'de gösterilmektedir. Ayrıca bu görüntülerin bir kısmı Şekil 3.2'de gösterilmektedir. Bu kitle tipleri 3 gruba ayrılarak aşağıda detaylandırılmıştır:


- Meme üzerindeki konumları arka plana yakın kısımlarda yer alan kitleler (Şekil 3.2 (a) ve (b)). Bu tip kitle konumları çekim işlemi için sıkıştırılan memenin uç kısımlarına denk gelmektedir. Bu konumda olan özellikle küçük ebatlı kitlelerin belirginliği oldukça düşmektedir.
- Meme üzerindeki konumları, memenin vücut tarafında bitişik olan kısmına denk gelen dolayısıyla mamografi görüntüsünün dik kenarına yakın olan kitleler (Şekil 3.2 (c) ve (d)). Memenin sıkıştırılma işlemi her ne kadar düzgün bir şekilde yapılsa bile bu tip bir kitlenin bir kısmı X-Ray plakasının dışında kalabilmektedir. Dolayısıyla bu tip kitlelerin yalnızca bir kısmı görüldüğünden dolayı kitlelere ait standart morfolojik özellikler görülmemektedir.
- Aşırı yoğun memede yer alan kitleler (Şekil 3.2 (e) ve (f)). Bu durumda yer alan kitlelerin diğer yoğun doku tipleri ile süperpozisyon miktarı da yüksek olduğundan dolayı tespit edilmesi zorlaşmaktadır.

EEKTS yöntemi, DDSM veri tabanında yer alan 1484 kitlenin hem MLO ve CC görünümüne uygulanmıştır. Sonuç olarak bir görünümde tespit edilemeyen kitlenin diğer görünümde tespit edilebildiği görülmüştür. Ancak, Tablo 3.4 'de görüntü isimleri kırmızı renk ile gösterilen yalnızca **5 adet** kitle hiçbir görünümde tespit edilememiştir.

Bazı kitlelerin konumları memenin vücut tarafında bitişik olan kısmına denk gelmesinden dolayı mamografi görüntüsünde bir kısmı gözükmemektedir. Bu nedenle bu tip kitleler standart morfolojik özelliklerini de kaybetmektedir. Bu tez çalışması kapsamında yapılan deneylerde; bozulan bölgenin yansımalarının ilgili görüntüye eklenmesi ile bu tip kitlelere ait morfolojik özelliklerin geri kazandırılabilceği görülmüştür. Bu kitleler için bu şekilde eklenmiş yansıma görüntüleri ile EEKTS yöntemi ile belirlenen kitlelerin bölütleme sonuçları Şekil 3.3 'de gösterilmiştir. Bu kitlelerin belirlemek için yapılan bu işlemin geliştirilen BDT sistemine performans katkısını bulmak için daha fazla deney yapılması gerekmektedir. Bu tez çalışması kapsamında bu amaç için herhangi bir çalışma yapılmamıştır.



Şekil 3.2. EEKTS yöntemi ile tespit edilemeyen belirginliği çok düşük kitleler



Şekil 3.3. Kısmi yansıma görüntüsü eklenen mamografi görüntüleri

Tablo 3.4. Belirginliği çok düşük kitlelerin yer aldığı mamografi görüntüleri


00037_RIGHT_CC	00094_RIGHT_MLO	00720_RIGHT_MLO	01262_RIGHT_CC
00056_LEFT_MLO	00106_LEFT_CC	00730_RIGHT_CC	01274_RIGHT_MLO
00066_LEFT_CC	00107_RIGHT_MLO	00734_RIGHT_MLO	01297_LEFT_MLO
00159_RIGHT_MLO	00187_LEFT_MLO	00737_LEFT_CC	01301_RIGHT_CC
00173_LEFT_CC	00215_RIGHT_CC	00747_LEFT_CC	01301_RIGHT_MLO
00238_RIGHT_CC	00224_LEFT_MLO	00801_LEFT_MLO	01327_LEFT_MLO
00343_LEFT_CC	00239_RIGHT_CC	00815_LEFT_MLO	01431_LEFT_MLO
00343_RIGHT_CC	00289_LEFT_CC	00829_LEFT_MLO	01439_LEFT_MLO
00343_RIGHT_MLO	00342_RIGHT_MLO	00869_LEFT_CC	01453_LEFT_MLO
00677_RIGHT_MLO	00361_RIGHT_MLO	00881_LEFT_CC	01493_RIGHT_CC
00837_RIGHT_CC	00370_RIGHT_CC	00988_LEFT_MLO	01514_LEFT_CC
00893_LEFT_CC	00411_RIGHT_CC	00997_LEFT_CC	01532_LEFT_CC
00924_RIGHT_CC	00411_RIGHT_MLO	01018_RIGHT_MLO	01557_RIGHT_CC
01090_LEFT_MLO	00426_RIGHT_CC	01039_RIGHT_CC	01557_RIGHT_MLO
01090_RIGHT_MLO	00439_RIGHT_MLO	01047_LEFT_CC	01583_RIGHT_MLO
01183_LEFT_MLO	00468_LEFT_CC	01047_LEFT_MLO	01608_RIGHT_CC
01187_LEFT_MLO	00468_LEFT_MLO	01124_RIGHT_CC	01638_RIGHT_CC
01254_RIGHT_MLO	00506_LEFT_MLO	01146_LEFT_CC	01650_LEFT_MLO
01257_RIGHT_CC	00526_RIGHT_CC	01150_LEFT_MLO	01656_LEFT_MLO
01316_RIGHT_MLO	00526_RIGHT_MLO	01155_RIGHT_CC	01680_LEFT_MLO
01614_LEFT_MLO	00528_LEFT_MLO	01173_RIGHT_CC	01682_LEFT_CC
01645_RIGHT_CC	00573_RIGHT_MLO	01175_RIGHT_MLO	01710_LEFT_MLO
01765_RIGHT_CC	00596_RIGHT_CC	01178_RIGHT_CC	01735_RIGHT_CC
01795_LEFT_MLO	00597_RIGHT_MLO	01203_RIGHT_MLO	01737_RIGHT_MLO
00021_RIGHT_MLO	00607_RIGHT_MLO	01207_RIGHT_MLO	01745_RIGHT_MLO
00044_RIGHT_CC	00617_RIGHT_MLO	01221_LEFT_CC	01801_RIGHT_CC
00076_LEFT_CC	00626_LEFT_MLO	01231_LEFT_CC	01804_LEFT_MLO
00092_RIGHT_MLO	00634_LEFT_CC	01233_LEFT_CC	01876_LEFT_CC
00094_RIGHT_CC	00708_RIGHT_CC		

3.2. Kitlelerin Belirlenmesi İçin Yapılan Deneylelerin Değerlendirmesi


Bu aşamada yapılan deneysel çalışmalarda, Tablo 3.2 'de gösterilen en yüksek DUY değeri için tespit edilen ilgi bölgeleri üzerinden alınan öznelilikler kullanılarak sınıflandırma işlemi yapılmaktadır. Yapılan sınıflandırma işlemlerinde elde edilen verinin

%25'i eğitim ve % 75'i test için kullanılmıştır. Bu deneysel çalışmaların performans sonuçları, ROC grafikleri üzerinden değerlendirilmektedir.

Bu aşamada yapılan ilk deneyde hem doku öznelikleri (22x4 adet) hem de istatistiksel öznelikleri (11 adet) kullanılmıştır. Bu deney ile farklı sınıflandırıcı yöntemlerinin ikili sınıflandırma performansındaki başarısının incelenmesi yapılarak Şekil 3.4'de ROC eğrileri ile gösterilmiştir. En iyi AuC değerinin RusBoosted metodu ile edilirken en yüksek DOG değerinin de DVM metodundan elde edildiği gözlemlenmiştir.




Şekil 3.4. Tüm öznelikleri için farklı sınıflandırıcıları metodlarının ROC Eğrileri



Şekil 3.5. Farklı boyuttaki çerçeveler ve EEKTS ile belirlenen bölütlenmiş bölge üzerinden alınan doku öznelikleri için ROC Eğrileri

Bu aşamada yapılan ikinci deneyde EEKTS ile bölütlenen kitleler üzerinden ve bu kitleleri çevreleyen maskeler üzerinden alınan doku özneliklerinin sınıflandırıcı performansına etkisi incelenmiştir. Bu maskeler; 10x10, 20x20 ve 30x30 piksel kare olacak şekilde belirlenmiştir. Bu maskeler ve bölütlenmiş bölge üzerinden alınan doku öznelikleri kullanılarak RusBoosted metodu ile sınıflandırma işlemi gerçekleştirilmiştir. Bu sınıflandırma işleminden elde edilen ROC eğrileri, Şekil 3.5'de gösterilmektedir. Bu şekilden de görüleceği üzere, kitle üzerinden alınan doku örneğinin büyümesiyle birlikte sınıflandırıcı başarısı artmaktadır. Ancak çerçeve boyutunun kitle dışına çıkması ile birlikte, yani daha büyük maskelerin kullanılması durumunda tekrar sınıflandırıcı başarısı

düştüğü yapılan deneysel çalışmalarda görülmüştür. Bu deneylerde en iyi performans sonucu, EEKTS yöntemi ile bölütlenen bölgeler üzerinden alınan doku öz niteliklerinden elde edilmiştir. Sonuç olarak bu tez çalışması kapsamında yapılan bölütleme işleminin sınıflandırıcı performansına olan katkısı büyük olmaktadır.



Şekil 3.6. İstatiksel öz niteliklerin gruplandırılması ile oluşturulan ROC Eğrileri

Bu aşamada yapılan son deneyde istatiksel öz niteliklerin sınıflandırıcı performansına olan etkisi incelenmiştir. Bu deney için öz nitelikler; morfolojik, parlaklık ve yuvalama tabanlı olarak 3 gruba ayrılmıştır. Daha sonra her bir grup için ayrı ayrı ve tüm öz niteliklerin kullanılması ile ROC eğrileri oluşturularak Şekil 3.6 'da gösterilmiştir. Bu

ROC eğrilerinden de görüleceği üzere, en düşük performans morfolojik tabanlı özneteliklerden elde edilmektedir. En yüksek performansın kitleye ait yuvalama miktarını gösteren özneteliğe ait olduğu görülmüştür. Bir kitlenin hayat süresi ile ilişkili olarak derinlik miktarına bağlı olarak ortaya çıkaran yuvalama özneteliği kitlenin belirginliğini gösteren en önemli faktördür.

Bu tez çalışması kapsamında geliştirilen EEKTS yöntemi ile literatürdeki bu alandaki öncü BDT çalışmalarının performans sonuçları Tablo 3.5 'de gösterilmektedir. Bu tabloda gösterilen çalışmaları aynı şartlar altında performansını değerlendirebilmek için kullanılan veri tabanlarına ait sonuçlar alt alta gösterilmiştir. Ancak bazı çalışmalar DDSM gibi büyük veri tabanındaki kitle içeren tüm görüntüler yerine belli sayıda görüntüleri seçerek kullanmışlardır. Hong vd. [114] yalnızca DDSM veri tabanındaki 400 adet görüntüyü seçmişlerdir. Eltonsy vd. [117] ise 540 adet görüntüyü seçerek kendi içinde görüntüleri zorluk derecesine kategorize edip her bir kategori için performans değerlerini ayrı ayrı sunmuşlardır. Bu tez çalışmasında geliştirilen yöntem ise CBIS-DDSM veri setinde kesin referans sonuçlarının yer aldığı 1484 adet kitle görüntüsü üzerinde test edilmiştir.

MIAS veri tabanı, DDSM veri tabanına göre oldukça küçük olup yalnızca 56 adet kitle içeren görüntü bulunmaktadır. Sonuç olarak bu veri tabanını kullanan tüm çalışmalar aynı şartlar altında 56 adet görüntü üzerinde performans değerlendirmesi yapmaktadır. EEKTS yöntemi ile bu veri tabanındaki tüm kitleler $YP_m=4.64$ oranı ile tespit edilebilmiştir.

INbreast veri tabanı, DDSM ve MIAS veri tabanlarına göre daha yeni olduğu için dijital mamografi cihazından elde edildiğinden dolayı görüntülerin kalitesi daha yüksektir. Ayrıca bu veri tabanı üzerindeki görüntüler için 107 adet görüntü için kesin referans sonuçlarına erişilebilmektedir. Sonuç olarak bu veri tabanını kullanan tüm çalışmalar aynı şartlar altında tüm kitleler üzerinde performans değerlendirmesi yapmaktadır. EEKTS yöntemi, Agrawal vd. [135] çalışmasından sonra en yüksek duyarlık değerine sahiptir. Bu iki çalışmanın duyarlık performans değeri birbirine göre çok yakın olmasına rağmen EEKTS yönteminin YP_m değeri, yaklaşık iki katı olarak oldukça yüksektir.

Tablo 3.5. Kitle belirleme işlemi yapan BDT sistemlerinin performans sonuçları

Kitle Belirleme işlemi yapan BDT çalışmaları	Yöntem Adı	Veritabanı	DUY %	YP_m
Önerilen Yöntem	OHS içerisinde EEKTS ile bölütleme ve sınıflandırma	DDSM	91.3	9.82
Hong vd. [114]	Topoğrafi Haritası /Yuvalama Derinliği	DDSM	100	3.1
Eltonsy vd. [117]	Eş merkezli Katmanlar/Geometrik	DDSM	92 61.6	5.4 5.1
Gao vd. [118]	Eş merkezli Katmanlar/MCA+CMM	DDSM	91.3	10.4
Liu vd. [119]	Eş merkezli Katmanlar/ Dar Tabanlı Aktif Kontur	DDSM	82.4	5.3
Casti vd. [124]	Gabor Filtre Faz Tepkisi Analizi	DDSM	82	11.9
Tai vd. [127]	Kompleks Doku Özellikleri	DDSM	90	4.8
Shen vd. [132]	Deep Active Learning /Self-Paced Learning	DDSM	90	2
Önerilen Yöntem	OHS içerisinde EEKTS ile bölütleme ve sınıflandırma	MIAS	100	4.64
Mudigonda vd. [116]	Topoğrafi Haritası/Hiyeraşik Gruplama	MIAS	81	2.2
Dominguez vd. [121]	Çoklu Eşikleme/ Bölge Sıralama Sistemi	MIAS	80	2.3
Hu vd. [130]	Adaptif Eşikleme/ Çoklu çözünürlük	MIAS	91.7	0.71
Önerilen Yöntem	OHS içerisinde EEKTS ile bölütleme ve sınıflandırma	INbreast	97	2.86
Jung vd. [133]	RetinaNet + Feature Pyramid Network	INbreast	94	1.5
Shen vd. [134]	Adversarial Learning+FCN	INbreast	87	0.5
Agarwal vd. [135]	Faster R-CNN	INbreast	98	1.67
Ribli vd. [136]	Faster R-CNN+Deep-CNN-s	INbreast	90	0.3

3.3. EEKTS Yöntemi ile Pektoral Kas Bölütlenmesi İçin Yapılan Deneyler

EEKTS yönteminin pektoral kas bölütlenmesi üzerine yapılan deneysel çalışmaların performans sonuçları bu kısımda sunulmaktadır. Pektoral kas bölgesine ait radyologlarca hazırlanmış kesin referans veri seti, INBREAST veri tabanı için olmasına rağmen DDSM ve MIAS veri tabanı için yer almamaktadır.


Ferrari vd. [85], geliřtirdikleri yöntemin performansını test etmek için MIAS veri tabanından 84 adet görüntünün yer aldığı veri seti oluşturmuşlardır. Bu veri setinde iki adet uzman radyoloğun hazırlamış olduđu kesin referans sonuçları yer almaktadır. Ayrıca bu Ferrari vd. [85] bu veri setindeki her bir görüntü için ayrı ayrı niteliksel ve niceliksel performans sonuçlarını isteyen arařtırmacılara sunmaktadırlar. Bu sebeplerden dolayı, pek çok arařtırmacı [86-94] pektoral kas bölütlemesi için geliřtirdikleri yöntemleri bu veri seti üzerinde test etmiştir. Sonuç olarak aynı veri setini kullanan bu arařtırmacılar çalışmalarının performanslarını aynı şartlar altında mukayese edebilmiştir. Bu tez çalışmasında pektoral kas bölgesinin bölütleme işleminin performansını ölçmek için yapılan deneylerde bahsi geçen bu sebeplerden dolayı MIAS ve INbreast veri tabanlarından 84 ve 201 adet görüntü içeren iki veri seti özellikle kullanılmıştır.

Bu aşamada yapılacak deneyler iki kısma ayrılmıştır. Öncelikle bozulmuş pektoral kas bölgelerinin bölütlenmesi için önerilen görüntüyü bloklara ayırma işleminin etkileri düz çizgi benzerliđi açısından incelenmiştir. İkinci kısımda, seçilen en uygun blok sayısı için EEKTS yönteminin performans deneyleri hem MIAS-INBREAST veri tabanları hem de bozulmuş pektoral kas görüntülerini içeren veri seti için yapılmıştır.

3.3.1. Blok Sayısının EEKTS Yöntemine olan Etkisinin İncelenmesi

Bu tez çalışması kapsamında geliştirilen pektoral kas bölütlemesi yönteminin özellikle bozulmuş pektoral kas bölgelerinde de yüksek performans göstermesi amaçlanmıştır. Bu amaç için görüntü bloklara ayrılarak bozuk pektoral kas parçaları, sağlam kısımlardan izole edilmiştir. Ayrıca bu bölünme sayesinde, bloklar içerisinde kalan sağlam pektoral kas sınırlarına ait konturların düz çizgi benzerliđi de artırılmıştır.

Bu aşamada; pektoral kas sınır parçaları için düz çizgi benzerliđinin, blok sayısı ile olan ilişkisini incelemek için yapılan deneylerin sonuçları sunularak irdelenmiştir. Bu amaçla 1, 2, 4, 8, 16 ve 32 blok sayısı için düz çizgi benzerliđi deneyleri yapılmıştır. Bu işlemlerin performans sonuçları analiz edilerek en uygun blok sayısının belirlenmesi amaçlanmaktadır.



Şekil 3.7. Örnek mamografi görüntüleri için tek bir düz çizgi ile pektoral kas bölütlenmesindeki hata oranları. DP, YP ve YN bölgeler sırasıyla kırmızı, mavi ve yeşil renkleri ile gösterilmektedir

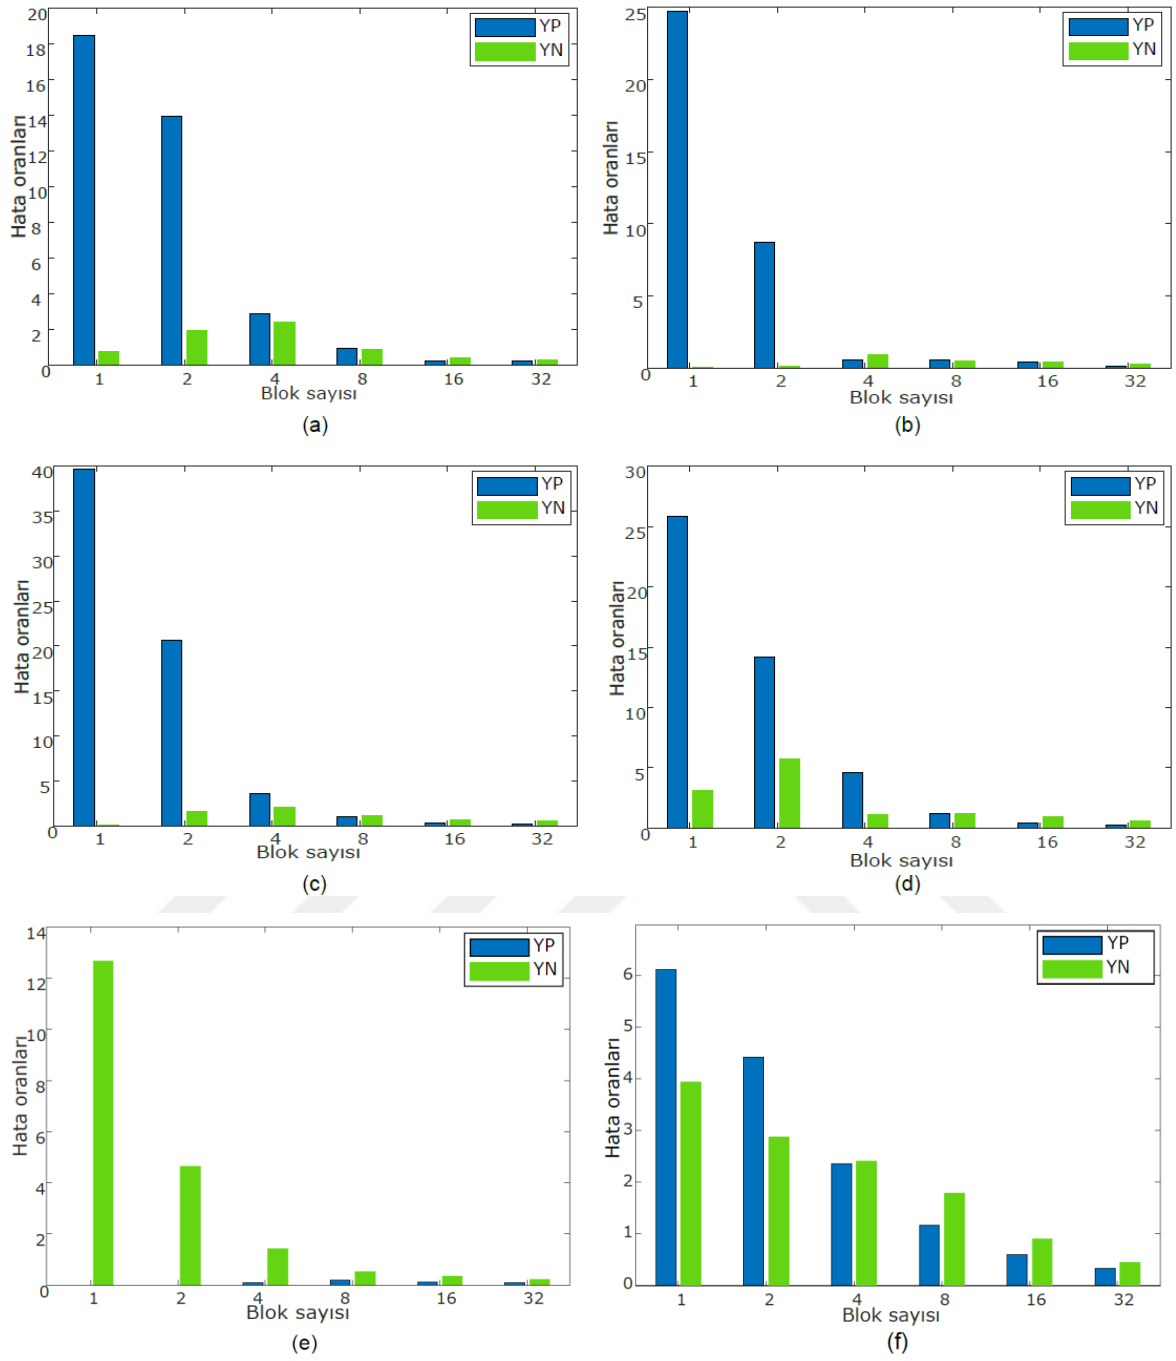
Bu aşamadaki deneyler için, MIAS veri setinden özellikle konkav ve konveks pektoral kas sınırına sahip olan 5 adet görüntü seçilmiştir. İlk deneyde, bu kavisli sınırlar, bölütleme işlemi için tek bir düz çizgi ile (Blok sayısı=1) temsil edilerek DP, YP ve YN bölgeleri niteliksel olarak kırmızı, mavi ve yeşil renklerle Şekil 3.7 'de sırasıyla gösterilmiştir. Bu şekilden de görüleceği üzere, bloklara ayırma işlemi yapılmazsa, düz çizginin temsil ettiği eğri sınırlar için bölütleme hatası çok yüksek çıkmaktadır.

İkinci deneyde ise birinci deneyde kullanılan 5 adet görüntü için 1, 2, 4, 8, 16 ve 32 adet bloğa ayırma işlemi yapılmıştır. Bloklar içinde kalan pektoral sınır parçaları, bölütleme işlemi için düz bir çizgi ile temsil edilmiştir. Daha sonra her bir görüntü için tüm blok sayıları için YP ve YN değerleri hesaplanarak mavi ve yeşil bar çubuklarla sırasıyla Şekil 3.8 (a-e) 'de gösterilmiştir. Bu grafiklerden de görülebileceği gibi, 1 blok için görüntülerin toplam hata oranları çok yüksek olmasına rağmen, blok sayısı arttıkça toplam hata oranları, bu sınırlar eğri şeklinde olsa bile hızlı bir şekilde azalmaktadır. Ayrıca 16 ve üstü blok sayısı için YP veya YN değerleri %1'in altına düşmektedir.

Üçüncü deneyde, MIAS ve INbreast veri tabanındaki 84 ve 201 adet görüntü kullanılmıştır. Değişen blok sayıları için YP_m ve YN_m ortalama hata değerleri hesaplanarak sırasıyla Şekil 3.8 (f)'de gösterilmiştir. Bu deneyin sonuçları, blok sayısı artması ile düz çizgi benzerliğinin arttığını ve bölütleme hata oranlarının 16 veya daha fazla blok sayısı için % 1'in altına düştüğünü göstermektedir. Yapılan deneysel çalışmalarda blok sayısının 16'dan fazla olması durumunda, bu işlemin performansa olan katkısını çok artırmadığı ve

aksine işlem yükünü artıracığı görülmüştür. Bu işlem yükü için yapılan test çalışmalarında; Intel Core i5 4460 3.2GHz 12GB RAM donanımına sahip bilgisayarda MATLAB 2018 yazılımı üzerinde yaklaşık bir blok sayısı için ortalama 1 saniye civarında sürdüğü görülmüştür. Sonuç olarak; bu tez çalışması kapsamında geliştirilen pektoral kas bölütleyen yöntem için blok sayısı 16 olarak belirlenmiştir.

Bir pektoral kas her zaman bir mamografi görüntüsünün göğüs duvarına yakın olan dikey kenarıyla kesişir. Sonuç olarak pektoral kasın dik yüksekliği bu kesişim noktası ile başlangıç noktası arasındaki mesafedir. Geliştirilen yöntemde, başlangıçta pektoral kas yüksekliği tahmin edilemediğinden, bölünme işlemi tüm görüntü boyunca dikey yönde gerçekleştirilir. Bu nedenle, pektoral kas yüksekliği ile görüntü yüksekliği arasındaki oran pektoral kas bloklarının sayısını etkiler. Bu amaçla, son deneyde, iki veri setindeki her bir görüntü için pektoral kas yüksekliğinin görüntü yüksekliğine göre dağılım analizi yapılmıştır. Bu dağılıma göre pektoral kas boyutu kişiden kişiye değişmekle birlikte pektoral kas yüksekliği tüm görüntülerin çoğu için görüntü yüksekliğinin yaklaşık yarısına karşılık gelir. Bu dağılım çan şeklinde bir eğri olduğu için Gauss dağılımının bir örneğidir. Özetle; pektoral kas bölgeleri çoğu orta büyüklükte iken, nadiren çok büyük ve çok küçük boyutlu pektoral kas örnekleri bulunmaktadır. Bu deneylerin sonucunda; 16 bloklu bölme işlemi yapılması durumunda, çoğu görüntü için pektoral kas bölgesinin yaklaşık 8 blokta yer aldığı ayrıca sağlam ve bozuk kısımların birbirinden ayrılması için bu blok sayısının yeterli olduğu görülmüştür.



Şekil 3.8. Blok sayısının pektoral kas bölütlenmesine etkisi. Bölütleme hata oranları sırasıyla (YP ve YN) mavi ve yeşil renkleri ile gösterilmektedir. (a) mdb 44, (b) mdb 75, (c) mdb 111, (d) mdb 112, (e) mdb 115, (f) Veri setindeki tüm görüntüler

3.3.2. Niceliksel Sonuçlar ve Değerlendirmesi


Bu tez çalışması kapsamında pektoral kas bölütlemesi için geliştirilen EEKTS yöntemi; Ferrari vd. [85] tarafından MIAS veri tabanından seçilen 84 adet görüntü için test

edilerek performans sonucu Tablo 3.6 'da gösterilmiştir. Aynı veri setini kullanan literatürde yer alan bu alandaki bazı öncü çalışmaların sonuçları da aynı tabloda sunulmaktadır. Bu performans sonuçlarına bakıldığında EEKTS yöntemi % 2.34 en düşük YN_m değeri ile en iyi performansı göstermektedir. Ayrıca % 0.92 YP_m değeri ile de en düşük % 0.58 YP_m değeri ile mukayese edilebilir olup üçüncü en iyi değere sahiptir.

Tablo 3.6. MIAS veri tabanından seçilen 84 görüntü için EEKTS ve bu alandaki bazı BDT çalışmalarının performans sonuçları

Performans Ölçütleri	Hough Yöntemi [85]	Gabor Yöntemi [85]	APs Yöntemi [86]	MST Yöntemi [86]	Watershed Yöntemi [87]	Li vd. [88]	Chen vd. [89]	EEKTS Yöntemi
YP_m	1.98	0.58	3.71	2.55	0.85	1.45	1.02	0.92
YN_m	25.19	5.77	5.95	11.68	4.88	5.52	5.63	2.34
$YP < 5$ & $YN < 5$	10	45	50	40	46	48	49	62
$\min(YP, YN) < 5$ & $5 < \max(YP, YN) < 10$	0	0	18	20	25	28	30	19
$\min(YP, YN) < 5$ & $\max(YP, YN) > 10$	0	0	11	18	13	7	4	3
$5 < YP < 10$ & $5 < YN < 10$	8	22	0	1	0	1	1	0
$5 < \min(YP, YN) < 10$ & $\max(YP, YN) > 10$	0	0	0	0	0	0	0	0
$YP > 10$ & $YN > 10$	66	17	5	3	0	0	0	0

Tablo 3.6 üzerinde ayrıca YP ve YN 'e ait bazı kritik eşik değerleri için 6 adet hata aralığı gösterilmektedir. Bu deney için kullanılan veri setindeki her bir görüntü için değerlendirme yapılarak, bu hata aralıklarına denk gelen görüntülerin sayıları Tablo 3.6'da verilmektedir. Bu sonuçların bar grafiği biçimindeki gösterimi Şekil 3.9 'da gösterilmektedir. Bu grafikten görüleceği üzere; EEKTS yöntemi, mukayese edilen diğer yöntemlere göre en iyi performansa sahiptir.



Şekil 3.9. Bölütleme Hata oranları için görüntülerin istatistiksel dağılımları

INbreast veri tabanı için EEKTS yöntemi ve bu alandaki öncü çalışmaların bölütleme sonuçları Tablo 3.7’de gösterilmektedir. Bu performans sonuçlarına bakıldığında EEKTS yöntemi % 1.15 en düşük YN_m değeri ile en iyi performansı göstermektedir. Fakat EEKTS yöntemi % 1.26 YP_m değeri ile en düşük değere sahip olan Rampun vd. [102] ‘na ait % 0.3 YP_m değeri karşısında ikinci en iyi performansı göstermektedir.

Tablo 3.7. INbreast veri tabanı için EEKTS yöntemi ve bu alandaki bazı BDT çalışmalarının performans sonuçları

Performans Ölçütleri	Shen vd. [100]	Shi vd. [101]	Rampun vd. [102]	EEKTS Yöntemi
YP_m	1,35	2,42	0,3	1,26
YN_m	1,27	13,61	5,7	1,15

Tablo 3.8. Hough, Gabor ve EEKTS yöntemlerinin örnek bozuk pektoral kas görüntülerinin her biri için ayrı ayrı performans sonuçları

		mdb 33	mdb 34	mdb 36	mdb 39	mdb 40	mdb 68	mdb 75	mdb 98	mdb 109	mdb 110	mdb 115	mdb 123
Hough Metodu	YP	16.04	0	0	15.19	0	0	0	100	100	0	0	0
	YN	40.96	74.48	23.65	47.92	92.70	26.75	26.69	23.44	3.48	48.65	28.62	87.98
Gabor Metodu	YP	0.13	9.67	0.41	0.74	0	0	0	100	23.10	0	3.27	0.37
	YN	24.73	11.95	11.65	13.77	13.76	19.69	19.87	0	42.38	10.06	4.68	8.24
EEKTS Metodu	YP	4.24	1.65	2.86	1.97	0.27	0.04	1.14	0.40	4.54	1.2	3.65	2.2
	YN	2.07	4.25	6.70	1.52	1.37	4.25	4.84	3.82	8.57	0.92	0.83	2.19

Tablo 3.9. Hough, Gabor ve EEKTS metotlarının örnek bozuk pektoral kas görüntüleri için performans sonuçları


Performans Ölçütleri	Hough Metodu	Gabor Metodu	EEKTS Metodu
YP_m	19,26	11,47	2,01
YN_m	43,77	15,06	3,44
YP<5 & YN<5	0	1	10
min(YP,YN)<5 & 5<max(YP,YN)<10	0	1	2
min(YP,YN)<5 & max(YP,YN)>10	0	7	0
5<YP<10 & 5<YN<10	0	0	0
5<min(YP,YN)<10 & max(YP,YN)>10	9	1	0
YP>10 & YN>10	3	1	0

EEKTS, Hough ve Gabor yöntemlerinin; Şekil 1.14 'de gösterilen bozulmuş pektoral kas bölgeleri üzerindeki niceliksel performans sonuçları her bir görüntü için ayrı ayrı Tablo 3.8 'de gösterilmektedir. Bu sonuçlar için elde edilen YP_m ve YN_m değerleri ile hata aralıklarına düşen görüntü sayıları Tablo 3.9 'da gösterilmektedir. Bu karşılaştırma sonuçlarına göre EEKTS yöntemi, Hough ve Gabor yöntemlerine göre oldukça yüksek performans göstermektedir.

3.3.3. Niteliksel Sonuçlar ve Değerlendirmesi


Şekil 1.14 'de gösterilen bozulmuş pektoral kas örnekleri için kesin referans maskeleri, EEKTS , Hough ve Gagor yöntemlerinin bölütleme sonuçları sırasıyla kırmızı,

sarı, mavi ve yeşil renkler ile Şekil 3.10 'da gösterilmektedir. Bu şekil üzerinden görüleceği üzere EEKTS yöntemi bozulmuş pektoral kas örnekleri için neredeyse uzman radyologlar ile aynı bölütleme sonuçlarını vermektedir.



Şekil 3.10. (a-l) MIAS ve (m-p) INbreast veri tabanından alınmış bozulmuş pektoral kas örnekleri için EEKTS , Hough ve Gabor yöntemleri ile radyologlara ait bölütleme sonuçları sırasıyla sarı, mavi, yeşil ve kırmızı renkleri ile gösterilmektedir


Şekil 3.10'un devamı



3.4. Pektoral Kas Bölgesi ile Süperpozisyon Olan Kitlelerinin İncelenmesi

MLO mamografi görüntülerinde yer alan pektoral kas bölgesi, doku ve yoğunluk özellikleri açısından kitleler ile aynı karakteristikleri göstermektedir. Bu nedenle bu bölgenin varlığı kitle belirleyen BDT sistemlerinin YP sayısını arttırmaktadır. Fakat süperpozisyon durumuna bağlı olarak kitlelerin konumu pektoral kas bölgesi sınırına hatta bu bölgenin içerisinde bile olabilmektedir. Sonuç olarak pektoral kas bölgesi çıkarılması işlemi ile YP düşürme bakımından performans artışı sağlanırken, YN artışı ile tersi bir

durum da oluşabilmektedir. Şekil 3.11 (a) ve (b) 'de mamografi görüntülerinde kitle ve benzeri nesnelere ve maskeleri sırasıyla kırmızı ve mavi ok ve çerçeveler ile gösterilmektedir.




Şekil 3.11. MIAS veri tabanında yer alan pektoral kas ile süperpozisyon olmuş (a) kitle , (b) YP nesnelere ve maskeleri

Bu tez çalışması kapsamında MIAS, InBreast ve DDSM veri tabanlarındaki MLO mamografi görüntülerindeki pektoral kas ve kitle pozisyonları arasındaki ilişki detaylıca incelenmiştir.

MIAS veri tabanında yalnızca 56 adet kitle içeren görüntü bulunmaktadır ve bunlardan yalnızca Şekil 3.11 (a) da gösterilen pektoral kas sınırına yakın bir kitle görülmüştür.


InBreast veri tabanında ise 116 kitle içeren görüntüden yalnızca 5 adet görüntüde pektoral kas ve kitle arasında süperpozisyon bulunmaktadır. Süperpozisyon durumuna bağlı olarak pektoral kas bölgesi ile tümüyle örtüşen kitleden başlayarak ve örtüşme miktarının azalan sırasıyla gösterilen kitleler Şekil 3.12 (a-e) 'de gösterilmektedir.




Şekil 3.12. INbreast veri tabanında yer alan pektoral kas ile süperpozisyon olmuş kitle örnekleri içeren MLO mamografi görüntüleri

DDSM veri tabanında ise 1484 kitle içeren görüntüden 48 adet görüntüde pektoral kas ve kitle arasında süperpozisyon bulunmaktadır. Bu kitleler pektoral kas sınırına yakın olanlar ve tümüyle içinde olanlar olmak üzere ikiye ayrılarak Şekil 3.13 ve Şekil 3.14 'de gösterilmektedir. Literatürde yer alan pektoral kas bölütleme ve çıkarma işlemleri yapan BDT yazılımları tümüyle pektoral kas içerisinde bulunan kitleleri dikkate almamışlardır. Sonuç olarak bu yazılımlar, pektoral kas çıkarılması durumunda bu tip kitleler için YN oluşturmaktadır.

Bu tez çalışması kapsamında kitle belirleme aşamasında pektoral kas bölgesi üzerinde oluşan YP sayısının DDSM, MIAS ve InBreast veri tabanları için sırasıyla $YP_m = 2.95$, $YP_m = 2.14$ ve $YP_m = 1.73$ olarak hesaplanmıştır. Sonuç olarak; pektoral kas bölgesinin çıkarılması ile bu YP_m değerleri kadar düşüş elde ederek geliştirilen BDT sisteminde performans artışı sağlanmıştır. Bu performans elde edilirken MIAS veri tabanında hiçbir YN oluşmamıştır. Ancak INBreast veri tabanında tümüyle süperpozisyon olan 1 adet kitle için YN oluşmuştur. Ayrıca DDSM veri tabanında ise pektoral kas bölgesi ile tümüyle örtüşen 24 adet kitle için YN oluşmaktadır.



Şekil 3.13. DDSM veri tabanında yer alan pektoral kas ile kısmen süperpozisyon olmuş kitle örnekleri içeren MLO mamografi görüntüleri



Şekil 3.14. DDSM veri tabanında yer alan pektoral kas ile tümüyle süperpozisyon olmuş kitle örnekleri içeren MLO mamografi görüntüleri

4. SONUÇLAR

Bu tez çalışmasında mamografi görüntülerindeki kitlelerin ve pektoral kas bölgesinin süperpozisyon etkisini dikkate alarak belirleme işlemi yapan yöntemler geliştirilmiştir. Önerilen yöntemler; MIAS, DDSM ve INbreast veri tabanlarında yer alan mamografi görüntüleri üzerinde test edilmiştir. Bu test sonuçları görüntülerdeki süperpozisyon durumuna göre kategorize edilerek ayrıntılı bir şekilde niceliksel ve niteliksel olarak gösterilmiştir.

Bu tez çalışmasında elde edilen sonuçlar 3 kısımda sunulmaktadır. Birinci ve ikinci kısımda süperpozisyon etkisi altındaki kitleler ve bozulmuş pektoral kas bölgeleri hakkında sonuçlar sırasıyla sunulacaktır. Son kısımda ise pektoral kas bölgesinin çıkarılmasının kitle belirleme performansına olan etkisi hakkındaki sonuçlar sunulmaktadır.

EEKTS yönteminin süperpozisyon etkisinde kalan kitleler üzerindeki sonuçları:

- Pektoral kas, süt kanalı, damarlar, glandular dokular tarafından süperpozisyona uğramış çoğu kitle 4 farklı yönden Gabor filtre çıktılarına uygulanan EEKTS yöntemi ile belirlenebilmiştir.
- Mamografi görüntüsünde meme bölgesinin dış kadranına yakın kısımlarda yer alan ve özellikle küçük ebatlı kitlelerin belirginliği olmamaktadır. Ayrıca göğüs bölgesine yakın olan kısımda kitlerin bir kısmı da filmin dışında kaldığında dolayı morfolojik özellikleri baskınlığı kaybolmaktadır. EEKTS yöntemi bu tip kitlelerde başarısız olmaktadır.
- EEKTS yönteminin çıktılardan olan yuvalama derinliği yani iç içe geçen konturların sayısı kitle sınıflandırma aşamasında başarıya olan etkisi en yüksek öznelik olduğu görülmüştür.
- EEKTS yöntemi ile bölütlenen şüpheli bölgeler üzerinden alınan doku özneliklerinin sınıflandırma işleminin başarısına olan katkısı, şüpheli bölgeleri çevreleyen farklı ebatlardaki maskeler üzerinden alınan doku özneliklerine göre erden oldukça yüksek olmaktadır.

EEKTS yönteminin bozulmuş pektoral kas bölgesi örnekleri üzerindeki sonuçları:

- Sağlam bir pektoral kas sınırı, topoğrafik harita üzerinde tek bir sürekli kontur ile gösterilebilmesine rağmen bozulmuş pektoral kas sınırı bu durum geçerli değildir.
- Bozulmuş pektoral kas sınırlarının bazı kısımları bulanık veya görünmez olabilmektedir. Topoğrafik haritanın bloklara bölünmesi işlemi ile bozuk ve sağlam sınır parçaları birbirinden ayrılarak farklı bloklar halinde lokalize edilir.
- Ayrıca pektoral kas sınırı eğri bir çizgi olsa bile, bölünmenin etkisi ile bloklar içerisindeki pektoral kasa ait kontur parçaları düz çizgilere benzer hale gelir. Böylece, bu konturların konumu, geometrisi ve topoğrafik özellikleri daha verimli ve istikrarlı hale gelir. Sonuç olarak, sağlam pektoral kas sınır parçaları için karakteristik özelliklere sahip özgül desenli konturlar ortaya çıkar.
- EEKTS yöntemi her bir blok için ayrı ayrı sonuç ürettiğinden dolayı, bozulmuş kısımlar sağlam kısımları etkilememektedir. Bu yöntem özellikle bozulmuş pektoral kas sınırları içeren görüntüler için test edilmiştir.
- EEKTS yöntemi, bozulmuş pektoral kas bölgelerinde bile uzman radyologların performansına yakın başarı göstermektedir.

Pektoral Kas Bölgesinin çıkarılmasının Kitle Belirleme işlemine olan etkisi:

- MLO mamografi görüntülerinde pektoral kas ile kitle arasındaki süperpozisyon durumuna bağlı olarak kitlenin kısmen yâda tümüyle pektoral kas içerisinde olduğu vakalar bulunmaktadır. Pektoral kas bölgesi çıkarma işlemi yaptıktan sonra kitle belirleme işlemi yapan literatürdeki BDT sistemleri bu tip kitleleri hesaba katmamışlardır.
- EEKTS yöntemi ile çıkarılan pektoral kas bölgesi ile kitle belirleme işlemindeki YP sayılarını düşürerek performans artışı sağlamaktadır.
- Ancak; EEKTS yöntemi, genel olarak kısmi süperpozisyon olan kitleleri etkilememesine rağmen, tümüyle süperpozisyon olan kitleleri pektoral kas bölgesi ile birlikte çıkarmaktadır.

5. ÖNERİLER

Mamografi görüntüleri üzerindeki şüpheli bölgelerin süperpozisyon etkisini dikkate alarak belirlenmesi için geliştirilen EEKTS yönteminin başarısı akciğer röntgen görüntüleri üzerinde şüpheli bölgelerin belirlenmesi üzerine yapılan bir çalışma [139] ile test edilmiştir. Bu çalışmaya benzer şekilde, diğer tıbbi görüntüler için EEKTS yöntemi güncellenebilir.

Bozulmuş pektoral kas bölgelerini bölütlemek için önerilen yatay bloklara ayırma işlemi, sınırlarının bir kısmı belirgin olmayan büyük ebatlı kitleler için radyal yâda farklı biçimlerde bölme işlemi yaparak başarımlarını incelenebilir.

Bu tez çalışmasında; EEKTS yönteminin süperpozisyon etkisini dikkate alarak performans testini yapmak için özellikle bozulmuş kitle ve pektoral kas sınırı içeren görüntüler seçilmiştir. Bu tipteki görüntüleri kategorize edilerek oluşturulacak standart ve ortak bir veri seti, bu alanda çalışma yapacak olan araştırmacıların hizmetine sunulabilir. Böylece bu veri setleri üzerinde çalışma yapan araştırmacılar yöntemlerinin performansını aynı şartlar altında zor görüntüler için aynı kesin referans ile ölçme ve birbirleriyle kıyaslama imkânı bulabilirler.

MLO mamografi görüntülerindeki pektoral kas bölgesi çıkaran çalışmalar pektoral kas ile süperpozisyon olmuş kitleleri dikkate almamışlardır. Önerilecek yeni bir yöntem ile pektoral kas bölgesi çıkarılırken hem YP sayısı düşürülebilir hem de pektoral kas ile süperpozisyona uğramış kitleler tespit edilerek YN oluşması engellenebilir.

Bu tez kapsamında geliştirilen BDT sistemi diğer araştırmacılar tarafından test edilmesi ve geliştirilmesi açısından açık kaynak kodlu olarak sunulabilir. Ayrıca bu BDT sisteminin internet üzerinden çevrimiçi olarak radyologların kullanımına açarak, alınan tıbbi görüşler ile interaktif bir şekilde geliştirilmesi sağlanabilir.

Bu tez çalışmasında geliştirilen BDT sistemi kitleleri iyi/kötü (benign/malign) sınıflandırması yapmamaktadır. Güncel BDT sistemleri bu amaç için derin öğrenmeye dayalı YZ yöntemleri ile yüksek performans elde etmektedirler. Geliştirilen BDT sistemi bu bakımdan güncelleştirilmesi sonucunda, radyologlar için daha kullanışlı bir hale getirilebilir.

Son yıllarda mamografi görüntüleri için büyük veri tabanları, araştırmacıların hizmetine sunulmakta ve bazı yarışmalar ile motive edilmektedir. Güncel ticari BDT sistemleri bu amaç için yüksek performans gösteren derin öğrenmeye dayalı YZ yöntemleri kullanmaktadır. Bu tez kapsamında geliştirilen yöntemleri büyük veri tabanları üzerinde Derin Öğrenme algoritmalarının da eklenmesi ile performans testleri yapılabilir.

6. KAYNAKLAR

1. Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A. ve Bray, F., Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries, CA: A Cancer Journal for Clinicians, 71, 3 (2021) 209–249.
2. Who, Dünya Çapında meme kanseri gerçeği, 2021. <https://www.who.int/cancer/detection/breastcancer/en/> Accessed 10-May-2021.
3. Salim, M., Dembrower, K., Eklund, M., Lindholm, P. ve Strand, F., Range of radiologist performance in a population-based screening cohort of 1 million digital mammography examinations, Radiology, 297, 1 (2020) 33–39.
4. Elmore, J. G., Jackson, S. L., Abraham, L., Miglioretti, D. L., Carney, P. A., Geller, B. M., Yankaskas, B. C., Kerlikowske, K., Onega, T., Rosenberg, R. D., Sickles, E. A. ve Buist, D. S. M., Variability in interpretive performance at screening mammography and radiologists' characteristics associated with accuracy, Radiology, 253, 3 (2009) 641–651.
5. Kim, H.-E., Kim, H. H., Han, B.-K., Kim, K. H., Han, K., Nam, H., Lee, E. H. ve Kim, E.-K., Changes in cancer detection and false-positive recall in mammography using artificial intelligence: a retrospective, multireader study, The Lancet Digital Health, 2, 3 (2020) e138–e148.
6. Erkara, O. D. D., Meme anatomisi, 2021. <https://www.memebuyutme.info.tr/meme-anatomisi-ve-islevi/> Accessed 10-May-2021.
7. İşgör, P. D. A., Meme içerisindeki önemli dokular, 2021. <http://www.adnanisgor.com/meme5kansermetin.html> Accessed 10-May-2021.
8. Müdürlüğü, H. S. G., Meme kanseri tarama programı ulusal standartları, 2017. <https://hsgm.saglik.gov.tr/tr/kanser-tarama-standartlari/listesi/meme-kanseri-tarama-program%C4%B1-ulusal-standartlar%C4%B1.html> Accessed 10-May-2021.
9. University, H., Mamografi cihazı aparatları, 2021. <https://www.health.harvard.edu/womens-health/what-do-the-new-mammography-guidelines-mean-for-you> Accessed 10-May-2021.
10. Smittenaar, C. R., Petersen, K. A., Stewart, K. ve Moitt, N., Cancer incidence and mortality projections in the UK until 2035, British Journal of Cancer, 115, 9 (2016) 1147–1155.
11. Chan, S. W. W., Cheung, P. S. Y., Chan, S., Lau, S. S., Wong, T. T., Ma, M., Wong, A. ve Law, Y. C., Benefit of ultrasonography in the detection of clinically and mammographically occult breast cancer, World Journal of Surgery, 32, 12 (2007) 2593–2598.

12. Sechopoulos, I., Teuwen, J. ve Mann, R., Artificial intelligence for breast cancer detection in mammography and digital breast tomosynthesis: State of the art, Seminars in Cancer Biology, (2020).
13. Nam, K. J., Han, B.-K., Ko, E. S., Choi, J. S., Ko, E. Y., Jeong, D. W. ve Choo, K. S., Comparison of full-field digital mammography and digital breast tomosynthesis in ultrasonography-detected breast cancers, The Breast, 24, 5 (2015) 649–655.
14. Haas, B. M., Kalra, V., Geisel, J., Raghu, M., Durand, M. ve Philpotts, L. E., Comparison of tomosynthesis plus digital mammography and digital mammography alone for breast cancer screening, Radiology, 269, 3 (2013) 694–700.
15. Friedewald, S. M., Rafferty, E. A., Rose, S. L., Durand, M. A., Plecha, D. M., Greenberg, J. S., Hayes, M. K., Copit, D. S., Carlson, K. L., Cink, T. M., Barke, L. D., Greer, L. N., Miller, D. P. ve Conant, E. F., Breast cancer screening using tomosynthesis in combination with digital mammography, JAMA, 311, 24 (2014) 2499.
16. Nguyen, T., Levy, G., Poncelet, E., Thanh, T. L., Prolongeau, J., Phalippou, J., Massoni, F. ve Laurent, N., Overview of digital breast tomosynthesis: Clinical cases, benefits and disadvantages, Diagnostic and Interventional Imaging, 96, 9 (2015) 843–859.
17. Kuhl, C. K., Schrading, S., Leutner, C. C., Morakkabati-Spitz, N., Wardelmann, E., Fimmers, R., Kuhn, W. ve Schild, H. H., Mammography, breast ultrasound, and magnetic resonance imaging for surveillance of women at high familial risk for breast cancer, Journal of Clinical Oncology, 23, 33 (2005) 8469–8476.
18. Nishikawa, R. M., Giger, M. L., Doi, K., Metz, C. E., Yin, F.-F., Vyborny, C. J. ve Schmidt, R. A., Effect of case selection on the performance of computer-aided detection schemes, Medical Physics, 21, 2 (1994) 265–269.
19. Heath, M., Bowyer, K., Kopans, D., Kegelmeyer, P., Moore, R., Chang, K. ve Munishkumar, S., Current status of the digital database for screening mammography, Computational Imaging and Vision, Bildiriler Kitabı: 457–460, Springer Netherlands, 1998.
20. Lee, R. S., Gimenez, F., Hoogi, A., Miyake, K. K., Gorovoy, M. ve Rubin, D. L., A curated mammography data set for use in computer-aided detection and diagnosis research, Scientific Data, 4, 1 (2017).
21. Program, T. C. I., Kanserli radyoloji veritabanı, 2021. <https://www.cancerimagingarchive.net/> Accessed 10-May-2021.
22. Chan, T. ve Vese, L., Active contours without edges, IEEE Transactions on Image Processing, 10, 2 (2001) 266–277.
23. Hoogi, A., Beaulieu, C. F., Cunha, G. M., Heba, E., Sirlin, C. B., Napel, S. ve Rubin, D. L., Adaptive local window for level set segmentation of CT and MRI liver lesions, Medical Image Analysis, 37 (2017) 46–55.
24. Hoogi, A., Subramaniam, A., Veerapaneni, R. ve Rubin, D. L., Adaptive estimation of active contour parameters using convolutional neural networks and texture analysis, IEEE Transactions on Medical Imaging, 36, 3 (2017) 781–791.

25. Brzakovic, D. ve Neskovic, M., Mammogram screening using multiresolution based image segmentation, *Series in Machine Perception and Artificial Intelligence, Bildiriler Kitabı*: 103–127, WORLD SCIENTIFIC, 1994.
26. Moreira, I. C., Amaral, I., Domingues, I., Cardoso, A., Cardoso, M. J. ve Cardoso, J. S., INbreast, *Academic Radiology*, 19, 2 (2012) 236–248.
27. Cokelaer, T., Bansal, M., Bare, C., Bilal, E., Bot, B. M., Neto, E. C., Eduati, F., Gönen, M., Hill, S. M., Hoff, B., Karr, J. R., Küffner, R., Menden, M. P., Meyer, P., Norel, R., Pratap, A., Prill, R. J., Weirauch, M. T., Costello, J. C., Stolovitzky, G. ve Saez-Rodriguez, J., DREAMTools: a python package for scoring collaborative challenges, *F1000Research*, 4 (2015) 1030.
28. Challenges, D., The digital mammography dream challenge, 2014. <https://dreamchallenges.org/> Accessed 10-May-2021.
29. BIONETWORKS, S., Açık kaynak kod bdt sistemi, 2021. <https://www.synapse.org/#!/Synapse:syn4224222/wiki/401743> Accessed 10-May-2021.
30. Lindholm, P. ve Strand, F., Introducing the multi-million image dataset from the population-based cohort of screen-age women (csaw) as a platform for deep learning algorithm training and validation, 2018 Conference on machine intelligence in medical imaging, 9, , 2018.
31. Dembrower, K., Lindholm, P. ve Strand, F., A multi-million mammography image dataset and population-based screening cohort for the training and evaluation of deep neural networks—the cohort of screen-aged women (CSAW), *Journal of Digital Imaging*, 33, 2 (2019) 408–413.
32. Halling-Brown, M. D., Warren, L. M., Ward, D., Lewis, E., Mackenzie, A., Wallis, M. G., Wilkinson, L. S., Given-Wilson, R. M., McAvinchey, R. ve Young, K. C., OPTIMAM mammography image database: A large-scale resource of mammography images and clinical data, *Radiology: Artificial Intelligence*, 3, 1 (2021) e200103.
33. Freer, T. W. ve Ulissey, M. J., Screening mammography with computer-aided detection: Prospective study of 12,860 patients in a community breast center, *Radiology*, 220, 3 (2001) 781–786.
34. Ciatto, S., Turco, M. R. D., Risso, G., Catarzi, S., Bonardi, R., Viterbo, V., Gnutti, P., Guglielmoni, B., Pinelli, L., Pandiscia, A., Navarra, F., Lauria, A., Palmiero, R. ve Indovina, P.L., Comparison of standard reading and computer aided detection (CAD) on a national proficiency test of screening mammography, *European Journal of Radiology*, 45, 2 (2003) 135–138.
35. Helvie, M. A., Hadjiiski, L., Makariou, E., Chan, H.-P., Petrick, N., Sahiner, B., Lo, S.-C. B., Freedman, M., Adler, D., Bailey, J., Blane, C., Hoff, D., Hunt, K., Joynt, L., Klein, K., Paramagul, C., Patterson, S. K. ve Roubidoux, M. A., Sensitivity of noncommercial computer-aided detection system for mammographic breast cancer detection: Pilot clinical trial, *Radiology*, 231, 1 (2004) 208–214.

36. Fenton, J. J., Taplin, S. H., Carney, P. A., Abraham, L., Sickles, E. A., D'Orsi, C., Berns, E. A., Cutter, G., Hendrick, R. E., Barlow, W. E. ve Elmore, J. G., Influence of computer-aided detection on performance of screening mammography, New England Journal of Medicine, 356, 14 (2007) 1399–1409.
37. Gromet, M., Comparison of computer-aided detection to double reading of screening mammograms: Review of 231,221 mammograms, American Journal of Roentgenology, 190, 4 (2008) 854–859.
38. Lehman, C. D., Wellman, R. D., Buist, D. S. M., Kerlikowske, K., Tosteson, A. N. A. ve Miglioretti, D. L., Diagnostic accuracy of digital screening mammography with and without computer-aided detection, JAMA Internal Medicine, 175, 11 (2015) 1828.
39. Henriksen, E. L., Carlsen, J. F., Vejborg, I. M., Nielsen, M. B. ve Lauridsen, C. A., The efficacy of using computer-aided detection (CAD) for detection of breast cancer in mammography screening: a systematic review, Acta Radiologica, 60, 1 (2018) 13–18.
40. McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H., Back, T., Chesus, M., Corrado, G. S., Darzi, A., Etemadi, M., Garcia-Vicente, F., Gilbert, F. J., Halling-Brown, M., Hassabis, D., Jansen, S., Karthikesalingam, A., Kelly, C. J., King, D., Ledsam, J. R., Melnick, D., Mostofi, H., Peng, L., Reicher, J. J., Romera-Paredes, B., Sidebottom, R., Suleyman, M., Tse, D., Young, K. C., Fauw, J. D. ve Shetty, S., International evaluation of an AI system for breast cancer screening, Nature, 577, 7788 (2020) 89–94.
41. Yanase, J. ve Triantaphyllou, E., The seven key challenges for the future of computer-aided diagnosis in medicine, International Journal of Medical Informatics, 129 (2019) 413–422.
42. Thrall, J. H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K. ve Brink, J., Artificial intelligence and machine learning in radiology: Opportunities, challenges, pitfalls, and criteria for success, Journal of the American College of Radiology, 15, 3 (2018) 504–508.
43. Le, E., Wang, Y., Huang, Y., Hickman, S. ve Gilbert, F., Artificial intelligence in breast imaging, Clinical Radiology, 74, 5 (2019) 357–366.
44. Tariq, A., Purkayastha, S., Padmanaban, G. P., Krupinski, E., Trivedi, H., Banerjee, I. ve Gichoya, J. W., Current clinical applications of artificial intelligence in radiology and their best supporting evidence, Journal of the American College of Radiology, 17, 11 (2020) 1371–1381.
45. Recht, M. P., Dewey, M., Dreyer, K., Langlotz, C., Niessen, W., Prainsack, B. ve Smith, J. J., Integrating artificial intelligence into the clinical practice of radiology: challenges and recommendations, European Radiology, 30, 6 (2020) 3576–3584.
46. Food, U., Administration, D. et al., Summary of safety and effectiveness data: R2 technologies, P970058, (1998).
47. Nishikawa, R. M., Haldemann, R. C., Papaioannou, J., Giger, M. L., Lu, P., Schmidt, R. A., Wolverton, D. E., Bick, U. ve Doi, K., Initial experience with a prototype clinical intelligent mammography workstation for computer-aided diagnosis, M. H. Loew, editor, Medical Imaging 1995: Image Processing, SPIE, 1995.

48. Roehrig, J., Doi, T., Hasegawa, A., Hunt, B., Marshall, J., Romsdahl, H., Schneider, A., Sharbaugh, R. ve Zhang, W., Clinical results with r2 imagechecker system, *Computational Imaging and Vision, Bildiriler Kitabı*: 395–400, Springer Netherlands, 1998.
49. Garvican, L. ve Field, S., A pilot evaluation of the r2 image checker system and users' response in the detection of interval breast cancers on previous screening films, *Clinical radiology*, 56, 10 (2001) 833–837.
50. Leon, S., Brateman, L., Honeyman-Buck, J. ve Marshall, J., Comparison of two commercial CAD systems for digital mammography, *Journal of Digital Imaging*, 22, 4 (2008) 421–423.
51. Cascio, D., Fauci, F., Iacomi, M., Raso, G., Magro, R., Castrogiovanni, D., Filosto, G., Ienzi, R. ve Vasile, M. S., Computer-aided diagnosis in digital mammography: comparison of two commercial systems, *Imaging in Medicine*, 6, 1 (2014) 13–20.
52. Baker, J. A., Rosen, E. L., Lo, J. Y., Gimenez, E. I., Walsh, R. ve Soo, M. S., Computer-aided detection (CAD) in screening mammography: sensitivity of commercial CAD systems for detecting architectural distortion, *American Journal of Roentgenology*, 181, 4 (2003) 1083–1088.
53. Cole, E. B., Zhang, Z., Marques, H. S., Hendrick, R. E., Yaffe, M. J. ve Pisano, E. D., Impact of computer-aided detection systems on radiologist accuracy with digital mammography, *American Journal of Roentgenology*, 203, 4 (2014) 909–916.
54. iCAD, Ticari bdt sistemi ile kitle belirginles_tirme, 2020. <https://www.icadmed.com/powerlook-tomo-detection.html> Accessed 10-May-2021.
55. Balleyguier, C., Arfi-Rouche, J., Levy, L., Toubiana, P.R., Cohen-Scali, F., Toledano, A. Y. ve Boyer, B., Improving digital breast tomosynthesis reading time: A pilot multi-reader, multi-case study using concurrent computer-aided detection (CAD), *European Journal of Radiology*, 97 (2017) 83–89.
56. Benedikt, R. A., Boatsman, J. E., Swann, C. A., Kirkpatrick, A. D. ve Toledano, A. Y., Concurrent computer-aided detection improves reading time of digital breast tomosynthesis and maintains interpretation performance in a multireader multicase study, *American Journal of Roentgenology*, 210, 3 (2018) 685–694.
57. Conant, E. F., Toledano, A. Y., Periaswamy, S., Fotin, S. V., Go, J., Boatsman, J. E. ve Hoffmeister, J. W., Improving accuracy and efficiency with concurrent use of artificial intelligence for digital breast tomosynthesis, *Radiology: Artificial Intelligence*, 1, 4 (2019) e180096.
58. Hsu, W. ve Hoyt, A. C., Using time as a measure of impact for AI systems: Implications in breast screening, *Radiology: Artificial Intelligence*, 1, 4 (2019) e190107.
59. BV., S. M., Ticari bdt sistemi ile kitle belirlenmesi, 2020. <https://screenpoint-medical.com/> Accessed 10-May-2021.
60. Samulski, M., Hupse, R., Boetes, C., Mus, R. D. M., den Heeten, G. J. ve Karssemeijer, N., Using computer-aided detection in mammography as a decision support, *European Radiology*, 20, 10 (2010) 2323–2330.

61. Hupse, R., Samulski, M., Lobbes, M., den Heeten, A., Imhof-Tas, M. W., Beijerinck, D., Pijnappel, R., Boetes, C. ve Karssemeijer, N., Standalone computer-aided detection compared to radiologists' performance for the detection of mammographic masses, European Radiology, 23, 1 (2012) 93–100.
62. Sasaki, M., Tozaki, M., Rodríguez-Ruiz, A., Yotsumoto, D., Ichiki, Y., Terawaki, A., Oosako, S., Sagara, Y. ve Sagara, Y., Artificial intelligence for breast cancer detection in mammography: experience of use of the ScreenPoint medical transpara system in 310 japanese women, Breast Cancer, 27, 4 (2020) 642–651.
63. Lång, K., Dustler, M., Dahlblom, V., Åkesson, A., Andersson, I. ve Zackrisson, S., Identifying normal mammograms in a large screening population using artificial intelligence, European Radiology, 31, 3 (2020) 1687–1692.
64. Rodriguez-Ruiz, A., Lång, K., Gubern-Merida, A., Teuwen, J., Broeders, M., Gennaro, G., Clauser, P., Helbich, T. H., Chevalier, M., Mertelmeier, T., Wallis, M. G., Andersson, I., Zackrisson, S., Sechopoulos, I. ve Mann, R. M., Can we reduce the workload of mammographic screening by automatic identification of normal exams with artificial intelligence? a feasibility study, European Radiology, 29, 9 (2019) 4825–4832.
65. Rodríguez-Ruiz, A., Krupinski, E., Mordang, J.-J., Schilling, K., Heywang-Köbrunner, S. H., Sechopoulos, I. ve Mann, R. M., Detection of breast cancer with mammography: Effect of an artificial intelligence support system, Radiology, 290, 2 (2019) 305–314.
66. Rodriguez-Ruiz, A., Lång, K., Gubern-Merida, A., Broeders, M., Gennaro, G., Clauser, P., Helbich, T. H., Chevalier, M., Tan, T., Mertelmeier, T., Wallis, M. G., Andersson, I., Zackrisson, S., Mann, R. M. ve Sechopoulos, I., Stand-alone artificial intelligence for breast cancer detection in mammography: Comparison with 101 radiologists, JNCI: Journal of the National Cancer Institute, 111, 9 (2019) 916–922.
67. Radiologica, Meme kanseri teshis klinigi, 2015. [https://radiologica.com. tr/](https://radiologica.com.tr/) Accessed 10-May-2021.
68. Software, T. P., Ticari bdt sistemi, 2015. [https://threepalmsoft.com/ products/cadone/](https://threepalmsoft.com/products/cadone/) Accessed 10-May-2021.
69. Tabar, L., Mammography, Journal de Radiologie, 90, 10 (2009) 1279.
70. A.Ş., S. H. S., Görüntüleme cihazı ile bdt sisteminin kullanılması, 2021. [https://www.siemens-healthineers.com/dk/mammography/news/ how-cad-can-help-save-time-in-mammography-reading.html](https://www.siemens-healthineers.com/dk/mammography/news/how-cad-can-help-save-time-in-mammography-reading.html) Accessed 10-May-2021.
71. Therapixel, Mammoscreen bdt sistemi ile kitle belirlenmesi, 2021. <https://www.mammoscreen.com/how-it-works> Accessed 10-May-2021.
72. Schaffter, T., Buist, D. S. M., Lee, C. I., Nikulin, Y., Ribli, D., Guan, Y., Lotter, W., Jie, Z., Du, H., Wang, S., Feng, J., Feng, M., Kim, H.-E., Albiol, F., Albiol, A., Morrell, S., Wojna, Z., Ahsen, M. E., Asif, U., Yepes, A. J., Yohanandan, S., Rabinovici-Cohen, S., Yi, D., Hoff, B., Yu, T., Neto, E. C., Rubin, D. L., Lindholm, P., Margolies, L. R., McBride, R. B., Rothstein, J. H., Sieh, W., Ben-Ari, R., Harrer, S., Trister, A., Friend, S., Norman, T., Sahiner, B., Strand, F., Guinney, J., Stolovitzky, G., Mackey, L., Cahoon,

- J., Shen, L., Sohn, J. H., Trivedi, H., Shen, Y., Buturovic, L., Pereira, J. C., Cardoso, J. S., Castro, E., Kalleberg, K. T., Pelka, O., Nedjar, I., Geras, K. J., Nensa, F., Goan, E., Koitka, S., Caballero, L., Cox, D. D., Krishnaswamy, P., Pandey, G., Friedrich, C. M., Perrin, D., Fookes, C., Shi, B., Negrie, G. C., Kawczynski, M., Cho, K., Khoo, C. S., Lo, J. Y., Sorensen, A. G. ve and, H. J., Evaluation of combined artificial intelligence and radiologist assessment to interpret screening mammograms, JAMA Network Open, 3, 3 (2020) e200265.
73. Pacilè, S., Lopez, J., Chone, P., Bertinotti, T., Grouin, J. M. ve Fillard, P., Improving breast cancer detection accuracy of mammography with the concurrent use of an artificial intelligence tool, Radiology: Artificial Intelligence, 2, 6 (2020) e190208.
74. Vourch, A. L., Edouard, P. ve Laurent, N., Breast screening and artificial intelligence: an independent evaluation of two different software carried out at valenciennes hospital, C. V. Ongeval, N. Marshall ve H. Bosmans, editors, 15th International Workshop on Breast Imaging (IWBI2020), SPIE, 2020.
75. Technologies, K. M., Derin Öğrenme tabanlı mamografi yazılım Şirketi, 2021. <https://www.kheironmed.com> Accessed 10-May-2021.
76. Harvey, H., Karpati, E., Khara, G., Korkinof, D., Ng, A., Austin, C., Rijken, T. ve Kecskemethy, P., The role of deep learning in breast screening, Current Breast Cancer Reports, 11, 1 (2019) 17–22.
77. Harvey, H., Heindl, A., Khara, G., Korkinof, D., O’Neill, M., Yearsley, J., Karpati, E., Rijken, T., Kecskemethy, P. ve Forrai, G., Deep learning in breast cancer screening, Artificial Intelligence in Medical Imaging, Bildiriler Kitabı: 187–215, Springer International Publishing, 2019.
78. Korkinof, D., Harvey, H., Heindl, A., Karpati, E., Williams, G., Rijken, T., Kecskemethy, P. ve Glocker, B., Perceived realism of high-resolution generative adversarial network–derived synthetic mammograms, Radiology: Artificial Intelligence, 3, 2 (2021) e190181.
79. Ganesan, K., Acharya, U. R., Chua, K. C., Min, L. C. ve Abraham, K. T., Pectoral muscle segmentation: A review, Computer Methods and Programs in Biomedicine, 110, 1 (2013) 48–57.
80. Sapate, S. ve Talbar, S., An overview of pectoral muscle extraction algorithms applied to digital mammograms, Medical Imaging in Clinical Applications, Bildiriler Kitabı: 19–54, Springer International Publishing, 2016.
81. Mustra, M., Grgic, M. ve Rangayyan, R. M., Review of recent advances in segmentation of the breast boundary and the pectoral muscle in mammograms, Medical & Biological Engineering & Computing, 54, 7 (2015) 1003–1024.
82. Moghbel, M., Ooi, C. Y., Ismail, N., Hau, Y. W. ve Memari, N., A review of breast boundary and pectoral muscle segmentation methods in computer-aided detection/diagnosis of breast mammography, Artificial Intelligence Review, 53, 3 (2019) 1873–1918.
83. Kwok, S., Chandrasekhar, R. ve Attikiouzel, Y., Automatic pectoral muscle

- segmentation on mammograms by straight line estimation and cliff detection, The Seventh Australian and New Zealand Intelligent Information Systems Conference, 2001, IEEE, 2001.
84. Kwok, S., Chandrasekhar, R., Attikiouzel, Y. ve Rickard, M., Automatic pectoral muscle segmentation on mediolateral oblique view mammograms, IEEE Transactions on Medical Imaging, 23, 9 (2004) 1129–1140.
 85. Ferrari, R., Rangayyan, R., Desautels, J., Borges, R. ve Frere, A., Automatic identification of the pectoral muscle in mammograms, IEEE Transactions on Medical Imaging, 23, 2 (2004) 232–245.
 86. Ma, F., Bajger, M., Slavotinek, J. P. ve Bottema, M. J., Two graph theory based methods for identifying the pectoral muscle in mammograms, Pattern Recognition, 40, 9 (2007) 2592–2602.
 87. Camilus, K. S., Govindan, V. K. ve Sathidevi, P., Pectoral muscle identification in mammograms, Journal of Applied Clinical Medical Physics, 12, 3 (2011) 215–230.
 88. Li, Y., Chen, H., Yang, Y. ve Yang, N., Pectoral muscle segmentation in mammograms based on homogenous texture and intensity deviation, Pattern Recognition, 46, 3 (2013) 681–691.
 89. Chen, C., Liu, G., Wang, J. ve Sudlow, G., Shape-based automatic detection of pectoral muscle boundary in mammograms, Journal of Medical and Biological Engineering, 35, 3 (2015) 315–322.
 90. Raba, D., Oliver, A., Martí, J., Peracaula, M. ve Espunya, J., Breast segmentation with pectoral muscle suppression on digital mammograms, Pattern Recognition and Image Analysis, Bildiriler Kitabı: 471–478, Springer Berlin Heidelberg, 2005.
 91. Hazarika, M. ve Mahanta, L. B., A novel region growing based method to remove pectoral muscle from MLO mammogram images, Lecture Notes in Electrical Engineering, Bildiriler Kitabı: 307–316, Springer Singapore, 2017.
 92. Mustra, M. ve Grgic, M., Robust automatic breast and pectoral muscle segmentation from scanned mammograms, Signal Processing, 93, 10 (2013) 2817–2827.
 93. Mughal, B., Muhammad, N., Sharif, M., Rehman, A. ve Saba, T., Removal of pectoral muscle based on topographic map and shape-shifting silhouette, BMC Cancer, 18, 1 (2018).
 94. Kinoshita, S. K., Azevedo-Marques, P. M., Pereira, R. R., Rodrigues, J. A. H. ve Rangayyan, R. M., Radon-domain detection of the nipple and the pectoral muscle in mammograms, Journal of Digital Imaging, 21, 1 (2007) 37–49.
 95. Rampun, A., Morrow, P. J., Scotney, B. W. ve Winder, J., Fully automated breast boundary and pectoral muscle segmentation in mammograms, Artificial Intelligence in Medicine, 79 (2017) 28–41.
 96. Ture, H. ve Kayikcioglu, T., Segmentation of pectoral muscle by optimum contour selection approach, 2017 Medical Technologies National Congress (TIPTEKNO), IEEE, 2017.

97. Yin, K., Yan, S., Song, C. ve Zheng, B., A robust method for segmenting pectoral muscle in mediolateral oblique (MLO) mammograms, International Journal of Computer Assisted Radiology and Surgery, 14, 2 (2018) 237–248.
98. Maitra, I. K., Nag, S. ve Bandyopadhyay, S. K., Technique for preprocessing of digital mammogram, Computer Methods and Programs in Biomedicine, 107, 2 (2012) 175–188.
99. Taghanaki, S. A., Liu, Y., Miles, B. ve Hamarneh, G., Geometry-based pectoral muscle segmentation from MLO mammogram views, IEEE Transactions on Biomedical Engineering, 64, 11 (2017) 2662–2671.
100. Shen, R., Yan, K., Xiao, F., Chang, J., Jiang, C. ve Zhou, K., Automatic pectoral muscle region segmentation in mammograms using genetic algorithm and morphological selection, Journal of Digital Imaging, 31, 5 (2018) 680–691.
101. Shi, P., Zhong, J., Rampun, A. ve Wang, H., A hierarchical pipeline for breast boundary segmentation and calcification detection in mammograms, Computers in Biology and Medicine, 96 (2018) 178–188.
102. Rampun, A., López-Linares, K., Morrow, P. J., Scotney, B. W., Wang, H., Ocaña, I. G., Maclair, G., Zwiggelaar, R., Ballester, M. A. G. ve Macía, I., Breast pectoral muscle segmentation in mammograms using a modified holistically-nested edge detection network, Medical Image Analysis, 57 (2019) 1–17.
103. Ture, H. ve Kayikcioglu, T., Accurate detection of distorted pectoral muscle in mammograms using specific patterned isocontours, IEEE Access, 8 (2020) 147370–147386.
104. Cheng, H., Shi, X., Min, R., Hu, L., Cai, X. ve Du, H., Approaches for automated detection and classification of masses in mammograms, Pattern Recognition, 39, 4 (2006) 646–668.
105. Rangayyan, R. M., Ayres, F. J. ve Desautels, J. L., A review of computer-aided diagnosis of breast cancer: Toward the detection of subtle signs, Journal of the Franklin Institute, 344, 3-4 (2007) 312–348.
106. Oliver, A., Freixenet, J., Martí, J., Pérez, E., Pont, J., Denton, E. R. ve Zwiggelaar, R., A review of automatic mass detection and segmentation in mammographic images, Medical Image Analysis, 14, 2 (2010) 87–110.
107. Ganesan, K., Acharya, U. R., Chua, C. K., Min, L. C., Abraham, K. T. ve Ng, K.-H., Computer-aided breast cancer detection using mammograms: A review, IEEE Reviews in Biomedical Engineering, 6 (2013) 77–98.
108. Katzen, J. ve Dodelzon, K., A review of computer aided detection in mammography, Clinical Imaging, 52 (2018) 305–309.
109. Gardezi, S. J. S., Elazab, A., Lei, B. ve Wang, T., Breast cancer detection and diagnosis using mammographic data: Systematic review, Journal of Medical Internet Research, 21, 7 (2019) e14464.
110. Pedro, R. W. D., Machado-Lima, A. ve Nunes, F. L., Is mass classification in

- mammograms a solved problem? - a critical review over the last 20 years, Expert Systems with Applications, 119 (2019) 90–103.
111. Ramadan, S. Z., Methods used in computer-aided diagnosis for breast cancer detection using mammograms: A review, Journal of Healthcare Engineering, 2020 (2020) 1–21.
 112. Bagchi, S., Tay, K. G., Huong, A. ve Debnath, S. K., Image processing and machine learning techniques used in computer-aided detection system for mammogram screening - a review, International Journal of Electrical and Computer Engineering (IJECE), 10, 3 (2020) 2336.
 113. Fujita, H., AI-based computer-aided diagnosis (AI-CAD): the latest review to read first, Radiological Physics and Technology, 13, 1 (2020) 6–19.
 114. Hong, B.-W. ve Sohn, B.-S., Segmentation of regions of interest in mammograms in a topographic approach, IEEE Transactions on Information Technology in Biomedicine, 14, 1 (2010) 129–139.
 115. Quellec, G., Lamard, M., Cozic, M., Coatrieux, G. ve Cazuguel, G., Multiple-instance learning for anomaly detection in digital mammography, IEEE Transactions on Medical Imaging, 35, 7 (2016) 1604–1614.
 116. Mudigonda, N., Rangayyan, R. ve Desautels, J. L., Detection of breast masses in mammograms by density slicing and texture flow-field analysis, IEEE Transactions on Medical Imaging, 20, 12 (2001) 1215–1227.
 117. Eltonsy, N. H., Tourassi, G. D. ve Elmaghraby, A. S., A concentric morphology model for the detection of masses in mammography, IEEE Transactions on Medical Imaging, 26, 6 (2007) 880–889.
 118. Gao, X., Wang, Y., Li, X. ve Tao, D., On combining morphological component analysis and concentric morphology model for mammographic mass detection, IEEE Transactions on Information Technology in Biomedicine, 14, 2 (2010) 266–273.
 119. Liu, X. ve Zeng, Z., A new automatic mass detection method for breast cancer with false positive reduction, Neurocomputing, 152 (2015) 388–402.
 120. Agrawal, P., Vatsa, M. ve Singh, R., Saliency based mass detection from screening mammograms, Signal Processing, 99 (2014) 29–47.
 121. Domínguez, A. R. ve Nandi, A. K., Detection of masses in mammograms via statistically based enhancement, multilevel-thresholding segmentation, and region selection, Computerized Medical Imaging and Graphics, 32, 4 (2008) 304–315.
 122. Choi, J. Y., Kim, D. H., Plataniotis, K. N. ve Ro, Y. M., Computer-aided detection (CAD) of breast masses in mammography: combined detection and ensemble classification, Physics in Medicine and Biology, 59, 14 (2014) 3697–3719.
 123. Chakraborty, J., Midya, A. ve Rabidas, R., Computer-aided detection and diagnosis of mammographic masses using multi-resolution analysis of oriented tissue patterns, Expert Systems with Applications, 99 (2018) 168–179.
 124. Casti, P., Mencattini, A., Salmeri, M., Ancona, A., Mangeri, F., Pepe, M. ve Rangayyan, R., Contour-independent detection and classification of mammographic

- lesions, Biomedical Signal Processing and Control, 25 (2016) 165–177.
125. Sampaio, W. B., Diniz, E. M., Silva, A. C., de Paiva, A. C. ve Gattass, M., Detection of masses in mammogram images using CNN, geostatistic functions and SVM, Computers in Biology and Medicine, 41, 8 (2011) 653–664.
 126. Masotti, M., Lanconelli, N. ve Campanini, R., Computer-aided mass detection in mammography: False positive reduction via gray-scale invariant ranklet texture features, Medical Physics, 36, 2 (2009) 311–316.
 127. Tai, S.-C., Chen, Z.-S. ve Tsai, W.-T., An automatic mass detection system in mammograms based on complex texture features, IEEE Journal of Biomedical and Health Informatics, 18, 2 (2014) 618–627.
 128. Dong, M., Lu, X., Ma, Y., Guo, Y., Ma, Y. ve Wang, K., An efficient approach for automated mass segmentation and classification in mammograms, Journal of Digital Imaging, 28, 5 (2015) 613–625.
 129. Jen, C.-C. ve Yu, S.-S., Automatic detection of abnormal mammograms in mammographic images, Expert Systems with Applications, 42, 6 (2015) 3048–3055.
 130. Hu, K., Gao, X. ve Li, F., Detection of suspicious lesions by adaptive thresholding based on multiresolution analysis in mammograms, IEEE Transactions on Instrumentation and Measurement, 60, 2 (2011) 462–472.
 131. De Sampaio, W. B., Silva, A. C., de Paiva, A. C. ve Gattass, M., Detection of masses in mammograms with adaption to breast density using genetic algorithm, phylogenetic trees, LBP and SVM, Expert Systems with Applications, 42, 22 (2015) 8911–8928.
 132. Shen, R., Yan, K., Tian, K., Jiang, C. ve Zhou, K., Breast mass detection from the digitized x-ray mammograms based on the combination of deep active learning and self-paced learning, Future Generation Computer Systems, 101 (2019) 668–679.
 133. Jung, H., Kim, B., Lee, I., Yoo, M., Lee, J., Ham, S., Woo, O. ve Kang, J., Detection of masses in mammograms using a one-stage object detector based on a deep convolutional neural network, PLOS ONE, 13, 9 (2018) e0203355.
 134. Shen, R., Yao, J., Yan, K., Tian, K., Jiang, C. ve Zhou, K., Unsupervised domain adaptation with adversarial learning for mass detection in mammogram, Neurocomputing, 393 (2020) 27–37.
 135. Agarwal, R., Díaz, O., Yap, M. H., Lladó, X. ve Martí, R., Deep learning for mass detection in full field digital mammograms, Computers in Biology and Medicine, 121 (2020) 103774.
 136. Ribli, D., Horváth, A., Unger, Z., Pollner, P. ve Csabai, I., Detecting and classifying lesions in mammograms with deep learning, Scientific reports, 8, 1 (2018) 1–7.
 137. Ture, H. ve Kayikcioglu, T., Classification of salient dense regions in mammograms based on the minimum nesting depth approach, 2015 23rd Signal Processing and Communications Applications Conference (SIU), IEEE, 2015.
 138. Ture, H. ve Kayikcioglu, T., Detection and segmentation of masses in mammograms by the rule based elimination approach, 2017 25th Signal Processing and Communications

Applications Conference (SIU), IEEE, 2017.

139. Ture, H. ve Kayikcioglu, T., Detection and segmentation of nodules in chest radiographs based on lifetime approach, IFMBE Proceedings, Bildiriler Kitabı: 539–547, Springer Singapore, 2017.
140. Haralick, R. M., Shanmugam, K. ve Dinstein, I., Textural features for image classification, IEEE Transactions on Systems, Man, and Cybernetics, SMC-3, 6 (1973) 610–621.
141. Connors, R. W., Trivedi, M. M. ve Harlow, C. A., Segmentation of a high-resolution urban scene using texture operators, Computer Vision, Graphics, and Image Processing, 25, 3 (1984) 273–310.
142. Albrechtsen, F. et al., Statistical texture measures computed from gray level cooccurrence matrices, Image processing laboratory, department of informatics, university of oslo, 5, 01 (2008) 01–14.
143. Unser, M., Sum and difference histograms for texture classification, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8, 1 (1986) 118–125.

ÖZGEÇMİŞ

İlk ve orta öğrenimini İstanbul'da tamamladı. 1995 yılında Trabzon Fatih Lisesi'nden mezun oldu. 1995 yılında, Karadeniz Teknik Üniversitesi Elektronik Mühendisliği lisans eğitimine başladı. 1999 yılında lisans derecesini aldığı bölümden dördüncülük derecesi ile bitirdi. 2000 yılında KTÜ Elektronik Mühendisliği Bölümünde yüksek lisansına başladı. 2000 yılında Fen Bilimleri Enstitüsüne bağlı olarak Araştırma Görevlisi olarak atandı. 2003 yılında aynı bölümde yüksek lisansını tamamladı ve aynı yıl içerisinde Türk Telekom Avrupa Yakası Bölge Müdürlüğü Bilişim Ağları Biriminde Uzman Yardımcısı olarak çalıştı. 2007 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Bölümü'nde doktora eğitimine başladı. KTÜ Bilgi İşlem Daire Başkanlığında Ağ Birimi sorumlusu olarak halen çalışmaya devam etmektedir.

1 adet SCI/expanded indeksli dergi ve 6'si ulusal ve uluslararası konferanslarda olmak üzere toplam 7 adet yayını mevcuttur. Yabancı dil olarak İngilizce bilmektedir.