

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**MAMOGRAFİ GÖRÜNTÜLERİNİN YORUMLANMASIYLA BİLGİSAYARLI  
TEŞHİS SİSTEMİNİN TASARIMI**

**DOKTORA TEZİ**

**Bil. Yük. Müh. Burçin KURT**

**ARALIK 2014  
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**MAMOGRAFİ GÖRÜNTÜLERİNİN YORUMLANMASIYLA BİLGİSAYARLI**  
**TEŞHİS SİSTEMİNİN TASARIMI**

**Bilgisayar Yük. Müh. Burçin KURT**

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

**Tezin Enstitüye Verildiği Tarih : 30.10.2014**  
**Tezin Savunma Tarihi : 03.12.2014**

**Tez Danışmanı : Prof. Dr. Vasif V. NABİYEV**

**Trabzon 2014**

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Ana Bilim Dalında  
Burçin KURT Tarafından Hazırlanan

MAMOGRAFİ GÖRÜNTÜLERİNİN YORUMLANMASIYLA BİLGİSAYARLI  
TEŞHİS SİSTEMİNİN TASARIMI

başlıklı bu çalışmada, Enstitü Yönetim Kurulunun 11/11/2014 gün ve 1576 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda

DOKTORA TEZİ  
olarak kabul edilmiştir.

Jüri Üyeleri

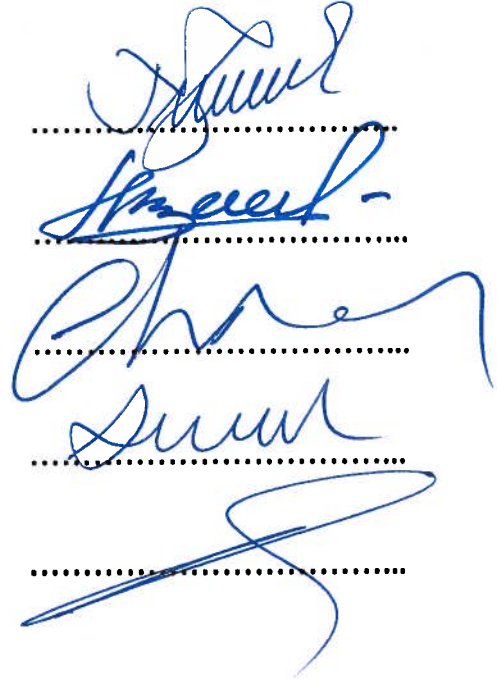
Başkan : Prof. Dr. Nejat YUMUŞAK

Üye : Prof. Dr. Vasif V. NABİYEV

Üye : Prof. Dr. Cemal KÖSE

Üye : Prof. Dr. Ali GANGAL

Üye : Prof. Dr. Kemal TURHAN



Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

## ÖNSÖZ

Dünyada meme kanseri, tüm kanser vakalarının %25'i olmak üzere kadınlarda en önde gelen kanser türüdür ve her yıl yaklaşık her 8 kadından 1'ine meme kanseri teşhisi konulmaktadır. Erken teşhis, hayatta kalma oranı için oldukça önemlidir. Deneyimli radyologların bile doğru değerlendirme oranı %65-75 arasında değişmektedir. Bilgisayar destekli tanı (Computer Aided Diagnosis - CAD) sistemleri, medikal görüntüleri yorumlamada radyologlara yardımcı olmak için geliştirilmektedir ve okuyucu duyarlılığı ortalama %10 artabilmektedir. Bununla birlikte, şüpheli kanser vakalarının %65-90 arası iyi huylu çıkmaktadır, bu da birçok gereksiz biyopsi yapıldığı anlamına gelmektedir. Bu nedenle iyi huylu/kötü huylu sınıflaması yapabilen bir CAD sistemi geliştirmek oldukça önemlidir. Bu tez çalışmasında, yeni yaklaşımlar ortaya konularak mamografi görüntülerinde kitle ve mikrokalsifikasyonların tespitini ve iyi huylu/kötü huylu değerlendirmesini gerçekleyen meme kanseri karar destek sisteminin tasarımı gerçekleştirilmiştir.

Çalışmalarında bilgilerimi, desteğini ve tecrübelerini esirgemeyen değerli hocam, danışmanım sayın Prof. Dr. Vasif V. NABİYEV'e sonsuz teşekkürlerimi bir borç bilirim. Doktora süresince fikirlerine başvurduğum jüri üyelerine ayrıca teşekkür ederim. Çalışma hayatımda beni destekleyen ve tecrübelerinden faydalandığım anabilim dalı başkanım sayın Prof. Dr. Kemal TURHAN'a çok teşekkür ederim. Tez çalışmamı STZ.2011-2 kodlu SANTEZ projesi kapsamında destekleyen Türkiye Cumhuriyeti Bilim, Teknoloji ve Sanayi Bakanlığı ve AKGÜN Yazılım'a teşekkürü bir borç bilirim.

Bu günlere gelmemde büyük pay sahibi olan sevgili aileme teşekkürlerimi sunarım.

Burçin KURT

Trabzon 2014

## **TEZ BEYANNAMESİ**

Doktora Tezi olarak sunduđum “Mamografi Görüntülerinin Yorumlanmasıyla Bilgisayarlı Teşhis Sisteminin Tasarımı” başıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Vasif V. NABIYEV’in sorumluluğunda 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. 24/10/2014

Burçin KURT

## İÇİNDEKİLER

	<b><u>Sayfa No</u></b>
ÖNSÖZ .....	III
TEZ BEYANNAMESİ .....	IV
İÇİNDEKİLER .....	V
ÖZET .....	VIII
SUMMARY .....	IX
ŞEKİLLER DİZİNİ .....	X
TABLolar DİZİNİ .....	XV
SEMBOLLER DİZİNİ.....	XVI
1. GENEL BİLGİLER .....	1
1.1. Giriş .....	1
1.2. Ön İşlemler.....	6
1.2.1. Meme Bölgesinin Bölütlenmesi .....	7
1.2.1.1. Medyan Filtreleme.....	10
1.2.1.2. Matematiksel Morfoloji .....	10
1.2.1.3. Bağlı Bileşen Etiketleme.....	11
1.2.1.4. Meme Bölgesi Bölütleme Performansının Değerlendirilmesi .....	12
1.2.2. Pektoral Kasın (Koltuk Altı Bölgesi) Çıkarılması .....	13
1.2.2.1. Otsu N Eşikleme.....	15
1.2.3. Mamografi Görüntülerinin İyileştirilmesi.....	17
1.2.3.1. Morfolojik İyileştirme.....	20
1.2.3.2. Dalgacık Tabanlı Eşikleme .....	21
1.2.3.2.1. Dalgacık Dönüşümü ve Çok Ölçekli Analizi.....	21
1.2.3.2.2. Sürekli Dalgacık Dönüşümü .....	23
1.2.3.2.3. Ayrık Dalgacık Dönüşümü .....	24
1.2.3.3. Kontrast Sınırlı Adaptif Histogram Eşitleme .....	32
1.2.3.4. Anizotropik Difüzyon Filtreleme .....	35
1.2.3.5.1. Logaritmik AME (LogAME) ve Logaritmik AMEE (LogAMEE).....	39
1.3. Şüpheli Bölgelerin Belirlenmesi.....	41

1.3.1.	Şüpheli Kitle Bölgelerinin Belirlenmesi.....	41
1.3.1.1.	Shannon ve Non-Shannon Entropi Ölçüleri.....	42
1.3.1.2.	Shannon ve Non-Shannon Entropi Ölçüleri ile Şüpheli Bölgelerin Bölütlenmesi .....	44
1.3.2.	Şüpheli Mikrokalsifikasyon Bölgelerinin Belirlenmesi .....	48
1.3.2.1.	Kaba Entropi ile Optimum Eşik Değerinin Bulunması .....	49
1.3.2.2.	Bulanık Tabanlı Mikrokalsifikasyon İyileştirme .....	49
1.3.2.3.	İteratif Eşikleme ile Bölütleme.....	51
1.4.	Anormalliklerin Tespiti.....	51
1.4.1.	Kitle Tespiti.....	52
1.4.1.1.	Özellik Çıkarma ve Sınıflama .....	53
1.4.1.1.1.	Gri Seviye Eş Oluşum Matrisi ile Özellik Çıkarma .....	54
1.4.1.1.2.	Destek Vektör Makinesi ile Sınıflama.....	58
1.4.1.1.3.	Yapay Sinir Ağı ile Sınıflama .....	61
1.4.1.2.	Yanlış Pozitif İndirgeme .....	62
1.4.1.2.1.	Olasılıklı Sinir Ağı.....	62
1.4.2.	Mikrokalsifikasyonların Tespiti .....	64
1.4.2.1.	Özellik Çıkarma ve Sınıflama .....	65
1.4.2.1.1.	İstatistiksel Özellikler .....	66
1.4.2.2.	Yanlış Pozitif İndirgeme .....	66
1.4.2.2.1.	Kademeli Korelasyon Sinir Ağı .....	67
1.5.	Anormalliklerin İyi Huylu/Kötü Huylu Değerlendirilmesi .....	69
1.5.1.	Kitle için İyi Huylu/Kötü Huylu Değerlendirmesi.....	69
1.5.1.1.	Özellik Çıkarma ve Sınıflama .....	70
1.5.1.1.1.	Yerel Homeopati Özelliği .....	71
1.5.1.1.2.	Dalgacık Dönüşümü Tabanlı Özellikler .....	71
1.5.1.1.3.	K-Ortalama Algoritması ile Sınıflama.....	73
1.5.1.1.4.	Tekli Karar Ağacı Algoritması ile Sınıflama .....	74
1.5.2.	Mikrokalsifikasyonlar için İyi Huylu/Kötü Huylu Değerlendirmesi .....	77
1.5.2.1.	Özellik Çıkarma ve Sınıflama .....	77
1.5.2.1.1.	Gri Seviye Dizi Uzunluk Matrisi ile Özellik Çıkarma .....	78
1.5.2.1.2.	Lineer Diskriminant Analiz ile Sınıflama.....	80
2.	YAPILAN ÇALIŞMALAR .....	83

2.1.	Veritabanı.....	87
2.2.	Meme Bölgesinin Bölütlenmesi .....	88
2.3.	Pektoral Kasın (Koltuk Altı Bölgesi) Çıkarılması .....	92
2.4.	Kitle Tespiti ve İyi Huylu/Kötü Huylu Değerlendirmesi.....	96
2.4.1.	Kitle Tespiti için Görüntünün İyileştirilmesi .....	96
2.4.2.	Şüpheli Kitle Bölgelerinin Belirlenmesi.....	102
2.4.3.	Özellik Çıkarma ve Sınıflama .....	113
2.4.4.	Kitle Tespiti Yanlış Pozitif İndirgeme.....	119
2.4.5.	Kitle İyi Huylu/Kötü Huylu Değerlendirilmesi .....	123
2.5.	Mikrokalsifikasyonların Tespiti ve İyi Huylu/Kötü Huylu Değerlendirmesi...128	
2.5.1.	Mikrokalsifikasyonların Tespiti için Görüntünün İyileştirilmesi.....	129
2.5.2.	Şüpheli Mikrokalsifikasyon Bölgelerinin Belirlenmesi .....	131
2.5.3.	Özellik Çıkarma ve Sınıflama .....	137
2.5.4.	MCs Tespiti Yanlış Pozitif İndirgeme .....	141
2.5.5.	Mikrokalsifikasyon İyi Huylu/Kötü Huylu Değerlendirilmesi .....	146
3.	BULGULAR VE İRDELEME.....	151
3.1.	Kitle Tespiti Sonuçları ve İstatistiksel Değerlendirme .....	151
3.2.	Kitle İyi Huylu/Kötü Huylu Değerlendirme Sonuçları ve İstatistiksel Değerlendirme .....	154
3.3.	Mikrokalsifikasyon Tespiti Sonuçları ve İstatistiksel Değerlendirme .....	156
3.4.	Mikrokalsifikasyon İyi Huylu/Kötü Huylu Değerlendirme Sonuçları ve İstatistiksel Değerlendirme .....	159
3.5.	Kitle Tespiti Algoritmasının MCs Görüntülerinde Test Sonuçları .....	161
3.6.	MCs Tespiti Algoritmasının Kitle Görüntülerinde Test Sonuçları .....	162
3.7.	Önerilen Algoritmaların Koşma Sürelerine İlişkin Değerlendirme .....	163
4.	SONUÇLAR .....	165
5.	ÖNERİLER.....	169
6.	KAYNAKLAR.....	170
7.	EKLER.....	185

ÖZGEÇMİŞ



Doktora Tezi

ÖZET

MAMOGRAFİ GÖRÜNTÜLERİNİN YORUMLANMASIYLA BİLGİSAYARLI  
TEŞHİS SİSTEMİNİN TASARIMI

Burçin KURT

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Prof. Dr. Vasif V. NABİYEV  
2014, 184 Sayfa, 4 Ek Sayfa

Bu çalışmada, mamografi görüntülerindeki meme kanserine neden olan kitle ve mikrokalsifikasyon olmak üzere en önemli iki anormalliğin tespiti ve bu anormalliklerin iyi huylu/kötü huylu değerlendirilmesi için yeni yaklaşımlar ortaya konularak bütün bir tespit ve teşhis sisteminin tasarımı gerçekleştirilmiştir. Burada, kitle görüntülerinin iyileştirilmesi için farklı yöntemlerin hibrid kullanımı ile özgün bir iyileştirme algoritması ve şüpheli kitle bölgelerinin belirlenmesinde kullanılan Havrda&Charvat entropisine dayalı bölütlemeye dinamik parametre kullanımı için formül geliştirilmiştir. Bununla birlikte, kitle tespiti için yeni bir yaklaşım olarak yapay sinir ağı ve olasılıklı sinir ağı yöntemleri kullanılmıştır. Benzer şekilde, mikrokalsifikasyonların tespiti için de yapay ve kademeli korelasyon sinir ağı yöntemleri kullanılmıştır. Tespit edilen kitle ve mikrokalsifikasyon bölgelerinin iyi huylu/kötü huylu değerlendirilmesi için sırasıyla K-ortalama ile tekli karar ağacı ve destek vektör makinası ile lineer diskriminant analiz yöntemlerinin hibrid kullanımları yeni yaklaşımlar olarak uygulanmıştır. Yapılan çalışmada kullanılan MIAS veritabanı üzerinde kitle tespiti için %84.5 duyarlılık, %99.5 özgüllük ve 0.254 FPPi; mikrokalsifikasyonların tespiti için %86 duyarlılık, %98.3 özgüllük ve 1.163 FPPi; kitle ve mikrokalsifikasyonların iyi huylu/kötü huylu doğru değerlendirme oranları sırasıyla ortalama %93.9 ve %100 olarak elde edilmiştir. Elde edilen sonuçların literatürdeki benzer çalışmalarla kıyaslanması gerçekleştirilerek üstünlükleri ortaya koyulmuştur.

**Anahtar Kelimeler:** Mamografi, Şüpheli kitle ve mikrokalsifikasyon bölgelerinin belirlenmesi, Kitle tespiti, Mikrokalsifikasyon tespiti, MIAS, Meme kanseri.

PhD. Thesis

## SUMMARY

### THE DESIGN OF COMPUTER DIAGNOSTIC SYSTEM WITH INTERPRETATION OF MAMMOGRAPHY IMAGES

Burçin KURT

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Computer Engineering Graduate Program  
Supervisor: Prof. Dr. Vasif V. NABIYEV  
2014, 184 Pages, 4 Pages Appendix

In this study, the design of a complete detection and diagnosis system for mammography images was carried out by putting new approaches for detecting the masses and microcalcifications which are the most important abnormalities that causes the breast cancer, and evaluating benignity/malignancy of these abnormalities. Here, with the use of different methods hybrid for mass images enhancement, an unique enhancement algorithm and with the use of a dynamic parameter in Havrda&Charvat entropy based segmentation for identifying suspicious mass regions, a formula have been developed. Furthermore, as a new approach for mass detection, artificial and probabilistic neural network methods were used. Similarly, for the detection of microcalcifications, artificial and cascade correlation neural network methods were used. For benign/malign evaluation of detected mass and microcalcification regions the hybrid use of K-Means with single decision tree and support vector machine with linear discriminant analysis methods were used respectively as a new approach. In this study, on MIAS database for mass detection 84.5% sensitivity, 99.5% specificity and 0.254 FPPi; for microcalcifications detection 86% sensitivity, 98.3% specificity and 1.163 FPPi; average accurate rates for benign/malign evaluation of mass and microcalcifications are respectively 93.9% and 100% were obtained. By performing the comparison of these obtained results on MIAS database with the similar studies in literature, advatages have been outlined.

**Key Words:** Mammography, Identification of suspicious mass and microcalcification regions, Mass detection, Microcalcification detection, MIAS, Breast cancer.

## ŞEKİLLER DİZİNİ

### Sayfa No

Şekil 1.1.	Geliştirilen MKKDS'ne ait genel şema.....	3
Şekil 1.2.	Geliştirilen MKKDS'ne ait detaylı şema.....	4
Şekil 1.3.	(a) MLO (b) CC mamografi görüntüleri (Lancaster Genel Hastanesi dergisi) .	7
Şekil 1.4.	Disk yapı elemanı .....	11
Şekil 1.5.	Dalgacık Dönüşümü .....	21
Şekil 1.6.	Sinyalin zaman tabanlı, frekans tabanlı ve <i>STFT</i> görünüşleri.....	22
Şekil 1.7.	(a) Sinüs dalgası (b) Bazı dalgacık türleri .....	23
Şekil 1.8.	Sürekli dalgacık dönüşümü .....	24
Şekil 1.9.	Ayrık sinyal $f(n)$ 'nin CMF ile ortogonal dalgacık dönüşümü (İki düzeyde genişleme) .....	25
Şekil 1.10.	CMF ile ters dalgacık dönüşümü (İki düzeyde genişleme).....	25
Şekil 1.11.	Üç seviye analiz için bir boyutlu ayrık diydik dalgacık dönüşümü ayrıştırma ve yeniden yapılandırma filtre bankası uygulaması ( $H_s^*(w)$ , $H_s(w)$ 'nin karmaşık eşleniğini gösterir) .....	27
Şekil 1.12.	İki seviye analiz için çok boyutlu ayrık diydik dalgacık dönüşümü (sol) ayrıştırma ve (sağ) yeniden yapılandırma filtre bankası uygulaması .....	28
Şekil 1.13.	Diydik dalgacık ayrıştırma ağacı örneği .....	28
Şekil 1.14.	Ayrık diydik dalgacık dönüşümü kullanılarak gürültü azaltma ve iyileştirme (Üç seviye ayrıştırma).....	30
Şekil 1.15.	Biortogonal 3.1 ayrışma ve yeniden yapılanma fonksiyonları.....	31
Şekil 1.16.	Biortogonal 3.1 ayrışma ve yeniden yapılanma filtreleri.....	31
Şekil 1.17.	(a) Orijinal görüntü (b) Histogram eşitleme sonucu.....	32
Şekil 1.18.	512x512'lik bir görüntünün 64 eşit kare bölgeleye ayrılmış yapısı ve etiketlenmesi.....	33
Şekil 1.19.	(a) Bir IR bölgesi komşuları ile (b) (i,j) bölgesinin 1. çeyreği ve ona en yakın dört bölge ile ilişkileri .....	34
Şekil 1.20.	Sağ BR bölgeleri ve komşulukları.....	34
Şekil 1.21.	Sol üst CR grubu bölgesi ve komşulukları.....	35
Şekil 1.22.	Difüzyon eşitliği için ayrık sayısal şema .....	36
Şekil 1.23.	Perona-Malik Tip I ile difüzyon sonuçları [44] $K=20$ ve $\Delta t = 0.2$ .....	37
Şekil 1.24.	Perona-Malik Tip II ile difüzyon sonuçları [44] $K=20$ ve $\Delta t = 0.2$ .....	38

Şekil 1.25.	Anormallik içeren mamografi görüntüleri .....	52
Şekil 1.26.	Farklı kitle örnekleri .....	52
Şekil 1.27.	Dört mesafeden ( $d$ ) ve dört açıdan ( $\theta$ ) GLCM ölçümünün geometrisi.....	54
Şekil 1.28.	5x5 boyutlu görüntü için GLCM matrisi .....	55
Şekil 1.29.	Ayırma düzleminin grafiksel gösterimi .....	58
Şekil 1.30.	(a) Doğrusal ayrılan (b) Doğrusal ayrılamayan küme grafikleri.....	59
Şekil 1.31.	PNN ağ yapısı.....	63
Şekil 1.32.	Kademeli korelasyon sinir ağı mimarisi .....	67
Şekil 1.33.	Daubechies 2 ölçekleme ve dalgacık fonksiyonları .....	72
Şekil 1.34.	Daubechies 2 ayırma ve yeniden yapılanma filtreleri.....	72
Şekil 1.35.	Karar ağacı örneği .....	75
Şekil 1.36.	4x4 boyutlu görüntüye ait GLRL matrisi.....	78
Şekil 2.1.	(a) Kadınlarda en sık görülen ilk 10 kanser (yaşa göre standardize edilmiş) (b) Meme kanserinin yaşa özel hızlarının dağılımı (2009 istatistikleri).....	83
Şekil 2.2.	Geliştirilen MKKDS sistemine ait şemalar .....	86
Şekil 2.3.	Meme bölgesinin bölütlenmesi için önerilen algoritma .....	89
Şekil 2.4.	(a) Orijinal görüntü (mdb265) (b) Medyan filtre uygulanmış ikili görüntü (c) Morfolojik açma işlemi ve bağlı bileşen etiketleme ile seçilen en büyük alan (d) Eritme ile kaba meme sınırı çıkarılmış görüntü (e) Meme bölgesi bölütlenmiş görüntü .....	90
Şekil 2.5.	(a) Orijinal görüntü (b) Meme bölgesi bölütleme program sonucu (c) GT görüntü .....	90
Şekil 2.6.	Pektoral kas bölgesinin çıkarılması için geliştirilen algoritma .....	92
Şekil 2.7.	Pektoral kas bölgesi örnekleri .....	93
Şekil 2.8.	(a) Meme bölgesi bölütlenmiş görüntü (b) Otsu $N=2$ eşiklenmiş ve etiketlenmiş görüntü (c) Pektoral kas bölütleme sonucu .....	94
Şekil 2.9.	(a) Meme bölgesi bölütlenmiş görüntü (b) Bölütleme sonucu belirlenen en büyük iki alan (c) Pektoral kas çıkarımı sonucu.....	95
Şekil 2.10.	Kitle tespiti için geliştirilen iyileştirme algoritması .....	97
Şekil 2.11.	(a) Orijinal görüntü (Mdb017) (b) Top-hat dönüşümü (c) Dalgacık tabanlı eşikleme (d) CLAHE (e) Anizotropik difüzyon filtreleme (f) İyileştirilmiş görüntü (g) İyileştirilmiş ve bölütlenmiş görüntü.....	98
Şekil 2.12.	(a) Orijinal görüntü (b) İyileştirilmiş ve bölütlenmiş görüntü .....	98
Şekil 2.13.	(a) Ayırıştırma seviyesi=1 (b) Ayırıştırma seviyesi=2 (c) Ayırıştırma seviyesi=3 (d) Ayırıştırma seviyesi=4 olan ayırıştırılmış ve dalgacık tabanlı eşikleme sonucu elde edilen görüntüler .....	100

Şekil 2.14.	Şüpheli kitle adayı bölgelerin belirlenmesine için geliştirilen algoritma .....	102
Şekil 2.15.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) $\alpha=0.2$ ve $t=183$ (d) $\alpha=0.4$ ve $t=151$ (e) $\alpha=0.7$ ve $t=133$ .....	103
Şekil 2.16.	Statik ve dinamik $\alpha$ değerleri için HC kriter fonksiyonu grafiği .....	104
Şekil 2.17.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (çerçeve kitle bölgesini göstermek için manuel çizilmiştir) (c) Havrda&Charvat entropisi ile bölütlenmiş görüntü (d) Pektoral kas çıkarılmış ve Havrda&Charvat entropisi ile bölütlenmiş görüntü .....	105
Şekil 2.18.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat ve Otsu $N=2$ eşikleme (d) Havrda&Charvat ve Otsu $N=3$ eşikleme.....	106
Şekil 2.19.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat entropi ve Otsu $N=3$ eşikleme (d) Renyi entropi ve Otsu $N=3$ eşikleme.....	108
Şekil 2.20.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat entropi ve Otsu $N=3$ eşikleme (d) Şüpheli kitle bölgesine ait şüpheli piksel sayısı .....	110
Şekil 2.21.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat entropi ve Otsu $N=3$ eşikleme (d) Şüpheli kitle adayı bölgelerin belirlenmesi.....	111
Şekil 2.22.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Şüpheli kitle adayı bölgelerin belirlenmesi (d) Elde edilen $80 \times 80$ boyutlu ROI bölge örnekleri .....	112
Şekil 2.23.	Bazı örneklere ait GLCM özellikleri .....	113
Şekil 2.24.	Kitle tespiti için geliştirilen algoritma .....	115
Şekil 2.25.	(a) Orijinal görüntü (b) Şüpheli kitle adayı bölgelerin belirlenmesi (c) ANN_1 ile sınıflama sonucu (d) Önerilen algoritma sonucu .....	116
Şekil 2.26.	(a) Kitle tespiti sınıflama sonucu üst üste gelen bölgeler (b) Çerçeve birleştirme algoritması sonucu elde edilen bölge .....	118
Şekil 2.27.	(a) Orijinal mamogram (çerçeve kitle bölgesini göstermektedir) (b) Kitle tespiti sonucu .....	118
Şekil 2.28.	Kitle tespiti FP indirgeme eğitim örneklerine ait elde edilen özellikler .....	120
Şekil 2.29.	(a) Orijinal görüntü (b) ANN_1 ve ANN_2 ile kitle tespit sonucu (c) (b)+PNN ile FP indirgeme sonucu.....	121
Şekil 2.30.	(a) Orijinal görüntü (b) Şüpheli kitle bölgelerinin belirlenmesi (pektoral kas çıkarılmış görüntüden) (c) (b)+Kitle tespiti sonucu (d) Şüpheli kitle bölgelerinin belirlenmesi (pektoral kas çıkarılmamış görüntüden) (e) (d)+Kitle tespiti sonucu .....	122
Şekil 2.31.	Kitle iyi huylu/kötü huylu değerlendirmesi eğitim örneklerine ait elde edilen özellikler .....	124

Şekil 2.32.	Kitle İyi huylu/kötü huylu değerlendirme için geliştirilen algoritma .....	126
Şekil 2.33.	(a) Orijinal görüntü (b) ANN_1 ve ANN_2 sonucu (c) (b)+PNN sonucu (d) (c)+İyi huylu/kötü huylu değerlendirme sonucu (TP bölgesi; 0.875 olasılıkla kötü huylu) .....	126
Şekil 2.34.	(a) Orijinal görüntü (b) Kitle tespiti ve iyi huylu/kötü huylu değerlendirme için önerilen sistem sonucu .....	127
Şekil 2.35.	(a) Orijinal görüntü (Mdb209) LogAMEE=37.19 (b) Top-hat dönüşümü LogAMEE=48.58 (c) Dalgacık tabanlı iyileştirme LogAMEE=76.13 (d) CLAHE LogAMEE=84.45.....	129
Şekil 2.36.	(a) Orijinal görüntü (Mdb209) (b) Top-hat dönüşümü (c) (b)+ Dalgacık tabanlı iyileştirme (d) (c)+CLAHE .....	130
Şekil 2.37.	(a) Orijinal görüntü (b) İyileştirilmiş ve bölütlenmiş görüntü .....	130
Şekil 2.38.	Şüpheli mikrokalsifikasyon bölgelerinin belirlenmesi için önerilen algoritma .....	131
Şekil 2.39.	(a) Bölütlenmiş ve iyileştirilmiş görüntü (b) Otsu N=3 eşikleme (c) (b)+Genleşme (d) Üstte kalan bölgenin çıkarılması (d) Şüpheli bölgelerin çerçevelemesi.....	132
Şekil 2.40.	Şüpheli MC bölgelerinin belirlenmesi için entropi ve bulanık tabanlı yaklaşımlar .....	133
Şekil 2.41.	(a) Bölütlenmiş ve iyileştirilmiş görüntü (Mdb213) (b) Tsallis entropi ve bulanık tabanlı iyileştirme (c) (b)+İteratif eşikleme sonucu .....	134
Şekil 2.42.	(a) Bölütlenmiş ve iyileştirilmiş görüntü (Mdb213) (b) Entropi ile bulanık tabanlı iyileştirme (c) (b)+ CLAHE (d) (c)+İteratif eşikleme (e) Şüpheli MC bölgelerinin çerçevelemesi .....	134
Şekil 2.43.	(a) Bölütlenmiş ve iyileştirilmiş görüntü (Mdb238) (b) Entropi ile bulanık tabanlı iyileştirme (c) (b)+ CLAHE (d) (c)+İteratif eşikleme .....	136
Şekil 2.44.	Bazı örneklere ait mikrokalsifikasyon tespiti için çıkarılan özellikler .....	137
Şekil 2.45.	(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Tsallis entropi ile bulanık tabanlı şüpheli bölgelerin belirlenmesi ve MCs tespit sonucu (d) Önerilen algoritma ile şüpheli bölgelerin belirlenmesi ve MCs tespit sonucu .....	140
Şekil 2.46.	MCs tespiti FP indirgeme eğitim örneklerine ait elde edile özellikler .....	142
Şekil 2.47.	(a) Orijinal görüntü (b) MCs tespit sonucu (c) (b)+CCNN_1 ile FP indirgeme sonucu .....	143
Şekil 2.48.	(a) Orijinal görüntü (b) Şüpheli MCs bölgelerinin belirlenmesi (pektoral kas çıkarma algoritması uygulanmış görüntü) (c) (b)+MCs tespiti sonucu (d) Şüpheli MCs bölgelerinin belirlenmesi (pektoral kas çıkarma algoritması uygulanmamış görüntü) (e) (d)+MCS tespiti sonucu .....	144

Şekil 2.49.	MCs iyi huylu/kötü huylu değerlendirmesi eğitim örneklerine ait elde edilen özellikler.....	146
Şekil 2.50.	MCs İyi huylu/kötü huylu değerlendirmesi için geliştirilen algoritma .....	148
Şekil 2.51.	(a) Orijinal görüntü (b) Mikrokalsifikasyonların tespiti ve iyi huylu/kötü huylu değerlendirme için önerilen sistem sonucu .....	149
Şekil 3.1.	Kitle tespiti aşamalarına ait istatistiksel değerlendirme sonuçları .....	152
Şekil 3.2.	Kitle tespiti için önerilen algoritmaya ait ROC eğrisi ve AUC (or Az (in mathematics), Area Under ROC Curve) .....	153
Şekil 3.3.	Kitle tespiti için önerilen algoritmaya ait FROC eğrisi.....	153
Şekil 3.4.	Kitle kanser tespitine ait ROC eğrisi ve AUC .....	155
Şekil 3.5.	MCs tespiti aşamalarına ait istatistiksel değerlendirme sonuçları .....	157
Şekil 3.6.	MCs tespiti için önerilen algoritmaya ait ROC eğrisi ve AUC.....	158
Şekil 3.7.	MCs tespiti için önerilen algoritmaya ait FROC eğrisi .....	158
Şekil 3.8.	MCs kanser tespitine ait ROC eğrisi ve AUC.....	160
Şekil 3.9.	MCs görüntülerinde kitle tespiti algoritması sonuçlarına ait grafik.....	162
Şekil 3.10.	Kitle görüntülerinde MCs tespiti algoritması sonuçlarına ait grafik .....	162

## TABLULAR DİZİNİ

	<b><u>Sayfa No</u></b>
Tablo 1.1.	GLCM özelliklerine ait formüller ve açıklamalar.....56
Tablo 1.2.	SVM çekirdek fonksiyonları.....60
Tablo 1.3.	İstatistiksel özelliklere ait formüller ve açıklamalar.....66
Tablo 1.4.	GLRLM özelliklerine ait formül ve açıklamalar.....79
Tablo 2.1.	Dünyada meme kanserinin en sık görüldüğü ilk 20 ülke (2012 istatistikleri).....84
Tablo 2.2.	MIAS veritabanı istatistikleri.....88
Tablo 2.3.	Meme bölgesi bölütleme performansının değerlendirilmesi.....92
Tablo 2.4.	Kitle tespiti için görüntü iyileştirme performansının değerlendirilmesi.....100
Tablo 2.5.	Farklı seviyelerde dalgacık tabanlı eşikleme performansının değerlendirilmesi.....102
Tablo 2.6.	Verilen örnekler için statik, dinamik $\alpha$ değerleri ve bunlara karşılık gelen eşik değerleri.....105
Tablo 2.7.	Kitle tespiti için geliştirilen SVM modellerine ait eğitim performansı sonuçları.....114
Tablo 2.8.	Kitle tespiti için geliştirilen SVM modellerine ait parametreler.....114



## SEMBOLLER DİZİNİ

AUC yada Az	: ROC eğrisi altındaki alan (Area under ROC curve)
BFGS	: Broyden, Fletcher, Goldfarb and Shanno
BI-RADS	: Meme görüntüleme raporlama ve veri sistemi (Breast imaging reporting and data system)
CAD	: Bilgisayar destekli tanı (Computer-aided diagnosis)
CADe	: Bilgisayar destekli tespit (Computer-aided detection)
CC	: Kademeli korelasyon (Cascade correlation)
CCL	: Bağlı bileşen etiketleme (Connected component labeling)
CCNN	: Kademeli korelasyon sinir ağı (Cascade correlation neural network)
CIRC	: Sınırlı kitleler (Well-defined/circumscribed masses)
CLAHE	: Kontrast sınırlı adaptif histogram eşitleme (Contrast limited adaptive histogram equalization)
CM	: Bütünlük (Completeness)
CR	: Doğruluk (Correctness)
FN	: Yanlış negatif (False negative)
FP	: Yanlış pozitif (False positive)
FPpI	: Görüntü başına FP değeri (False positive per image)
FPR	: Yanlış pozitif oranı (False positive ratio)
FROC	: Serbest tepkili ROC (Free-response ROC)
GLCM	: Gri seviye eş oluşum matrisi (Gray level co-occurrence matrix)
GLDS	: Gri seviye fark istatistikleri (Gray level difference statistics)
GLRLM	: Gri seviye dizi uzunluk matrisi (Gray level run length matrix)
GT	: Yer doğruluğu (Ground truth)
LDA	: Lineer diskriminant analiz (Linear discriminant analysis)
LogAME	: Logaritmik Michelson kontrast ölçüsü (Logarithmic Michelson contrast measure)
LogAMEE	: Entropi ile LogAME (LogAME by entropy)
MC	: Mikrokalsifikasyon (Microcalcification)
MCs	: Mikrokalsifikasyonlar (Microcalcifications)

MIAS	: Mamografik görüntü analiz derneği (Mammographic image analysis society)
MISC	: Diğer kitleler (Other, ill-defined masses)
MKKDS	: Meme kanseri karar destek sistemi
PLIP	: Parametrelili logaritmik görüntü işleme (Parameterized logarithmic image processing)
PNN	: Olasılıklı sinir ağı (Probabilistic neural network)
ROC	: Alıcı işletim karakteristiği (Receiver operating characteristic)
ROI	: İlgi alanı (Region of interest)
SDT	: Tekli karar ağacı (Single decision tree)
SPIC	: Speküle kitleler (Spiculated masses)
SVM	: Destek vektör makinesi (Support vector machine)
TN	: Doğru negatif (True negative)
ToWaCAD	: Kitle tespiti için geliştirilen iyileştirme algoritması
TP	: Doğru Pozitif (True Positive)
YSA	: Yapay sinir ağı (Artificial neural network)

## 1. GENEL BİLGİLER

### 1.1. Giriş

Kanser, hücrelerin büyümesini düzenlemede ve onları sağlıklı tutmada sorumlu olan genlerdeki mutasyonlar veya anormal değişiklikler sonucu ortaya çıkar. Normalde vücudumuzdaki hücreler düzenli bir büyüme süreci ile kendilerini değiştirirler: sağlıklı hücreler ölen eski hücrelerin yerini alır. Ancak zaman içinde bir hücrede belirli genlerde mutasyonlar görülebilir ve diğerlerinde görülmeyebilir. Bu değişim, hücreye kontrol ya da bir emir olmaksızın bölünme yeteneği kazandırır, bu şekilde kendileri gibi daha çok hücre üretme ve tümör oluşturma yeteneği kazandırır.

Bir tümör iyi huylu (sağlık için tehlikeli değil) ya da kötü huylu (tehlikeli olma potansiyeli olan) olabilir. İyi huylu (benign) tümörler kanser olarak değerlendirilmezler: görünüşleri normale yakındır, yavaş büyürler ve yakın dokulara hücum etmezler ya da vücudun diğer bölgelerine yayılmazlar. Kötü huylu (malignant) tümörler kanser gibidir ve kötü huylu hücreler nihayetinde orijinal tümörün ötesinde vücudun diğer bölümlerine kan damarları ve lenf kanalları yoluyla yayılabilirler [1]. Kanserinin nedeni genellikle belirlenemez. Ancak, hücrenin büyümesini kontrol eden kromozomdaki değişiklikler kanseri oluşturduğundan, bu değişiklikler aileden kalıtsal olarak gelebileceği gibi enfeksiyon, ilaç, sigara, kimyasal ve başka sebeplerden de olabilir.

Dünyada meme kanseri, tüm kanser vakalarının %25'i olmak üzere kadınlarda en önde gelen kanser türüdür [2]. Her yıl yaklaşık her 8 kadından 1'ine meme kanseri teşhisi konulmaktadır [1]. Erken teşhis, hayatta kalma oranı için oldukça önemlidir. Meme kanserine işaret eden en önemli anormallikler kitle ve mikrokalsifikasyonlardır [3]. BI-RADS (Breast Imaging Reporting and Data System)'a göre kitle, en az iki farklı projeksiyonda görülebilen toplu bir alan işgal eden lezyon olarak tanımlanır [3-5]. Kalsifikasyonlar, meme dokusundaki kalsiyum depolarıdır [6].

Mamogramlar, memenin X-ışını görüntüleridir ve radyologlara erken teşhiste yardımcı olmak için kullanılan en yaygın görüntüleme tekniğidir [6]. Kitleler oldukça ince bir yapıdadır ve genellikle meme dokusunun yoğun olduğu kısımlarda oluşur [3], bununla birlikte mikrokalsifikasyonların çapı 0,5-1mm arası çok küçük değerler olduğundan [6],


tüm bunlar teşhis işlemini zorlaştırmaktadır. Radyologlar için de oldukça fazla sayıda olan mamografi görüntülerini her zaman doğru ve aynı şekilde değerlendirmek oldukça zordur.

İnsan incelemesinin bazı kısıtlamaları vardır ve bunun sonucunda meme lezyonlarının %10-30'u rutin tarama esnasında kaçırılmaktadır [7]. Deneyimli radyologların bile doğru değerlendirme oranı %65-75 arasında değişmektedir [3]. Tanısal başarıyı arttırmak amacıyla, ilgili anormalliği tespit etmek ve sınıflamak için gelişmiş görüntü işleme ve örüntü tanımaya dayalı çeşitli bilgisayar destekli teknikler kullanılabilir. Böylece, tanı için radyoloğa ikinci bir görüş vererek yardımcı olabilir [6]. Bilgisayar destekli tanı (Computer Aided Diagnosis - CAD) sistemleri, medikal görüntüleri yorumlamada radyologlara yardımcı olmak için geliştirilmektedir. CAD sistemlerinin desteği ile okuyucu duyarlılığı ortalama %10 artabilmektedir [7]. Bununla birlikte, şüpheli kanser vakalarının %65-90 arası iyi huylu çıkmaktadır, bu nedenle iyi huylu/kötü huylu sınıflaması yapabilen bir CAD sistemi geliştirmek oldukça önemlidir [3].

Son zamanlarda, CAD sistemleri Amerika Birleşik Devletlerinde tarama merkezleri ve hastanelerde mamogramlar üzerinden meme kanseri tespiti için yapılan rutin klinik çalışmalarının bir parçası haline gelmiştir. Bu da CAD sistemlerinin farklı görüntüleme yöntemlerinden elde edilmiş medikal görüntülerdeki birçok farklı anormalliklerin tespit ve teşhisinde yaygın olarak uygulanmaya başlanacağını göstermektedir [8].

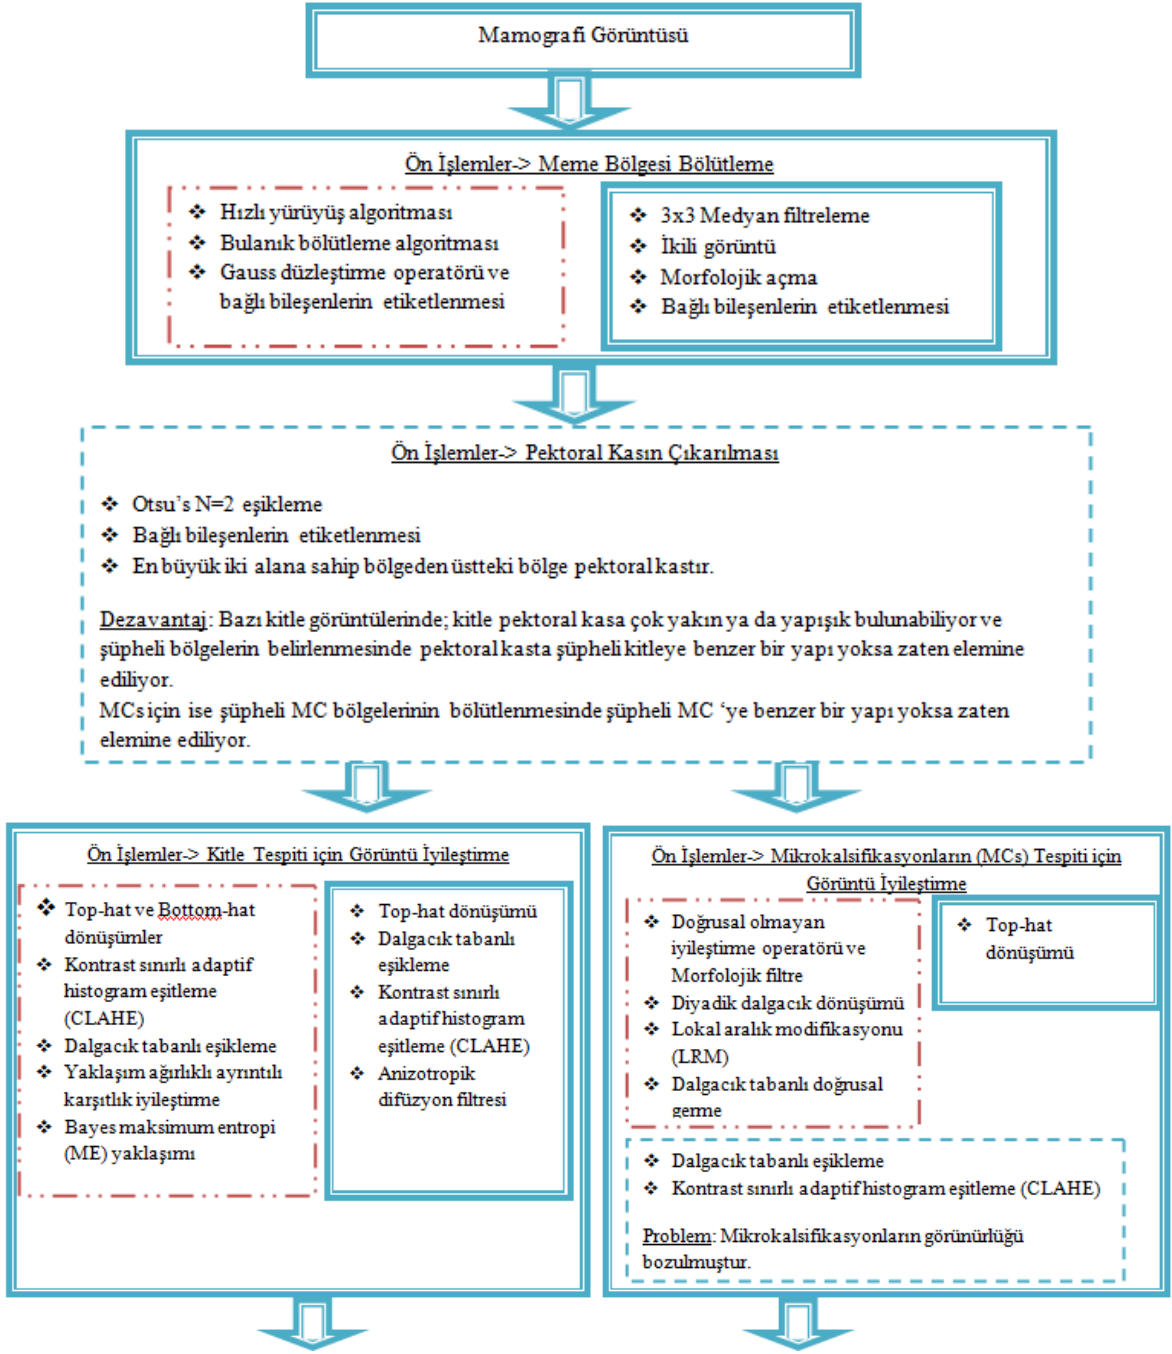
Tezin amacı mamografi görüntülerinde kitle ve mikrokalsifikasyonların tespiti ve iyi huylu/kötü huylu değerlendirmesi için yeni yaklaşımlar ortaya konulması, mevcut çalışmalarla kıyaslandığında kullanılan görüntü sayısının daha fazla olması ve bununla birlikte yüksek duyarlılık ve özgüllük değerlerinin elde edilmesidir.

Bu tez çalışmasında, mamografi görüntüleri üzerinde kitle ve mikrokalsifikasyonların tespitini ve iyi huylu/kötü huylu olasılığını değerlendiren akıllı bir meme kanseri CAD sistemi yani meme kanseri karar destek sistemi (MKKDS) geliştirilmiştir. Yapılan tez çalışması, Türkiye Cumhuriyeti Bilim, Teknoloji ve Sanayi Bakanlığı ile AKGÜN Yazılım tarafından STZ.2011-2 kodlu SANTEZ projesi olarak desteklenmiştir. Geliştirilen MKKD sistemi birçok aşamadan oluşan oldukça geniş ve karmaşık bir sistemdir. Sisteme ilişkin şemalar genel ve detaylı olmak üzere iki farklı şekilde aşağıda verilmiştir.



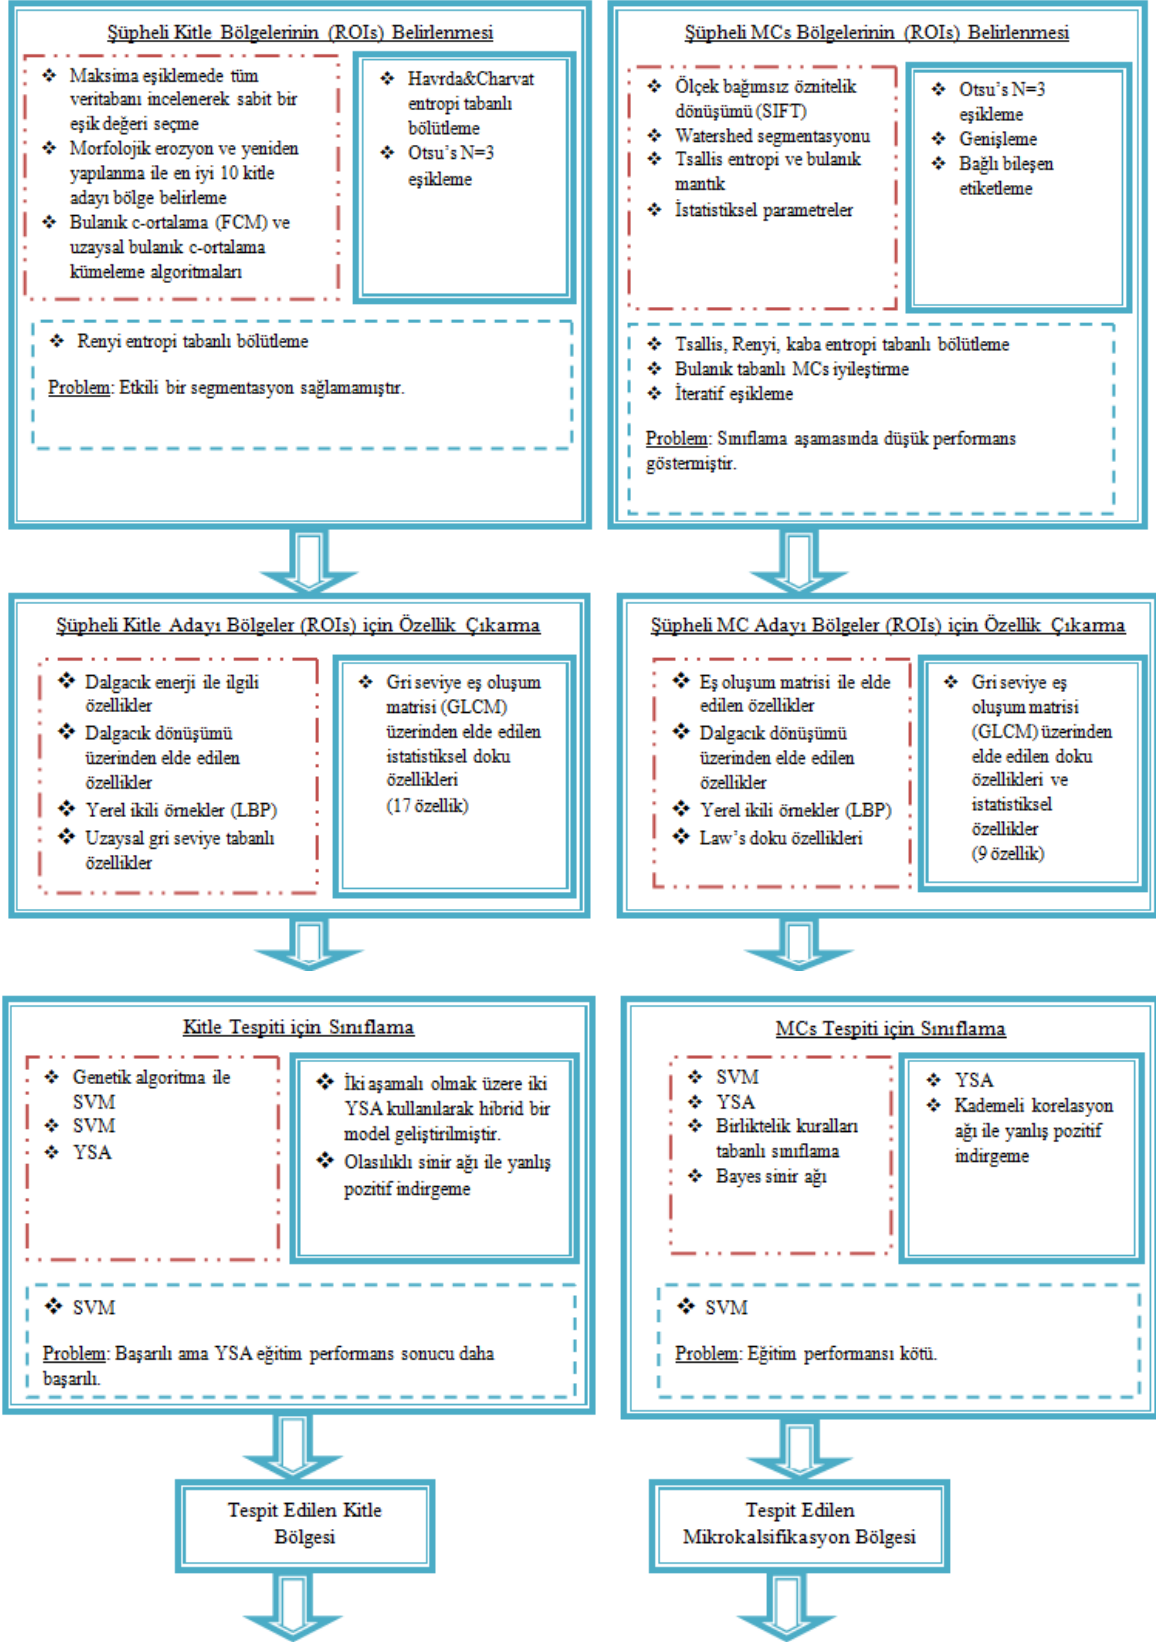
Şekil 1.1. Geliştirilen MKKDS'ne ait genel şema

Şekil 1.1.'de geliştirilen MKKD sistemine ait yapılan işlemler kabaca verilmiştir. Yapılan çalışmada, farklı yapıda anormallikler olan kitle ve mikrokalsifikasyonlar için aynı işlem adımlarını içeren farklı algoritmalar geliştirilmiştir. Buna göre, mamografi görüntüsü alındıktan sonra ön işlemler kısmında; meme bölgesinin bölütlenmesi, pektoral kasın çıkarılması, kitle ve mikrokalsifikasyon görüntülerinin iyileştirilmesi gerçekleştirilmektedir. Daha sonra şüpheli kitle ve mikrokalsifikasyon bölgeleri belirlenir. Belirlenen şüpheli kitle ve mikrokalsifikasyon bölgelerinin özellikleri çıkarılıp sınıflama yapılarak kitle ve mikrokalsifikasyonların tespiti gerçekleştirilir. Son olarak tespit edilen kitle ve mikrokalsifikasyon bölgelerinin özellikleri çıkarılıp sınıflanarak kitle ve mikrokalsifikasyonların iyi huylu/kötü huylu değerlendirmesi ile işlemler tamamlanır. Yapılan işlemlere ilişkin detaylar Şekil 1.2'deki şemada verilmiştir.

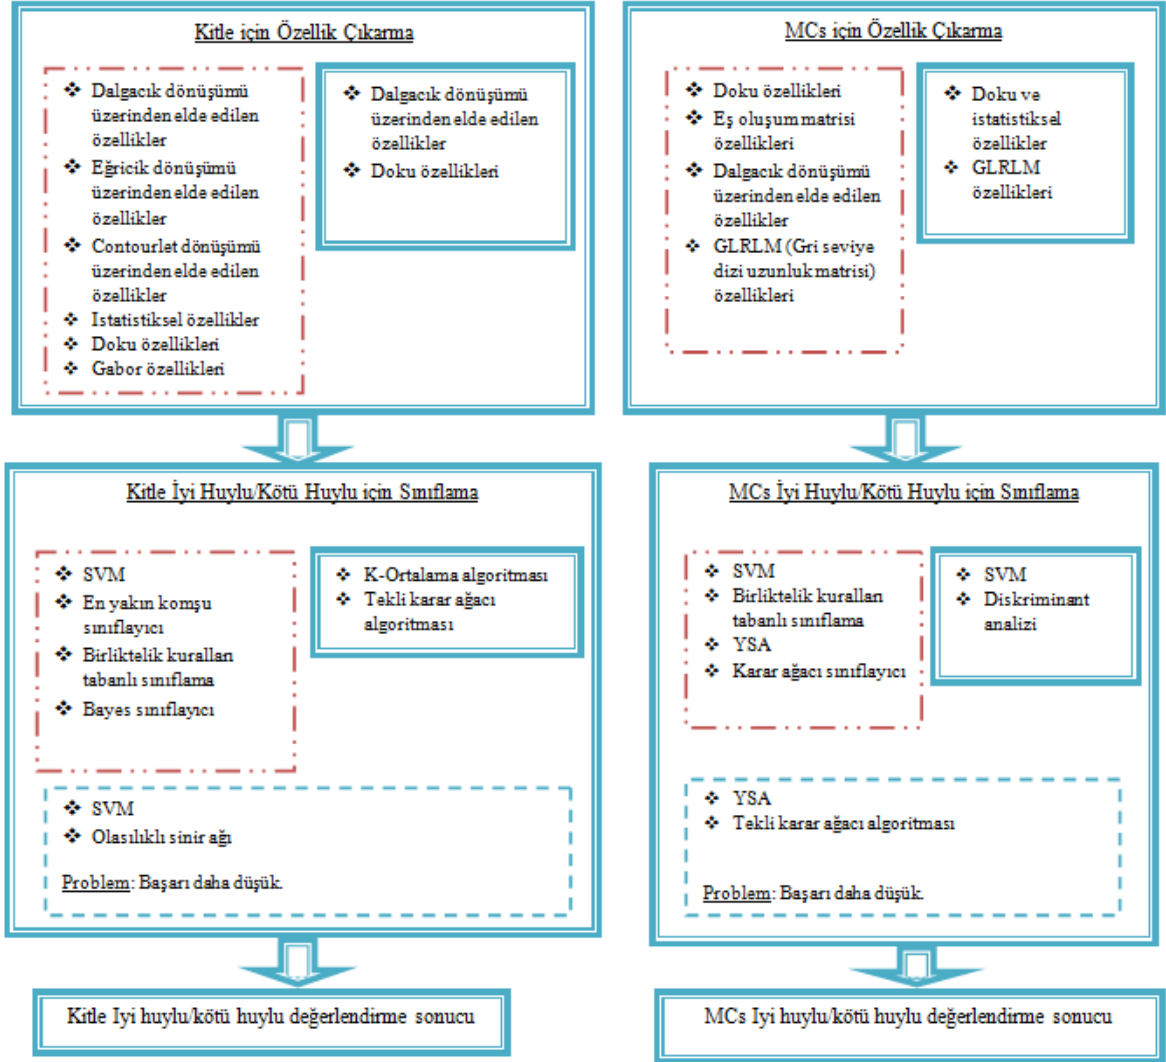


Şekil 1.2. Geliştirilen MKKDS'ne ait detaylı şema

Şekil 1.2.'nin devamı



Şekil 1.2.'nin devamı



Şekil 1.2.'de MKKDS'ne ait yapılan işlemler daha detaylı görülmektedir. Burada, kesikli ve iki noktalı çerçeve literatürde yer alan farklı çözüm yöntemlerinden bazılarını; sadece kesikli olan çerçeve ise tez çalışmasında yapılan ancak belirtilen sebeplerden dolayı sistemde kullanılmayan kısımları göstermektedir. Bu şekilde çalışmanın kapsamı ve akışı daha iyi anlaşılmaktadır. Sonraki bölümlerde akışta yer alan kısımlar detaylı bir biçimde anlatılacaktır.

## 1.2. Ön İşlemler


Mamografi görüntüleri genelde düşük görüntü kalitesine sahiptir ve meme dokusundan kaynaklı farklılıklar da anormalliklerin tespitini zorlaştırmaktadır. Bunların



yanında, görüntüde meme bölgesi dışında çekim gürültüleri, etiketler de bulunabilmektedir. Bunların sonucunda, görüntünün iyileştirilmesi ve istenmeyen bölgelerin elemine edilmesi için ön işlemler uygulanmıştır.

### 1.2.1. Meme Bölgesinin Bölütlenmesi

Mamografi görüntüleri resmin çekim aşamasına bağlı olarak iki temel grup altında toplanırlar. Bunlar, CC (Craino-Caudal) ve MLO (Mediolateral Oblique) görüntülerdir. CC tipi görüntüler, arka plan ve meme olmak üzere iki kısımdan oluşurken, MLO türü görüntüler arka plan, meme ve koltuk altı kası olmak üzere üç kısımdan oluşur. MLO görüntüler meme bölgesini daha kapsamlı içermektedir ve literatürde yaygın olarak kullanılmaktadır. Bu nedenlerle, çalışmada MLO türü görüntüler kullanılmıştır.



Şekil 1.3. (a) MLO (b) CC mamografi görüntüleri (Lancaster Genel Hastanesi dergisi)

Görüntü bölütleme yöntemlerinden en önemlisi görüntünün sadece parlaklık bilgisinin göz önüne alınması ile bölütleme işleminin gerçekleştirildiği eşikleme işlemidir. Bir diğer bölütleme işlemi de farklı yüzeylerin veya bölgelerin yan yana gelmeleriyle oluşan kenar bölgelerin bulunmasıdır. Bölütleme neticesinde sadece aranan bölümlerin tutulması ve

gereksiz kısımların görüntüden çıkarılması hedeflenir. Böylece gereksiz işlemler ve tüm görüntü üzerinde yapılan işlemler sonucu başarı düşüklüğü engellenir.

Meme sınırının tespiti, daha sonraki işlemler için gerekli olan ilgi alanının (Region of Interest-ROI) belirlenmesinde en önemli ön işlem adımıdır. Bununla birlikte mamogram çakıştırma uygulamalarının birçoğunda meme sınırı eşleştirilmekte, bu sebeple de bu çalışmalarda ilk adım, meme sınırı tespiti olmaktadır [9]. Boyut, şekil, doku, sıkıştırma oranı ve buna bağlı olarak yoğunluk değerleri gibi parametrelerin değişimlerinin yüksek olması ve meme sınırının çok düşük gri seviyesi değişimine sahip bir bölgede bulunması sebebiyle meme sınırının tespit edilmesi oldukça zordur. Ayrıca, sınır tespit metodlarının başarısı, görüntü elde edilmesi sırasındaki deri katlanmaları ve çekim hataları gibi şartlardan ve arka plan gürültüsünden çok etkilenmektedir.

Meme kenarı tespitinde son on yılda birçok metod sunulmuştur. Bu metotlardan ilki eşik alma yöntemidir. Kallergi ve arkadaşlarının [10], elle bölütleme yapmasıyla başlayan çalışmalar, Yin ve arkadaşları [11] ile Bick ve arkadaşlarının [12] eşik alma ve morfolojik işlemler uygulamalarıyla devam etmiş, Masek ve Attikiouzel [13, 14] ise mamogramlarda iteratif adaptif eşik alma işlemi gerçekleştirmiştir. Diğer yöntemlerle kıyaslandığında histogram ve eşik alma temelli yöntemler basittir ve hızlı çalışır. Ancak en iyi eşik değeri belirleme işlemi oldukça güçtür ve tek bir eşik değeri kullanımı çoğunlukla yetersizdir. Bu sebeple de iteratif olarak birden fazla eşik değeri seçilmesi veya bu uygulamanın adaptif olarak yapılması gerekmektedir. Bir başka çalışmada [15], yerel adaptif eşik alma yöntemi kullanılmıştır. Burada, en yüksek gri seviyeden en düşük gri seviyeye adım adım inilerek her bir gri seviye eşik değeri olarak uygulanmıştır ve eşik değeri, eşik alınmış görüntünün çevresinin karesi alanına bölünerek elde edilen sıklık (compactness) değerini en küçük değer olarak seçilir. Bu yaklaşımın doğruluk ve güvenilirlik yönünden iyi sonuçlar verdiği ifade edilmiştir.

Yapa ve arkadaşları [16], cilt sınırını ve meme bölgesini bölütleme için hızlı yürüyüş (fast marching) algoritmasını kullanan yeni bir algoritma geliştirmişlerdir. Geleneksel hızlı yürüyüş algoritması yerel görüntü gradyan bilgilere dayanmaktadır. Ancak, mamografi görüntülerindeki düşük karışıklık sebebiyle yerel gradyan bilgi, doğru cilt sınırı tahmini için yeterli değildir. Bununla birlikte, geleneksel hızlı yürüyüş algoritmasına göre hız fonksiyonuna dayalı görüntü sınırını durdurmaya yönelik gelişen ön beklenmektedir. Mamogramlar gibi düşük karışıklı ve gürültülü görüntüler için iyi çalışmamaktadır [16]. Bu nedenle, bu yaklaşımda gelişen önün istenilen sınıra yakın durması için bir kısıt

önerilmiştir. Bunun için istenilen sınır çizgisinde bir “bitiş noktası” atanır ve gelişen ön bu noktaya ulaştığında durur. Böylece, meme bölgesi ve sınırı doğru bir şekilde elde edilir. Bunlarla birlikte, gürültüyü azaltmak, istenmeyen etiketleri kaldırmak ve alanın homojenliğini geliştirmek için Gauss düzleştirme algoritması nitelik morfolojik operatörler kullanılarak ön işleme gerçekleştirilmiştir. Daha sonra önerilen hızlı yürüyüş algoritması ve sonra da sınırdaki sahte pikselleri kaldırmak ve düzgün bir sınır elde etmek için morfolojik işlemler kullanılmıştır [16]. Burada “bitiş noktası” için sabit bir kısıt olması bir dezavantajdır.

Wirth ve arkadaşları [17], meme bölgesini bölütleme için bulanık mantığa dayalı bir algoritma kullanmışlardır. Burada da, öncelikle gürültüleri bastırmak için morfolojik işlem uygulanmıştır ardından bulanık kural tabanlı algoritma ile meme dokusu bölgesi sınıflanmıştır. Bulanık tabanlı sınıflama için her piksel için belirtilen komşulukta sapmaların boyutu ile tutarsızlık standardı ölçek olarak hesaplanır ve bulanık karar kurallarına giriş olarak verilerek çıkış yani karar elde edilir [17]. Burada da bulanık karar kuralları belirlenirken kümelerle ilişkin değerler kullanılan veritabanına göre belirlendiğinden bir dezavantaj oluşturabilir. Bununla birlikte, her piksel için yapılan hesaplama da zaman açısından olumsuz bir etki oluşturmaktadır.

Bir başka çalışmada [18], global histogram hesaplanır ve Gauss operatörü ile düzleştirilir. N tane yüzde değeri belirlenerek bu değerlere karşılık gelen piksel parlaklıkları ( Örneğin %10, %15, %20 ve eşik değeri karşılıkları 220, 210, 200 ) ile N tane eşik değeri elde edilir. Her değer ile sırayla görüntü eşiklenir ve üst üste binen maskeler elde edilir. En küçük eşik değerinin sınırı ile en büyük eşik değerinin sınırı istatistiksel olarak değerlendirilir ve en son eşik değeri olarak ortalama gri seviye hesaplanır [18]. Daha sonra bağlı bileşenlerin etiketlenmesi (Connected Component Labeling-CCL) yöntemi kullanılarak en büyük alan meme bölgesi olarak belirlenmektedir.

Çalışmada, hızlı ve işlem karmaşıklığının az olması nedeniyle önerilen algoritma; medyan filtreleme, morfolojik açma işlemi, bağlı bileşen etiketleme ve başlangıç (kaba) meme sınırının çıkarımı işlemlerini birleştirir ve bu şekilde kaba meme sınırı ve buradan da meme bölgesi elde edilir [19].

### 1.2.1.1. Medyan Filtreleme

Medyan filtre doğrusal olmayan bir dijital filtreleme tekniğidir ve genellikle gürültülerin kaldırılması için kullanılır. Bu tür bir gürültü azaltma yöntemi daha sonraki işlemler için bir ön işleme adıdır. Medyan filtreleme gürültüyü kaldırırken kenarları da koruduğundan oldukça yaygın kullanılan bir görüntü işleme tekniğidir [20]. Burada 3x3 boyutlu penceredeki piksel gri seviye değerleri küçükten büyüğe doğru sıralanır ve orta değer, merkez pikselin yeni gri seviye değeri olarak atanır.

Medyan filtreleme işleminden sonra bir sonraki aşamada morfolojik işlem için ikili görüntü oluşturulur. İkili görüntü elde etmek için mamogram görüntüsü piksel değerlerinin ortalaması eşik değeri olarak kullanılmaktadır.

### 1.2.1.2. Matematiksel Morfoloji

Matematiksel morfoloji, imgenin şekilsel yapısına dayanan kümeler teorisine üzerine kurulmuş bir yaklaşımdır. Matematiksel morfoloji teorisinin temelleri ilk olarak Georges Matheron ve Jean Serra [21] tarafından 1980'li yıllarda atılmıştır. Bu metodun temelinde iki morfolojik operatör olan aşınma ve genişleme yatmaktadır. Aşınma işlemi kümeler cebirinde kesişim işlemine, genişleme işlemi ise kümeler cebirinde birleşim işlemine denk düşmektedir [22]. Bu temel işlemler aşağıdaki denklemlerle tanımlanmaktadır.

$$X \oplus B = \{p \in Z^2: p = x + b, x \in X, b \in B\} \text{ (genişleme)} \quad (1.1)$$

$$X \ominus B = \{p \in Z^2: p + b \in X, \forall b \in B\} \text{ (aşınma)} \quad (1.2)$$

İmge üzerinde aşınma işleminin hemen ardından genişleme işlenmesi uygulanması sonucu açma işlemi elde edilir. İmge içerisindeki nesnelere ve nesnelere arasındaki boşluklar yapısal elemanın büyüklüğüne göre temizlenir. İmge üzerinde kalan nesnelere orijinal imgedeki şekillerinden biraz daha küçük hale gelir. Açma işlemi ile birbirine yakın iki nesne imgede fazla değişime sebebiyet vermeden ayrılmış olurlar [22]. İkili açma işlemi denklem 1.3 ile tanımlanmaktadır.

$$A \circ B = (A \ominus B) \oplus B \quad (1.3)$$

Genel olarak, en büyük alana sahip nesne meme bölgesidir ve diğerleri bilgi plakaları ya da gürültüler olabilir. Önerilen algoritmada, daha iyi ve daha basit bir ikili meme görüntüsünün elde edilmesi için morfolojik açma işlemi uygulanmaktadır. Böylece nesne bölgelerindeki meme olmayan bölgelerin bir kısmı silinebilir. Burada morfolojik açma işlemi için kullanılan yapı elemanı yarıçapı 2 piksel olan bir diskdir.

$$\begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Şekil 1.4. Disk yapı elemanı

### 1.2.1.3. Bağlı Bileşen Etiketleme

Bağlı bileşen etiketleme bilgisayar ile görmede ikili görüntülerdeki bağlı bölgeleri bulmak için kullanılmaktadır. Bununla birlikte, renkli görüntülerde ve yüksek boyutlu veriler de kullanılabilir [23]. Bağlı bileşen etiketleme algoritması aşağıdaki gibidir.

Bağlı Bileşen Etiketleme Algoritması:

- 1.Tarama
  - Adım 1. Her piksel için önce sütun sonra satır yoluyla incele
  - Adım 2. Eğer piksel arka plana ait değilse
  - Adım 3. O pikselin komşu piksellerini al
  - Adım 4. Komşu piksellerin hiç biri etiketlenmemiş ise o piksel için yeni bir etiket ata
  - Adım 5. Komşu pikseller etiketlenmiş ise en küçük etiket değerini o piksel için ata
- 2.Tarama
  - Adım 1. Her piksel için önce sütun sonra satır yoluyla incele
  - Adım 2. Eğer piksel arka plana ait değilse
  - Adım 3. O pikselin etiketini komşularındaki en küçük etiket değeri ile değiştir

Etiketleme işleminden sonra bağımsız bölgeler belirlenmiş olur. İkili görüntüde etiketleme işleminden sonra halen birçok meme olmayan nesne bulunmaktadır ancak bunların boyutları meme nesnesinin boyutundan daha küçüktür. Önerilen algoritma, nesnelere etiketlemek için mamogramdaki meme bölgesinin karakteristiğini kullanır ve en büyük boyutlu nesneyi meme bölgesi olarak çıkarır. Böylece geriye kalan nesnelere arka plan olarak belirlenir. Elde edilen ikili görüntüde meme ve arka plan olmak üzere iki bölge bulunmaktadır. Bu görüntüden, görüntüye morfolojik eritme uygulanarak elde edilen görüntü çıkarılarak başlangıç meme sınırı kaba bir şekilde belirlenir.

Meme sınırı belirlendikten sonra meme bölgesi kolayca bölümlenebilir ve böylece istenmeyen etiketler, çekim gürültüleri de elenmiş olur. Bunun sonucunda, işlem karmaşıklığı az, hızlı ve başarılı sonuçlar veren bir algoritma gerçekleştirilmiştir.

#### **1.2.1.4. Meme Bölgesi Bölütleme Performansının Değerlendirilmesi**

Belirli bir veritabanı üzerinde algoritmanın performansı; doğruluk, güvenilirlik ve sağlamlık gibi performans göstergeleri ile karakterize edilebilir. Bunlardan ilki olan doğruluk, algoritmanın geçerlilik ve doğruluk derecesi ile ilgilidir. Doğruluk genellikle hesaplanan değerler ve manuel olarak belirlenen meme bölgesi (Ground Truth- GT) arasındaki fark olarak tanımlanır. Algoritma, geniş sayıda test durumu üzerinde doğru sonuçlar üretir ise güvenilir sayılır. Sağlamlık ise algoritmanın, örneğin radyopak artefaktlar (mikroskopik, radyolojik ve ultrasonografik incelemelerde, insan eliyle oluşturulmuş, yapay yapı veya görünüm) gibi çeşitli durumları tolere etme kapasitesi ile ilgilidir. Ayrıca sağlamlık, algoritma çeşitli test dizilerine ve farklı mamogramlara uygulanarak değerlendirilebilir. Performans göstergeleri, verilen algoritmanın performansını niceleyici olarak belirlemek için hesaplanabilir ölçümler gerektirmektedir [24].

Bölütleme algoritmalarının, deneysel sonuçlarda değerlendirilmesi için iki performans ölçümü tanımlanmıştır. Bölütleme algoritması ile çıkarılan bölgenin GT ile eşleşen kısmı doğru pozitif (True Positive-TP) olarak ifade edilir yani algoritmanın meme bölgesi olarak tespit ettiği kısmı göstermektedir. GT'da bulunan ancak algoritma ile tespit edilemeyen pikseller yanlış negatif (False Negative-FN) sınıflamalar olarak ifade edilir. Bu pikseller meme bölgesinde eksik sayılır. Bu durumun tam tersi yani GT'da yer almayan

ancak algoritma sonucunda bulunan pikseller ise yanlış pozitif (False Positive-FP) olarak ifade edilir.

Bunların sonucunda, bütünlük ve doğruluk olmak üzere iki ölçüm türetilir ve bu ölçümler için optimum değer 1'dir [24]. Bütünlük, bölütlenen bölge tarafından açıklanan GT bölgesinin yüzdesini, doğruluk ise doğru çıkarılan meme bölgesinin yüzdesini temsil etmektedir.

$$\text{Bütünlük (CM)} \approx \frac{TP}{TP+FN} \quad (1.4)$$

$$\text{Doğruluk (CR)} \approx \frac{TP}{TP+FP} \quad (1.5)$$

Bütünlük ve doğruluk yüzdeleri %95'ten büyük ise algoritma doğru kabul edilmektedir [17]. Bu iki ölçütün, tek bir ölçütte birleştirilmesiyle, optimum değeri 1 olan genel bir ölçüt elde edilebilir ve aşağıdaki gibi ifade edilmektedir.

$$\text{Kalite (quality)} \approx \frac{TP}{TP+FN+FP} \quad (1.6)$$

Böylece bölütleme algoritması sonucu elde edilen görüntü ile GT görüntüsü kullanılarak TP, FP, FN değerleri ve bu değerler kullanılarak CM ve CR değerlendirme ölçütleri hesaplanır. Elde edilen sonuçlara göre performansı ve algoritmanın doğruluğu, güvenilirliği hakkında bilgi edinilebilir. Algoritmanın aşamalarına ve sonuçlara ilişkin detaylar ilerleyen bölümlerde anlatılacaktır.

### 1.2.2. Pektoral Kasın (Koltuk Altı Bölgesi) Çıkarılması

Pektoral kas, mamogramların çoğunda baskın yoğunluklu bölgeyi temsil eder ve bu yüzden pektoral kasın çıkarılması, yanlış bölge bölütlenmesinin azaltılmasında etkilidir. Malagelada tarafından [25] yapılan doktora tezinde, mamografi görüntüleri üzerinden otomatik kitle segmentasyonu gerçekleştirilmektedir. Burada, pektoral kasın çıkarılması için bölge büyüyen (region growing) algoritması kullanılmıştır. Mamogram histogramında meme dokusu orta gri seviye değerlerini, etiketler ve koltuk altı bölgesi ise yüksek gri seviye değerlerini göstermektedir. Bölge büyüyen algoritmasının çekirdek değeri

histogramdaki iki bölge arasındaki maksimum ve minimum parlaklık değerleri arasında bir değer alınır. Daha sonra bölge büyüyen yaklaşımı ile pikselin parlaklık değerine göre pektoral kas bölgesine ait olup olmadığına karar verilir. Sonra da morfolojik işlemler uygulanır [25]. Bir diğer çalışmada, dijital mamografi görüntülerinde pektoral kas bölgesinin bastırılması ile meme ve arka plan bölgelerinin bölütlenmesinden bahsedilmiştir. Yapılan bu çalışmada [18] bölge büyüyen algoritması ile pektoral kas bölgesi bastırılmıştır. Ancak, bazı mamogramlarda koltuk altı ya oldukça küçük ya da neredeyse hiç çıkmayabilir. Bu durumda, histogram tepe değerlerinde farklılıklar olacaktır ve bunun sonucunda da meme bölgesinden bir kısım pektoral kas bölgesi olarak çıkarılabilir. Bu da istenmeyen bir sonuçtur.

Byung ve arkadaşları [26], izo kontör haritası olarak adlandırılan topografik yaklaşım kullanmışlardır. Buna göre, belirgin bölgeler, kontörlerin derin yarı konsantrik modelini oluştururlar. Kontörler arası ilişkilerin hiyerarşik bir biçimde gösterildiği temsili bir ağaç yardımıyla görüntülerin topolojik ve geometrik yapıları incelenir. Bölgenin çıkıklığı, topolojik olarak minimum yuvalama derinliği diye ölçülür. Mamogramların izo kontör haritaları üzerinden minimum yuvalama derinlikli temel kontörler yardımıyla meme ve pektoral kas bölgeleri bölütlenmiştir. Deneysel sonuçlara göre önerilen sistemin kitle tespitinde de kullanılabileceği gösterilmiştir. Dezavantajı ise uzun ve karmaşık hesaplamalarıdır.

Çalışmada, pektoral kas çıkarımı için Otsu N eşikleme (Otsu's N thresholding) metodu kullanılmıştır. Daha sonra bağlı bileşen etiketleme yöntemi ile bölütlenen bölgeler etiketlenmiştir ve en büyük iki bölgeden (bunlardan biri pektoral kas diğeri eş yoğunluklu olan bölge) üstte kalan bölge pektoral kas olarak seçilir (pektoral kas üst kısımda kaldığı için). Ancak, bazı mamogramlarda pektoral kas görüntüde yer almayabilir nadiren ya da bazılarında yumuşak meme dokusu ile pektoral kasın birleşik olarak aynı yoğunlukta olduğu durumlarda, elde edilen üst bölge pektoral kas ile yumuşak meme dokusunun yapışık hali olacağından pektoral kas çıkarımı mümkün olmayabilir.

Bu gibi durumlarda meme bölgesinin de yanlışlıkla çıkarılmasını önlemek için bir alan kontrolü gerçekleştirilmiştir. Elde edilen üst bölge belli bir değerin üstünde ise (pektoral kas olamayacak kadar büyük ise) pektoral kas çıkarımı yapılmaz. Aksi halde elde edilen bölge pektoral kastır. Algoritma ve sonuçlara ilişkin detaylı bilgi ilerleyen bölümlerde verilecektir.



### 1.2.2.1. Otsu N Eşikleme

Otsu N eşikleme, optimum eşik değerleri kullanarak görüntüyü sınıflara bölen otomatik bir eşik değeri seçme yöntemidir. Bu yöntem, gri seviye histogramının sadece sıfır ve birinci kümülatif momentlerini kullanır ve bunu gerçekleştirmek de karmaşık değildir [27]. Gri seviye değerleri  $[0, 1, 2, \dots, L-1]$  olan bir görüntümüz olsun. Görüntüyü  $C_1$  ve  $C_2$  olmak üzere iki sınıfa ayıracak şekilde bir  $k$ ,  $0 < k < L-1$ , eşik değeri seçelim.  $C_1$ , yoğunluk değerleri  $[0, k]$  arasında olan pikselleri,  $C_2$  ise yoğunluk değerleri  $[k+1, L-1]$  arasında olan pikselleri içermektedir. Bir pikselin  $C_1$  sınıfına ait olma olasılığı  $P_1(k)$ ,  $k$  eşik değeri kullanılarak kümülatif toplam ile hesaplanabilir.

$$P_1(k) = \sum_{i=0}^k P_i \quad (1.7)$$

Benzer şekilde,  $C_2$  sınıfının olasılığı  $P_2(k)$ 'dir.

$$P_2(k) = \sum_{i=k+1}^{L-1} P_i = 1 - P_1(k) \quad (1.8)$$

$C_1$  ve  $C_2$  sınıflarına atanan piksellerin ortalama yoğunluk değerleri aşağıdaki gibidir.

$$m_1(k) = \frac{1}{P_1(k)} \sum_{i=0}^k i P_i \quad (1.9)$$

$$m_2(k) = \frac{1}{P_2(k)} \sum_{i=k+1}^{L-1} i P_i \quad (1.10)$$

Global ortalama ise,

$$m_G = \sum_{i=0}^{L-1} i P_i \quad (1.11)$$

Burada amaç, aşağıdaki kriteri maksimize edebilecek optimum  $k$  değerini bulmaktır.

$$y(k) = \frac{\sigma_B^2(k)}{\sigma_G^2} \quad (1.12)$$

Burada,  $\sigma_B^2(k)$  sınıfın varyansını göstermektedir ve aşağıdaki gibi ifade edilir.

$$\sigma_B^2(k) = P_1(m_1 - m_G)^2 + P_2(m_2 - m_G)^2 \quad (1.13)$$

Ve  $\sigma_G^2$  ise global varyansı göstermektedir ve aşağıdaki formülle ifade edilir.

$$\sigma_G^2 = \sum_{i=0}^{L-1} (i - m_G)^2 P_i \quad (1.14)$$

Böylece,  $\sigma_B^2(k)$  değerini maksimize eden optimum eşik değeri  $k$  elde edilir.

Örneğin Otsu N=3 eşikleme için algoritma adımları aşağıdaki gibidir. Burada,  $k_1, k_2, k_3$  olmak üzere 3 eşik değeri elde edilir ve bu değerler kullanılarak görüntü 4 sınıfa bölütlenir.

Otsu N=3 Eşikleme Algoritması:

*Adım 1.* Giriş görüntüsünün normalize histogramı hesaplanır. Histogram elemanları  $P_i, i=0,1,2,\dots,L-1$  ile gösterilir ve burada  $L$  gri seviye değerlerinin sayısını göstermektedir.

*Adım 2.*  $k_1, k_2$  ve  $k_3$  eşik değerleri kullanılarak 4 sınıf için kümülatif toplam,  $P_1, P_2, P_3, P_4$  hesaplanır.

$$P_1 = \sum_{i=0}^{k_1} P_i \quad P_2 = \sum_{i=k_1+1}^{k_2} P_i \quad (1.15)$$

$$P_3 = \sum_{i=k_2+1}^{k_3} P_i \quad P_4 = \sum_{i=k_3+1}^{L-1} P_i$$

*Adım 3.* Aşağıdaki formül kullanılarak global yoğunluğun ortalaması,  $m_G$ , formül (1.11) ile hesaplanır.

*Adım 4.* Aşağıdaki formüller ile sınıflar için ortalama yoğunluk değerleri hesaplanır.

$$m_1 = \frac{1}{P_1} \sum_{i=0}^{k_1} i P_i \quad m_2 = \frac{1}{P_2} \sum_{i=k_1+1}^{k_2} i P_i$$

$$m_3 = \frac{1}{P_3} \sum_{i=k_2+1}^{k_3} i P_i \quad m_4 = \frac{1}{P_4} \sum_{i=k_3+1}^{L-1} i P_i \quad (1.16)$$

*Adım 5.* Sınıflar arası varyans aşağıdaki gibi hesaplanır.

$$\sigma_\beta^2(k_1, k_2, k_3) = P_1(m_1 - m_G)^2 + P_2(m_2 - m_G)^2 + P_3(m_3 - m_G)^2 + P_4(m_4 - m_G)^2$$

$$\sigma_\beta^2(k_1, k_2, k_3), \begin{cases} k_1 = 1, \dots, k_2 - 1 \\ k_2 = k_1 + 1, \dots, k_3 - 1 \\ k_3 = k_2 + 1, \dots, L - 2 \end{cases} \quad (1.17)$$

*Adım 6.* Optimum eşik değerleri sınıflar arası varyansı maksimize eden değere karşılık olan değerlerdir.

$$\sigma_\beta^2(k_1, k_2, k_3), \max \sigma_\beta^2(k_1, k_2, k_3), 0 < k_1 < k_2 < k_3 < L - 1 \quad (1.18)$$

Eğer bu maksimum değer tek değilse bu durumda bu maksimum değerlere karşılık gelen değerlerin ortalaması alınarak optimum k değeri elde edilir.

Çalışmada pektoral kasın çıkarılması için Otsu N=2 eşikleme kullanılmıştır. Buna göre görüntü koltuk altı, meme bölgesinin iç kısmı ve arka plan olmak üzere üç sınıfa ayrılmaktadır. Böylece pektoral kas çıkarılmış olur ancak bazı kitle görüntülerinde; kitle pektoral kasa çok yakın ya da yapışık bulunabiliyor ve ileriki aşama olan şüpheli bölgelerin belirlenmesinde pektoral kasta şüpheli kitleye benzer bir yapı yoksa elemine edildiği görülmüştür. Aynı şekilde mikrokalsifikasyonlar (MCs) için de ileriki aşama olan şüpheli MC bölgelerinin bölütlenmesinde şüpheli MC'ye benzer bir yapı yoksa elemine edildiği görülmüştür. Bu nedenlerden dolayı bu kısım daha sonra kaldırılmıştır. Sonuçlar ve ayrıntılar ilerleyen bölümlerde verilecektir.

### 1.2.3. Mamografi Görüntülerinin İyileştirilmesi

Mamografi görüntüleri çoğunlukla düşük kontrastlık ve nispeten yüksek gürültü içeriği ile karakterize edilir. Bu, mamografi görüntülerinde şüpheli bölgelerin belirlenmesi işlemini zorlaştırır. Bu yüzden, dijital mamogramlarda şüpheli bölgelerin belirlenmesi işleminin gerçekleşmesinden önce görüntü iyileştirme işlemine ihtiyaç vardır. İyileştirme;

karşıtlık iyileştirme, gürültülerin kaldırılması ve kenarların iyileştirilmesi olarak gerçekleştirilebilir. Karşıtlık iyileştirme filtrelerinin uygulanması, karşıtlıkta gizli değişiklikler içeren alanların okunabilirliğini arttırabilir [28]. Mamografi görüntülerinin iyileştirilmesi için geniş bir literatür taraması yapılmıştır.

Alhadidi [29] ve arkadaşları tarafından yapılan çalışmada MATLAB fonksiyonları yardımı ile elmas şeklinde bir yapı elementi kullanılarak mamografi görüntülerine erime ve genişleme işlemleri uygulanmıştır. Daha sonra sırasıyla görüntünün top-hat ve bottom-hat dönüşümleri elde edilmiştir. Görüntüdeki nesnelere ve boşluklar arasındaki karşıtlığı maksimize etmek ve onları birbirinden ayırmak için orijinal görüntü, top-hat dönüşümü gerçekleştirilen görüntü ile toplanır ve elde edilen görüntüden bottom-hat dönüşümü gerçekleştirilmiş görüntü çıkarılır. Böylece iyileştirilmiş görüntü elde edilir.

Yerel karşıtlığın, yerel yoğunluk tarafından değiştirilmesi düşüncesine dayalı yoğunluk ağırlıklı karşıtlık iyileştirme (Density-Weighted Contrast Enhancement-DWCE) yönteminin, Gauss filtresinin varyansının deneysel olarak tanımlanması ve bununla birlikte varyanstaki küçük çeşitliliklerin karşıtlık iyileştirme performansını etkilemesi (farklı boyutlarda düşük karşıtlıklı yapılar oluşabilir) gibi dezavantajlarının olmasından dolayı Zhuangzhi [30] ve arkadaşları yaklaşım ağırlıklı ayrıntılı karşıtlık iyileştirme (An Approximation-Weighted Detail Contrast Enhancement-AWDCE) yöntemini geliştirmişlerdir. Bu yöntem, Gauss filtreleme yerine çoklu seviyede Daubechies dalgacık dönüşümü ve detaylı görüntünün, yaklaşım görüntüsü ile çarpımını içermektedir. AWDCE filtreleme, faktör tarafından seçilen seviyelerdeki detay görüntülerdeki her pikselin ağırlıklandırılması ile gerçekleştirilir. Bu sebeple, bu yöntem ile farklı ölçeklerdeki kitle karşıtlığı iyileştirilebilir ve işlemler hızlanabilir. Ve son olarak morfolojik işlemler olan top-hat ve bottom-hat dönüşümleri uygulanmıştır. Bunların sonucunda iyileştirmenin yapıldığı ancak görüntüdeki gürültülerin de arttığı görülmüştür.

Yosvany [31] ve arkadaşları tarafından yapılan “Meme Kanseri Patolojik Lezyonlarının Tespiti İçin Geliştirilen Bilgisayar Destekli Teşhis Sistemi” çalışmasında kontrast sınırlı adaptif histogram eşitleme (Contrast Limited Adaptive Histogram Equalization-CLAHE) algoritması kullanılmıştır. Bu, adaptif histogram eşitleme (Adaptive Histogram Equalization-AHE) algoritmaları olarak bilinen sınıfın bir alt tipidir. CLAHE algoritması, görüntüyü içeriksel (döşeme olarak adlandırılan) bölgelere böler ve her bir bölgeye histogram eşitleme işlemini uygular. Bu, kullanılan gri değerlerin dağılımını düzenler ve böylece görüntüdeki gizli özellikleri daha görünür kılar. Yapay sınırların

kaldırılması için komşu bölgeler bilineer interpolasyon kullanılarak birleştirilir. Karşıtlık, özellikle homojen bölgelerdeki, görüntüdeki herhangi bir gürültüyü yükseltmekten kaçınmak için sınırlanabilir. Bu yaklaşım şüpheli bölgelerin iyileştirilmesinde kullanılmıştır.

Bir başka çalışmada [28], dijital mamografi görüntülerinin iyileştirilmesi için dalgacık tabanlı eşikleme yöntemi kullanılmıştır. Burada, karşıtlık iyileştirme için matematiksel morfoloji ve dalgacık tabanlı eşiklendirme metotları kullanılmıştır. Daha sonra önerilen metot VisuShrink ve BayesShrink karşıtlık iyileştirme teknikleri ile karşılaştırılmıştır. Geliştirilen algoritmanın daha üstün bir görüntü kalitesi ve daha yüksek karşıtlık geliştirme indeksi (CII) değerleri gösterdiğinden bahsedilmektedir. Çalışmada geliştirilen iyileştirme algoritmasında, ilk aşamada top-hat dönüşümü kullanılmıştır, daha sonra dalgacık ayrıştırma yöntemi uygulanmıştır ve ayrıştırma (dalgacık dönüşümü) sonucu elde edilen detay katsayıları eşik değeri kullanılarak filtrelenmiştir. Böylece gürültüler kaldırılır ve son olarak dalgacık yeniden yapılandırma (ters dalgacık dönüşümü) yöntemi ile gürültüleri elenmiş, iyileştirilmiş görüntü elde edilir.

Radu Mutihac [32], dijital X- ışını mamografi görüntülerinin iyileştirilmesi için Bayes maksimum entropi (dağınım) tabanlı bir algoritma geliştirmiştir. Burada, doğrudan uzamsal alanda işlem yapan istatistiksel bir metot olan Bayes maksimum entropi (Maximum Entropy-ME) yaklaşımı kullanılmıştır. Böylece sayısal Fourier ve ters Fourier dönüşümleri ve dönüşüm uzaylarındaki sinyallerin kesilmesinden kaynaklı içsel hatalar ortadan kaldırılır. Bayes görüntü onarımının esas zorluğu görüntüler için ilk kuralın belirlenmesidir. ME ilkesi bu sorunu çözer ve onarılmış görüntüyü pozitif olmaya zorlar. Böylece sahte negatif alanlar ve tamamlayıcı pozitif alanlar yok edilir ve onarılan görüntünün dinamik aralığı büyük ölçüde iyileştirilir. Görüntü entropisine dayalı görüntü onarımı, önemli gürültülerde, kayıp ya da bozuk veride dahi etkilidir. Bu ME ilkesinin görüntü onarımındaki ters problemi uygun düzenlemesinden kaynaklanmaktadır. İlk bilgi ile deneysel veriyi içeren bilgi birleştirildiği zaman tüm tutarlı gereksinimler karşılanır.

Bhateja [33] ve arkadaşları tarafından mikrokalsifikasyonlarla ilgili yapılan çalışmada görüntü karşıtlığını iyileştirmek için doğrusal olmayan iyileştirme operatörü kullanılmıştır. Burada iyileştirme işlemi şüpheli bölgelerin iyileştirilmesinde kullanılmıştır. Bir başka çalışmada [34], mamografi görüntülerinin iyileştirilmesi için matematiksel morfoloji ve diyadik dalgacık dönüşümü (dyadic wavelet transform) kullanılmıştır. Burada

da iyileştirme işlemi mikrokalsifikasyonlar için ROI bölgelerinde kullanılmıştır. Papadopoulou ve arkadaşları tarafından [35] yapılan çalışmada mikrokalsifikasyon kümelerinin tespiti için kontrast sınırlı adaptif histogram eşitleme (CLAHE), yerel aralık modifikasyonu (Local Range Modification-LRM) ve artık ayırık dalgacık (Redundant Discrete Wavelet-RDW) lineer germe ve çekme olmak üzere 5 farklı yöntem denenmiş ve karşılaştırılmıştır. Bunun sonucunda diğerlerine göre en iyi sonuç yerel aralık modifikasyonu ve dalgacık tabanlı doğrusal germe yöntemleri için elde edilmiştir. Ancak bu yöntemlerin de sınıflama performansını önemli derecede etkilemediğinden bahsedilmektedir.

Yapılan tez çalışmasında, kitle ve mikrokalsifikasyonların yapılarının farklılığından dolayı ilgili anormalliklerin tespiti için farklı iyileştirme algoritmaları geliştirilmiştir. Kitle tespiti için geliştirilen iyileştirme algoritmasında top-hat dönüşümü, dalgacık tabanlı eşikleme, CLAHE ve anizotropik difüzyon filtreleme yöntemleri kullanılmıştır. Geliştirilen algoritma kitle görünümünü belirginleştirmiştir. Mikrokalsifikasyonların tespitinde iyileştirme işlemi için sadece top-hat dönüşümü kullanılmıştır. Dalgacık tabanlı eşikleme ve CLAHE yöntemleri de denenmiştir. Ancak, bunların sonucunda mikrokalsifikasyonların görünürlüğü bozulmuştur. Sonuçlara ilişkin detaylar ilerleyen bölümlerde anlatılacaktır.

### 1.2.3.1. Morfolojik İyileştirme

Morfolojik karşıtlık iyileştirme Meyer [36] tarafından önerilen morfolojik top-hat notasyonuna dayanmaktadır. Top-hat filtresi, görüntüde yapı elemanına uyan özellikleri korur, diğerlerini kaldırır [28]. Açma işlemi ile top-hat aşağıdaki formül ile ifade edilir.

$$h_o = f - (f \circ A) \quad (1.19)$$

Burada  $f$ , orijinal görüntüyü;  $A$  ise yapı elemanını göstermektedir. Benzer şekilde kapama işlemi ile ikili top-hat aşağıdaki formül ile ifade edilir.

$$h_c = (f \odot A) - f \quad (1.20)$$

Açma işlemi ile top-hat sonucu tepe ve sırt özellikleri elde edilir, bu özelliklerin orijinal görüntüye eklenmesi ile parlak yapılar vurgulanır. Kapama işlemi ile top-hat

sonucu vadi ve oluk gibi özellikler elde edilir. Bunun, sonuç görüntüsünden çıkarılması ile de koyu yapılar vurgulanır [28].

$$M = f + h_o - h_c \quad (1.21)$$


Bu, görüntüdeki yüksek frekansları (gürültü) azaltır. Ancak, matematiksel morfolojinin bir dezavantajı da gürültünün halen bir kısmı kalır. Kalan gürültüyü kaldırmak için dalgacık dönüşümü kullanıldı.

### 1.2.3.2. Dalgacık Tabanlı Eşikleme

Dalgacıklar, son 20 yıldır sinyal ve görüntü işlemede yaygın olarak kullanılmaktadır. Dalgacıklar, medikal görüntülemeye ilk olarak 1991 yılında MR görüntülerinde gürültü azaltmak için dalgacık dönüşümü uygulamaları konulu çalışmada açıklanmıştır [37]. Bundan sonra dalgacık dönüşümleri tomografik yeniden yapılandırma, görüntü sıkıştırma, gürültü azaltma, görüntü iyileştirme, doku analizi ve bölütleme gibi birçok konuya başarıyla uygulanmıştır.

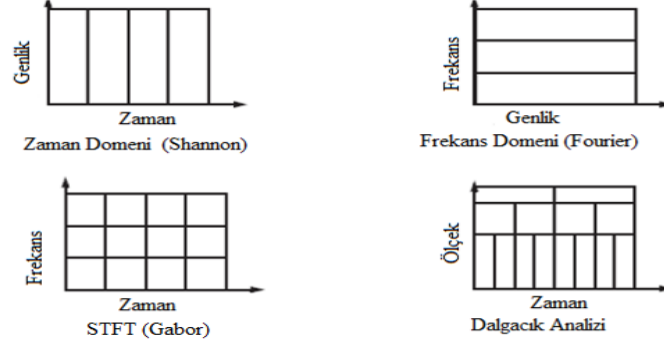
#### 1.2.3.2.1. Dalgacık Dönüşümü ve Çok Ölçekli Analizi

Dalgacık analizi, düşük frekans bilgisinin daha kesin olarak istendiği yerde uzun zaman aralığı kullanılmasına, yüksek frekans bilgisinin istendiği yerde de daha kısa bölgeler kullanılmasına izin verir [38].



Şekil 1.5. Dalgacık Dönüşümü

Bir sinyalin zaman tabanlı, frekans tabanlı ve kısa zamanlı *Fourier* dönüşümü (Short Time Fourier Transform-STFT) görünüşleri:




Şekil 1.6. Sinyalin zaman tabanlı, frekans tabanlı ve *STFT* görünümleri

Dalgacık analizi zaman-frekans bölgesi yerine zaman-ölçek (time-scale) bölgesini kullanmaktadır. Dalgacıkların en önemli avantajı lokal analize olanak tanınmasıdır. Yani uzun bir sinyalin belli bir bölgesini analiz edebiliriz. Örneğin, görsel olarak zor fark edilebilecek kadar küçük bir süreksizlik bölgesi olan bir sinüzoidal sinyal ele alalım. Böyle bir sinyal gerçek yaşamda gürültülü anahtarlama veya güç dalgalanması nedeniyle karşımıza çıkabilir. Bu sinyalin *Fourier* katsayılarının çiziminde tek bir frekansı ifade eden iki tepeli düz bir spektrumdan başka bir şey olmayacaktır. Fakat dalgacık katsayılarının çizimi süreksizlik olan yerin gerçek konumunu tam olarak gösterecektir [38]. Dalgacık analizi verinin eğilim, kırılma noktası, yüksek dereceden türevlerdeki süreksizlik noktaları ve öz-benzerlik gibi diğer sinyal analiz tekniklerinin başaramadığı anlamlı bir görünüşünü bize sağlamaktadır. Ayrıca dalgacık dönüşümü sinyal sıkıştırma ve gürültü azaltma konularında da oldukça başarılı olabilmektedir.

Dalgacık sıfır ortalama değerli ve kısıtlı süreli bir dalga şeklindedir. Örneğin, *Fourier* dönüşümündeki temel sinyal olan sinüzoidal sinyal ile karşılaştıracak olursak, sinüzoidal sinyal kısıtlı süreli değildir. Sinüzoidal sinyalin düzgün ve tahmin edilebilir olmasına karşılık dalgacıklar düzensiz ve asimetrik olmaya meyillidir.





Şekil 1.7. (a) Sinüs dalgası (b) Bazı dalgacık türleri

*Fourier* analizi bir sinyali değişik frekanslardaki sinüzoidal dalgalara parçalayarak yapılır. Benzer olarak, dalgacık analizi bir sinyali orijinal dalgacığın kaymış ve ölçeklenmiş versiyonlarına parçalayarak yapılır [38]. Dalgacık analizi, iki veya daha çok boyutlu veriye de (görüntü) uygulanabilir.

Zaman domeninde çeşitli genliklere sahip süreksiz sinyal yapılarını analiz etmek için farklı geçici yerler için farklı destek boyutları ile zaman-frekans atomları kullanmak gereklidir. Örneğin yüksek frekanslı yapılarda, zaman içinde hızla değişen, değişiklik yörüngelerini tam bir şekilde izlemek için daha yüksek geçici çözünürlüğe ihtiyaç vardır. Öte yandan daha düşük frekanslar için frekans değeri üzerinde daha iyi bir ölçüm vermek için oldukça yüksek mutlak frekans çözünürlüğü gerekir. Dalgacık dönüşümü tüm bu gereksinimleri karşılayacak doğal bir ifade sağlar.

### 1.2.3.2.2. Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü, sinyalin bütün  $t$  anlarında dalgacık fonksiyonu  $\psi$ 'nin ölçeklenmiş ve kaymış versiyonlarının toplamı olarak tanımlanır.

$$C(\text{ölçek}, \text{konum}) = \int_{-\infty}^{+\infty} f(t) \Psi(\text{ölçek}, \text{konum}, t) dt \quad (1.22)$$


Dalgacık dönüşümünün sonucunda dalgacık katsayıları  $C$ 'ler ölçek ve konumun bir fonksiyonu olarak elde edilirler. Her katsayıyı uygun olarak ölçeklenmiş ve kaymış dalgacıklarla çarparak orijinal sinyali tekrar elde edebiliriz. Ölçekleme, sinyalin gerilmesi

ve sıkıştırılması anlamında kullanılmaktadır (Ölçek azaldıkça sinyal sıkıştırılır). Bir dalgacığın kaydırılmasının anlamı onun başlama noktasının geciktirilmesidir.

Dalgacık analizinde, dalgacık ölçeği ve frekans arasında aşağıda belirtilen ilişki vardır:

- Düşük ölçek  $a \rightarrow$  Sıkıştırılmış dalgacık  $\rightarrow$  Hızlı değişen detaylar  $\rightarrow$  Yüksek frekans  $\psi$
- Yüksek ölçek  $a \rightarrow$  Uzatılmış dalgacık  $\rightarrow$  Yavaş değişen kaba özellikler  $\rightarrow$  Düşük frekans  $\psi$

Sürekli dalgacık dönüşümünün anlamı mümkün olan her ölçek ve konumda (kaydırma sürekli bir fonksiyon) işlem yapılabilmesidir [38].



Şekil 1.8. Sürekli dalgacık dönüşümü

### 1.2.3.2.3. Ayrık Dalgacık Dönüşümü

$N$  uzunluklu bir boyutlu verilen bir sinyalin,  $\{ f(n), n=0, \dots, N-1 \}$ , ölçekleme parametresi  $s=2^j$ 'ye göre ayrık ortogonal (dikgenlik) dalgacık dönüşümü, ayrık fonksiyonların bir dizisi şeklinde aşağıdaki gibi düzenlenebilir:

$$\{L_j f, \{W_j f\}_{j \in [1, J]}\} \quad (1.23)$$

burada  $L_j f = Lf(2^j n, 2^j)$  ve  $W_j f = Wf(2^j n, 2^j)$ .

$s = 2^j$  ölçekli,  $N/2^j$  uzunluklu  $W_j f$  dalgacık katsayıları ve en büyük ayrışma derinliği  $J$ , sinyal uzunluğu  $N(\sup(J) = \log_2 N)$  ile sınırlandırılmıştır [39]. Hızlı

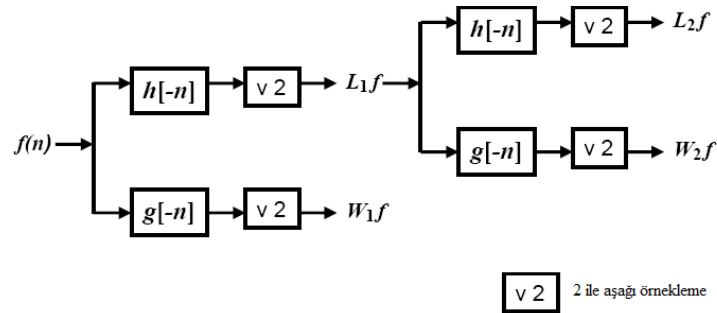
uygulama için (filtre banka algoritmaları gibi), ölçek fonksiyonu  $\varphi$  ve dalgacık fonksiyonu  $\psi$  kullanılarak aşağıdaki şekilde bir eşlenik ayna filtreleri (Conjugate Mirror Filter-CMF)  $h$  ve  $g$  elde edilebilir:

$$h[n] \leq \frac{1}{\sqrt{2}} \varphi\left(\frac{t}{2}\right) \quad \text{ve} \quad g[n] \leq \frac{1}{\sqrt{2}} \psi\left(\frac{t}{2}\right) \quad (1.24)$$


Eşlenik ayna filtresi  $k$  aşağıdaki ilişkiyi sağlar:

$$|\hat{k}(w)|^2 + |\hat{k}(w + \pi)|^2 = 2 \quad \text{ve} \quad \hat{k}(0) = 2 \quad (1.25)$$

Buradan  $h$ 'nin alçak geçiren,  $g$ 'nin ise yüksek geçiren filtre olduğu kanıtlanabilir. Giriş sinyaline bu iki filtre uygulanarak formül (1.23)'deki gibi ayrık ortogonal dalgacık dönüşümü Şekil 1.9'da gösterildiği gibi hesaplanabilir. Ortogonal temeli için, giriş sinyali dalgacık katsayılarından aynı filtre çifti kullanılarak Şekil 1.10'daki gibi yeniden elde edilebilir.



Şekil 1.9. Ayrık sinyal  $f(n)$ 'nin CMF ile ortogonal dalgacık dönüşümü (İki düzeyde genişleme)



Şekil 1.10. CMF ile ters dalgacık dönüşümü (İki düzeyde genişleme)

Burada  $h$  ve  $g$  sırasıyla alçak geçiren ve yüksek geçiren ayrıştırma filtreleridir. Şekil 1.9'da görüldüğü gibi ayrık dalgacık dönüşümünden sonra elde edilen verinin toplamı giriş sinyalinin uzunluğu ile aynıdır. Bu sebeple bu tip dönüşümler, dalgacık dönüşümü daha iyi bir uzamsal frekans lokalizasyonu sağladığından veri sıkıştırma için uygun olan sinyalin sıkıştırılmış bir temsilini sağlar [39].

Mallat ve Zhong tarafından diyadik (çiftli) dalgacık dönüşümü önerilmiştir. Dalgacık dönüşümünün daha genel bir çerçevesinin farklı yeniden yapılandırma ve ayrıştırma filtreleri ile düzenlenmesi biortogonal (çift dikgenlik) temelini oluşturur. Bu tip genelleme, dalgacık fonksiyonlarının tasarlanmasında daha fazla esneklik sağlar. Bu durumda formül (1.23)'e benzer şekilde  $s(n)$  sinyalinin ayrık diyadik dalgacık dönüşümü ayrık fonksiyonların dizisi şeklinde tanımlanır.

$$\{S_M s(n), \{W_m s(n)\}_{m \in [1, M]}\}_{n \in \mathbb{Z}} \quad (1.26)$$

Burada  $S_M s(n) = s * \phi_M(n)$  ve  $DC$  bileşeni görüntünün ortalama değerini ya da giriş sinyalinin işlenmemiş bilgisini temsil eder. Verilen dalgacık  $\psi(x)$  ve yeniden yapılandırma  $X(x)$  fonksiyon çifti, ayrık diyadik dalgacık dönüşümü (ayrıştırma ve yeniden yapılandırma)  $H, G$  ayrıştırma filtreleri çifti ve  $K$  yeniden yapılandırma filtresi kullanılarak hızlı filtre banka şeması ile gerçekleştirilebilir [39].

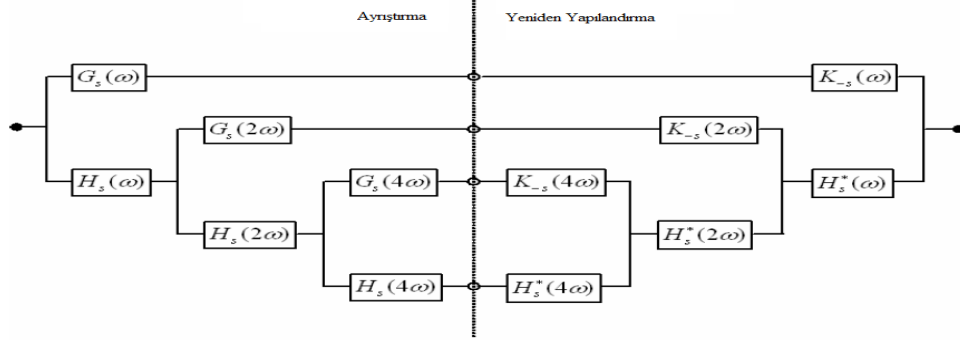
$$\begin{aligned} \hat{\phi}(2w) &= e^{-iws} H(w) \hat{\phi}(w), \\ \hat{\psi}(2w) &= e^{-iws} G(w) \hat{\psi}(w), \\ \hat{\chi}(2w) &= e^{-iws} K(w) \hat{\chi}(w). \end{aligned} \quad (1.27)$$

Burada  $s, \psi(x)$  bağımlı örnekleme kaymasıdır. Bu üç filtre ile aşağıdaki formül sağlanır.

$$|H(w)|^2 + G(w)K(w) = 1 \quad (1.28)$$

$F_s(w) = e^{-iws} F(w)$  tanımlanarak, burada  $F; H, G$  ya da  $K$  olabilir, filtre bankası oluşturularak ayrık diyadik dalgacık dönüşümü Şekil 1.11'deki gibi gerçekleştirilebilir.  $m+1$  seviyesinde (filtreler dalgacık ölçeği  $2^m$  seviyesinde uygulanır) tanımlı filtreler  $F(2^m w), 1$ .

seviyeden ( $F(w)$ ) takip eden filtre katsayıları arasına  $2^m-1$  tane 0 eklenerek oluşturulur. 1.seviyedeki tam sayı olmayan kaymalar en yakın tam sayıya yuvarlanır.



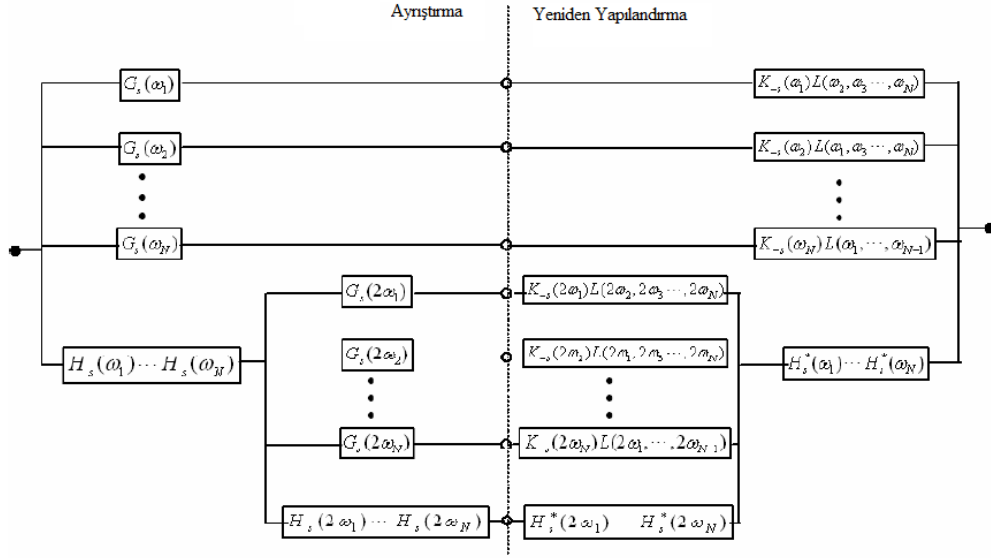
Şekil 1.11. Üç seviye analiz için bir boyutlu ayrık diydik dalgacık dönüşümü ayrıştırma ve yeniden yapılandırma filtre bankası uygulaması ( $H_s^*(w)$ ,  $H_s(w)$  'nin karmaşık eşleniğini gösterir)

Görüntü işleme uygulamalarında, biz genellikle iki, üç ya da hatta daha fazla boyutlu veriler ile ilgileniriz. Çerçeveyi daha yüksek boyuta uzatmak oldukça kolaydır. Çok boyutlu dalgacık temelleri, her boyut boyunca tanımlanabilen ayrık temel fonksiyonların tensör (üçten fazla elemana dayanarak tanımlanabilen vektör niceliği) ile oluşturulabilir [39]. Bu bağlamda  $N$  boyutlu ayrık diydik dalgacık dönüşümü  $M$  analiz seviyeleri ile dalgacık katsayıları kümesi şeklinde ifade edilebilir.

$$\{S_M s, \{W_m^1 s, W_m^2 s, \dots, W_m^N s\}_{m \in [1, M]}\} \quad (1.29)$$

Burada  $W_m^k s = \langle s, \psi_m^k \rangle$ ,  $m$  ölçekte  $k$ . koordinat boyunca detay bilgisini ifade eder. Dalgacık temeli, ayrılabilir dalgacık fonksiyonları  $\psi^k, k = 1, \dots, N$  kümesinden genişletilir ve çevrilir (örneğin 3B gibi).


$$\psi_{m, n_1, n_2, n_3}^k(x, y, z) = \frac{1}{2^{3m/2}} \psi^k\left(\frac{x-n_1}{2^m}, \frac{y-n_2}{2^m}, \frac{z-n_3}{2^m}\right), \quad k = 1, 2, 3. \quad (1.30)$$



Şekil 1.12. İki seviye analiz için çok boyutlu ayrık diyadik dalgacık dönüşümü (sol) ayrıştırma ve (sağ) yeniden yapılandırma filtre bankası uygulaması

Bu çerçevede  $N$  boyutlu diyadik dalgacık dönüşümü ile yapılandırma iç boyutlardaki korelasyonların telafisi için ayrılmaz filtre  $L_N$  gerektirir.

$$\sum_{l=1}^N K(w_l)G(w_l)L_N(w_1, \dots, w_{l-1}, w_{l+1}, \dots, w_N) + \prod_{l=1}^N |H(w_l)|^2 = 1 \quad (1.31)$$



Şekil 1.13. Diyadik dalgacık ayrıştırma ağacı örneği

Yukarıdaki şekilde diydik dalgacık ayrıştırma ağaç yapısı görülmektedir. Ayrıştırma işleminde bu ağaç yapısına göre filtreler uygulanarak işlem gerçekleştirilmektedir.

#### 1.2.3.2.4. Dalgacık Dönüşümü ile Görüntü İyileştirme

Gürültü iyileştirme,  $N$  gürültü bileşeni ile bozulmuş  $Y$  sinyal bileşeninden gerçek  $X$  işaret bileşenini ayırmaya çalışan bir tahmin problemi olarak görülebilir.

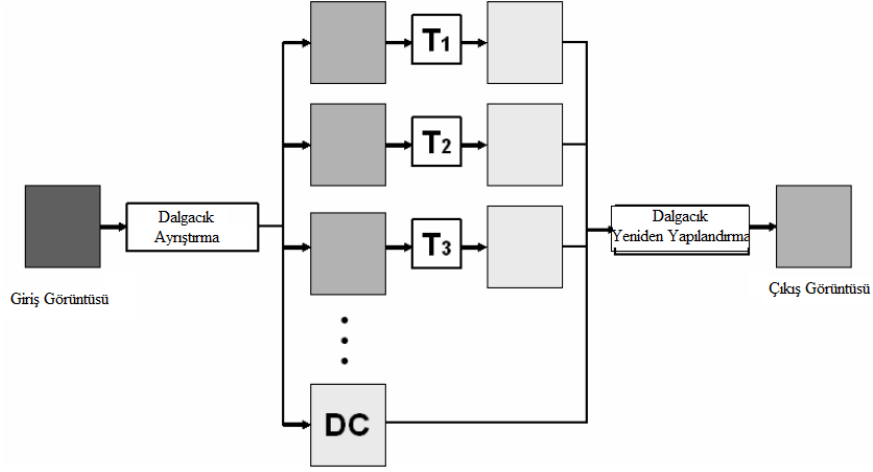
$$Y = X + N \quad (1.32)$$

Bu tahmin, ortonormal temelde (ortogonal ve normalize edilmiş) eşiklendirme kestirimi ile hesaplanabilir.

$$\hat{X} = \sum_{m=0}^{N-1} p_m(\langle X, g_m \rangle) g_m \quad (1.33)$$

Burada  $p_m$ , doğru sinyal katsayılarını korur iken gürültü bileşenlerini kaldırmayı amaçlayan eşiklendirme fonksiyonudur. Eğer  $p_m$  fonksiyonu, dönüşüm domeninde katsayı değerlerini korumak ya da arttırmak için değiştirilir ise yukarıdaki eşitlik ile gerçek sinyal bileşenindeki ilgili bazı özelliklerin iyileştirilmesi mümkündür.

Aşağıdaki şekilde, dalgacık dönüşümleri kullanılarak çoklu ölçekli iyileştirme ve gürültü azaltma çerçeveleri gösterilmiştir. Biortogonal temelli yukarı tamamlamalı diydik dalgacık dönüşümü kullanılmıştır. Şekilde görüldüğü gibi eşiklendirme ve iyileştirme fonksiyonları, dalgacık filtrelerinden bağımsız olarak gerçekleştirilebilir ve filtre bankası çerçevesine kolaylıkla katılabilir. (*DC* görüntünün ortalama değerini gösterir ve genellikle işlem boyunca sabit kalır.)



Şekil 1.14. Ayrık diyadik dalgacık dönüşümü kullanılarak gürültü azaltma ve iyileştirme (Üç seviye ayrıştırma)

Gürültü azaltma işlemi için dalgacık eşiklemede, eşik değeri önemli bir role sahiptir. Büyük değerler yararlı sinyal bileşenlerini elemine ederken küçük değerler gürültü bileşenlerinden etkili bir şekilde kurtulamazlar. Bu sebeple eşik değeri  $T$ 'ye karar vermenin çeşitli yolları vardır. Bağlı olup olmamasına göre eşik değeri  $T$ , dalgacık ölçekleri ve uzamsal yerler karşısında değişirler.

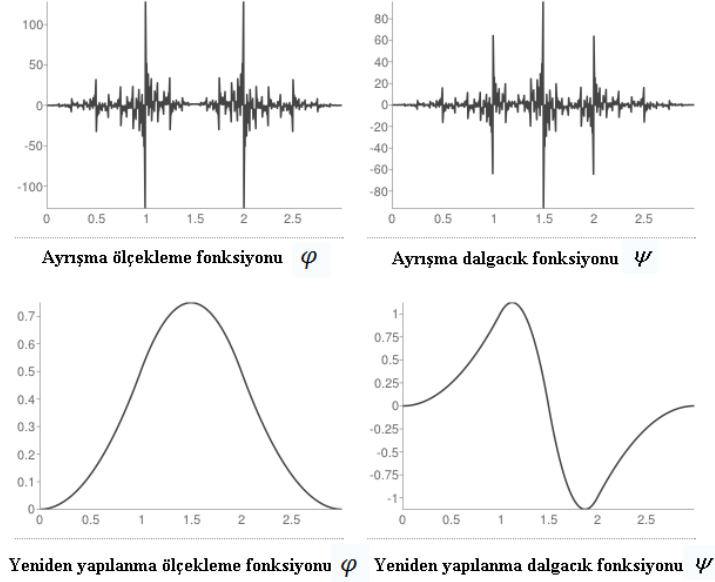
- Global Eşik: Basit bir  $T$  değeri farklı ölçeklerdeki bütün deneysel dalgacık katsayılarına global olarak uygulanır.  $T$ =sabit
- Seviye Bağımlı Eşik: Her dalgacık analizi seviyesi için farklı bir eşik değeri seçilir.  
 $T=T(j)$ ,  $i=1,\dots,J$ .  $J$ , dalgacık genişlemedeki en üst seviyedir.
- Uzamsal Adaptif Eşik: Eşik değeri  $T$ , bireysel dalgacık katsayılarının yerel özelliklerine dayalı uzamsal olarak değişir. Çoğunlukla,  $T$  ayrıca seviye bağımlıdır.

$$T = T_j(x, y, z).$$

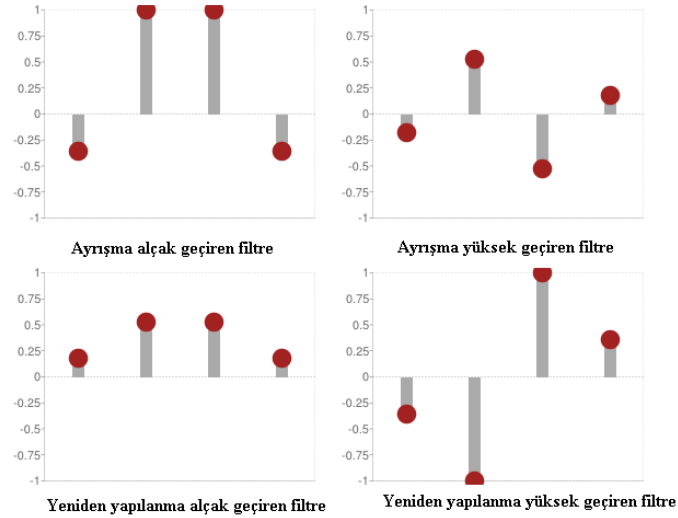
Biortogonal dalgacık gösteriminin, ortogonal dalgacık gösterimine göre birçok avantajı vardır. Alt bant görüntüleri, çeviri altında değişmez ve örtüşme yoktur. Düzleştirme simetrik ve asimetrik dalgacık fonksiyonları, sinyal uzantısının aksetmesi ile sınır etkilerinin azaltılması için kullanılabilir. Bu avantajlar, görüntü gürültü azaltma ve



iyileştirme uygulamalarında yaygın olarak kullanılmaktadır [28]. Bu nedenle, yapılan tez çalışmasında biortogonal dalgacık (biortogonal 3.1) kullanılmıştır. Kullanılan dalgacığa ait ayrıştırma ve yeniden yapılandırma fonksiyon ve filtrelerine ilişkin grafikler aşağıda verilmiştir.



Şekil 1.15. Biortogonal 3.1 ayrıştırma ve yeniden yapılanma fonksiyonları



Şekil 1.16. Biortogonal 3.1 ayrıştırma ve yeniden yapılanma filtreleri

Dalgacık ayrıştırma işlemi iki seviyede gerçekleştirilmiştir. Dalgacık ayrıştırma işleminden sonra eşikleme işlemi uygulanmıştır. Burada her seviye için bir eşik değeri


seçilir ve detay katsayılarına uygulanır. Aşağıdaki formül ile ifade edilen seviye bağımlı eşik değeri kullanılmıştır.

$$T_j = j \log(\max(d_j)) \quad (1.34)$$

Daha sonra yeniden yapılandırma işlemi ile iyileştirilmiş görüntü elde edilir. Böylece dalgacık tabanlı eşikleme ile iyileştirme işlemi gerçekleştirilmiş olur. Bundan sonra mamografi görüntülerindeki karışıklığın iyileştirilmesi için CLAHE yöntemi kullanılmıştır.

### 1.2.3.3. Kontrast Sınırlı Adaptif Histogram Eşitleme


Görüntü iyileştirmede sıkça kullanılan histogram eşitlemede tüm görüntü histogramı ile yoğunluk dinamik aralığı genişletilerek görüntü kalitesi iyileştirilebilir. Histogram eşitlemede görüntünün yoğunluk dağılımı normalize edilerek düzgün bir yoğunluk dağılımına sahip sonuç görüntüsü elde edilir ve böylece iyileştirme işlemi gerçekleştirilir. Fakat histogram eşitlemede tüm görüntünün yoğunluk dağılımı kullanıldığından bu bazı görüntülerde ortalama yoğunluk orta seviyeye getirildiğinde solmuş etkiye sebep olabilir. Ve dar bir bölgede kalabalık bir yoğunluk dağılımına sahip görüntülerde ise birçok gürültü pikselinin oluşmasına neden olabilir. Bu problemleri çözmek için yerel histogram eşitleme teknikleri geliştirilmiştir [40].



Şekil 1.17. (a) Orijinal görüntü (b) Histogram eşitleme sonucu

Adaptif histogram eşitleme değiştirilmiş bir histogram eşitleme işlemidir ve yerel veri üzerinde iyileştirme işlemi gerçekleştirir. Buradaki ana düşünce görüntü ızgara şeklinde dikdörtgen bölgelere bölünür ve her bir bölgeye standart histogram eşitleme işlemi


uygulanır. Optimum bölge boyutları ve sayısı görüntüye göre değişmektedir. Görüntü alt bölgelere ayrılıp her bölgeye histogram eşitleme işlemi uygulandıktan sonra alt bölgeler bi-lineer interpolasyon yöntemi [41] ile birleştirilerek iyileştirilmiş bütün bir görüntü elde edilir.



Şekil 1.18. 512x512'lik bir görüntünün 64 eşit kare bölgeye ayrılmış yapısı ve etiketlenmesi

Ancak adaptif histogram eşitlemede ise gürültü problemi ortaya çıkmıştır. Bunu engellemek için homojen bölgelerde kontrast iyileştirmenin sınırlandırılması gerekmektedir, bu amaçla da çalışmada kontrast sınırlı adaptif histogram eşitleme yöntemi kullanılmıştır. Bu yaklaşımda öncelikle her bir bölgenin histogramı hesaplanır. Sonra istenen kontrast genişlik sınırına dayalı olarak histogramların kırılması için kırma sınır değeri elde edilir. Daha sonra her histogram bu kırma sınır değerini aşmayacak şekilde yeniden dağıtılır. Son olarak, gri seviye haritalama için elde edilen kontrast sınırlı histogramların kümülatif dağılım fonksiyonları (Cumulative Distribution Function-CDF) belirlenir.

CLAHE yönteminde pikseller, dört en yakın komşuları kullanılarak haritalanır. Bi-lineer interpolasyon ile alt bölgeler birleştirilirken, bölgeler komşuluklarına göre önceki şekilde görüldüğü gibi IR, CR ve BR olmak üzere üç gruba ayrılır [42]. Her bölge dört çeyrek parça olarak düşünülür. Aşağıdaki şekilde görüldüğü gibi IR grubundaki her bölgenin her çeyreği dört komşuya sahiptir.




Şekil 1.19. (a) Bir IR bölgesi komşuları ile (b) (i,j) bölgesinin 1. çeyreği ve ona en yakın dört bölge ile ilişkileri

Bu durumda IR grubuna ait bölgelerdeki piksellerin yeni değerleri aşağıdaki formül ile hesaplanır.

$$p_y = \frac{s}{r+s} * \left( \frac{y}{x+y} f_{i-1,j-1}(p_e) + \frac{x}{x+y} f_{i,j-1}(p_e) \right) + \frac{r}{r+s} * \left( \frac{y}{x+y} f_{i-1,j}(p_e) + \frac{x}{x+y} f_{i,j}(p_e) \right) \quad (1.35)$$

Burada  $p_y$  ve  $p_e$  sırasıyla yeni ve eski piksel değerlerini ifade etmektedir. BR grubundaki bölgeler için komşuluk yapısı biraz farklıdır. Bu gruptaki en sağdaki bölgelerin 1. ve 3. çeyreğindeki piksellerin komşuluk yapıları IR grubundaki bölgeler ile aynıdır.




Şekil 1.20. Sağ BR bölgeleri ve komşulukları

Ancak 2. ve 4. çeyrekteki pikseller için komşuluk yapısı farklıdır ve bu çeyreklerdeki yeni piksel değerleri aşağıdaki formül ile hesaplanır. Bu durum BR grubundaki en soldaki bölgeler için de tam tersidir.

$$p_y = \frac{s}{r+s} * f_{i,j-1}(p_e) + \frac{r}{r+s} * f_{i,j}(p_e) \quad (1.36)$$

Bu durum BR grubundaki en soldaki bölgeler için de tam tersidir. CR grubundaki bölgeler için farklı çeyrekler farklı karakteristiklere sahiptir. Bu gruptaki 1. çeyrek diğerlerinden oldukça farklıdır çünkü diğer hiç bir bölge ile komşuluğu yoktur.



Şekil 1.21. Sol üst CR grubu bölgesi ve komşulukları

Hiç bir bölge ile komşuluğu olmayan 1. çeyrekteki piksellerin değeri değişmez.

$$p_y = f_{i,j}(p_e) \quad (1.37)$$


Bununla birlikte 4. çeyrek ise IR grubu bölgelerine benzer bir komşuluk yapısına sahip iken 2. ve 3. çeyrekteki pikseller BR bölgelerindeki iki yan çeyreğe benzer bir komşuluk yapısına sahiptirler. Bu şekilde her bölge için gri seviye haritalama yapılarak sonuç görüntüsü elde edilir. CLAHE yönteminin ardından oluşan küçük keskinlikleri yumuşatmak için anizotropik difüzyon filtreleme kullanılmıştır.

#### 1.2.3.4. Anizotropik Difüzyon Filtreleme

Anizotropik difüzyon filtreleme işlemi, küçük gürültülerin elemine edilmesi için kullanılan bir düzleştirme işlemidir. Aşağıdaki şekilde bir difüzyon denklemi düşünelim.

$$I_t = \nabla \cdot (f(\|\nabla I\|)\nabla I) \quad (1.38)$$

Buradaki fikir, görüntüdeki herhangi bir piksel için aşağıda gösterildiği gibi dört en yakın komşu kullanılmıştır [43, 44]. *N*, *S*, *E* ve *W* sırasıyla kuzey, güney, doğu ve batı komşuları göstermektedir.



Şekil 1.22. Difüzyon eşitliği için ayrık sayısal şema

Bu yaklaşım ile herhangi bir  $f$  fonksiyonu için Perona-Malik difüzyon eşitliği için genel sayısal şema aşağıdaki gibidir.

$$I(x, y, t + \Delta t) = I(x, y, t) + \Delta t. [f_N D_N I + f_E D_E I + f_W D_W I + f_S D_S I]_{x,y,t} \quad (1.39)$$

Burada,

$$\begin{aligned} D_N I(x, y) &\equiv I(x, y-1) - I(x, y) \\ D_S I(x, y) &\equiv I(x, y+1) - I(x, y) \\ D_E I(x, y) &\equiv I(x+1, y) - I(x, y) \\ D_W I(x, y) &\equiv I(x-1, y) - I(x, y) \end{aligned} \quad (1.40)$$

$$\begin{aligned} f_N &= f(D_N I(x, y)) \\ f_S &= f(D_S I(x, y)) \\ f_E &= f(D_E I(x, y)) \\ f_W &= f(D_W I(x, y)) \end{aligned} \quad (1.41)$$

Bu sayısal şemayı istikrarlı yapmak için  $0 \leq \Delta t \leq \frac{1}{4}$  ihtiyaç vardır [44]. Bu sonuçlar bize Perona-Malik difüzyonunu Tip I ve Tip II şeklinde uygulamaya izin verir.

Perona-Malik difüzyon eşitliği: Tip I

$$I_t = \nabla \cdot \left( \frac{1}{1 + (\|\nabla I\|/K)^2} \nabla I \right) \quad (1.42)$$

Perona-Malik difüzyon eşitliği: Tip II

$$I_t = \nabla \cdot (e^{-(\|\nabla I\|/K)^2} \nabla I) \quad (1.43)$$

Burada  $K$  bir sabittir. Farklı difüzyon zamanlarına göre Perona-Malik Tip I ve Perona-Malik Tip II ile gerçekleştirilen difüzyon sonuçları aşağıda verilmiştir.



(a) Orijinal görüntü

(b) Difüzyon zamanı  $t=1$



(c) Difüzyon zamanı  $t=2$


(d) Difüzyon zamanı  $t=5$



(e) Difüzyon zamanı  $t=10$

(f) Difüzyon zamanı  $t=15$

Şekil 1.23. Perona-Malik Tip I ile difüzyon sonuçları [44]  $K=20$  ve  $\Delta t = 0.2$



Şekil 1.24. Perona-Malik Tip II ile difüzyon sonuçları [44]  $K=20$  ve  $\Delta t = 0.2$

Şekil 1.23 ve Şekil 1.24'e göre, Tip I difüzyon sonuçlarının Tip II sonuçlarına göre bulanıklaştırmanın daha çok olduğu ve Tip II'de detayların daha iyi korunduğu görülmektedir. Bu nedenle, yapılan tez çalışmasında, Perona-Malik difüzyon tip II difüzyon eşitliği kullanılmıştır. Bununla birlikte, sonuçlara göre difüzyon zamanı olarak detayların çok kaybolmaması için  $t=2$ 'nin daha optimum bir değer olduğu görülmektedir. Çalışmada, parametreler;  $\Delta t = 0.25$ ,  $K=30$  ve difüzyon zamanı  $t=2$  olarak alınmıştır. Bu



değerler bulanıklaştırma miktarını etkilemektedir. Detaylar ve sonuçlara ilişkin görüntüler ilerleyen bölümlerde verilecektir.

### 1.2.3.5. Görüntü İyileştirme Performansının Değerlendirilmesi

İyileştirme işleminden sonra sonuç görüntülerindeki gelişmenin ölçümü genellikle zordur. Bu problem özellikle görüntü iyileştirme işlemi, daha sonraki tespit, sınıflama ve tanıma gibi görüntü işlemleri için bir önışleme basamağı ise daha zordur. İyileştirme yönteminin hem nesnel hem de öznel geçerliliğini belirtebilen evrensel bir ölçü yoktur. Ancak, performans ölçümü için gerekli olan üç özellik verilebilir.

İlk olarak, istenilen karakteristiğı bütünsel bir şekilde ölçmelidir, burada bu kontrast yani karşıtlıktır. İkincisi, karakteristiğın artışı ve azalması arasında oransal bir ilişki göstermesi gerekir. Son olarak da, uygun değer noktaları bulmak için sonuç olarak çıkan karakteristikleri olması gerekir. Bunun bir örneğı, yerel ekstrem kullanılmasıdır.

Son zamanlarda, Panetta ve arkadaşları [45] tarafından Logaritmik AME (logaritmik Michelson Kontrast Ölçüsü) ve logaritmik AMEE (Entropi ile logaritmik AME) görüntü iyileştirme ölçüleri olarak sunulmuştur. Bunlar iyileştirme performansını ölçmek için objektif araçlardır. Logaritmik AME ve Logaritmik AMEE, önceki ölçüler üzerine görüntü bilgilerinin işlenmesi için logaritmik yöntemler ortaya konularak geliştirilmiştir. Bu optimizasyonlar sonucunda daha doğru ve sağlam görüntü iyileştirme ölçüleri elde edilmiştir.

#### 1.2.3.5.1. Logaritmik AME (LogAME) ve Logaritmik AMEE (LogAMEE)

Bu ölçüler, görüntü  $k_1 \times k_2$  boyutlu bloklara ayrılıp her bloğun ölçüsü hesaplanıp daha sonra sonuçların ortalaması alınarak hesaplanmaktadır. Bu yeni ölçüler aşağıdaki gibi formüller ile ifade edilmektedir:

$$\log AME_{k_1 k_2}(\phi) = \frac{1}{k_1 k_2} \otimes \sum_{i=1}^{k_1} \sum_{j=1}^{k_2} \frac{1}{20} \otimes \ln \left( \frac{I_{max}(k_1 k_2) \ominus I_{min}(k_1 k_2)}{I_{max}(k_1 k_2) \oplus I_{min}(k_1 k_2)} \right) \quad (1.44)$$

$$\log AMEE_{k_1 k_2}(\phi) = \frac{1}{k_1 k_2} \otimes \sum_{i=1}^{k_1} \sum_{j=1}^{k_2} \frac{I_{max}(k_1 k_2) \ominus I_{min}(k_1 k_2)}{I_{max}(k_1 k_2) \oplus I_{min}(k_1 k_2)} * \ln \left( \frac{I_{max}(k_1 k_2) \ominus I_{min}(k_1 k_2)}{I_{max}(k_1 k_2) \oplus I_{min}(k_1 k_2)} \right) \quad (1.45)$$

Burada kullanılan  $\otimes$ ,  $\ominus$ ,  $\oplus$  ve  $*$  işlemleri parametrelili logaritmik görüntü işleme (Parameterized Logarithmic Image Processing-PLIP) modeli tarafından tanıtılmış işlemlerdir. PLIP modeli, daha doğru görüntü işleme için Panetta ve arkadaşları [46] tarafından geliştirilmiştir.

Görüntü işlemeye doğrusal olmayan bir çerçeve verir. Ayrıca, piksel değerlerini  $[0, M]$  aralığı içinde tutmanın yanı sıra insan görme sistemi görüşünden daha doğru görüntü işlemeyi sağlamak için tasarlanmıştır. PLIP modeli, aşağıdaki şekilde özetlenebilir:

$$a \oplus b = a + b - \frac{ab}{\lambda(M)} \quad a \ominus b = k(M) \frac{a-b}{k(M)-g} \quad (1.46)$$

$$c \otimes a = \lambda(M) - \lambda(M) \left(1 - \frac{a}{\lambda(M)}\right)^c \quad a * b = \varphi^{-1}(\varphi(a) \cdot \varphi(b)) \quad (1.47)$$

$$\varphi(a) = -\lambda(M) \cdot \ln^\beta \left(1 - \frac{a}{\lambda(M)}\right) \quad \varphi^{-1}(a) = \lambda(M) \cdot \left[1 - \exp\left(\frac{-a}{\lambda(M)}\right)^{1/\beta}\right] \quad (1.48)$$

Burada,  $a$  ve  $b$  gri seviye piksel değerlerini;  $c$  ve  $\beta$  sabit değerleri;  $M$  ise maksimum aralık değerini göstermektedir.

$\gamma(M)$ ,  $k(M)$  ve  $\lambda(M)$  ise keyfi fonksiyonları belirtmektedir ve  $g$  aşağıdaki şekilde hesaplanabilir:

$$g(i, j) = M - f(i, j) \quad (1.49)$$

Burada  $f(i, j)$  orijinal görüntüyü göstermektedir. Bu durumda  $g(i, j)$  fonksiyonu görüntünün negatifi gibidir. Literatür tarama sonuçlarından yararlanılarak kullanılan değişkenlere ait optimum değerler aşağıda verilmiştir.

$$\gamma(M) = k(M) = \lambda(M) = 1026, \quad \beta = 2 \quad (1.50)$$

Yapılan tez çalışmasında, iyileştirme performansının değerlendirilmesi için LogAME'nin biraz daha geliştirilmiş olan LogAMEE ölçüsü kullanılmıştır. Sonuçlar ikinci bölümde verilecektir.

Bu adımla beraber ön işlemler bitmiştir. Bunun sonucunda meme bölgesi bölütlenmiş ve iyileştirilmiş mamografi görüntüsü elde edilmiştir. Bundan sonraki aşamada, ilgili anormalliklere ilişkin şüpheli bölgeler belirlenecektir.

### **1.3. Şüpheli Bölgelerin Belirlenmesi**

Meme kanserinin bilgisayar destekli tanısında, ilgili anormalliklerin tespiti için kullanılacak olan şüpheli bölgelerin belirlenmesi oldukça önemli bir aşamadır. Bu bölgeler, görüntünün bizim için anlamlı olan yani en önemli bilgilerini içeren ilgi bölgesidir. Burada, kitle ve kalsifikasyon aday bölgeler belirlenerek, bundan sonraki aşamalarda bu bölgeler üzerinden çalışılarak ilgili anormallikler tespit edilir. Bu nedenle, bu aşama ileri tespit ve teşhis aşamaları için oldukça önemlidir.

Şüpheli bölgelerin belirlenmesi otomatik ve elle olmak üzere iki şekilde yapılmaktadır. Şüpheli bölgelerin elle belirlendiği çalışmalarda [47-52], bölgeler ya uzman radyologlar ya da veritabanındaki bilgilerden (ilgili anormalliğin yer bilgisi) yararlanılarak belirlenmektedir. Daha sonra belirlenen bu bölgeler üzerinde özellik çıkarma ve sınıflama yapılarak anormallik içerip içermediğine karar verilmektedir. Bu sistemler yarı-otomatik karar destek sistemleri olarak da adlandırılmaktadır. Yapılan tez çalışmasında, şüpheli bölgelerin belirlenmesi otomatik olarak yapılmaktadır. Bu kısım ilgili anormalliğe göre şüpheli kitle ve şüpheli mikrokalsifikasyon bölgelerinin belirlenmesi olmak üzere iki başlıkta incelenmiştir.

#### **1.3.1. Şüpheli Kitle Bölgelerinin Belirlenmesi**

Fatima [53] ve arkadaşları tarafından yapılan çalışmada ise kitle tespitinde ilgili alanların çıkarılmasında maksima eşikleme kullanılmıştır. Ancak, burada maksima eşiklemede tüm veritabanı incelenerek ortalama sabit bir eşik değeri seçilerek işlemler gerçekleştirilmiştir. Otomatik kitle belirlenmesi için Hussein [54] ve arkadaşları tarafından yapılan çalışmada, morfolojik eritme ve yeniden yapılanma yöntemlerinin hibridlenmesiyle en iyi 10 kitle aday bölge belirlenmiştir. Ardından, alan minimizasyonuna dayalı bir bölütleme algoritması ile kitle aday bölgeler çıkarılmıştır. Ancak bu kısıtlama bazı durumlarda ilgili anormallik bölgesinin kaçırılmasına sebep olabilir. Bir diğer çalışmada, Ravi [55] tarafından, meme kanseri bilgisayar destekli tanı

için etkili şüpheli bölge bölütlenmesi algoritması ile ilgili yapılan tez çalışmasında, şüpheli bölgelerin bölütlenmesi için sağlam bulanık c-ortalama (Robust Fuzzy C-Means-RFCM) ve uzaysal bulanık c-ortalama (Spatial Fuzzy C-Means-SFCM) kümeleme algoritmaları kullanılmıştır. Burada, SFCM özellik ve spektral etki alanları bilgilerini kullanmaktadır. Bu iki alandaki verinin kullanılması ile gürültü duyarlılığının azaltılması ve daha iyi bir kümeleme sağlanmış olur. Ancak bu çalışma tomosentez (üç boyutlu) görüntüleri için gerçekleştirilmiştir.

Bir başka çalışmada [56] kitle bölgesi şablonu kullanarak şüpheli kitle bölgelerini belirlemişlerdir. Kitle bölgesi şablonu ile meme bölgesinde gezinen pencere arasındaki korelasyon katsayısı hesaplanmıştır ve en büyük katsayıya sahip bölge şüpheli bölge olarak işaretlenmiştir. Ancak burada şüpheli bölge meme bölgesinin büyük bir kısmı olarak belirlendiğinden tespit işlemi için verimli bir ön filtreleme sağlamayabilir. Moayedı [57] ve arkadaşları tarafından yapılan çalışmada, bir filtreleme adımı olarak anormallik olasılığı oldukça yüksek olan bölgelerin seçilmesi gerektiği söylenmektedir. Bu nedenle, bağlı olarak adlandırılan birbirine bağlı pikseller bazı morfolojik işlemlere dayalı olarak benzer şekilde etiketlenerek bölge etiketleme işlemi gerçekleştirilmiştir. Mamogram piksel çözünürlüğüne göre, büyük alanlar yani bağlı bileşenler kümesinin en az %25'ine karşılık gelen alanlar şüpheli bölgeler olarak etiketlenmektedir. Ancak, bölütleme sonuçlarına ilişkin detay verilmemiştir.

Yapılan tez çalışmasında, şüpheli kitle bölgelerinin belirlenmesi için etkili istatistiksel yöntemlerden olan Shannon ve non-Shannon entropi ölçüleri [58] incelenmiş ve Havrda&Charvat entropi tabanlı bölütleme ile Otsu bölütleme metodunun daha gelişmiş bir hali olan Otsu N eşikleme [27] yöntemlerinin hibrid kullanımı gerçekleştirilmiştir. Bu yöntemlerin hibrid kullanımına literatürde daha önce rastlanmamıştır, bu açıdan yeni bir yaklaşım olarak öne çıkmaktadır. Otsu N eşikleme yöntemi daha önce anlatıldığından burada Shannon ve non-Shannon entropi ölçülerinden bahsedilecektir.

### **1.3.1.1. Shannon ve Non-Shannon Entropi Ölçüleri**

Entropi, bir bilgi teorisi kavramıdır ve bilgi miktarını ölçmek için kullanılır [59]. Entropi, bilgi kaynağının olasılıklı davranışı olarak da tanımlanmaktadır. Bu tanıma göre, rastgele bir  $A$  olayının  $P(A)$  olasılığı ile oluşması için aşağıdaki bilgi birimlerini içermesi gerektiğinden bahsedilmektedir [59].

$$I(A) = \log[1/P(A)] = -\log[P(A)] \quad (1.51)$$

$I(A)$  miktarı,  $A$  olayının öz bilgisi olarak adlandırılmaktadır. Olayın öz bilgi miktarı, olasılığı ile ters orantılıdır. Bilgi teorisindeki entropinin temel içeriği bir sinyal ya da rastgele bir olaydaki rastgeleliğin ne kadar olduğuyla ilgilidir. Buna bakmanın alternatif yolu, sinyal ile ne kadar bilgi taşındığı hakkında konuşularak yapılabilir. Entropi, rastgelelik ölçütüdür.

$p_1, p_2, \dots, p_b, \dots, p_k$  ayrık kaynağın olasılık dağılımı olsun. Bu nedenle,  $0 \leq p_i \leq 1$  ve  $\sum_{i=1}^k p_i = 1$ , burada  $k$  durumların toplam sayısıdır. Bir ayrık kaynağın entropisi genellikle olasılık dağılımından elde edilir. Çeşitli entropi ölçütleri [58] aşağıdaki gibi tanımlanabilir.

Shannon Entropi Ölçütü: Shannon entropi, aşağıdaki formül ile ifade edilir.

$$S = -\sum_{i=0}^k p_i \ln(p_i) \quad (1.52)$$

Non-Shannon Entropi Ölçütleri:

a) Renyi Entropisi:

$$R = \frac{1}{1-\alpha} \ln\left(\sum_{i=0}^k p_i^\alpha\right) \quad \alpha \neq 1, \alpha > 0 \quad (1.53)$$

b) Havrda ve Charvat Entropisi:

$$HC = \frac{1}{1-\alpha} \left(\sum_{i=0}^k p_i^\alpha - 1\right) \quad \alpha \neq 1, \alpha > 0 \quad (1.54)$$

c) Kapur Entropisi:

$$K_{\alpha,\beta} = \frac{1}{\beta-\alpha} \ln \frac{\sum_{i=0}^k p_i^\alpha}{\sum_{i=0}^k p_i^\beta} \quad \alpha \neq \beta, \alpha > 0, \beta > 0 \quad (1.55)$$

### 1.3.1.2. Shannon ve Non-Shannon Entropi Ölçüleri ile Şüpheli Bölgelerin Bölütlenmesi

Mamografi; meme arka planı, doku arka planı ve şüpheli bölge olmak üzere üç farklı nesnenin birleşimidir. Meme arka planı teşhis için bir bilgi sağlamaz. Bu nedenle, mamogram analiz çalışmalarında göz ardı edilebilir. Yaklaşık olarak, bir mamogramın üçte birinden fazlası meme arka planıdır. Bu da, meme dokularının ortalama gri seviye değerini etkileyecektir [59]. Bu nedenle, meme dokularının ortalama gri seviye değeri, meme arka plan pikselleri çıkarılarak aşağıdaki gibi tanımlanabilir [60].

$$k = \frac{1}{n} \sum_{i,j \in R}^M \sum_{i,j \in R}^N f(i, j) \quad (1.56)$$

Burada  $M$ ,  $N$  mamogramın boyutları;  $R$ , gri seviye değerleri  $>100$  olan bölge;  $n$ , bu bölgedeki piksellerin sayısı;  $f(i, j)$  ise,  $i$  ve  $j$  koordinatlarındaki gri seviye değeridir.

$p_1, p_2, \dots, p_b, \dots, p_{k-1}, p_k, p_{k+1}, \dots, p_L$  mamogramdaki gri seviye değerlerinin olasılık dağılımı olsun. Burada,  $p_k$  mamogramın normalize histogramıdır.

$$p_k = h_k / (M \times N) \quad (1.57)$$

$h_k$  ise mamogramın gri seviye histogramıdır. Bu dağılımdan, üç tane olasılık dağılımı çıkarabiliriz; birincisi meme arka planı için, ikincisi doku arka planı için ve üçüncüsü de şüpheli bölge için. Bu olasılık dağılımları aşağıdaki gibi ifade edilebilir:

Meme arka planına ait olasılık dağılımı:

$$\frac{p_1}{p_{k-1}}, \frac{p_2}{p_{k-1}}, \dots, \dots, \frac{p_{k-1}}{p_{k-1}} \quad (1.58)$$

Doku arka planına ait olasılık dağılımı:

$$\frac{p_k}{p_t - p_{k-1}}, \frac{p_{k+1}}{p_t - p_{k-1}}, \dots, \frac{p_t}{p_t - p_{k-1}} \quad (1.59)$$

Şüpheli bölgeye ait olasılık dağılımı:

$$\frac{p_{t+1}}{1-p_t}, \frac{p_{t+2}}{1-p_t}, \dots, \dots, \frac{p_L}{1-p_t} \quad (1.60)$$

Burada,  $P_{k-1} = \sum_{i=1}^{k-1} P_i$ ,  $P_t = \sum_{j=1}^t P_j$ ,  $t$  eşik değerini ve  $L$  mamogramdaki maksimum gri seviye değerini göstermektedir.

Shannon entropisi eşikleme yaklaşımına dayanmaktadır. Shannon entropisine göre doku arka planı piksellerinin entropisi ve şüpheli bölge piksellerinin entropisi aşağıdaki şekilde ifade edilebilir:

Doku arka planı pikselleri için Shannon entropisi:

$$S_{TB}(t) = - \sum_{i=k}^t \frac{P_i}{P_t - P_{k-1}} \ln \left( \frac{P_i}{P_t - P_{k-1}} \right) \quad (1.61)$$

Şüpheli bölge pikselleri için Shannon entropisi:

$$S_{SR}(t) = - \sum_{i=t+1}^L \frac{P_i}{1-P_t} \ln \left( \frac{P_i}{1-P_t} \right) \quad (1.62)$$

Shannon entropisi, eşikleme yaklaşımına dayalı,  $S_{TB}(t) + S_{SR}(t)$  değerini maksimize ederek optimum eşik değerini  $t_{opt}^S$ , elde eder [58].

$$t_{opt}^S = Arg_{t=k}^L max[S_{TB}(t) + S_{SR}(t)] \quad (1.63)$$

Bu optimum eşik değeri şüpheli bölgeyi, doku arka planından ayırmaktadır.

Benzer şekilde Renyi entropisi de eşikleme yaklaşımına dayanmaktadır ve Renyi entropisine göre doku arka planı pikselleri ile şüpheli bölge piksellerine ait entropiler aşağıdaki gibi ifade edilmektedir:

Doku arka planı pikselleri için Renyi entropisi:

$$R_{TB}(t) = \frac{1}{1-\alpha} \ln \left[ \sum_{i=k}^t \left( \frac{P_i}{P_t - P_{k-1}} \right)^\alpha \right] \quad (1.64)$$

Şüpheli bölge pikselleri için Renyi entropisi:

$$R_{SR}(t) = \frac{1}{1-\alpha} \ln \left[ \sum_{i=t+1}^L \left( \frac{P_i}{P_t - P_{k-1}} \right)^\alpha \right] \quad (1.65)$$

Burada  $\alpha \neq 1$ ,  $\alpha > 0$

Renyi entropisi, eşikleme yaklaşımına dayalı,  $R_{TB}(t) + R_{SR}(t)$  değerini maksimize ederek optimum eşik değerini  $t_{opt}^R$ , elde eder [58].

$$t_{opt}^R = Arg_{t=k}^L max [R_{TB}(t) + R_{SR}(t)] \quad (1.66)$$

Renyi entropisinden sonra Havrda ve Charvat entropisi de eşikleme tekniğine dayanmaktadır. Buna göre, doku arka planı pikselleri ve şüpheli bölge pikselleri için Havrda ve Charvat entropisi de aşağıdaki şekilde tanımlanmaktadır:

Doku arka planı pikselleri için Havrda ve Charvat entropisi:

$$HC_{TB}(t) = \frac{1}{1-\alpha} \left[ \sum_{i=k}^t \left( \frac{P_i}{P_t - P_{k-1}} \right)^\alpha - 1 \right] \quad (1.67)$$

Şüpheli bölge pikselleri için Havrda ve Charvat entropisi:

$$HC_{SR}(t) = \frac{1}{1-\alpha} \left[ \sum_{i=t+1}^L \left( \frac{P_i}{1 - P_t} \right)^\alpha - 1 \right] \quad (1.68)$$

Havrda ve Charvat entropisi, yaygın olmayan bir özelliğe sahiptir. Böylece eşikleme yaklaşımı tabanlı Havrda ve Charvat entropisi,

$HC_{TB}(t) + HC_{SR}(t) + (1 - \alpha)HC_{TB}(t)HC_{SR}(t)$  değerini maksimize ederek optimum eşik değerini  $t_{opt}^{HC}$ , elde eder [58].

$$t_{opt}^{HC} = Arg_{t=k}^L max [ HC_{TB}(t) + HC_{SR}(t) + (1 - \alpha)HC_{TB}(t)HC_{SR}(t) ] \quad (1.69)$$

Son olarak da, yine eşikleme yaklaşımına dayalı Kapur entropisinden bahsedeceğiz. Kapur entropisinin tanımına göre doku arka planı ve şüpheli bölge piksellerinin olasılık dağılımlarına ait entropiler aşağıdaki gibidir:



Doku arka planı pikselleri için olasılık dağılımına ait Kapur entropisi:

$$K_{TB}(t) = \frac{1}{\beta - \alpha} \ln \left[ \frac{\sum_{i=k}^t \left( \frac{P_i}{P_t - P_{k-1}} \right)^\alpha}{\sum_{i=k}^t \left( \frac{P_i}{P_t - P_{k-1}} \right)^\beta} \right] \quad (1.70)$$

Şüpheli bölge pikselleri için olasılık dağılımına ait Kapur entropisi:

$$K_{SR}(t) = \frac{1}{\beta - \alpha} \ln \left[ \frac{\sum_{i=t+1}^L \left( \frac{P_i}{1 - P_t} \right)^\alpha}{\sum_{i=t+1}^L \left( \frac{P_i}{1 - P_t} \right)^\beta} \right] \quad (1.71)$$

Burada  $\alpha \neq \beta$ ,  $\alpha > 0$ ,  $\beta > 0$

Kapur entropisi, eşikleme yaklaşımına dayalı,  $K_{TB}(t) + K_{SR}(t)$  değerini maksimize ederek optimum eşik değerini  $t_{opt}^K$ , elde eder [58].

$$t_{opt}^K = Arg_{t=k}^L max[K_{TB}(t) + K_{SR}(t)] \quad (1.72)$$

Optimum eşik değeri,  $t_{opt}^*$ ,  $* \in \{S, R, HC, K\}$ , şüpheli bölgeyi doku arka planından ayırır.

Deneysel sonuçlara bakıldığında, non-Shannon (Renyi, Havrda&Charvat, Kapur) entropi ölçülerinin, mamogram görüntülerinde şüpheli bölgeyi doku arka planından ayırmada daha tatmin edici sonuçlar verdiğini ortaya koymaktadır [58]. Non-Shannon entropi ölçülerinin, Shannon entropi ölçüsüne bir başka üstünlüğü de değerleri ayarlama kullanılabilecek  $\alpha$ ,  $\beta$  gibi parametreler içermesidir. Bu parametreler, aynı sınıf mamogram görüntüleri için görüntü işleme zincirinde ayar parametreleri olarak önemli bir rol oynayabilirler. Ayrıca, Havrda&Charvat entropisinin non-Shannon ölçüleri arasında yaygın olmayan bir özelliğe sahip olduğu görülmektedir. Yani, Havrda&Charvat entropi tabanlı bölütleme yaklaşımı, mamogram görüntülerinde sonradan eklenmeyen içeriğin varlığını yakalama yeteneğine sahiptir [58]. Bununla birlikte, daha sonradan Tsallis bu niceliği, fiziksel entropi ölçüsü olarak sunmuştur [61]. Bu nedenle, günümüzde Havrda&Charvat entropisine yaygın olarak Tsallis entropisi de denilmektedir.

Havrda&Charvat entropisine dayalı bölütlemede  $\alpha$  parametresi için bir formül geliştirilmiştir. Bu kısma ve sonuçlara ilişkin detaylar ilerleyen bölümlerde anlatılacaktır.

### 1.3.2. Şüpheli Mikrokalsifikasyon Bölgelerinin Belirlenmesi

Guan ve arkadaşları tarafından yapılan çalışmada [62], şüpheli mikrokalsifikasyon bölgelerinin bölütlenmesi için ölçek değişmeyen özellik dönüşümü (Scale Invariant Feature Transform-SIFT) yöntemi kullanılmıştır. Burada, SIFT metodu ile MC'lerin bölütlenmesi için anahtar noktalar hesaplanmaktadır. Ancak, SIFT ile başlangıçta pek çok nokta bulunmuştur, bu da bölütleme işlemini zorlaştırmaktadır. Bu nedenle, daha sonra radyologların şüpheli bölgeleri işaretleme sonuçları analiz edilerek doğru anahtar noktaları belirlemek için uygun bir eşik değeri ayarlanmıştır. Bu durum bir dezavantaj oluşturmaktadır. Bir başka çalışmada, çok ölçekli morfolojik yeniden yapılan ile elde edilen gradyan görüntüleri için işaretleyiciler belirlenir ve daha sonra havza (watershed) algoritması kullanılarak MC kümeleri belirlenmektedir [63]. Ancak, burada işlem karmaşıklığı fazladır ve sonuçlara ilişkin pek bilgi verilmemiştir. Balakumaran ve arkadaşları [64], öncelikle iyileştirilmiş mamografi görüntüsünü kesilmemiş dalgacık dönüşümü (undecimated wavelet transform, filtre alt örnekleme yapılmadan uygulanır) ile ayırıştırır ve buradan yatay ve dikey ayrıntılı görüntüler kullanarak 3. ve 4. dereceden istatistiksel parametreler, çarpıklık (skewness) ve basıklık (kurtosis) ile şüpheli MC bölgeleri belirler. Yatay yada dikey bant geçiren görüntü 32x32 boyutlu örtüşen karelerle taranır ve her kareye ait çarpıklık ve basıklık değerleri hesaplanır. Çarpıklık değeri  $>0.2$  ve basıklık değeri  $>4$  ise bu alan şüpheli bölge olarak kabul edilir. Sabit değerlere göre bölütleme dezavantaj oluşturmaktadır. Mohanalin ve arkadaşları [65] tarafından önerilen yaklaşımda Tsallis bir başka adıyla Hvarda&Charvat entropi tabanlı eşikleme kullanılmıştır. Burada, optimum eşik değeri hesaplama formülünde yer alan parametre için (0,2] aralığında değişmek üzere her parametre değerine karşılık bir bulanık değer hesaplanır ve maksimum bulanıklığa karşılık gelen eşik değeri seçilir. Daha sonra bu eşik değeri kullanılarak bulanık tabanlı iyileştirme yapılarak MC'lar belirgin hale getirilip iteratif eşikleme ile bölütlenir.

Yapılan tez çalışmasında, Tsallis, Renyi ve kaba entropi tabanlı bölütleme ve bulanık tabanlı MCs iyileştirme ile iteratif eşikleme yöntemleri denenmiştir ancak tespit aşamasında düşük performans elde edilmiştir. Bunun sonucunda, Otsu  $N=3$ , genişleme ve

bağlı bileşen etiketleme yöntemleri ile başarılı sonuçlar elde edilmiştir. Detaylar ve sonuçlar ilerleyen bölümlerde anlatılacaktır. Tsallis (Havrda&Charvat), Renyi entropi ve Otsu N eşikleme yöntemlerinden önceden bahsedildiğinden bu kısımda kaba entropi, bulanık tabanlı iyileştirme ve iteratif eşikleme yöntemlerinden bahsedilecektir.

### 1.3.2.1. Kaba Entropi ile Optimum Eşik Değerinin Bulunması

Kaba entropi ile görüntü bölütleme ilk olarak görüntü eşikleme rutinleri alanlarında tanıtılmıştır [66]. Sunulan kaba entropi ölçüsü, görüntüyü ön ve arka plan olmak üzere iki nesneye ayırmak için uygulanmıştır [67]. Kaba entropi, veri kümeleme için bir kalite ölçüsü olarak kabul edilir ve sağlam kümeleme programlarının geliştirilmesi için olasılık ve teorik alt yapı vermektedir. Bir görüntünün kaba entropisi (Rough Entropy-RE) aşağıdaki gibi tanımlanır.

$$RE_T = -\frac{e}{2} [R_{O_T} \ln(R_{O_T}) + R_{B_T} \ln(R_{B_T})] \quad (1.73)$$

$$R_{O_T} = 1 - \frac{|O_T|}{|O_T|} , R_{B_T} = 1 - \frac{|B_T|}{|B_T|} \quad (1.74)$$

Verilen görüntü için  $T$  eşik değerine dayalı  $O_T$  nesne ve  $B_T$  arka plan olmak üzere görüntünün kaba küme gösterimi yukarıda görülmektedir. Nesne ve arka planın kabalığı sırasıyla  $R_{O_T}$  ve  $R_{B_T}$  ile ifade edilmektedir.  $O_T$  ve  $B_T$  kaba kümelerdir. Her  $T$  için görüntünün  $RE_T$  değeri hesaplanır ve maksimum  $RE_T$ , optimum eşik değerini vermektedir.

$$T^* = \arg \max_T RE_T \quad (1.75)$$

İstenilen eşik değerini elde etmek, kaba entropi değerini maksimize etmek temelde nesne ve arka plan arasındaki pürüzlülüğü minimize etmek demektir [66].

### 1.3.2.2. Bulanık Tabanlı Mikrokalsifikasyon İyileştirme

Mikrokalsifikasyonları iyileştirmek için bulanık yaklaşım oldukça uygundur. Bulanıklaştırma yoğunluk değerlerinin 0 ile 1 aralığına dönüştürülmesini içerir. Bu

herhangi bir uygun bulanık üyelik fonksiyonu ile yapılabilir. Bu fonksiyon MCs yoğunluklarının yerini tespit etmek için kullanılır. Basitliği ve sağlamlığından dolayı genellikle Gauss üyelik fonksiyonu kullanılmaktadır. MCs, dokudan daha yüksek yoğunluk değerine sahip olduklarından fonksiyonun bulanık bölgesi ortalama yoğunluk değeri ile maksimum yoğunluk değeri arasından olmalıdır [65]. Burada, maksimum üyelik değerini yoğunluk değeri kaba entropi ile elde edilen eşik değeri  $t^*$  den yüksek olanlar verir ve geri kalanlar da bastırılmış olur. Gauss fonksiyonu aşağıdaki formül ile ifade edilir.

$$\pi_{m,n} = \exp\left(-\frac{|g_{mn}-maxN|^2}{f_h^2}\right) \quad (1.76)$$

$maxN$  ,  $f_h^2$  sırasıyla maksimum yoğunluk değerini ve Gauss üyelik fonksiyonunun bant genişliğini göstermektedir. Gauss fonksiyonunun bant genişliği aşağıdaki gibi hesaplanabilir.

$$f_h^2 = \max\{(t^* - k), (maxN - t^*)\} \quad (1.77)$$

Burada  $t^*$ , kaba entropi ile bulunan eşik değerini göstermektedir. Bununla birlikte, görüntünün düzensizliğini hesaplamak için yerel geometrik bilgileri kullanılmaktadır. Bunun için yerel değişkenler aşağıdaki gibi hesaplanabilir:

$$\mu_{m,n} = \frac{1}{W_x * W_x} \sum_{j=1}^{W_x^2} g_{m,n} \quad (1.78)$$

$$\sigma_l^2 = \frac{1}{W_x * W_x} \sum_{j=1}^{W_x^2} [g_{m,n} - \mu_{m,n}] \quad (1.79)$$

Burada  $W_x$  ,  $\mu_{m,n}$  ,  $\sigma_l^2$  sırasıyla pencere boyutu, yerel ortalama ve yerel varyansı göstermektedir. Hesaplanan düzensizlik faktörü kaba entropi ile bulunan optimum eşik değeri kullanılarak normalize edilir.

$$V_l = \begin{cases} \frac{\sigma_l^2}{t^*} , & \text{eğer } \sigma_l^2 \leq t^* \\ 1 , & \text{aksi takdirde} \end{cases} \quad (1.80)$$

İyileştirilmiş mamogram aşağıdaki formül ile elde edilir.

$$G_{enh} = \pi_{m,n} * V_l * maxN \quad (1.81)$$

$\pi_{m,n}$  , bulanıklaştırılmış mamogramı göstermektedir.

### 1.3.2.3. İteratif Eşikleme ile Bölütleme

Bu teknik, eşik değerini iteratif bir biçimde seçmektedir. İlk olarak giriş görüntüsünün ortalama gri değeri başlangıç eşik değeri  $T_0$  olarak alınır. Bu eşik değeri, Mcs şüpheli bölgelerin belirlenmesi için kullanılır ve eşikleme işleminden sonra yeni türetilen görüntü yeni giriş görüntüsü olarak alınır. Aynı prosedür yeni bulunan eşik değeri ile bir önceki eşik değeri arasındaki fark, önceden belirlenmiş bir değerden ( $\xi$ ) küçük oluncaya kadar tekrarlanır [65]. Bu durum aşağıdaki formül ile ifade edilir.

$$(abs(T - T_0)) < \xi \quad (1.82)$$

Yapılan tez çalışmasında  $\xi$  değeri 8 olarak alınmıştır.


## 1.4. Anormalliklerin Tespiti

Meme kanserine işaret eden en önemli meme anormallikleri kitle ve mikrokalsifikasyonlardır.

Kitle (Mass): BI-RADS'a göre kitle, en az iki farklı projeksiyonda görülebilen toplu bir alan işgal eden lezyon olarak tanımlanır. Sadece tek bir projeksiyonda potansiyel bir kitle görülür ise üç boyutluluğu kanıtlanana kadar 'Asimetri' ya da 'Asimetri Yoğunluğu' olarak adlandırılır. Kitleler farklı yoğunluklara(yağ içeren, düşük yoğunluklu, yüksek yoğunluklu), farklı kenarlara (sınırları belli, çok küçük yuvarlak çıkıntılı, anlaşılmaz, belirsiz, keskin noktalara sahip) ve farklı şekillere (yuvarlak, oval, yuvarlak çıkıntılı, düzensiz) sahiptirler.

Düzgün ve sınırları belli kenarlara sahip yuvarlak ve oval kitleler iyi huylu değişiklikleri gösterir. Öte yandan kötü huylu bir kitle genellikle keskin noktalara, pürüzlü ve bulanık sınırlara sahiptir.


Mikrokalsifikasyon (Microcalcification): Kalsifikasyonlar, meme dokusundaki kalsiyum depolarıdır. İyi huylu kalsifikasyonlar genellikle düzgün ve yuvarlak konturlar ile daha büyük ve daha iridirler. Kötü huylu kalsifikasyonlar ise çok sayıda, kümelenmiş, küçük, boyut ve şekil olarak çeşitlilik gösteren, açısallık, düzensiz şekillenmiş olabilir ve yön belirlemede dallanma gösterebilir.



Şekil 1.25. Anormallik içeren mamografi görüntüleri

#### 1.4.1. Kitle Tespiti

Kitle boyutları 3mm ile 30mm arasında değişen ve mamogramlarda en çok görülen iki anormallikten (diğeri kalsifikasyon) biridir. Bununla birlikte, kitleler sınır ve şekil karakterlerine göre speküle kitleler (SPIC), sınırlı kitleler (CIRC) ve diğeri kitleler (MISC) [68] olmak üzere üç sınıfa ayrılabilir. Bu da, kitle tespiti işlemini daha karmaşık ve zor bir hale getirmektedir.



Şekil 1.26. Farklı kitle örnekleri

Kitle tespiti; özellik çıkarma, sınıflama ve yanlış pozitif indirgeme olmak üzere üç kısımda incelenecektir.

#### 1.4.1.1. Özellik Çıkarma ve Sınıflama


Samma ve arkadaşları [54] tarafından yapılan çalışmada; belirledikleri 10 şüpheli kitle adayı bölgelere ait şekilsel ve dalgacık enerji ile ilgili özellikler kullanılmıştır. Sınıflama için genetik algoritma ile destek vektör makinesi (Support Vector Machine-SVM) yöntemlerinin kombinasyonu kullanılmıştır. Ancak, burada şekilsel özellikler kullanıldığından bölgedeki kitlenin sınırının çıkarılması ve bölge eğer kitle içermiyor ise içerisindeki benzer yapının sınırının çıkarılması gibi ekstra işlemler gerektirmektedir. Bununla birlikte sınır çıkarma işleminin doğruluğu da dikkate alınmalıdır. Bir başka çalışmada, dalgacık ya da eğricik dönüşümü uygulanır ve elde edilen katsayılar fazla olduğundan istatistiksel  $t$  testi kullanılarak eşik değeri yardımıyla özellikler belirlenmiştir [69]. Burada 46080 özellik 5663 özelliğe indirgenmiştir ancak bu da oldukça yüksek bir özellik sayısıdır. Sınıflama işlemi için ise SVM kullanılmıştır. Llado [70] ve arkadaşları kitle özellik çıkarma işlemi için yerel ikili örnekler (Local Binary Patterns-LBP) ve sınıflama için de SVM kullanmışlardır. Burada şüpheli bölgeler farklı boyutlardadır.

Bir diğer çalışmada [71], öncelikle bölge büyütme algoritması ile şüpheli kitle adayları bölgeler belirlendikten sonra uzaysal gri seviye tabanlı yöntem kullanılarak özellikler çıkarılmıştır. Burada; karşıtlık, enerji, homojenlik ve korelasyon özellikleri kullanılarak başarılı sonuçlar elde edildiğinden bahsedilmektedir. Daha sonra SVM yöntemi ile sınıflama işlemi gerçekleştirilmiştir. Cheng [72] ve arkadaşları tarafından, kitle tespiti için yapılan çalışmada şüpheli bölgeler veritabanı bilgileri kullanılarak manuel olarak farklı boyutlarda çıkarılmıştır. Tespit işlemi için entropi, tek düzelik, kontrast ve maksimum eş-oluşum matrisi özellikleri ile bulanık sinir ağı modeli kullanılmıştır. Nithya [73] ve arkadaşları tarafından yapılan çalışmada; yoğunluk histogramı, gri seviye eş oluşum matrisi (Gray Level Co-occurrence Matrix-GLCM) ve yoğunluk tabanlı özellikler olmak üzere üç farklı özellik çıkarma yöntemi kullanılmıştır. Bunun sonucunda tespit işlemi için korelasyon, enerji, entropi, homojenlik ve kare varyans toplamı özellikleri çıkarılmıştır. Sınıflama için ise çok katmanlı yapay sinir ağı kullanılmıştır ve başarılı sonuçlar elde edildiğinden bahsedilmektedir.

Araştırma sonuçlarına göre GLCM üzerinden elde edilen özellikler literatürde [72-76] oldukça başarılı sonuçlar elde etmiştir. Bunun sonucunda, tez çalışmamızda gri seviye eş oluşum matrisine dayalı istatistiksel doku özellikleri kullanılmıştır.

#### 1.4.1.1.1. Gri Seviye Eş Oluşum Matrisi ile Özellik Çıkarma

Gri seviye eş oluşum matrisi, ikinci dereceden istatistiksel doku özelliklerinin çıkarılması için geliştirilmiş bir yöntemdir. GLCM doku özellikleri, literatürde [73, 77-82] mamogramlardaki normal ve anormal meme dokusunu ayırmak için etkili özellikler olarak sunulmuştur. Doku özellikleri, komşu piksellerdeki gri seviyelerin istatistiksel dağılımından hesaplanabilir. Bununla birlikte, her kombinasyondaki gri seviye noktalarının sayısına göre istatistikler birinci derece, ikinci derece ve daha yüksek derece olmak üzere sınıflanmaktadır [83]. GLCM ilk olarak Haralick [84] tarafından ikinci dereceden istatistiksel doku özellikleri olarak sunulmuştur ve  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  olmak üzere dört yönde ve 1, 2, 3, 4 olmak üzere dört mesafede hesaplanabilir. GLCM,  $M \times N$  boyutlu bir matristir ve burada  $M$  ve  $N$ ,  $G$  görüntüsündeki gri seviyelerin sayısına eşittir [83].  $P(i, j / d, \theta)$  matris elemanı, giriş görüntüsündeki  $i$  değerli pikselin belirtilen aralıklı ilişki içinde  $j$  değerli piksel ile görünme sayısının toplamını göstermektedir. Belirtilen aralık ilişkisi,  $d$  mesafesi ve  $\theta$  açısı ile tanımlanır.



Şekil 1.27. Dört mesafeden ( $d$ ) ve dört açıdan ( $\theta$ ) GLCM ölçümünün geometrisi

$0$ 'dan  $G-1$ 'e kadar  $G$  gri seviye içeren  $M \times N$  boyutlu bir giriş görüntüsü olsun ve  $f(m, n)$ ,  $n$ . satırdaki  $m$  örneğini göstere.



$$A = \begin{cases} 1, & \text{eğer } f(m,n) = i \text{ ve } f(m + \Delta d, n + \Delta \theta) = j \\ 0, & \text{aksi takdirde} \end{cases} \quad (1.83)$$

Örneğin, 5x5 boyutlu 4 gri seviyeli ve buna karşı düşen gri seviye eş oluşum matrisi  $P(i, j | \Delta d=1, \Delta \theta=0)$ , aşağıda verilmiştir.

<u>GÖRÜNTÜ</u>					<u>p(i,j:1.0)</u>				
0	1	1	2	3		<b>j=0</b>	<b>1</b>	<b>2</b>	<b>3</b>
0	0	2	3	3	<b>i=0</b>	1/20	2/20	1/20	0
0	1	2	2	3	<b>1</b>	0	1/20	3/20	0
1	2	3	2	2	<b>2</b>	0	0	3/20	5/20
2	2	3	3	2	<b>3</b>	0	0	2/20	2/20

Şekil 1.28. 5x5 boyutlu görüntü için GLCM matrisi

Şekil 1.28'de görüldüğü gibi gri seviyelerin sayısı matris boyutunu etkilemektedir. Bununla birlikte  $G \times G$  matrisinin her  $(d, \theta)$  kombinasyonu için geçici olarak çok fazla veriye ve belleğe ihtiyaç vardır [83]. Bu nedenle çalışmada eş oluşum matrisini hesaplamak için daha yakın komşuların dikkate alınması açısından  $d=1, \theta=0$  olarak alınmıştır. GLCM matrisinden birçok doku özelliği çıkarılabilir [84]. Yapılan tez çalışmasında, kontrast (contrast), küme gölge (cluster shade), enerji (energy), kare varyans toplamı (sum of squares variance), otokorelasyon (autocorrelation), küme önemi (cluster prominence), farklılık (dissimilarity), entropi (entropy), homojenlik (homogeneity), maksimum olasılık (maximum probability), toplam ortalama (sum average-sa), toplam varyans (sum variance), toplam entropi (sum entropy), entropi farkı (difference entropy), korelasyon bilgi ölçüsü (information measure of correlation), korelasyon 2 bilgi ölçüsü (information measure of correlation2), normalize ters fark momenti (inverse difference moment normalized) olmak üzere 17 özellik çıkarılmıştır. GLCM özelliklerini açıklamak için aşağıda verilen gösterimler kullanılmaktadır.

$$P_x(i) = \sum_{j=0}^{G-1} P(i, j) \quad P_y(j) = \sum_{i=0}^{G-1} P(i, j) \quad (1.84)$$

$$\mu = \sum_{i,j=0}^{G-1} i P(i, j) \quad (1.85)$$

$$\mu_x = \sum_{i=0}^{G-1} i p_x(i) \quad \mu_y = \sum_{j=0}^{G-1} j p_y(j) \quad (1.86)$$

$$\sigma_x^2 = \sum_{i=0}^{G-1} (P_x(i) - \mu_x(i))^2 \quad \sigma_y^2 = \sum_{j=0}^{G-1} (P_y(j) - \mu_y(j))^2 \quad (1.87)$$

$$P_{x+y}(k) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j), k = 0, 1, \dots, 2(G-1) \quad (1.88)$$

$$HXY = - \sum_{i,j=0}^{G-1} P(i, j) \log_2 P(i, j) \quad (1.89)$$

$$HXY1 = - \sum_{i,j=0}^{G-1} P(i, j) \log_2 (P_x(i)P_y(i)) \quad (1.90)$$

$$HXY2 = - \sum_{i,j=0}^{G-1} P_x(i)P_y(i) \log_2 (P_x(i)P_y(i)) \quad (1.91)$$

Burada  $P$ , GLCM olarak adlandırılır.  $G$ , gri seviye sayısını ve  $\mu$ ,  $P$ 'nin ortalamasını göstermektedir. Bununla birlikte,  $\mu_x$ ,  $\mu_y$ ,  $\sigma_x^2$  ve  $\sigma_y^2$  sırasıyla  $P_x$  ve  $P_y$ 'ye ait ortalamaları ve varyansları göstermektedir.  $HX$  ve  $HY$  ise  $P_x$  ve  $P_y$ 'nin entropileridir.  $P_x(i)$  ise  $P(i, j)$ 'nin satırları toplamından elde edilen matristeki  $i$ . giriştir. Çıkarılan 17 GLCM özelliğine ait formüller ve açıklamalar aşağıdaki tabloda verilmiştir.

Tablo 1.1. GLCM özelliklerine ait formüller ve açıklamalar

Özellikler	Formül	Açıklama
Kontrast	$\sum_{i,j=0}^{G-1} P(i, j)(i - j)^2$	Bir piksel ile komşusu arasındaki yoğunluk kontrastı.
Küme gölge	$\sum_{i,j=0}^{G-1} P(i, j)(i + j - \mu_x - \mu_y)^3$	Matrisin çarpıklık ölçüsüdür ve yüksek olması görüntünün simetrik olmaması anlamına gelir.
Enerji	$\sum_{i,j=0}^{G-1} P(i, j)^2$	Enerji, ikinci açısal momentin (ASM) düzenliliği olarak da bilinir ve GLCM'den gelen kare elemanlarının toplamıdır.
Kareler toplamı, varyans	$\sum_{i,j=0}^{G-1} P(i, j)(i - \mu)^2$	Bu özellik $P(i, j)$ 'nin ortalamasından farklı olarak elemanlara nispeten daha yüksek ağırlıklar koyar.
Otokorelasyon	$\sum_{i,j=0}^{G-1} (P_x - \mu_x)(P_y - \mu_y) / \sigma_x \sigma_y$	Görüntüde mevcut olan dokunun inceliği ve kabalığı gibi düzenlilik miktarını değerlendirmek için kullanılır.

Tablo 1.1'in devamı

Küme önemi	$\sum_{i,j=0}^{G-1} P(i,j)(i+j-\mu_x-\mu_y)^4$	Bu da matrise ait bir çarpıklık ölçüsüdür, ancak düşük olması eş oluşum matrisinin ortalama değeri etrafında bir tepe olması anlamına gelir ve bu da görüntü için gri seviyeler arasında küçük farklılıklar var demektir.
Farklılık	$\sum_{i,j=0}^{G-1} P(i,j) i-j $	GLCM'den çapraz yönde hareket edildiğinde ağırlıkların doğrusal artışı kullanan kontrasta ilişkin bir ölçüdür.
Entropi	$-\sum_{i,j=0}^{G-1} P(i,j) \log(P(i,j))$	İstatistiksel rastgeleliği ölçer.
Homojenlik	$\sum_{i,j=0}^{G-1} \frac{P(i,j)}{1+ i-j }$	GLCM' deki elemanların çapraz yönde dağılımını ölçer.
Maksimum olasılık	$\text{Max}(i,j)P(i,j)$	Piksellerin bir kombinasyonu penceredeki piksel çiftlerine hakimse yüksek maksimum değerler ortaya çıkar.
Toplam ortalama	$\sum_{i=0}^{2G-2} i P_{x+y}$	Görüntüdeki homojen parlaklık ya da koyuluk toplam ortalamaya karar verir ve daha homojen koyu görüntüde bu değer düşüktür.
Toplam varyans	$\sum_{i=0}^{2G-2} (i-sa)^2 P_{x+y}(i)$	Oluşum frekansı, eş oluşum matrisinin en düşük ve en yüksek hücrelerinde eşit olarak yoğunlaştığında yüksek değer gösterir.
Toplam entropi	$-\sum_{i=0}^{2G-2} P_{x+y}(i) \log(P_{x+y}(i))$	Entropi, görüntüdeki düzensizlik ya da doku karmaşıklığı ölçüsüdür.
Entropi farkı	$-\sum_{i=0}^{G-1} P_{x+y}(i) \log(P_{x+y}(i))$	Gri seviye dağılımının rastgeleliğini ölçer.
Korelasyon bilgi ölçüsü	$\frac{HXY - HXY1}{\max(HX, HY)}$	Görüntüdeki gri ton doğrusal bağımlılıkların ölçüsüdür.
Korelasyon 2 bilgi ölçüsü	$\sqrt{1 - \exp[-2.0(HXY2 - HXY)]}$	Aynı şekilde görüntüdeki gri ton doğrusal bağımlılıkların farklı bir ölçümüdür.
Normalize ters fark momenti	$\sum_{i,j=0}^{G-1} \frac{P(i,j)}{1+ i-j ^2}$	Bu özellik görüntü homojenliğini ölçer. Kontrast ve enerji ile ilişkilidir. Pikseller arası küçük gri seviye farklılıklarında büyük değerler gösterir.

Böylece özellik çıkarma işlemi tamamlanmıştır. Bundan sonraki basamak özelliği çıkarılan şüpheli bölgelerin sınıflanması aşamasıdır. Sınıflama işleminde özelliği çıkarılan bölgenin kitle ya da normal doku bölgesi kararı verilir. Sınıflama işlemi için literatür çalışmalarında daha başarılı sonuçlar verdiği için yaygın olarak SVM [54, 69-71] ve YSA (Yapay Sinir Ağı) [72, 73, 77, 85-87] kullanılmaktadır. Yapılan tez çalışmasında SVM ve

YSA yöntemleri denenmiştir. Eğitim performans sonucu YSA'nın daha iyi olması sebebiyle sınıflamaya YSA yöntemi ile devam edilmiştir.


#### 1.4.1.1.2. Destek Vektör Makinesi ile Sınıflama

SVM; yüksek performans garantilemek için istatistiksel öğrenme teorisinin sonuçlarına dayandırılan çok yüksek düzeyde hiper düzlem sınıflama metodudur. SVM sınıflayıcı, sınıflar arası mesafeyi maksimize edecek hiper düzlemi arayan yapısal riski minimize etme prensibine dayanmaktadır [88-90]. □ Hem doğrusal olarak ayrılabilen hem de edilemeyen veri kümesini sınıflandırabilir. SVM doğrusal olarak ayrılamayan veriyi, doğrusal olarak ayrılması mümkün olan çok boyutlu uzaya haritalayabilir. Böylece, doğrusal olmayan bir eşlem ile  $n$  boyutlu veri kümesine  $m > n$  olacak şekilde  $m$  boyutlu yeni bir veri kümesine dönüştürülerek yüksek boyutta doğrusal sınıflandırma işlemi yapılır. Uygun bir dönüşüm ile her zaman veri bir hiper düzlem ile iki sınıfa ayrılabilir. Hiper düzleme en yakın öğrenme verileri destek vektörleri olarak adlandırılır.

Ayırıcı hiper düzlem ile en yakın pozitif ve negatif veri noktaları arasındaki mesafeye SVM sınıflayıcının marjı (mesafe, kenar, tolerans) denir ve ayırma düzlemi olarak aşağıdaki formül ile ifade edilir.

$$D(x) = (w, x) + b \quad (1.92)$$

Burada  $x$ , yüksek boyutlu uzaya haritalanan veri kümesi vektörünü;  $w$  ve  $b$  ise SVM'nin tahmin edeceği hiper düzlem parametrelerini göstermektedir.



Şekil 1.29. Ayırma düzleminin grafiksel gösterimi

Eğitim kümemiz aşağıdaki gibi olsun.

$X = \{x_i, y_i\}, i = 1, 2, \dots, m$  ve  $y_i \in \{-1, 1\}$  :

$$(w \cdot x_i) + b > +1, \text{ eğer } y_i = +1 \quad (1.93)$$

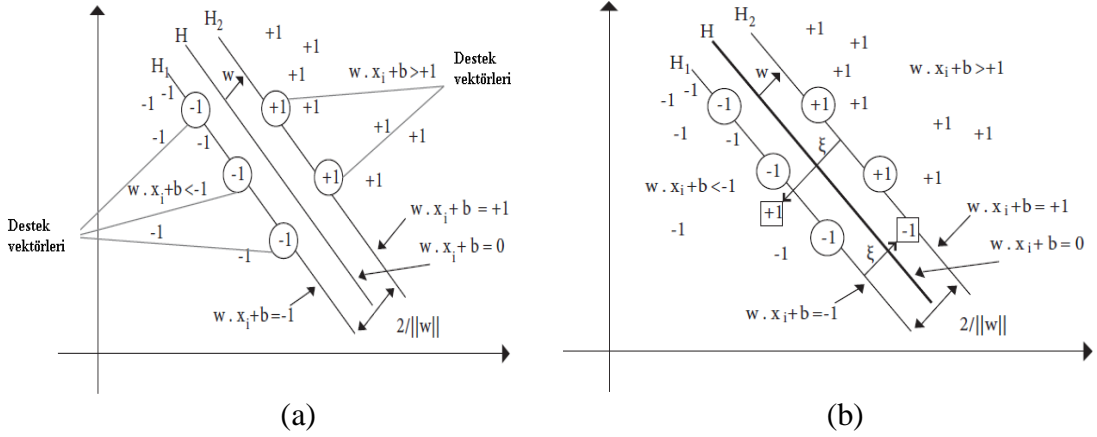
$$(w \cdot x_i) + b < -1, \text{ eğer } y_i = -1 \quad (1.94)$$

$$y_i(w \cdot x_i) + b \geq +1 \quad (1.95)$$

Burada  $(w, b)$  hiper düzlemi, eğitim kümesindeki bütün örnekleri doğru ayırabilen bir sınıflayıcıdır.

$$\text{sınıf}(x_i) = \begin{cases} +1 & \text{eğer } w \cdot x_i + b > 0 \\ -1 & \text{eğer } w \cdot x_i + b < 0 \end{cases} \quad (1.96)$$

Orijin ile ayırıcı hiper düzlem  $H$  arasındaki mesafe  $|b|/\|w\|$ ' dir.



Şekil 1.30. (a) Doğrusal ayrılan (b) Doğrusal ayrılamayan küme grafikleri

Marjının genişliği aşağıdaki gibi ifade edilir.

$$m = 2/\|w\| \quad (1.97)$$

$w$  ve  $x$ 'i hesaplamak aşağıdaki kısıtlamalar ile birlikte fonksiyonun minimumunu bulma problemidir [88].

- $m(w) = \frac{1}{2}(w \cdot w)$  minimize etmek
- $y_i[w \cdot x_i + b] \geq 1, i=0, 1, \dots, m$

Öğrenme kümesi doğrusal olarak ayrılamıyor ise  $\xi_i$  değişkeni eklenir. Bu değişken, eğitim setinde doğru sınıflanan örnekler için 0, ancak sınıflayıcının doğru tarafında yer almayan örnekler için ise hiper düzleme olan mesafeyi arttırmak için pozitif bir değerdir. Burada,

$$\frac{\|w\|^2}{2} + C \sum_{i=1}^m \xi_i \quad (1.98)$$

aşağıdaki kısıtlamalar ile minimize edilir.

- $y_i[w \cdot x_i + b] \geq 1 - \xi_i, i=1, \dots, m$
- $\xi_i \geq 0, \xi_i \quad i=1, \dots, m$

Formül (1.98)'de yer alan  $C$  değişkeni, kullanıcı tarafından ayarlanabilen bir sabittir. Büyük  $C$  değeri, sınıflandırma hatalarına yüksek ceza verir ve sonuç olarak yanlış sınıflanan örnek sayısını minimize etmeye çalışır. Küçük  $C$  değeri ise marjı maksimize eder ve böylece optimum ayırıcı hiper düzlem öğrenme kümesindeki hatalara karşı daha az duyarlı olur. Doğrusal olarak ayrılamayan giriş verisini yüksek boyutlu özellik uzayına etkili bir biçimde haritalamak için çekirdek fonksiyonları kullanılır ve daha sonra bu uzayda doğrusal metotlar uygulanabilir. Çekirdek fonksiyonları ve formülleri aşağıdaki tabloda verilmiştir.

Tablo 1.2. SVM çekirdek fonksiyonları

Çekirdek Fonksiyon	Formül
Doğrusal	$x_i * x_j$
Polinomal	$(\gamma x_i \cdot x_j + katsayı)^{derece}$
Radyal tabanlı fonksiyon (RBF)	$exp(-\gamma  x_i * x_j ^2)$
Sigmoid	$tanh(\gamma x_i \cdot x_j + katsayı)$

Yapılan tez çalışmasında, SVM eğitim performansı YSA eğitim performansından daha düşük çıktığından sınıflama için YSA kullanılmıştır. Bu kısım ile ilgili sonuçlar ilerleyen bölümlerde verilecektir.

#### 1.4.1.1.3. Yapay Sinir Ağı ile Sınıflama

Yapay sinir ağları birbirine bağlı çok sayıda işlemci birimin oluşturduğu bir sistemdir. İnsan beyni deneyimlerinden faydalanarak öğrenir. YSA, biyolojik sinir ağları model alınarak geliştirilmiştir. Genel anlamda YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak da tanımlanabilir. YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur [91].

Tanıma sistemlerinde genellikle çok katmanlı ağlar (ÇKA) kullanılmaktadırlar. Bunun nedeni, ÇKA'nın doğrusal olmayan problemleri başarıyla çözmesidir. Yapılan tez çalışmasından iki tane 3 katmanlı ağ geliştirilmiştir ve önerilen algoritma ile hibrid bir yapı oluşturulmuştur (ikinci bölümde anlatılacak). Geliştirilen bu ağlar, BFGS (Broyden, Fletcher, Goldfarb and Shannon) [92] eğitim algoritması kullanılarak eğitilmiştir. BFGS algoritması ikinci dereceden Newton optimizasyon yöntemlerine dayalı hızlı, etkili bir öğrenme algoritmasıdır ve kısıtsız doğrusal olmayan optimizasyon problemlerini çözmek için iteratif bir yöntemdir. BFGS yöntemlerinin, optimuma yakın kuadratik bir Taylor açılımı olmadıkça yakınsamaya ihtiyacı yoktur ve fonksiyonun hem birinci hem ikinci türevlerini kullanması gerekmez. Ancak, BFGS düzgün olmayan optimizasyonlar için de iyi performansa sahip olduğunu kanıtlamıştır [93]. BFGS algoritması [94],  $k$  iterasyonunda ağırlıkları ( $w$ ) güncellemek için aşağıdaki formülü kullanır.

$$w^{k+1} = w^k - \mu_{k+1} M_{k+1} \nabla E(w^k) \quad (1.99)$$

Burada  $\nabla E(w^k)$ , hata fonksiyonunun gradyanını göstermektedir.  $\mu_{k+1}$  pozitif ve her iterasyonda aşağıdaki gibi hesaplanan Hessian matrisinin yaklaşımıdır.

$$M_{k+1} = M_k + I \left( 1 + \frac{\gamma_k^T M_k \gamma_k}{\delta_k^T \gamma_k} \right) \frac{\delta_k^T \delta_k}{\delta_k^T \gamma_k} - \frac{\delta_k \gamma_k^T M_k + M_k \gamma_k \delta_k^T}{\delta_k^T \gamma_k} \quad (1.100)$$

$$\gamma_k = \nabla E(w^k) - \nabla E(w^{k-1}) \quad (1.101)$$

$$\delta_k = w^k - w^{k-1} \quad (1.102)$$

Başlangıç değeri  $M_0$ , birim matristir ( $I$ ). Bu şekilde öğrenme gerçekleştirilir. Öğrenen ağ artık tahmin işlemini yapabilir. Yapılan tez çalışmasında giriş katmanında önceki aşamada elde edilen GLCM özellikleri kullanılmıştır. Geliştirilen algoritma ve ağlara ilişkin bilgiler ilerleyen bölümlerde anlatılacaktır.

#### 1.4.1.2. Yanlış Pozitif İndirgeme

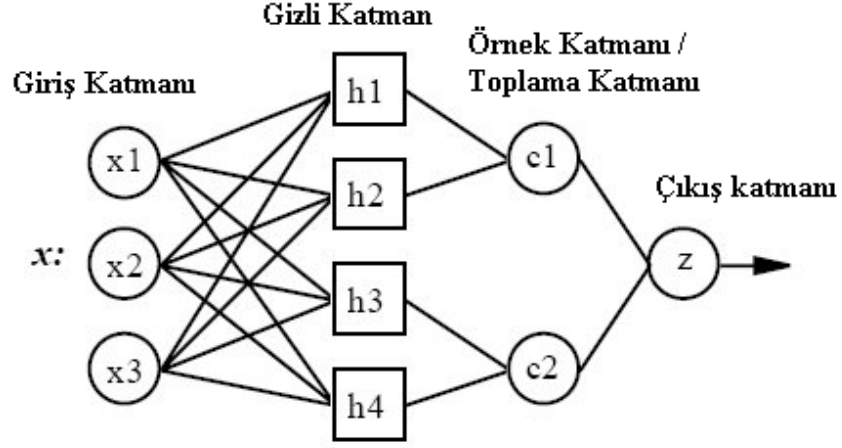
Yanlış pozitif, hasta olmadığı halde hasta yani şüpheli bölge normal doku olduğu halde kitle bölgesi olarak sınıflanan örnekleri belirtmektedir. Sınıflama sonucunda FP oranını indirmek için ekstra bölütleme, iyileştirme, sınıflama ve vb. yöntemler kullanılabilir. Yapılan tez çalışmasından, FP oranını indirmek için olasılıklı sinir ağı yöntemi kullanılarak ikinci bir sınıflama gerçekleştirilir.

##### 1.4.1.2.1. Olasılıklı Sinir Ağı

Olasılıklı sinir ağı (Probabilistic Neural Network-PNN), Specht [95] tarafından geliştirilmiş, radyal temel fonksiyonu (Radial Basic Function-RBF) ve Bayes teorisine dayalı ileri beslemeli bir sinir ağıdır. PNN, istatistiksel örüntü tanıma ve ileri beslemeli yapay sinir ağlarının bazı en iyi özelliklerini birleştirir ve Bayes posterior olasılıklar ile çıktılar üretebilir [96]. PNN nöronunun transfer fonksiyonu olan Gauss fonksiyonunun kısmi yanıt karakterinden dolayı, PNN herhangi bir sürekli fonksiyona yüksek doğrulukla yakınsayabilir. Bu nedenle, doğrusal olmayan sınıflama problemleri için çok başarılı sonuçlar verebilir. PNN'nin birçok avantajı vardır. Eğitim hızı, geri beslemeli (Backpropagation-BP) ağlara göre çok daha hızlıdır ve belirli kolaylıkla rastlanan koşullar altında Bayes optimal sonuca yaklaşabilir [97, 98]. Bununla birlikte, gürültülü örneklerle karşı dirençlidir.

PNN; meme kanseri teşhisi, kanama tespiti, beyin tümörü sınıflaması, Alzheimer teşhisi, Parkinson hastalığı ve yaprak tanıma gibi birçok çalışmada [96-101] kullanılmış ve başarılı sonuçlar elde edilmiştir. Yapılan tez çalışmasında, dört katmanlı PNN ağı kullanılmıştır.





Şekil 1.31. PNN ağ yapısı

Giriş katmanı: Giriş katmanında her tahmin değişkeni için bir nöron vardır.

Gizli katmanı: Giriş katmanındaki giriş değerleri  $x$  vektörü ile ifade edilsin. Gizli nöron, giriş nöronunun merkez noktasından Öklid mesafesini hesaplar ve sigma değerleri kullanarak RBF çekirdek fonksiyonunu uygular. Sonuç değeri, örnek katmanına iletilir.

Örnek/Toplama katmanı: Burada hedef değişkenin her bir kategorisi için bir nöron vardır. Her eğitim durumunun gerçek hedef kategorisi, her bir gizli nöron ile birlikte tutulur. Gizli nörondan gelen ağırlıklandırılmış değer sadece gizli nöronun kategorisine karşılık gelen örnek nöron ile beslenir. Örnek nöronlar, temsil ettikleri sınıf için değerleri toplarlar.

Çıkış katmanı: Çıkış yani karar katmanı, örnek katmanında biriken her hedef kategori için ağırlıklı oyları karşılaştırır ve en yüksek oyu alanı tahmini hedef kategorisi yani çıkış olarak kullanır.

Yapılan işlemlere ilişkin formüllere bakarsak;

$$z_i = x \cdot w_i$$

(1.103)

Burada  $x$ ; giriş vektörünü,  $w_i$  ise ağırlık vektörünü göstermektedir. Daha sonra doğrusal olmayan nöron aktivasyon fonksiyonu uygulanır [95] yani RBF fonksiyonu. RBF fonksiyonu olarak genellikle Gauss fonksiyonu kullanılmaktadır.

$$g_i(x) = \exp \left[ -\frac{(w_i - x)'(w_i - x)}{2\sigma^2} \right] \quad (1.104)$$

Bu Bayes işlevi, olayların göreceli olasılığını dikkate alır ve tahmini geliştirmek için ön bilgi olarak kullanır [99]. Daha sonra toplama katmanında her bir kategoriye karşılık gelen girişler toplanır. Bu prosedür her sınıf için tekrarlanır ve normalize edilmemiş yoğunluk fonksiyonları tahmin edilir. PNN, genel olarak  $M$  farklı sınıf için aşağıdaki şekilde ifade edilir.

$$y_i(x) = \frac{1}{n_j} \sum_{i=1}^{n_j} g_i(x), \quad j = 1, \dots, M \quad (1.105)$$

Burada  $n_j$ ,  $j$  sınıfındaki veri sayısıdır. Bu şekilde olasılıklar hesaplanır ve  $x$  verisi için eğer  $y_k(x) > y_i(x)$ ,  $j \in [1, \dots, M]$  ise  $k$  sınıfına atanır. Yani çıkış katmanı olasılıkların maksimumunu alır ve bizim çalışmamızda kitle bölgeleri için 1, normal doku bölgeleri için ise 0 üretir. Böylece, kitle tespitinde FP oranını indirmek için PNN kullanılarak sınıflama sonucu kitle bölgesi olarak sınıflanan bölgeler tekrar bir filtrelemeye tabi tutularak son karar verilir. Bunun sonucunda FP oranı azaltılmıştır. Sonuçlara ilişkin detaylar ilerleyen bölümlerde verilecektir.

#### 1.4.2. Mikrokalsifikasyonların Tespiti

Mikrokalsifikasyonlar, ince ve parlak noktalar şeklinde görüldükleri için tespit etmek kolay değildir. Bununla birlikte, MC kümelerinin yaklaşık %10-%40'ı küçük boyutlu ve belli olmadıklarından radyologlar tarafından kaçırılmaktadır [102]. Bu nedenle MC bölgelerinin tespiti oldukça zor ve önemlidir. MCs tespiti; özellik çıkarma, sınıflama ve yanlış pozitif indirgeme olmak üzere üç kısımda incelenecektir.

### 1.4.2.1. Özellik Çıkarma ve Sınıflama

Leonardo ve arkadaşları [103] tarafından yapılan çalışmada, eş oluşum matrisi kullanılarak karşıtlık, homojenlik, ters farklılık momenti, entropi ve enerji doku özellikleri çıkarılmıştır. Daha sonra sınıflama için ise Bayes sinir ağı (Bayesian Neural Network-BNN) kullanılmıştır. Burada normal, iyi huylu ve kötü huylu olmak üzere üç sınıflama yapılmıştır. Bu üç sınıflama sonuçlarına göre iyi huylu tespit başarısı düşüktür. Bir başka çalışmada [104], dalgacık katsayıları kullanılarak MC görünürlükleri iyileştirilmiş ve daha sonra da tespit edilmiştir. Sabu ve arkadaşları [105]; GLCM, gri seviye dizi uzunluk matrisi (Gray Level Run Length Matrix-GLRLM), LBP, gri seviye fark istatistikleri (Gray Level Difference Statistics-GLDS), Law's doku özellikleri ve fraktal bazlı doku analizinden ve bahsedilmektedir. Bu yaklaşımlardan elde edilen özellikler verilmiştir. Diğer bir çalışmada [106], GLCM özellikleri ile birliktelik kuralları tabanlı sınıflama yöntemleri kullanılmıştır. Burada, GLCM doku özelliklerinden kontrast, korelasyon, enerji ve homojenlik ile istatistiksel özelliklerden ortalama, medyan, varyans, çarpıklık ve basıklık özellikleri kullanılmıştır. Daha sonra, bazı özelliklere ilişkin sınır değerleri yani birliktelik kuralları belirlenerek sınıflama işlemi gerçekleştirilmiştir. Jelvehfard ve arkadaşları [107] tarafından yapılan çalışmada, farklı boyutlardaki şüpheli bölgelere ait iki boyutlu dalgacık dönüşümü kullanılarak özellikler çıkarılır ve ardından SVM yöntemiyle sınıflama işlemi gerçekleştirilmiştir.

Stelios ve arkadaşları [108], mikrokalsifikasyon kümelerinin tespiti için matematiksel morfoloji ile özellik çıkarımının ardından YSA yöntemi ile sınıflama işlemi gerçekleştirilmiştir. Bir başka çalışmada [109], dalgacık dönüşümü kullanılarak özellikler belirlenmiştir. Ancak sayı olarak çok fazla olduğundan her vektör için enerji hesaplanarak özellik sayısı indirgenmiştir. Sınıflama için ise YSA kullanılmıştır. Nikhil ve arkadaşları [110] tarafından yapılan çalışmada; ortalama, varyans, ortalama enerji, basıklık, çarpıklık, kontrast vb. 24 özellikler çıkarılmış, sınıflama işlemi de YSA ile gerçekleştirilmiştir. Sonuç olarak, MC bölgelerinin tespiti için betimleme başarısından dolayı çoğunlukla doku ve istatistiksel özellikler tercih edilirken, en yaygın kullanılan sınıflama yöntemleri ise YSA ve SVM 'dir.

Yapılan tez çalışmasında mikrokalsifikasyon bölgelerinin tespiti için küme önemi, enerji, kontrast, korelasyon bilgi ölçüsü, normalize ters fark momenti olmak üzere GLCM doku özellikleri ve ortalama, varyans, çarpıklık ve basıklık gibi istatistiksel özellikler

kullanılmıştır. GLCM doku özelliklerine ilişkin detaylı bilgi önceden verildiğinden burada istatistiksel özelliklerden bahsedilecektir.

#### 1.4.2.1.1. İstatistiksel Özellikler

Matematikte, moment bir dizi noktanın şekline ilişkin belirli bir kantitatif ölçüsüdür. Buna göre; birinci moment ortalamayı, ikinci moment varyansı, üçüncü standardize moment çarpıklığı ve dördüncü standardize moment ise basıklığı vermektedir. Bu özelliklere ilişkin formül [111] ve açıklamalar aşağıdaki tabloda verilmiştir.

Tablo 1.3. İstatistiksel özelliklere ait formüller ve açıklamalar

Özellikler	Formül	Açıklama
Ortalama	$\bar{x} = \frac{1}{N} \sum_{j=1}^N x_j$	Bir dağılımın merkezsiz konum noktasını bulmaya çalışır.
Varyans	$Var(X) = \sigma^2 = \frac{1}{N-1} \sum_{j=1}^N (x_j - \bar{x})^2$	Değerlerin ne ölçekte veya ne derecede yaygın olduklarını tanımlamayı hedef alır.
Çarpıklık (Skewness)	$\gamma_1 = \frac{\mu^3}{\sigma^3} = \frac{1}{N} \sum_{j=1}^N \left( \frac{x_j - \bar{x}}{\sigma} \right)^3$	Olasılık dağılımının simetrik olamayışının ölçülmesidir.
Basıklık (Kurtosis)	$\gamma_2 = \frac{\mu^4}{\sigma^4} - 3 = \left\{ \frac{1}{N} \sum_{j=1}^N \left( \frac{x_j - \bar{x}}{\sigma} \right)^4 \right\} - 3$	Olasılık dağılımının, sivriliği veya basıklık özelliğinin ölçülmesidir.

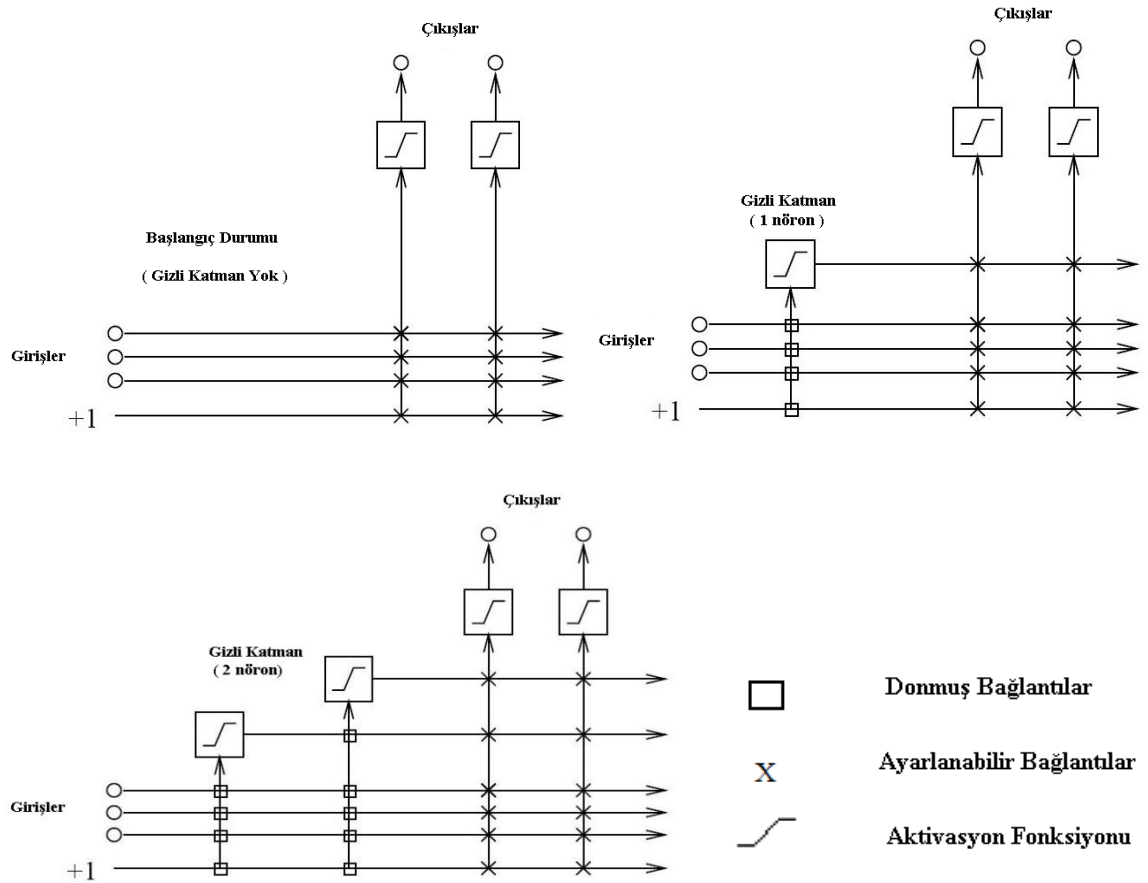
Böylece mikrokalsifikasyon bölgelerinin tespiti için özellik çıkarma işlemi tamamlanmıştır. Sınıflama için SVM ve YSA yöntemleri denenmiştir ve YSA eğitim performansı daha başarılı olduğundan YSA yöntemi kullanılmıştır. Bu yöntemlere ilişkin bilgi önceden verildiğinden burada bahsedilmeyecektir. Sonuçlara ilişkin detaylar ise ilerleyen bölümlerde verilecektir.

#### 1.4.2.2. Yanlış Pozitif İndirgeme

Yanlış pozitif, hasta olmadığı halde hasta yani şüpheli bölge normal doku olduğu halde MC bölgesi olarak sınıflanan örnekleri belirtmektedir. Sınıflama işleminden sonra aynen kitle tespitinde olduğu gibi FP bölgelerin indirgenmesi için ekstra bölütleme, iyileştirme, sınıflama ve vb. yöntemler kullanılabilir. Yapılan tez çalışmasından, FP oranını indirmek için olasılıklı sinir ağı yöntemi kullanılarak ikinci bir sınıflama gerçekleştirilir.

### 1.4.2.2.1. Kademeli Korelasyon Sinir Ağı

Kademeli korelasyon sinir ağı (Cascade Correlation Neural Network-CCNN) ilk olarak 1990 yılında Fahlman ve Libiere [112] tarafından geliştirilmiş ve yapıcı öğrenme kuralı olarak karakterize edilmiştir. Kademeli korelasyon (CC) üretken, ileri beslemeli ve danışmanlı bir öğrenme mimarisidir. CC, giriş ve çıkış katmanından oluşmak üzere minimal bir ağ yapısı ile başlar, daha sonra otomatik olarak eğitir ve gizli katman öğelerini tek tek ekleyerek çok katmanlı ağ yapısı oluşturur [113]. CCNN, ilk önce uygun öğrenme verileri ile eğitilir. Yaklaşım hatasında önemli bir azalma olduğunda ya da belli bir eğitim iterasyon sayısına ulaşıldığında eğitim prosedürü sonlanır ve elde edilen tüm ağırlıklar dondurulur [114].



Şekil 1.32. Kademeli korelasyon sinir ağı mimarisi

Bütün giriş ve çıkışlar birbirine ayarlanabilir bir ağırlık değeri  $w_{ij}$  ile bağlıdır. Ayrıca, bir sapma girişi vardır ve sabit değer olarak +1 alınmaktadır [115]. Eğitim algoritması gizli nöronlar olmadan başlar ve gizli nöronlar ağa tek tek eklenir. Her bir eklenen gizli nöron, ağın orijinal girişlerinden ve mevcut gizli nöronlardan bir bağlantı alır. Her gizli nöronun giriş ağırlıkları, ağa eklendikten sonra dondurulur. Bu yüzden her yeni nöron, ağa yeni bir nöron katmanı ekler. Yeni gizli nöron eklendikten sonra çıkış bağlantıları yeniden eğitilir.

Standart geri beslemeli algoritmalarından 10 kat daha hızlı öğrenir [113]. Ağ, kendi boyutuna ve topolojilerine kendi karar verir. Artımlı öğrenme yani zaten eğitilmiş bir ağa yeni bilgi ekleme, için oldukça kullanışlıdır.

CCNN için Eğitim Algoritması:

*Adım 1.* Giriş ve çıkış katmanı içeren CC sinir ağına başlanır

*Adım 2.* Bütün giriş nöronlarını, çıkış nöronlarına ayarlanabilir ağırlıklar ile bağlanır.

Her giriş nöron değeri kendi ağırlığı ile çarpılır ve bütün giriş nöronlarının giriş ağırlık değeri toplamı hesaplanır. Daha sonra ağırlıklandırılmış giriş toplamı sapma değeri (+1) ile çıkış nöronlarına gönderilir.

*Adım 3.* Her bir giriş biriminden ve mevcut gizli birimlerden bağlantı alan aday birim oluşturulur. Başlangıçta, aday birimler ile çıktı birimleri arasında bağlantı ve ağırlıklar yoktur.

*Adım 4.* Her aday birimine giden bağlantılar, ağın artık hatası (residual error) ile aday birimlerin aktivasyonu arasındaki korelasyonu maksimize etmek için seçili standart öğrenme algoritması ile eğitilir. Bu ayarın amacı,  $S$ 'yi maksimize etmektir.  $S$  aşağıdaki şekilde tanımlanır [116].

$$S = \sum_o |\sum_p (V_p - \bar{V})(E_{p,o} - \bar{E}_o)| \quad (1.106)$$

Burada;  $o$ , çıkış nöronu,  $p$  eğitim örneği,  $V_p$  eğitim örneği  $p$  için aday çıkışı ve  $E_{p,o}$  ise çıkış nöronu  $o$ 'daki hatayı göstermektedir. Bununla birlikte  $\bar{V}$  ve  $\bar{E}_o$  sırasıyla  $V_p$  ve  $E_{p,o}$  tüm eğitim örnekleri üzerindeki ortalamasıdır.  $S$ 'yi maksimize etmek için her bir aday birimin gelen ağırlıklarına göre  $S$ 'nin kısmi türevi aşağıdaki formül ile hesaplanır.

$$\frac{\partial S}{\partial w_i} = \sum \sigma_o (E_{p,o} - \overline{E_o}) f'_p I_{i,p} \quad (1.107)$$

Burada  $\sigma_o$ , aday değeri ile  $o$ , çıkış nöronu arasındaki korelasyonu göstermektedir.  $f'_p$ , aday birimin aktivasyon fonksiyonunun giriş değerleri toplamına göre  $p$  örneği için türevi ve  $I_{i,p}$  ise  $p$  örneği için aday birimin  $i$  biriminden aldığı giriştir. Her bir gelen bağlantı için  $\partial S/\partial w_i$  hesaplandıktan sonra gradyan çıkış uygulanır. Sadece ağırlıkların tek katmanı eğitilir. Artık  $S$ 'de bir gelişme yoksa ya da önceden tanımlı bir iterasyon sayısına ulaşıldı ise durulur.

*Adım 5.* Aday birim ağa katılır ve giriş ağırlıkları dondurulur.

*Adım 6.* Aday birimi gizli nöron olarak değiştirmek için aday birim ile bütün çıkış birimleri arasında bağlantı oluşturulur.

*Adım 7.* Eğitilen örnek kabul edilebilir hata değeri ile öğrenilmediyse *Adım 2*'ye gidilir. Aksi takdirde o örnek için eğitim tamamlanır.

FP indirgeme yöntemine ilişkin detaylar ve sonuçlar ilerleyen bölümlerde verilecektir. Bu şekilde MC bölgelerinin tespiti aşaması da tamamlanmıştır. Bundan sonra anormalliklerin iyi huylu ve kötü huylu değerlendirilmesi incelenecektir.

## 1.5. Anormalliklerin İyi Huylu/Kötü Huylu Değerlendirilmesi

Kitle ve mikrokalsifikasyon bölgeleri tespit edildikten sonra ilgili anormalliğin iyi huylu (selim) ve kötü huylu (habis) durumu değerlendirilebilir. Burada ilgili anormalliğin selim veya habis olasılığının belirlenmesi için özellik çıkarma ve sınıflama işlemleri gerçekleştirilmiştir.

### 1.5.1. Kitle için İyi Huylu/Kötü Huylu Değerlendirmesi

Kitleler farklı yoğunluklara (yağ içeren, düşük yoğunluklu, yüksek yoğunluklu), farklı kenarlara (sınırları belli, çok küçük yuvarlak çıkıntılı, anlaşılabilir, belirsiz, keskin noktalara sahip) ve farklı şekillere (yuvarlak, oval, yuvarlak çıkıntılı, düzensiz) sahiptirler. Düzgün ve sınırları belli kenarlara sahip yuvarlak ve oval kitleler iyi huylu değişiklikleri

gösterir. Öte yandan kötü huylu bir kitle genellikle keskin noktalara, pürüzlü ve bulanık sınırlara sahiptir [117]. Tespit edilen kitlelerin iyi huylu veya kötü huylu değerlendirmesi için özellik çıkarma ve sınıflama işlemleri gerçekleştirilmiştir.

### 1.5.1.1. Özellik Çıkarma ve Sınıflama

Mohamed ve arkadaşları tarafından yapılan çalışmada [118], dalgacık ve eğricik dönüşümleri kullanılarak özellikler çıkarılmıştır ve sınıflama sonuçları karşılaştırılmıştır. Bunun için 4 seviyede ayrışma yapıp her seviyedeki ilk en büyük 100 katsayı, toplamda 400 katsayı özellik vektörü olarak kullanılmıştır. Dalgacık ve eğricik dönüşümleri için 400'er özellik belirlenip Öklid mesafesine dayalı en yakın komşu sınıflayıcı ile iyi huylu ve kötü huylu sınıflama işlemi gerçekleştirilmiştir. Eğricik dönüşümünün, dalgacık dönüşümüne göre daha iyi performans gösterdiği bahsedilmektedir. Bir başka çalışmada [119], alt örneklenmemiş contourlet dönüşümü ve SVM yöntemleri kullanılmıştır. Contourlet dönüşümü ile elde edilen katsayılar sayıca fazla olduğundan normalizasyonun ardından enerji hesaplanarak bu sayı indirgenmiş ve elde edilen değerler özellik olarak kullanılmıştır. Daha sonra sınıflama işlemi SVM ile iki aşamada gerçekleştirilmiştir. Önce kitle veya normal doku sınıflaması yapıp ardından kitle ise iyi huylu veya kötü huylu sınıflaması gerçekleştirilmiştir. Muhammad ve arkadaşları [120], kitleleri temsil eden ve ayıran ortalama, standart sapma ve çarpıklık gibi dokusal özelliklerin çıkarılmasında farklı ölçek ve yönlerdeki Gabor filtre bankasını kullanmışlardır. Bu şekilde özellikler çıkarıldıktan sonra önerilen sistem ROI bölgesini SVM yöntemiyle önce kitle veya normal ardından kitle ise iyi huylu veya kötü huylu sınıflamasını yapmaktadır. Bir diğer çalışmada [121], istatistiksel ve doku özellikleri çıkarılarak Bayes sınıflayıcı ile normal, iyi huylu ve kötü huylu olmak üzere üç çıkışlı sınıflama yapılmıştır. Sonuç olarak doku özelliklerinin tespit işleminde yüksek doğruluk sağladığından ve istatistiksel özelliklerden daha etkili olduğundan bahsedilmektedir. Ancak önerilen sisteme ait istatistiksel performans değerlendirilmesi (duyarlılık, özgüllük) verilmemiştir. Mohanty ve arkadaşları tarafından yapılan çalışmada [122], ROI bölgelerine ait birinci dereceden ve ikinci dereceden istatistiksel özellikler çıkarılır ve özellik sayısının indirgenmesi için  $t$  testi kullanılmıştır. Buradan elde edilen özellikler birliktelik kuralları yöntemi kullanılarak sınıflandırılmıştır. ROI seçimi, veritabanına ilişkin bilgiler kullanılarak elle belirlenmiştir.



Yapılan tez çalışmasında, tespit edilen kitlelerin iyi huylu veya kötü huylu sınıflaması için Haralick doku özelliklerinden [123] yerel homeopati (local homeopathy), istatistiksel özelliklerden basıklık ve dalgacık dönüşümü elde edilen katsayılarının enerjileri kullanılarak özellik çıkarma işlemi gerçekleştirir. Basıklık özelliğine ilişkin bilgi önceden verildiğinden burada yerel homeopati ve dalgacık dönüşümü tabanlı özelliklerinden bahsedilecektir.

#### 1.5.1.1.1. Yerel Homeopati Özelliği


Homeopati benzerlik anlamına gelmektedir, bu durumda yerel homeopati ise yerel benzerlik olarak da ifade edilebilir. Haralick doku özelliklerinden yerel homeopati özelliği daha önceden belirttiğimiz eş oluşum matrisi üzerinden hesaplanmaktadır ve aşağıdaki formül ile ifade edilmektedir [124].

$$\sum_{i=0}^n \sum_{j=0}^n \frac{p(i,j)}{1+(i-j)^2} \quad (1.108)$$


Burada  $p(i,j)$ ; eş oluşum matrisindeki  $i$ .sıtr  $j$ .sütun elemanını,  $n$  ise matris satır ve sütun sayısını göstermektedir.

#### 1.5.1.1.2. Dalgacık Dönüşümü Tabanlı Özellikler

Dalgacık dönüşümüne ilişkin detaylı bilgi önceden verildiğinden burada dalgacık katsayıları kullanarak özellik çıkarma işleminden bahsedilecektir. Yapılan tez çalışmasında, iyi huylu veya kötü huylu sınıflaması için kitle bölgesine ilişkin özelliklerin çıkarılmasında literatürdeki başarısından dolayı [125-128] Daubechies dalgacığı kullanılmıştır. Kullanılan dalgacığa ait ayrıştırma ve yeniden yapılandırma fonksiyon ve filtrelerine ilişkin grafikler aşağıda verilmiştir.



Şekil 1.33. Daubechies 2 ölçekleme ve dalgacık fonksiyonları



Şekil 1.34. Daubechies 2 ayrıştırma ve yeniden yapılanma filtreleri

Burada katsayılar kullanılacağından sadece ayrıştırma işlemi yapılmıştır. Ayrıştırma işlemi sonucunda yüksek geçiren filtre ile elde edilen detay katsayıları  $D[n]$ , alçak geçiren filtre ile elde edilen tahmin katsayıları da  $A[n]$  ile ifade edilsin. Birinci seviye dalgacık ayrıştırma sonucu yatay  $Dh_1$ , köşegensel  $Dd_1$ , dikey  $Dv_1$  detay katsayıları ve bir de tahmini  $A_1$  katsayısı elde edilir. Bunlar sayıca çok fazla olduğundan özellik vektörü olarak kullanmak için boyut indirgeme gerçeklenir [129]. Bunun için aşağıda verilen formüller ile enerji değerleri hesaplanarak özellik olarak kullanılabilir.

$$Enerji (Eh) = \frac{1}{N \times M} \sum_{x=N} \sum_{y=M} |Dh_1(x, y)|^2 \quad (1.109)$$

$$Enerji (Ev) = \frac{1}{NxM} \sum_{x=N} \sum_{y=M} |Dv_1(x, y)|^2 \quad (1.110)$$

$$Enerji (Ed) = \frac{1}{NxM} \sum_{x=N} \sum_{y=M} |Dd_1(x, y)|^2 \quad (1.111)$$

Böylece her seviye için 3 enerji değeri yani 3 özellik elde edilir. Yapılan çalışmada, iki seviyeli ayrıştırma işlemi gerçekleştirilmiştir. Bunun sonucunda özelliklerimiz elde edilmiştir. Bundan sonra sınıflama işlemi için SVM, olasılıklı sinir ağı, K-ortalama ve tekli karar ağacı yöntemleri incelenmiştir. Yapılan tez çalışmasında, kitle iyi huylu veya kötü huylu sınıflaması için SVM ve olasılıklı sinir ağı performans sonuçları daha düşük olduğundan K-ortalama ve tekli karar ağacı yöntemleri kullanılmıştır. Sonuçlara ilişkin detaylar ilerleyen bölümlerde verilecektir.

#### 1.5.1.1.3. K-Ortalama Algoritması ile Sınıflama

K-ortalama algoritması, giriş verisini birbirlerine olan mesafeye göre çoklu sınıflara ayıran danışmansız bir kümeleme algoritmasıdır. Algoritma veri özelliklerinin bir uzay vektörü oluşturduğunu varsayar ve bunlar içerisinde doğal kümelemeyi bulmaya çalışır. Bu algoritma, kare hata tabanlı amaç fonksiyonunu minimize ederek küme merkezlerine ve elemanlarına karar verir. Algoritmanın amacı küme merkezlerini birbirlerinden mümkün olduğu kadar uzağa yerleştirmek ve her veri noktasını en yakın küme merkezine birleştirmektir [130]. K-ortalama algoritmasında farklılık ölçüsü olarak genellikle Öklid mesafesi kullanılır. Amaç fonksiyonu  $J$  aşağıdaki gibi ifade edilir.

$$J = \sum_{i=1}^K (\sum_k \|x_k - c_i\|^2) \quad (1.112)$$

Burada  $K$ ; küme sayısını,  $c_i$ ; kümelerin merkezlerini ve  $x_k$  ise  $i$ . kümedeki  $k$ . veri noktasını göstermektedir. Bir veri noktası, merkezine en yakın olduğu kümeye aittir. Böylece kümeler ikili üyelik matrisi  $U$  ile gösterilir.  $U$  matrisinin elemanları aşağıdaki gibi belirlenir [130].

$$u_{ij} = \begin{cases} 1, & \text{eğer } \|x_k - c_i\|^2 \leq \|x_j - c_t\|^2, \forall t \neq i \\ 0, & \text{aksi takdirde} \end{cases} \quad (1.113)$$

Burada  $u_{ij}$ ,  $j$ . veri noktasının  $i$ . kümeye ait olup olmadığını gösterir. Amaç fonksiyonunu  $J$  minimize eden her küme merkezi  $c_i$  aşağıdaki formülle ifade edilir.

$$c_i = \frac{\sum_{j=1}^N u_{ij} x_j}{\sum_{j=1}^N u_{ij}} \quad (1.114)$$

$N$ , veri noktalarının sayısını göstermektedir. K-ortalama algoritmasının aşamaları aşağıda verilmiştir.

K-Ortalama Algoritması:

Adım 1. Başlangıçta  $K$  veri noktalarını küme merkezleri olarak seçin

Adım 2.  $U$  üyelik fonksiyonunu hesapla

Adım 3. Amaç fonksiyonunu  $J$  hesapla

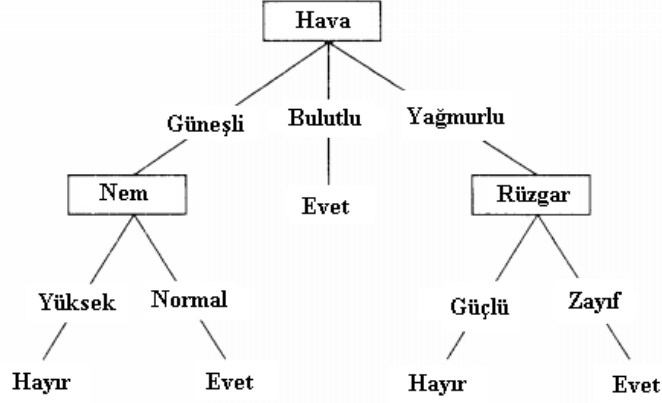
Adım 4. Formül (1.114)'e göre küme merkezlerini güncelle

Adım 5. Küme merkezleri sabit kalana kadar *Adım 2.*'ye git.

Böylece K-ortalama algoritması kullanılarak iyi huylu veya kötü huylu sınıflama işlemi gerçekleştirilir.

#### 1.5.1.1.4. Tekli Karar Ağacı Algoritması ile Sınıflama

Karar ağaçları, örnekleri ağacın kökünden aşağıya yaprak düğümlerine doğru sıralayarak sınıflamaktadır. Ağaçtaki her bir düğüm örneğe ilişkin özelliğin testidir ve her dal düğümünden, ona karşılık gelen o özellik için mümkün değerlerden birine doğru iner. Örnek, ağacın kök düğümünden başlar, o düğüm tarafından belirtilen özellik test edilir ve sonra aşağıya doğru özellik değerine karşılık gelen ağaç dalı boyunca hareket ederek sınıflanmaktadır [131]. Aşağıdaki şekilde havanın tenis oynamak için uygunluğuna karar veren basit bir karar ağacı örneği verilmiştir.



Şekil 1.35. Karar ağacı örneği

Bu öğrenmiş karar ağacı için; *Hava=Güneşli*, *Nem=Yüksek*, *Rüzgâr=Güçlü* ise *Tenis oynamak için uygun mu= Hayır* tahmini elde edilir.

Karar ağaçları, açıklayıcı olduklarından takip etmek kolaydır. Hem nominal hem sayısal giriş özellikleri kullanabilirler [132]. Karar ağaçları; parametre tahmini, gen fonksiyonu tahmini, özellik seçiminde, sınıflayıcı vb. çalışmalarda kullanılmaktadır [133-136]. Karar ağaçları örüntü sınıflamak için oldukça popüler ve pratik bir yaklaşımdır [136]. Karar ağacı, ağaç yapısı şeklinde bir akış şemasıdır ve her iç düğüm öznelik üzerinde bir testi, her dal ise o teste ilişkin sonucu ve her ağaç düğümü de sınıf etiketini temsil etmektedir. Karar ağacına ilişkin ağaç oluşturma aşamaları aşağıdaki gibidir.

#### Ağacı Oluşturma:

- Her düğümü incele ve en iyi olası ayrımı bul
  - Her giriş özelliğini incele
    - Her giriş özelliğindeki olası her ayrımı incele
- İki çocuk düğüm oluştur
- Her satırın hangi çocuk düğümüne gideceğine karar ver
- Bu işleme durma kriteri (Örneğin; minimum düğüm sayısı) sağlanana kadar devam et

Ağacı oluşturduktan sonra, her olası ağaç boyutu için yanlış sınıflandırma maliyeti hesaplanıp, optimal boyuta göre budama işlemi gerçekleştirilir. *ID3*, *C4.5* ve *CART* olmak üzere kullanılan üç öğrenme algoritması vardır [136].

### ID3 (Iterative Dichotomiser 3) Algoritması:

Bu algoritma ilk olarak 1986 yılında Quinlan [137] tarafından sunulmuştur. ID3 ayırıcı özelliği seçmek için bilgi kazancı ölçüsünü kullanır. Ağacı oluştururken kategorik özellikleri kabul eder. Gürültü var ise doğru sonuç vermez, bu durumda gürültünün ön işleme tekniği ile kaldırılması gerekir. Ağacı oluştururken her özellik için bilgi kazancı hesaplanır ve en yüksek değere sahip özellik kök düğüm olarak atanmak için seçilir. Bu özellik, kök düğüm olarak etiketlenir ve özelliğe ait bütün olası değerler arklar olarak temsil edilir. Daha sonra, tüm olası örnek sonuçlarının aynı sınıfa düşüp düşmediği test edilir. Eğer bütün örnekler aynı sınıfa düşüyorsa düğüm tek bir sınıf adı ile temsil edilir. Aksi takdirde, örnekleri sınıflamak için ayırıcı bir özellik seçilir.

### C4.5 Algoritması:

Bu algoritma Quinlan [138] tarafından ID3 algoritmasının bir uzantısı olarak geliştirilmiştir. Ağacı oluştururken hem kategorik hem de sürekli özellikleri tutabilir. Özellik seçme ölçüsü olarak kazanç oranını kullanır ve bu da özelliğe ait birçok çıkış değeri olduğu durumdaki dezavantajı kaldırır. İlk önce, her özellik için kazanç oranı hesaplanır ve maksimum değere sahip özellik kök düğüm olarak seçilir. Bununla birlikte, C4.5 karar ağacındaki gereksiz dalları kaldırarak sınıflama doğruluğunu geliştirir.

### CART Algoritması:

CART, sınıflama ve regresyon ağacı açılımı olarak Breiman [139] tarafından tanıtılmıştır. Ağacı oluştururken hem kategorik hem de sürekli özellikleri tutabilir. Özellik seçme ölçüsü olarak Gini indeksini kullanır. ID3 ve C4.5 algoritmalarının aksine ikili parçalar üretir. İkili ağaçlar ürettiğinden Gini indeksi ID3 ve C4.5'deki gibi olasılıklı varsayımlar kullanmaz.

Lavanya ve arkadaşları [136] tarafından yapılan çalışmada medikal veriler üzerinde karar ağacı sınıflayıcıları için performans değerlendirilmesi yapılmıştır. Sonuç olarak meme kanseri için sırasıyla CART ve C4.5 algoritmalarının en başarılı sonuçları verdiğinden bahsedilmektedir. Yapılan tez çalışmasında tekli karar ağacı (Single Decision Tree-SDT) sınıflayıcısı için CART algoritması kullanılmıştır.

## 1.5.2. Mikrokalsifikasyonlar için İyi Huylu/Kötü Huylu Değerlendirmesi

İyi huylu kalsifikasyonlar genellikle düzgün ve yuvarlak konturlar ile daha büyük ve daha iridirler. Kötü huylu kalsifikasyonlar ise çok sayıda, kümelenmiş, küçük, boyut ve şekil olarak çeşitlilik gösteren, açısız, düzensiz şekillenmiş olabilir ve yön belirlemede dallanma gösterebilir [117]. Tespit edilen mikrokalsifikasyonların iyi huylu veya kötü huylu değerlendirilmesi için özellik çıkarma ve sınıflama işlemleri gerçekleştirilmiştir.

### 1.5.2.1. Özellik Çıkarma ve Sınıflama

Phadke ve arkadaşları [104] tarafından yapılan çalışmada mikrokalsifikasyonların iyi huylu veya kötü huylu sınıflaması için dalgacık özellikleri ile SVM ve YSA yöntemleri kullanılmıştır. Burada Daubechies 4 dalgacığı ile 7 seviyeli ayrıştırma gerçekleştirilmiştir ve bunun sonucunda elde edilen 147 dalgacık katsayısı özellik vektörü olarak kullanılmıştır. Bir başka çalışmada [105] iyi huylu ve kötü huylu sınıflaması için fraktal bazlı doku özelliklerinden bahsedilmektedir. Thangavel ve arkadaşı [140] tarafından yapılan çalışmada, tespit edilen MC kümelerinin şekil ve görünümü ile ilgili özellikler belirlenip birliktelik kuralları tabanlı sınıflayıcı kullanılarak normal doku, iyi huylu MC ve kötü huylu MC olmak üzere üç farklı şekilde sınıflandırılmıştır. Diğer bir çalışmada [141], birinci dereceden istatistikler, eş oluşum matrisi özellikleri, dizi uzunluk matrisi özellikleri ve Law doku enerji ölçüleri olmak üzere dört farklı kategoride doku özellikleri kullanılarak K- en yakın komşu algoritması ile iyi huylu veya kötü huylu sınıflaması gerçekleştirilmiştir. Tirtajaya ve arkadaşı [142] tarafından yapılan çalışmadan dalgacık dönüşümü katsayıları özellik vektörü ile SVM sınıflayıcı kullanılarak iyi huylu ve kötü huylu değerlendirilmesi gerçekleştirilmiştir. Bir başka çalışmada [143]; ortalama, varyans, basıklık ve çarpıklık gibi istatistiksel özellikler çıkarılarak normal doku, iyi huylu ve kötü huylu olmak üzere üç çıkışlı sınıflama işlemi karar ağacı ile gerçekleştirilmiştir.

Yapılan tez çalışmasında, tespit edilen mikrokalsifikasyonların iyi huylu veya kötü huylu sınıflaması için çarpıklık, kontrast, ortalama, homojenlik gibi dokusal ve istatistiksel özellikler ile GLRLM özellikleri kullanılmıştır. Belirtilen dokusal ve istatistiksel özelliklere ilişkin bilgi önceden verildiğinden burada GLRLM özelliklerinden bahsedilecektir.

### 1.5.2.1.1. Gri Seviye Dizi Uzunluk Matrisi ile Özellik Çıkarma

Gri seviye dizi uzunluk matrisi, doku analizi için doku özelliklerinin çıkarılabildiği bir matristir. Doku, referans pikselden belirli bir yöndeki gri seviye piksel modeli olarak anlaşılabilir. Dizi uzunluğu ise belirli bir yöndeki aynı gri seviye değerine sahip komşu piksellerin sayısıdır [144]. Bir görüntüde, komşu piksellerin aynı gri seviye sahip olması ölçüler doku özelliği belirlenmeye çalışılır. Komşu piksellerin uzun uzadıya aynı gri seviyede bulunması kalın hatlı kaba bir dokuyu temsil ederken az sayıda komşu pikselin aynı gri seviyeye sahip olması daha hızlı değişimin olduğu daha ince bir dokuyu temsil eder [145]. Eğer GLRLM,  $P$  ile gösterilirse,  $P(i,j)$ 'nin değeri,  $i$  değerinin  $j$  değeriyle bazı belirlenmiş konumsal ilişkiler içinde kaç kez birleştiğini belirtir. Bu şöyle de açıklanabilir,  $P(i,j)$ ,  $i$  gri seviyesinin  $j$  uzunluğunda kaç defa meydana geldiğini gösterir.

Bu tanımlama açısal olarak  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  olmak üzere farklı yönler için yapılabilmekle beraber en yaygın kullanımı yatay doğrultuda yapılan tanımlamadır. Gri seviye dizi uzunluk metodu, farklı uzunlukların gri seviye sayılarının hesaplanmasına dayanır. Örneğin  $4 \times 4$  boyutlu, 4 gri seviyeli bir görüntüye ait  $0^\circ$  yönündeki GLRL matrisi,  $P(i,j) | \theta = 0^\circ$ , aşağıdaki gibi ifade edilir.

		Dizi uzunluğu (j)						
		j	1	2	3	4	5	6
Gri seviye (i)	i							
	1	1	8	0	0	0	0	0
	2	2	4	1	0	0	0	0
	3	4	1	0	0	0	0	0

GÖRÜNTÜ	
1	1 1 2 2 1 1
3	3 3 1 1 2 2
1	1 1 2 3 1 1
3	3 1 2 2 1 1
1	1 1 3 2 2 2
2	2 3 1 1 2 2

Şekil 1.36.  $4 \times 4$  boyutlu görüntüye ait GLRL matrisi

Bir gri seviye uzunluğu, aynı gri seviye değerine sahip doğrusal bir komşu pikseller dizisidir. Gri seviye dizi uzunluğu içindeki piksellerin sayısıdır [145]. GLRL matrisini kullanarak oluşturulan özelliklerden en yaygın olarak kullanılanlar aşağıdaki tabloda verilmiştir [146, 147].



Tablo 1.4. GLRLM özelliklerine ait formül ve açıklamalar

Özellikler	Formül	Açıklama
Kısa ilkel vurgusu (Short Run Emphasis)	$SRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{j^2}$	Kısa dizi uzunluklarının dağılımını ölçer. İnce dokular için büyük olması beklenir.
Uzun ilkel vurgusu (Long Run Emphasis)	$LRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i,j) * j^2$	Uzun dizi uzunluklarının dağılımını ölçer. Kaba yapıli dokular için büyük olması beklenir.
Düşük gri seviye ilkel vurgusu (Low Gray-Level Run Emphasis)	$LGRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{i^2}$	Düşük gri seviye değerlerin dağılımını ölçer. Düşük gri seviyeli görüntü için büyük olması beklenir.
Yüksek gri seviye ilkel vurgusu (High Gray-Level Run Emphasis)	$HGRE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i,j) * i^2$	Yüksek gri seviye değerlerin dağılımını ölçer. Yüksek gri seviyeli görüntü için büyük olması beklenir.
Kısa ilkel düşük gri seviye vurgusu (Short Run Low Gray-Level Emphasis)	$SRLGE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j)}{i^2 * j^2}$	Kısa dizi uzunlukları ile birlikte düşük gri seviye dağılımını ölçer. Birçok kısa dizi uzunlukları ve düşük gri seviye değerli görüntü için yüksek olması beklenir.
Kısa ilkel yüksek gri seviye vurgusu (Short Run High Gray-Level Emphasis)	$SRHGE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j) * i^2}{j^2}$	Kısa dizi uzunlukları ile birlikte yüksek gri seviye dağılımını ölçer. Birçok kısa dizi uzunlukları ve yüksek gri seviye değerli görüntü için yüksek olması beklenir.
Uzun ilkel düşük gri seviye vurgusu (Long Run Low Gray-Level Emphasis)	$LRLGE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N \frac{p(i,j) * j^2}{i^2}$	Uzun dizi uzunlukları ile birlikte düşük gri seviye dağılımını ölçer. Birçok uzun dizi uzunlukları ve düşük gri seviye değerli görüntü için yüksek olması beklenir.
Uzun ilkel yüksek gri seviye vurgusu (Long Run High Gray-Level Emphasis)	$LRHGE = \frac{1}{n_r} \sum_{i=1}^M \sum_{j=1}^N p(i,j) * i^2 * j^2$	Uzun dizi uzunlukları ile birlikte yüksek gri seviye dağılımını ölçer. Birçok uzun dizi uzunlukları ve yüksek gri seviye değerli görüntü için yüksek olması beklenir.
Gri seviye farklılığı (Gray-level Non-uniformity)	$GLNU = \frac{1}{n_r} \sum_{i=1}^M \left( \sum_{j=1}^N p(i,j) \right)^2$	Görüntü boyunca gri seviye değerlerinin benzerliğini ölçer. Görüntüdeki gri seviye değerleri benzer ise küçük olması beklenir.

Tablo 1.4'ün devamı

İlkel uzunluk farklılığı (Run Length Non-uniformity)	$RLNU = \frac{1}{n_r} \sum_{i=1}^N \left( \sum_{j=1}^M p(i, j) \right)^2$	Görüntü boyunca dizi uzunluklarının benzerliğini ölçer. Görüntüdeki dizi uzunlukları benzer ise küçük olması beklenir.
İlkel yüzdesi (Run Percentage)	$RPC = \frac{n_r}{p(i, j) * j}$	Görüntüdeki homojenliği ve belli bir yöndeki dizi uzunlukları dağılımını ölçer. Belirli bir yöndeki bütün gri seviyelerin dizi uzunluğu 1 olduğu zaman RPC en büyüktür.

Böylece GLRL matrisi doku özellikleri çıkarılır. Bundan sonra sınıflama işlemi için SVM, YSA, tekli karar ağacı ve diskriminant analizi yöntemleri incelenmiştir. Yapılan tez çalışmasında, kitle iyi huylu veya kötü huylu sınıflaması için YSA ve tekli karar ağacı performans sonuçları daha düşük olduğundan SVM ve diskriminant analizi yöntemleri kullanılmıştır. Sonuçlara ilişkin detaylar ilerleyen bölümlerde verilecektir.

#### 1.5.2.1.2. Lineer Diskriminant Analiz ile Sınıflama

Geleneksel diskriminant (ayırma) analiz Fisher [148] tarafından sunulmuştur ve lineer diskriminant analiz olarak da bilinir. Lineer diskriminant analiz (Linear Discriminant Analysis-LDA) genel olarak sınıflama ve boyut azaltma problemlerinde kullanılmaktadır. LDA yöntemi belirli bir veri setinde sınıflar arası varyansın sınıf içi varyansa oranını maksimize eder ve böylece maksimal ayırabilirliği garanti etmiş olur [149]. LDA'nın temel fikri sınıfları en iyi ayıran lineer dönüşümü bulmaktır ve sınıflama dönüşüm uzayında Öklid mesafesi gibi bir metriğe göre gerçekleşir [150].

- İki Sınıf için LDA:

LDA, Fisher tarafından ilk olarak iki sınıf için sunulmuştur ve amacı çok değişkenli gözlemleri,  $x$ , tek değişkenli gözlemlere,  $y$ , dönüştürmektir öyle ki  $y$ 'nin türetildiği iki sınıf birbirinden mümkün olduğunca ayrılmış olsun.  $x_1, x_2, \dots, x_m$  ( $x_i = (x_{i1}, \dots, x_{ip})$ ) olmak üzere  $c_1$  ve  $c_2$  sınıflarına ait  $m$  tane  $p$  boyutlu örnek kümemiz olduğunu varsayalım. Bu iki sınıf için dağılım matrisleri aşağıdaki gibi verilmiştir.

$$S_i = \sum_{x \in c_i} (x - \bar{x}_i) (x - \bar{x}_i)' \quad (1.115)$$

Burada  $\bar{x}_i = \frac{1}{m_i} \sum_{x \in c_i} x$  ve  $m_i$  ise  $c_i$  sınıfındaki örneklerin sayısıdır. Bu durumda toplam sınıf içi dağılım matrisi aşağıdaki gibidir.

$$\hat{\Sigma}_w = S_1 + S_2 = \sum_i \sum_{x \in c_i} (x - \bar{x}_i) (x - \bar{x}_i)' \quad (1.116)$$

Sınıf arası dağılım matrisi ise aşağıdaki şekilde ifade edilir.

$$\hat{\Sigma}_b = (\bar{x}_1 - \bar{x}_2)(\bar{x}_1 - \bar{x}_2)' \quad (1.117)$$

Fisher kriteri, lineer dönüşümü  $\phi$ , *Rayleigh* katsayısını maksimize etmek için önermektedir. Bu katsayı; örneklerin sınıf arası dağılım matrisinin, sınıf içi dağılım matrisine oranıdır.

$$J(\phi) = \frac{|\phi^T \hat{\Sigma}_b \phi|}{|\phi^T \hat{\Sigma}_w \phi|} \quad (1.118)$$

Burada  $\Phi$ ,  $\hat{\Sigma}_w^{-1} \hat{\Sigma}_b$  matrisinin öz vektörü ile elde edilir.

- Çoklu Sınıf için LDA:

Eğer sınıf sayısı ikiden fazla ise Fisher diskriminant analizin genişletilmiş olarak çoklu diskriminant analiz kullanılmaktadır [150]. İki sınıflı da olduğu gibi yüksek boyutlu uzaydan düşük boyutlu uzaya izdüşüm yapılır ve dönüşüm sınıf içi dağılımın sınıf arası dağılıma oranını maksimize etmeyi öne sürmektedir. Ancak iki sınıflı durumun aksine maksimizasyon birkaç rakip sınıf arasında yapılır. Varsayalım ki  $n$  tane sınıf var ve sınıf içi matris aşağıdaki formül ile hesaplanır.

$$\hat{\Sigma}_w = S_1 + \dots + S_n = \sum_{i=1}^n \sum_{x \in c_i} (x - \bar{x}_i) (x - \bar{x}_i)' \quad (1.119)$$

Sınıf arası dağılım matrisi hesaplama olarak biraz daha farklıdır.

$$\hat{\Sigma}_b = \sum_{i=1}^n m_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})' \quad (1.120)$$

Burada  $m_i$  her sınıf için eğitim örneklerini,  $\bar{x}_i$  her sınıf için ortalamayı ve  $\bar{x}$  ise  $\bar{x} = \frac{1}{m} \sum_{i=1}^n m_i \bar{x}_i$  ile ifade edilen toplam ortalama vektörünü göstermektedir.  $\hat{\Sigma}_b$  ve  $\hat{\Sigma}_w$  değerlerini elde ettikten sonra iki sınıflı durumda olduğu gibi formül (1.117) ile lineer dönüşüm  $\Phi$  maksimize edilir. Dönüşüm  $\Phi$ , genel öz değer problemi çözülerek elde edilebilir.

$$\hat{\Sigma}_b \Phi = \lambda \hat{\Sigma}_w \Phi \quad (1.121)$$

$\hat{\Sigma}_b$  ve  $\hat{\Sigma}_w$  değerleri için üst sınırlar sırasıyla  $n-1$  ve  $m-n$ 'dir. Çoklu diskriminant analizi sınıflama için diskriminant özellikleri kullanan çok iyi bir yol sağlar.

- Sınıflama:

Dönüşüm,  $\Phi$  verildikten sonra dönüşüm uzayında uzaklık metriğine dayalı olarak sınıflama gerçekleşir.

Örneğin Öklid mesafesi  $d(x, y) = \sqrt{\sum_i (x_i - y_i)^2}$  ve kosinüs ölçüsü  $d(x, y) = 1 - \frac{\sum_i x_i y_i}{\sqrt{\sum_i x_i^2} \sqrt{\sum_i y_i^2}}$ . Yeni örnek  $z$ , aşağıdaki şekilde sınıflanır.

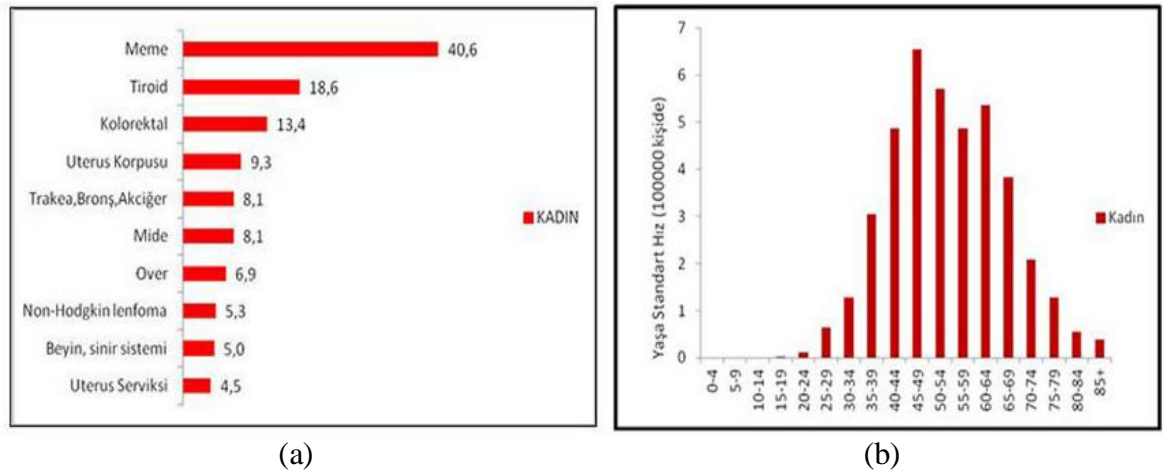
$$\underset{k}{\operatorname{argmin}} d(z\Phi, \bar{x}_k\Phi) \quad (1.122)$$

Burada  $\bar{x}_k$ ,  $k$ . sınıfın merkezidir.

Mikrokalsifikasyon bölgelerinin iyi huylu veya kötü huylu sınıflama detayları ve sonuçları ilerleyen bölümlerde verilecektir.

## 2. YAPILAN ÇALIŞMALAR

Kanser, hücrelerin büyümesini düzenlemede ve onları sağlıklı tutmada sorumlu olan genlerdeki mutasyonlar veya anormal değişiklikler sonucu ortaya çıkar. Bu değişim, hücreye kontrol ya da bir emir olmaksızın bölünme yeteneği kazandırır, bu şekilde kendileri gibi daha çok hücre üretme ve tümör oluşturma yeteneği kazandırır. Meme kanseri, meme hücrelerinde gelişen kötü huylu tümör anlamına gelir. Araştırmalar, meme hücreleri içerisinde, meme kanser riskini artıran bazı genler olduğunu göstermektedirler. Genetik değişiklikler, aileden (herediter) olabilir veya yaşam süresince gelişebilirler. Meme kanseri genellikle tek bir hücrede başlar. Günümüzde meme kanserinin nedeni ve nasıl gelişim göstereceği tam olarak bilinmemektedir. Kompleks bir hastalıktır ve her vaka birbirinin aynısı değildir [151]. Her 8 kadından birinin hayatının belirli bir zamanında meme kanserine yakalanacağı bildirilmektedir. Erkeklerde de görülmekle beraber, kadın vakaları erkek vakalarından 100 kat fazladır. Türkiye halk sağlığı kurumu kanser daire başkanlığının 2009 yılı istatistiklerine göre kadınlarda en çok görülen kanser türü meme kanseridir ve her 4 kadın kanserinden birisi olmaya devam etmektedir [152].



Şekil 2.1. (a) Kadınlarda en sık görülen ilk 10 kanser (yaşa göre standardize edilmiş) (b) Meme kanserinin yaşa özel hızlarının dağılımı (2009 istatistikleri)

Dünyada 2012 istatistiklerine göre meme kanserinin en sık görüldüğü ilk 20 ülke ve oranları [153] aşağıdaki tabloda verilmiştir.

Tablo 2.1. Dünyada meme kanserinin en sık görüldüğü ilk 20 ülke (2012 istatistikleri)

Sıra	Ülke	100.000'de Yaş Standardize Oranı (Dünya)
1	Belçika	111,9
2	Danimarka	105,0
3	Fransa	104,5
4	Hollanda	99,0
5	Bahamalar	98,9
6	İzlanda	96,3
7	Birleşik Krallık	95,0
8	Barbados	94,7
9	Amerika	92,9
10	İrlanda	92,3
11	Fransız Polinezyası	92,2
12	Almanya	91,6
13	İtalya	91,3
14	Finlandiya	89,4
15	Lüksemburg	89,1
16	Yeni Kaledonya	87,6
17	Avustralya	86,0
18	Malta	85,9
19	Yeni Zelanda	85,0
20	İsviçre	83,1

Diğer kanserlerde olduğu gibi meme kanseri için de erken teşhis oldukça önemlidir. Bunun için meme görüntüleme tekniklerine bakarsak;

- Manyetik rezonans görüntüleme (MRG)
- Ultrason görüntüleme
- X-ışını görüntüleme (mamografi) vb.

Şu anda mamografi rutin meme kanseri taramasında yaygın olarak kabul edilen tek yöntemdir.

- Düşük dozda radyasyon
- Yüksek kaliteli görüntü


- 5 ila 7 yıl sonraki kontrollere kıyasla ölüm oranını %25 ila %30'a kadar düşürür [154].

Bu nedenlerle yapılan tez çalışmasında mamografi görüntüleri kullanılmıştır. Bilgisayar destekli tespit (CADE) 50 yıldan fazla bir süre önce tanıtılmasına rağmen mamografi için CADe geliştirilmesinde ciddi ve başarılı girişimler son 20 yıl içerisinde olmuştur. CADe sistemleri radyologlarla karşılaştırıldığında yüksek hassasiyete ama zayıf özgüllüğe sahiptir. CADe, gözlem çalışmaları ve klinik değerlendirmelerde radyologlara daha çok kanser bulunabilmesinde yardımcı olmak için gösterilmektedir. Son klinik çalışmalar, CADe'nin kanser tespitini, iki radyolog tarafından çift okuma ile karşılaştırıldığında yaklaşık %10 oranında arttırdığını göstermektedir [155]. Ancak, yıldan yıla nüfustaki mevcut kanser sayısındaki değişiklikten dolayı CADe'nin klinik yararlarını ölçmek zordur. Bununla birlikte bir radyolog CADe kullanarak gözden kaçan kanser oranını azaltabilir. Son olarak, CADe'nin önemli bir amacı radyoloğun verimliliğini arttırmaktır. Mamografi için ilk CAD sistemi, Chicago Üniversitesi'nde bir araştırma projesinde geliştirilmiştir. Bugün ticari olarak R2 firması tarafından sunulmaktadır [156].


Meme kanserinde görülen anormallikler; kitleler, mikrokalsifikasyonlar, mimari bozukluk ve çift yönlü asimetri dir. Kitle; en az iki farklı projeksiyonda görülebilen toplu bir alan işgal eden lezyon olarak tanımlanır. Kalsifikasyonlar, meme dokusundaki kalsiyum depolarıdır. Mimari bozukluk; bir noktadan ışın yayan keskin noktalar ve odak geri çekilme (büzülme) ya da özel doku kenarının bozulmasını içerir. Çift yönlü asimetri ise iki taraf arasındaki meme özel dokusunun asimetrisindeki belirgin farklılığa işaret etmektedir [117]. Bunların arasında meme kanseri için en önemli ve en çok görülen anormallikler kitle ve mikrokalsifikasyonlardır.

Yapılan tez çalışmasında, mamografi görüntüleri üzerinde kitle ve mikrokalsifikasyonların tespitini ve iyi huylu/kötü huylu olasılığını değerlendiren akıllı bir meme kanseri CAD sistemi yani meme kanseri karar destek sistemi geliştirilmiştir. Geliştirilen sisteme ilişkin şema aşağıda verilmiştir.

### KİTLE TESPİTİ VE İYİ HUYLU/KÖTÜ HUYLU DEĞERLENDİRMESİ



### MİKROKALSİFİKASYONLARIN TESPİTİ VE İYİ HUYLU/KÖTÜ HUYLU DEĞERLENDİRMESİ



Şekil 2.2. Geliştirilen MKKDS sistemine ait şemalar

Şekil 2.2’de görüldüğü gibi sistem oldukça kapsamlı ve karmaşık birçok aşamadan oluşmaktadır. Bu da çalışmanın geniş kapsamlı olduğunu ve zorluğunu göstermektedir.



Literatürde, genellikle bölütleme, iyileştirme, şüpheli bölgelerin belirlenmesi, anormallik tespiti, iyi huylu/kötü huylu değerlendirilmesi gibi aşamalar farklı çalışmalar şeklinde ele alınmıştır. Kimi çalışmalar manuel olarak belirlenen şüpheli bölge ya da anormallik bölgesi üzerinden yürütülmüştür [47-52]. Bununla birlikte bütün aşamalar en önemli iki anormallik için de gerçekleşmiştir. Literatürde bu şekilde kapsamlı bütün bir sisteme rastlanmamıştır. Bundan sonraki kısımda, kullanılan veritabanı ve her iki anormallik için belirtilen aşamalara ilişkin yapılan çalışmalardan bahsedilecektir.

## 2.1. Veritabanı

Geliştirilen MKKDS sisteminde, 322 dijitalize edilmiş mamografi görüntüsü içeren uluslararası, açık ve literatürde sıkça kullanılan Mamografik Görüntü Analiz Derneği (MIAS) veritabanı kullanılmıştır [157]. Kullanılan veritabanındaki görüntüler 1024x1024 piksel boyutlarına sahip, MLO görüntülerdir. Bununla birlikte veritabanı, bilgisayar destekli tespit ve tanı çalışmalarında yararlanılabilecek arka plan dokusu;

- yağ  $F$ ,
- yağ-glandüler  $G$ ,
- yoğun-glandüler  $D$ ,

anormalliğin sınıfı;

- Kalsifikasyon CALC,
- İyi tanımlanmış / sınırlı kitleler CIRC (MASS),
- Spiküle kitleler SPIC (MASS),
- Çeşitli diğer kötü tanımlı kitleler MISC (MASS),
- Mimari distorsiyon ARCH,
- Asimetri ASYM,
- Normal NORM,

anormalliğin şiddeti;

- İyi huylu B (Benign)
- Kötü huylu M (Malign)

ve anormalliğin merkez koordinatları gibi özellikleri içeren detaylı bilgi vermektedir. Veritabanının karakterize edilmiş özelliklerine göre istatistikler aşağıdaki tabloda verilmiştir.

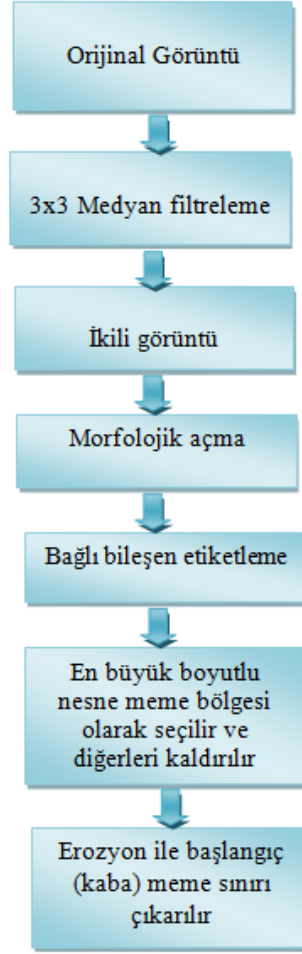
Tablo 2.2. MIAS veritabanı istatistikleri

		Anormalliğin Sınıfı ve Şiddeti																	
Doku	MASS																		
	CIRC			SPIC			MISC			CALC			ARCH			ASYM			NORM
	B	M	Σ	B	M	Σ	B	M	Σ	B	M	Σ	B	M	Σ	B	M	Σ	
F	12	2	14	2	3	5	3	5	8	2	4	6	4	2	6	1	3	4	66
G	5	2	7	4	3	7	3	2	5	3	4	7	2	4	6	2	2	4	67
D	3	0	3	5	2	7	1	1	2	8	7	15	3	4	7	3	4	7	76
Σ	20	4	24	11	8	19	7	8	15	13	15	28	9	10	19	6	9	15	209

Tablo 2.2’de MIAS veritabanına ilişkin detaylı istatistikler verilmiştir. Burada, *F*; yağ, *G*; yağ-glandüler, *D*; yoğun-glandüler meme dokusu tiplerini, *B*; iyi huylu, *M*; kötü huylu anormallik şiddetini göstermektedir. Sonuç olarak, yapılan tez çalışmasıyla ilgili olarak MIAS veritabanındaki 58 kitle, 28 mikrokalsifikasyon içeren ve 209 normal mamografi görüntüleri ele alınmıştır. Bununla birlikte, yapılan çalışmada veritabanındaki 1024x1024 boyutlu görüntüler işlem karmaşıklığı ve uzun koşma süresi sebebiyle 512x512 boyuta indirgenerek işlemler gerçekleştirilmiştir.

## 2.2. Meme Bölgesinin Bölütlenmesi

Meme bölgesinin bölütlenmesi, önceden de belirtildiği üzere her iki anormalliğin tespitinde yer alan ortak bir ön işlem aşamasıdır. Bölütleme neticesinde sadece aranan bölümlerin tutulması ve gereksiz kısımların görüntüden çıkarılması hedeflenir. Böylece gereksiz işlemler ve tüm görüntü üzerinde yapılan işlemler sonucu başarı düşüklüğü engellenir. Yapılan tez çalışmasında, meme bölgesinin bölütlenmesi için hızlı ve işlem karmaşıklığının az olması nedeniyle aşağıdaki algoritma [158] kullanılmıştır.




Şekil 2.3. Meme bölgesinin bölütlenmesi için önerilen algoritma

İlk olarak orijinal mamogramlardaki gürültünün biraz elemine edilmesi için 3x3 medyan filtre uygulanmaktadır. İkili görüntü oluşturma kısmı kaba bir sınır elde etmek için kullanılır ve çok hassas değildir. Çünkü gerçek meme sınır piksel değeri ile arka plan piksel değeri benzerdir. Burada, ikili görüntü elde etmek için mamogram görüntüsü piksel değerlerinin ortalaması eşik değeri olarak kullanılmaktadır. Genel olarak, en büyük alana sahip nesne meme bölgesidir ve diğerleri bilgi plakaları ya da gürültüler olabilir. Önerilen algoritma, daha iyi ve daha basit bir ikili meme görüntüsünün elde edilmesi için morfolojik açma işlemini uygulamaktadır. Böylece nesne bölgelerindeki meme olmayan bölgelerin bir kısmı silinebilir. Burada morfolojik açma işlemi için yarıçapı 2 piksel olan bir disk (Şekil 1.4) yapı elemanı kullanılmıştır. İkili görüntüde morfolojik açma işleminden sonra halen birçok meme olmayan nesne bulunmaktadır ancak bunların boyutları meme nesnesinin boyutundan daha küçüktür. Önerilen algoritma, nesnelere etiketlemek için mamogramdaki meme bölgesinin karakteristiğini kullanır ve en büyük boyutlu nesneyi meme bölgesi

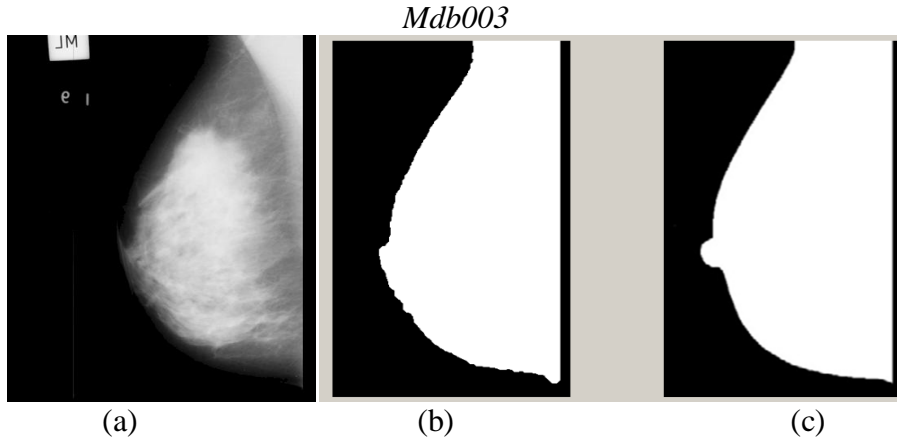
olarak çıkarır. Böylece geriye kalan en büyük boyutlu olmayan nesnelere arka plan olarak belirlenir. Elde edilen ikili görüntüde meme ve arka plan olmak üzere iki bölüt bulunmaktadır. Bu görüntüden, bu görüntüye morfolojik eritme uygulanarak elde edilen görüntü çıkarılarak başlangıç meme sınırı kaba bir şekilde belirlenir.

Algoritmaya ait işlem adımlarının çıktıları aşağıda verilmiştir.




Şekil 2.4. (a) Orijinal görüntü (mdb265) (b) Medyan filtre uygulanmış ikili görüntü (c) Morfolojik açma işlemi ve bağlı bileşen etiketleme ile seçilen en büyük alan (d) Eritme ile kaba meme sınırı çıkarılmış görüntü (e) Meme bölgesi bölütlenmiş görüntü

Önerilen algoritma ile başarılı sonuçlar elde edilmiştir. Algoritma performansının değerlendirilmesi için önceki bölümde bahsedilen bütünlük ve doğruluk ölçüleri kullanılmıştır. Burada bütünlük; bölütlenen bölge tarafından açıklanan GT (el ile belirlenen tam doğru meme bölgesi) bölgesinin yüzdesini, doğruluk ise doğru çıkarılan meme bölgesinin yüzdesini temsil etmektedir. Meme bölgesi bölütleme işlemine ilişkin program çıktıları aşağıda verilmiştir.



Şekil 2.5. (a) Orijinal görüntü (b) Meme bölgesi bölütleme program sonucu (c) GT görüntü

Şekil 2.5'in devamı



Yukarıdaki şekilde verilen program çıktılarına ait performans değerlendirme sonuçları aşağıdaki tabloda verilmiştir.

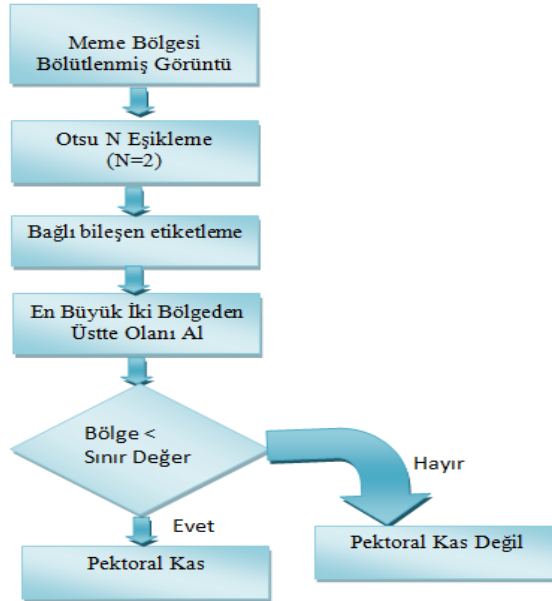
Tablo 2.3. Meme bölgesi bölütleme performansının değerlendirilmesi

Görüntü No	TP	FN	FP	CM (Bütünlük)	CR (Doğruluk)	Q (Quality)
Mdb003	60922	2645	120	0.958	0.998	0.956
Mdb006	91868	4416	0	0.954	1	0.954
Mdb016	60319	529	493	0.991	0.991	0.983
Mdb070	70758	3206	855	0.956	0.988	0.945

TP, FP ve FN değerleri piksel sayılarını göstermektedir. Tablodaki sonuçlara bakıldığında, çalışmada meme bölgesinin bölütlenmesinden sonra meme sınırının tam düzleştirilmemiş olmasına rağmen başarılı sonuçlar verdiği görülmektedir. Meme sınırının biraz pürüzlü olması ya da tam düzün olmaması anormalliklerin tespiti için bir önem taşımamaktadır. Bu sonuçlara göre geliştirilen bölütleme algoritmasının oldukça başarılı olduğu söylenebilir.


### 2.3. Pektoral Kasın (Koltuk Altı Bölgesi) Çıkarılması

Pektoral kas, mamogramların çoğunda baskın yoğunluklu bölgeyi temsil eder ve bu yüzden pektoral kasın çıkarılması, yanlış bölge bölütlenmesinin azaltılmasında etkilidir. Pektoral kas çıkarımına ilişkin geliştirilen algoritma aşağıdaki şekilde verilmiştir.




Şekil 2.6. Pektoral kas bölgesinin çıkarılması için geliştirilen algoritma

Çalışmada, pektoral kas çıkarımı için  $N=2$  alınarak görüntü farklı yoğunluklara sahip koltuk altı, yumuşak meme dokusu ve arka plan olmak üzere üç sınıfa ayrılmıştır. Daha sonra CCL yöntemi ile bölütlenen bölgeler etiketlenmiştir ve en büyük iki bölgeden (bunlardan biri pektoral kas diğeri yumuşak meme dokusu) üstte kalan bölge seçilir (pektoral kas üst kısımda kaldığı için). Bazı mamogramlarda pektoral kas görüntüde yer almayabilir nadiren ya da bazılarında yumuşak meme dokusu ile pektoral kasın birleşik olarak aynı yoğunlukta olduğu durumlarda, elde edilen üst bölge pektoral kas ile yumuşak meme dokusunun yapışık hali olacağından pektoral kas çıkarımı mümkün olmayabilir. Bu gibi durumlarda meme bölgesinin de yanlışlıkla çıkarılmasını önlemek için bir bölge alan kontrolü gerçekleştirilmiştir. Elde edilen üst bölge sınır değerinin üstünde ise (pektoral kas olamayacak kadar büyük ise) pektoral kas çıkarımı yapılmaz. Aksi halde elde edilen bölge pektoral kastır. Burada alan sınır değeri, veritabanı sonuçları incelenerek belirlenmiştir ve 512x512 boyutlu görüntü için bu değer 21.000 pikseldir.



Şekil 2.7. Pektoral kas bölgesi örnekleri



Şekil 2.7'deki en büyük pektoral kas alanına sahip iki örnek görülmektedir. Burada pektoral kası içeren dikdörtgen bölgelerin alanları hesaplanır ve yaklaşık yarısı pektoral kas bölgesi olarak alındığında yaklaşık olarak ortalama 21.000 piksel civarı olduğu görülmektedir. Böylece sınır değeri belirlenmiş olur.



Şekil 2.8. (a) Meme bölgesi bölütlenmiş görüntü (b) Otsu  $N=2$  eşiklenmiş ve etiketlenmiş görüntü (c) Pektoral kas bölütleme sonucu

Şekil 2.8’de *Mdb178* örneğinde pektoral kas çıkarılmıştır ancak *Mdb236* örneğinde elde edilen bölge sınır değerinin üstünde bir alana sahip olduğundan yumuşak meme dokusu kabul edilir ve pektoral kas çıkarımı yapılmaz. Böylece pektoral kasın olmadığı veya meme yumuşak dokusuna bağlı olduğu ayrılmadığı durumlarda bu alan sınır değeri kontrolü ile yanlış bölgenin bölütlenmesi önlenmiş olur. Bu şekilde başarılı bir algoritma geliştirilmiştir. Pektoral kas çıkarılmasına ilişkin program çıktıları aşağıdaki gibidir.



*Mdb003**Mdb006**Mdb016*


(a)

(b)

(c)

Şekil 2.9. (a) Meme bölgesi bölütlenmiş görüntü (b) Bölütleme sonucu belirlenen en büyük iki alan (c) Pektoral kas çıkarımı sonucu

Şekil 2.9'un devamı



Şekil 2.9'daki sonuçlara bakıldığında pektoral kas çıkarımı için geliştirilen algoritmanın başarılı sonuçlar verdiği görülmektedir ancak bazı kitle görüntülerinde; kitle pektoral kasa çok yakın ya da yapışık bulunabiliyor ve ileriki aşama olan şüpheli bölgelerin belirlenmesinde pektoral kasta şüpheli kitleye benzer bir yapı yoksa elemine edildiği görülmüştür. Aynı şekilde mikrokalsifikasyonlar için de ileriki aşama olan şüpheli MC bölgelerinin bölütlenmesinde şüpheli MC'ye benzer bir yapı yoksa elemine edildiği görülmüştür. Bu bölgede şüpheli görülen yapıların anormallik değil ise tespit aşamasında tamamen elemine edildiği görülmüştür. Bu nedenlerden dolayı bu kısım sistemden kaldırılmıştır. Şüpheli bölgelerin belirlenmesi ve anormalliğin tespit aşamalarında bu karşılaştırma sonuçları gösterilecektir.

#### **2.4. Kitle Tespiti ve İyi Huylu/Kötü Huylu Değerlendirmesi**

Bu kısım, daha önceden belirtildiği gibi kitle tespiti için görüntünün iyileştirilmesi, şüpheli kitle bölgelerinin belirlenmesi, kitle tespiti ve iyi huylu/kötü huylu değerlendirme aşamalarını kapsamaktadır. Bu aşamalara ilişkin detaylar aşağıda verilmiştir.

##### **2.4.1. Kitle Tespiti için Görüntünün İyileştirilmesi**


Mamografi görüntüleri çoğunlukla düşük kontrast ve nispeten yüksek gürültü içeriği ile karakterize edilir. Bu, mamografi görüntülerinde şüpheli bölgelerin belirlenmesi

işlemini zorlaştırır. Bu yüzden, dijital mamogramlarda şüpheli bölgelerin belirlenmesi işleminin gerçekleşmesinden önce görüntü iyileştirme işlemine ihtiyaç vardır. Yapılan tez çalışmasında literatürde yer alan başarılı yöntemlerden bazılarının literatürde rastlanmayan hibrid kullanımı geliştirilerek iyileştirme işlemi gerçekleştirilmiştir. Kitle tespiti için geliştirilen mamografi görüntü iyileştirme algoritmasına ait şema aşağıda verilmiştir.




Şekil 2.10. Kitle tespiti için geliştirilen iyileştirme algoritması

Top-hat dönüşümü, görüntüdeki yüksek frekansları (gürültü) azaltır. Ancak, gürültünün halen bir kısmı kalır. Kalan gürültüyü kaldırmak için biortogonal dalgacık (biortogonal 3.1) ile 2 seviyeli ayrıştırma işleminin ardından formül (1.35) kullanılarak her seviye için eşik değeri belirlenir ve detay katsayıları bu değere göre eşiklenir. Böylece dalgacık tabanlı eşikleme işlemi gerçekleştirilmiş olur. Ardından mamografi görüntülerindeki karışıklığın iyileştirilmesi için CLAHE yöntemi uygulanmıştır. Son olarak oluşan keskinlikleri yumuşatmak için anizotropik difüzyon filtreleme kullanılmıştır. İyileştirme işleminin ardından iyileştirilmiş görüntü bölütlenmiş görüntü ile birleştirilerek meme bölgesi bölütlenmiş ve iyileştirilmiş görüntü elde edilir. Geliştirilen algoritma kısaca ToWaCAD olarak adlandırılmıştır. İşlem adımlarına ait program çıktıları aşağıdaki gibidir.




Şekil 2.11. (a) Orijinal görüntü (Mdb017) (b) Top-hat dönüşümü (c) Dalgacık tabanlı eşikleme (d) CLAHE (e) Anizotropik difüzyon filtreleme (f) İyileştirilmiş görüntü (g) İyileştirilmiş ve bölütlenmiş görüntü

Şekil 2.11'deki çerçeve kitle bölgesini göstermektedir. Önerilen ToWaCAD algoritmasına ait program çıktıları aşağıda verilmiştir.



Şekil 2.12. (a) Orijinal görüntü (b) İyileştirilmiş ve bölütlenmiş görüntü

Şekil 2.12'nin devamı



Önceden bahsedildiği üzere, iyileştirme işleminden sonra sonuç görüntülerindeki gelişmenin ölçümü genellikle zordur. İyileştirme yönteminin hem nesnel hem de öznel geçerliliğini belirtebilen evrensel bir ölçü yoktur. Ancak, performans ölçümü için gerekli olan üç özellik verilebilir. İlk olarak, istenilen karakteristiği bütünsel bir şekilde ölçmelidir, burada bu kontrast yani karşıtlıktır. İkincisi, karakteristiğin artışı ve azalması arasında oransal bir ilişki göstermesi gerekir. Son olarak da, uygun değer noktaları bulmak için sonuç olarak çıkan karakteristikleri olması gerekir. Bunun bir örneği, yerel ekstrem kullanılmasıdır.

Logaritmik AMEE [45] görüntü iyileştirme ölçüsü olarak sunulmuştur ve iyileştirme performansını ölçmek için kullanılan objektif araçtır. Bu ölçü ile ilgili detaylı bilgiler önceki bölümde verilmiştir.


İyileştirme performansının değerlendirilmesi için yukarıda program çıktıları verilen mamografi görüntülerine ait ölçüm değerleri aşağıdaki tabloda verilmiştir.

Tablo 2.4. Kitle tespiti için görüntü iyileştirme performansının değerlendirilmesi

Görüntü No	LogAMEE (Orijinal)	LogAMEE (İyileştirilmiş)
Mdb010	20.580	46.507
Mdb017	16.570	28.088
Mdb053	20.742	22.431
Mdb058	20.965	59.240
Mdb069	36.315	64.617
Mdb178	14.740	35.333
Mdb204	28.043	69.380


Tablo 2.4.'te önerilen ToWaCAD algoritması sonucu elde edilen Şekil 2.12'deki mamografi görüntülerine ait hesaplanan LogAMEE ölçüm değerleri verilmiştir. Bu değerler karşılaştırılması için orijinal ve iyileştirilmiş görüntüler için hesaplanmıştır ve karşılaştırma sonucunda [159] iyileştirilmiş görüntülerin ölçüm değerlerinin daha yüksek olduğu görülmektedir. Bu da bize iyileştirme performansının arttığını göstermektedir.

*Mdb017* görüntüsüne ait farklı seviyelerdeki ayrıştırma çıktıları aşağıda verilmiştir.




Şekil 2.13. (a) Ayrıştırma seviyesi=1 (b) Ayrıştırma seviyesi=2 (c) Ayrıştırma seviyesi=3 (d) Ayrıştırma seviyesi=4 olan ayrıştırılmış ve dalgacık tabanlı eşikleme sonucu elde edilen görüntüler


Şekil 2.13'ün devamı



(b)



(c)



(d)

Şekil 2.13'de verilen farklı seviyelerdeki dalgacık tabanlı eşikleme sonucu elde edilen görüntülere bakarsak pek bir farklılık görülmemektedir. Sonuçlar LogAMEE performans ölçüsü kullanılarak değerlendirilmiştir.

Tablo 2.5. Farklı seviyelerde dalgacık tabanlı eşikleme performansının değerlendirilmesi

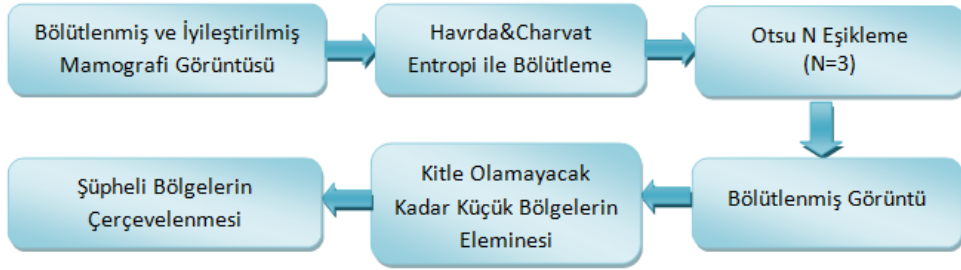
Dalgacık ayrıştırma seviyesi (Mdb017)	Dalgacık Tabanlı Eşikleme LogAMEE (Orijinal LogAMEE=16.570)
1	22.367
2	22.376
3	22.376
4	22.376

Tablo 2.5’de ayrıştırma seviyeleri arasında sadece 1. ve 2. seviyelerde küçük bir fark bulunmaktadır, bunun dışında değişmemektedir. Bu nedenle, yapılan çalışmada dalgacık tabanlı eşiklemede 2 seviyeli ayrıştırma gerçekleştirilmiştir.

Bununla birlikte, önerilen ToWaCAD algoritması [160] farklı medikal görüntüler üzerinde de test edilmiştir ve sonuçlar Ek 1’de verilmiştir. Sonuçlara göre önerilen ToWaCAD algoritmasının farklı medikal görüntüler için de ihtiyaçlara göre geliştirilerek kullanılabileceğini söyleyebiliriz.

#### 2.4.2. Şüpheli Kitle Bölgelerinin Belirlenmesi

Elde ettiğimiz meme bölgesi bölütlenmiş ve iyileştirilmiş görüntüdeki kitle arama alanını daraltmak ve tespit başarısını yükseltmek için şüpheli kitle bölgelerinin belirlenmesi aşaması gerçekleştirilmiştir. Burada, bölütleme algoritması ile şüpheli kitle bölgeleri belirlenir. Bunun için geliştirilen algoritma [161] şeması aşağıda verilmiştir.



Şekil 2.14. Şüpheli kitle aday bölgelerin belirlenmesine için geliştirilen algoritma

Algoritmada yer alan Havrda&Charvat entropisi ile bölütleme yönteminin işlem adımları aşağıdaki gibidir.



Havrda&Charvat Entropisi İle Bölütleme :

Adım 1. Meme bölgesinin ortalama gri seviye değeri,  $k$ , piksel değeri  $>100$  olan pikseller meme bölgesi pikselleri olarak alınıp, ortalama hesaplanır,

Adım 2. Mamogram görüntüsüne ait  $P_k$  normalize histogramı formül (1.58) ile hesaplanır,

Adım 3.  $t=k$  eşik değeri olarak alınır,

Adım 4.  $HC_{TB}$  ve  $HC_{SR}$  değerleri (1.67) ve (1.68) formülleri ile hesaplanır,


Adım 5. Bu değerler kullanılarak formül (1.69) ile  $t_{opt}$  değeri hesaplanır,

Adım 6.  $t$ , eşik değeri bir arttırılır ve  $t \leq 255$  ise Adım 4'e git,

Adım 7.  $t$  eşik değerleri için elde edilen  $t_{opt}$  değerleri arasından maksimum olan seçilir,

Adım 8. Maksimum  $t_{opt}$  değeri veren,  $t$  eşik değeri şüpheli bölgeleri bölütlemek için kullanılır.

Yukarıda literatürde yer alan Havrda&Charvat entropisi ile eşikleme algoritması verilmiştir. Yapılan tez çalışmasında, meme dokusunun ortalama gri seviye değeri  $k$  hesaplanırken  $>100$  değerine sahip pikseller yerine önceden elde ettiğimiz meme bölgesi bölütlenmiş görüntü kullanılarak ortalama gri seviye değeri dinamik olarak daha sağlıklı bir şekilde hesaplanmaktadır. Bununla birlikte,  $HC_{TB}$ ,  $HC_{SR}$  ve  $t_{opt}$  değerleri hesaplanırken formüllerde yer alan  $\alpha$  parametresi, literatürdeki çalışmalarda kullanılan veritabanına göre sabit bir değer belirlenmiştir. Farklı  $\alpha$  değerlerine ait bölütleme sonuçları aşağıdaki gibidir.




Şekil 2.15. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c)  $\alpha=0.2$  ve  $t=183$  (d)  $\alpha=0.4$  ve  $t=151$  (e)  $\alpha=0.7$  ve  $t=133$

Yukarıdaki şekilde  $\alpha$  değerleri ve bu değerler için hesaplanan optimum  $t$  eşik değerleri görülmektedir. Farklı meme dokuları ve kitle çeşitleri dikkate alındığından optimum bir  $\alpha$  değeri hesaplamak bölütleme işlemi için oldukça önemlidir. Buna göre, yapılan tez çalışmasında ise  $\alpha$  parametresi aşağıdaki formül geliştirilerek her görüntü için dinamik olarak hesaplanmıştır [161, 162].

$$\alpha = 1 - \left( \frac{k}{255} \right) \quad (2.1)$$

Burada  $k$  değeri önceden belirttiğimiz gibi meme bölgesinin ortalama gri seviye değerini göstermektedir. Bu değer 255'e bölünerek normalize edilir. Şüpheli piksellerin ortalama gri seviye değeri bu değerden büyük olacağından 1 tam değerinden çıkarılarak  $\alpha$  değeri elde edilir. Veritabanındaki bazı örneklere ilişkin statik ve dinamik  $\alpha$  değerlerinin karşılaştırılmasına ilişkin grafik ve tablo aşağıda verilmiştir.




Şekil 2.16. Statik ve dinamik  $\alpha$  değerleri için HC kriter fonksiyonu grafiği

Şekil 2.16'da dinamik  $\alpha$  değeri kullanıldığında örneklere ait HC kriter fonksiyonlarının maksimum değerlerinin daha belirgin bir tepe yaptığı ve böylece buna karşılık gelen eşik değerinin daha belirleyici olduğu görülmektedir. Yani statik  $\alpha$  değeri kullanıldığında HC kriter fonksiyonu sonuç değerlerinin birbirine daha yakın çıktığı ve bunlara karşılık gelen eşik değerlerinin ise daha uzak olduğu görülmektedir. Dinamik  $\alpha$  değeri kullanıldığında ise HC kriter fonksiyonunun maksimum değeri tepe yaptığından buna yakın olan değerlere karşılık gelen eşik değerleri de birbirine yakındır. Buna ilişkin detaylı program çıktıları Ek 2'de verilmiştir.

Tablo 2.6. Verilen örnekler için statik, dinamik  $\alpha$  değerleri ve bunlara karşılık gelen eşik değerleri


Görüntü no	Statik $\alpha$ değerleri		Dinamik $\alpha$ değerleri	
	$\alpha$	$t$	$\alpha$	$t$
Mdb001	0.2	169	0.48	143
Mdb028	0.2	179	0.47	134
Mdb080	0.2	179	0.5	150
Mdb265	0.2	183	0.49	151

Böylece dinamik  $\alpha$  değeri kullanmak daha hassas daha sağlıklı bir bölütleme sağlamıştır. Bu örneklere ait program çıktıları aşağıdaki gibidir.

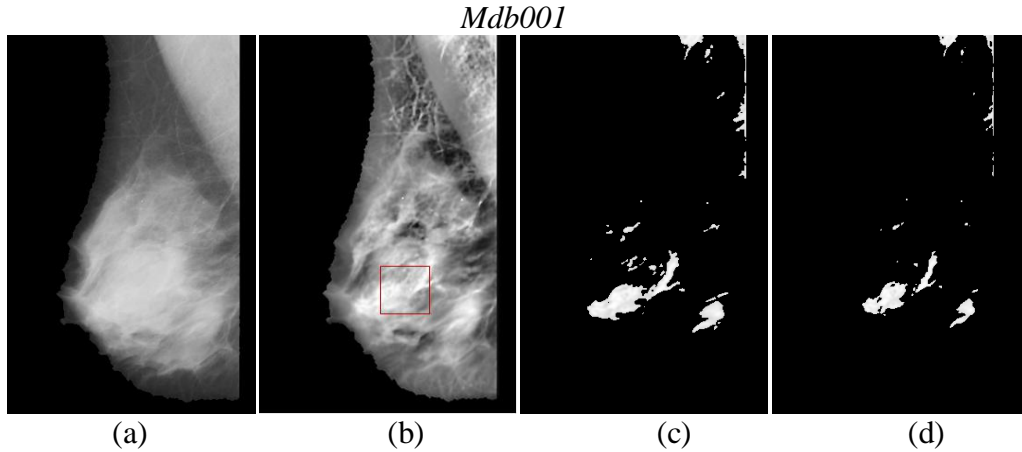


Şekil 2.17. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (çerçeve kitle bölgesini göstermek için manuel çizilmiştir) (c) Havrda&Charvat entropisi ile bölütlenmiş görüntü (d) Pektoral kas çıkarılmış ve Havrda&Charvat entropisi ile bölütlenmiş görüntü

Şekil 2.17'nin devamı




Şekil 2.17'de dinamik  $\alpha$  değeri kullanılarak Havrda&Charvat entropisi ile bölütlenmiş sonuçlar görülmektedir. Burada hem pektoral kas çıkarılmış görüntü üzerinden bölütleme hem de çıkarılmamış görüntü üzerinden bölütleme sonuçları da verilmiştir. Buna göre, pektoral kas çıkarımının bazı sonuçlar için olumlu bazıları için olumsuz olduğunu söyleyebiliriz. Pektoral kas çıkarılmamış bölütleme sonuçlarında pektoral kasın bir kısmının kaldığı görülmektedir. Ancak bunlar ileriki aşamalarda elenecektir. Havrda&Charvat yaklaşımının ardından Otsu  $N=3$  ile eşikleme gerçekleştirilmiştir. Sonuçlar aşağıdaki şekilde verilmiştir.






Şekil 2.18. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat ve Otsu  $N=2$  eşikleme (d) Havrda&Charvat ve Otsu  $N=3$  eşikleme

Şekil 2.18'in devamı




Şekil 2.18'de görüldüğü gibi Havrda&Charvat yönteminin ardından Otsu  $N=2$  ve  $N=3$  eşikleme yöntemleri uygulanmış ve sonuçlar karşılaştırılmıştır. Otsu  $N=3$  sonuçlarında elemine biraz daha fazladır. Bu nedenle Otsu  $N=3$  eşikleme yöntemi kullanılmıştır. Bununla birlikte, yapılan tez çalışmasında, Renyi entropi tabanlı bölütleme de denenmiş ve sonuçlar aşağıdaki şekilde karşılaştırılmıştır.

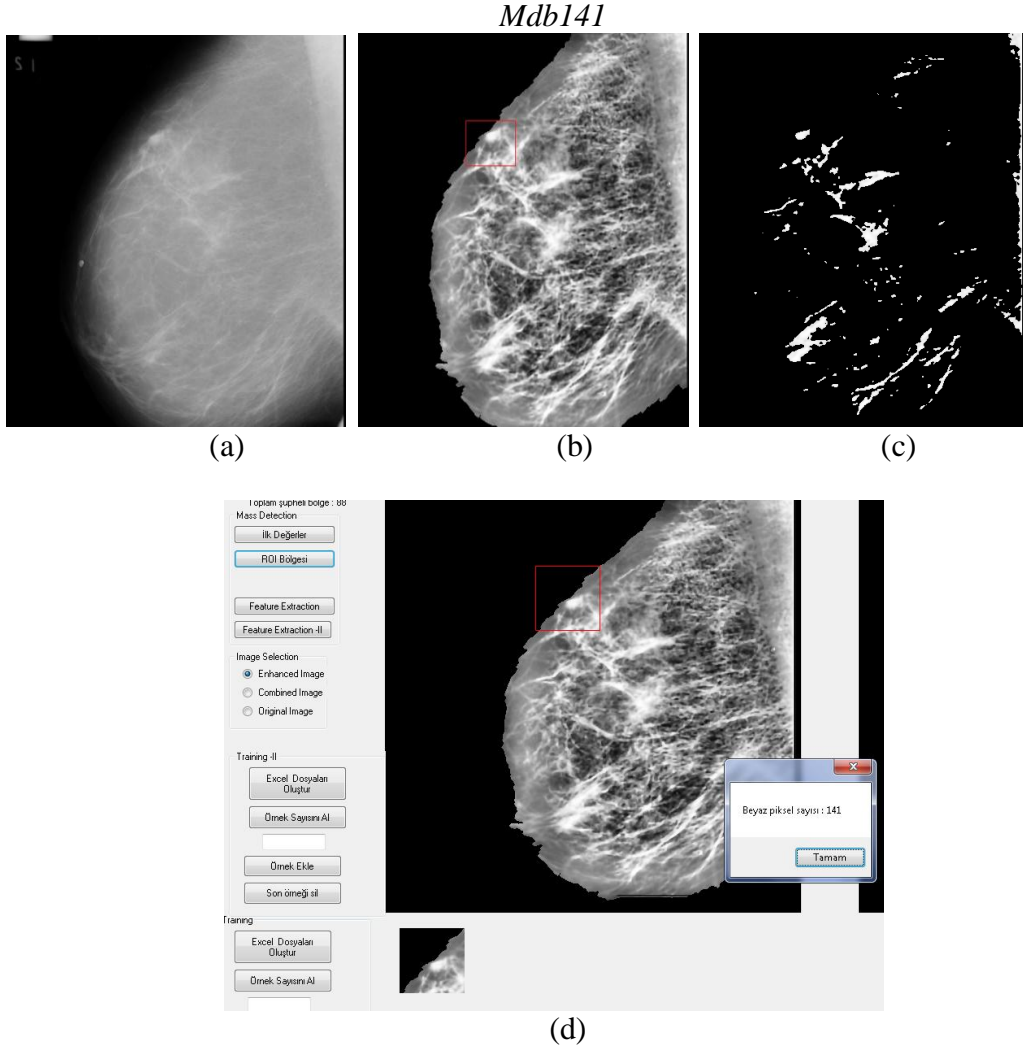
*Mdb001**Mdb028**Mdb080*

Şekil 2.19. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat entropi ve Otsu N=3 eşikleme (d) Renyi entropi ve Otsu N=3 eşikleme

Şekil 2.19'un devamı




Şekil 2.19'da görüldüğü gibi Renyi entropi ile elde edilen sonuçlarda kitle bölgesi çok küçülmekte ve hatta neredeyse elemine olabilmeye durumundadır. Bu nedenle, yapılan çalışmada şüpheli kitle bölgelerinin bölütlenmesinde Havrda&Charvat entropi yaklaşımı ile Otsu  $N=3$  eşikleme yöntemleri kullanılmıştır. Bundan sonra, elde edilen bölgelerin çerçevesi yani ROI bölgelerin elde edilmesi için görüntü en küçük ve en büyük kitleyi kapsayabilecek şekilde  $50 \times 50$  boyutlu kareler ile pencere kenarının yarısı adımlarla ilerlenerek (kitle bölgesinin yerini daha doğru tespit etmek için) taranır. Her taranan kare bölge belli bir değerin altında şüpheli piksel içeriyorsa ( $50 \times 50 / 25 = 100$ ) yani kitle olmayacak kadar küçük bir alan ise bu bölge elenir ve bu şekilde şüpheli kitle aday bölgeler belirlenir.



Şekil 2.20. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat entropi ve Otsu  $N=3$  eşikleme (d) Şüpheli kitle bölgesine ait şüpheli piksel sayısı


Şekil 2.20’de en küçük kitle içeren örneklerden biri verilmiştir ve burada kitleyi içeren şüpheli bölgedeki şüpheli yani beyaz piksel sayısı (bölütlemde elde edilen) 141’dir. Bu nedenle şüpheli bölge sınır değeri 100 piksel olarak alınmıştır. Buna göre, şüpheli bölgelerin belirlenmesine ait örnekler aşağıda verilmiştir.





Şekil 2.21. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Havrda&Charvat entropi ve Otsu  $N=3$  eşikleme (d) Şüpheli kitle aday bölgelerin belirlenmesi

Bir görüntü için şüpheli kitle bölgeleri elde edildikten sonra her ROI kitle içeriyor mu içermiyor mu kararını vermek için tek tek incelenecektir. Bunun için 50x50 boyutlu ROI bölgesi çok büyük kitleler için tam kapsama ve kenardan yakalama durumunda kitleyi daha iyi içine almak için dört yönden 15 piksel genişletilir ve sonuç olarak 80x80 boyutlu ROI bölgesi elde edilir.



Şekil 2.22. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Şüpheli kitle aday bölgelerin belirlenmesi (d) Elde edilen 80x80 boyutlu ROI bölge örnekleri

Bundan sonraki adımda elde edilen ROI bölgesine ait özellik çıkarma ve sınıflama işlemleri gerçekleştirilerek bölgenin kitle içerip içermediği kararı verilerek kitle tespiti işlemi tamamlanacaktır.

### 2.4.3. Özellik Çıkarma ve Sınıflama

Kitle tespiti için literatürde oldukça başarılı olan Tablo 1.1.'de belirtilen GLCM doku özellikleri kullanılmıştır. Kontrast, küme gölge, enerji, kare varyans toplamı, otokorelasyon, küme önemi, farklılık, entropi, homojenlik, maksimum olasılık, toplam ortalama, toplam varyans, toplam entropi, entropi farkı, korelasyon bilgi ölçüsü, korelasyon2 bilgi ölçüsü, normalize ters fark momenti olmak üzere 17 özellik çıkarılmıştır. Bazı örneklere ait çıkarılan GLCM özellikleri aşağıda verilmiştir.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
	Kontrast	Küme gölge	Enerji	Kare varyans toplamı	Otokorelasyon	Küme önemi	Farklılık	Entropi	Homojenlik	Maksimum olasılık	Toplam ortalama	Toplam varyans	Toplam entropi	Entropi farkı	Korelasyon bilgi ölçüsü	Korelasyon2 bilgi ölçüsü	Normalize ters fark momenti	İstenen Sonuç
1																		
2	28,3449	15850631,01	0,0013	1973,8899	848225,6397	280703788,8	3,5611	7,1612	0,3489	0,0155	313,9386	7593,079	5,4867	1,3055	-0,7371	0,9996	0,2579	0
3	15,0489	29180650,53	0,0012	627,3774	3197236,151	17639426,18	2,9116	7,0497	0,3749	0,0036	350,085	2497,054	5,2593	0,2817	-0,6663	0,9989	0,2871	0
4	17,7141	13684817,46	0,0008	1263,473	1063570,819	69485432,46	3,084	7,3581	0,3648	0,0027	288,8767	5096,382	5,6151	1,7776	-0,7362	0,9997	0,2739	0
5	9,1388	46526620,05	0,0016	394,4437	6545659,39	5744186,656	2,2987	6,672	0,4259	0,0044	394,9123	1552,34	5,014	0	-0,662	0,9994	0,3467	1
6	56,5834	4993537,923	0,0324	4479,1542	199633,0789	744071342,4	3,4866	6,4671	0,481	0,1783	235,453	18146,81	5,1587	2,1384	-0,8414	0,9998	0,4128	0
7	51,7802	4126974,632	0,035	4236,5137	176152,8544	622297938	3,2059	6,3896	0,5064	0,1853	214,7742	17112,21	5,1362	2,7256	-0,8525	0,9998	0,4454	0
8	54,8513	9019068,537	0,0012	943,5134	1159705,342	81115363,37	4,0617	7,1436	0,3605	0,0149	253,1123	3669,37	5,2908	2,5292	-0,6524	0,9988	0,2757	0
9	37,4047	11321632,85	0,001	584,584	1954771,232	12460302,32	4,0858	7,2056	0,3468	0,0093	262,3899	2271,187	5,2306	2,312	-0,6022	0,9979	0,2628	0
10	53,8717	12064464,5	0,0007	588,5564	193687,246	11959406,97	5,0831	7,4855	0,3106	0,0025	267,7328	2299,921	5,232	2,1987	-0,5156	0,9954	0,2246	0
1	68,9084	10071705,8	0,0014	757,1005	1474642,717	66426340,75	4,5815	7,1535	0,3742	0,0119	258,1831	2894,159	5,1583	2,5031	-0,5833	0,9973	0,2997	0
2	66,3519	14838835,57	0,001	1269,1282	1181442,175	159185868,4	4,4301	7,3692	0,3445	0,0153	297,8636	4857,104	5,3979	1,301	-0,6356	0,9988	0,2598	1
3	247,9472	3380591,254	0,0269	2739,259	272617,5303	352034561,7	5,4076	6,5725	0,4151	0,1622	210,8307	10441,51	4,8074	2,7838	-0,6201	0,9973	0,3397	0
4	44,6799	9441194,441	0,0011	542,1232	1858686,887	14029539,6	4,3293	7,2566	0,3425	0,0051	247,3964	2113,274	5,1702	3,127	-0,5583	0,9967	0,2581	0
5	22,2856	20863658,38	0,0008	1238,055	1417779,249	51099222,87	3,3805	7,3741	0,3672	0,0025	327,3505	4930,918	5,5189	0,9456	-0,6879	0,9994	0,2818	1
6	20,8313	21419052,41	0,0008	1287,6744	1390004,261	52625501,42	3,2835	7,3869	0,3674	0,0025	330,9484	5142,852	5,5659	1,0193	-0,7051	0,9995	0,2807	1
7	32,1948	10565766,9	0,0007	741,4454	1510468,368	20381785,18	4,2505	7,4546	0,3035	0,0021	260,5245	2912,591	5,362	2,4873	-0,5909	0,998	0,2085	0
8	136,3454	6681060,75	0,0168	3113,3941	344341,4584	628320404,5	5,4799	6,7115	0,4093	0,1266	259,9907	12736,74	4,9602	1,2511	-0,6525	0,9983	0,3365	0
9	96,3671	897855,4182	0,2024	5726,1267	67640,4516	752119269,9	3,1168	4,5742	0,615	0,4435	154,1142	22913,92	3,755	1,7717	-0,8997	0,9988	0,5616	0
10	60,3312	14227411,71	0,0006	998,4992	1446860,77	28725676,81	5,4707	7,6666	0,2879	0,0024	288,3296	3705,166	5,4467	1,8297	-0,5679	0,9978	0,199	0
11	67,3638	12491722,39	0,0006	698,1314	1751887,782	17288743,78	5,7302	7,6347	0,294	0,0022	273,0036	2720,672	5,3204	2,1164	-0,5149	0,9958	0,1956	0
12	125,1389	7179713,549	0,0169	3164,9835	356756,9825	691528702,5	5,1709	6,5811	0,4158	0,1266	266,8905	12969,06	4,8471	0,8857	-0,6385	0,9978	0,3424	0
13	40,0521	17409255,12	0,0008	498,0394	2888800,077	8908140,377	4,4723	7,3441	0,3173	0,0025	296,1638	1949,734	5,148	1,0535	-0,5172	0,9951	0,2283	0
14	27,806	19886947,67	0,001	434,5393	3555755,43	6809443,494	3,7487	7,16	0,3478	0,0028	306,1829	1700,01	5,0884	0,6204	-0,5452	0,9959	0,2602	0
15	41,9375	14159394,14	0,0009	1130,3275	1233787,202	58277529,7	4,0476	7,3447	0,3687	0,004	290,7932	4449,632	5,4291	1,8877	-0,6541	0,999	0,2903	1
16	25,4829	1341449,88	0,0017	441,3517	2747729,579	7821920,48	3,3497	6,8742	0,3682	0,0082	271,9877	1738,857	4,9882	1,9281	-0,5848	0,9968	0,309	0
17	26,4331	21965721,3	0,0008	1745,0084	1112775,16	142710777	3,8245	7,4475	0,3286	0,0039	340,6252	6808,22	5,6178	1,1253	-0,7101	0,9996	0,2371	1
18	29,1611	17125373,12	0,0007	1449,4858	1101017,464	62332839,04	3,6867	7,4552	0,3393	0,0024	310,7291	5718,811	5,5472	1,5504	-0,6768	0,9993	0,2492	0
19	28,1117	19307635,62	0,0007	1135,1438	1478335,421	40800220,19	4,0146	7,515	0,3186	0,0021	318,413	4467,205	5,504	1,153	-0,6388	0,999	0,2283	0
20	53,8975	8557642,71	0,0161	5026,1924	264068,7581	9811144167,6	4,5127	6,9679	0,3694	0,1248	281,1547	19571,74	5,3645	1,6367	-0,7613	0,9996	0,2856	0

Şekil 2.23. Bazı örneklere ait GLCM özellikleri

Özellikler çıkarıldıktan sonra sınıflama işlemi için hızlı bir şekilde olası yöntemleri denemek ve en başarılı yöntemi belirleyip geliştirmek için proje kapsamında alınan STATISTICA 12©StatSoft ve DTREG 10©PhilSherrod paket programlarından yararlanılmıştır. Yapılan tez çalışmasında, kitle tespiti için literatürde en başarılı bulunan SVM ve YSA yöntemleri denenmiştir.

Tablo 2.7. Kitle tespiti için geliştirilen SVM modellerine ait eğitim performansları sonuçları

	Model 1			Model 2			Model 3			Model 4			Model 5			Model 6		
	Kitle	Normal	Tümü	Kitle	Normal	Tümü	Kitle	Normal	Tümü	Kitle	Normal	Tümü	Kitle	Normal	Tümü	Kitle	Normal	Tümü
<b>Toplam</b>	51	396	447	35	278	313	45	156	201	51	396	447	35	278	313	45	156	201
<b>Doğru</b>	14	393	407	15	276	291	10	156	166	0	396	396	15	276	291	0	156	156
<b>Yanlış</b>	37	3	40	20	2	22	35	0	35	51	0	51	20	2	22	45	0	45
<b>Eğitim Performansı</b>	%27.4	%99.2	%91.0	%42.8	%99.2	%92.9	%22.2	%100	%82.5	%0	%100	%88.5	%91.0	%42.8	%99.2	%0	%100	%77.6

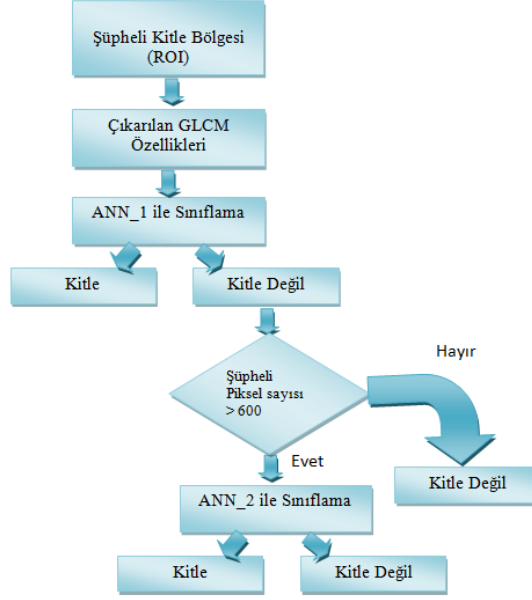
Tablo 2.7’de farklı eğitim örnek sayıları ve çekirdek fonksiyonlarına ait geliştirilen SVM modellerinin eğitim performans sonuçları verilmiştir. Buna göre, kitle örneklerinin eğitim performansının çok düşük olduğu ve hatta bazı modellerde ise tamamen başarısız olduğu görülmektedir. Literatürde kitle tespiti için önerilen algoritalarda SVM yöntemi şekil, dalgacık ve yerel ikili örnek özellikleri ile kullanılmıştır. Bununla birlikte, genetik algoritma ve optimizasyon yöntemleri ile birlikte kullanımı da önerilmiştir. Çalışmada, GLCM özellikleri için geliştirilen SVM modellerinde, kullanılan eğitim örnekleri ile başarılı bir performans elde edilemediği söylenebilir. Geliştirilen SVM modellerine ilişkin parametreler aşağıdaki tabloda verilmiştir.

Tablo 2.8. Kitle tespiti için geliştirilen SVM modellerine ait parametreler

Model no	Eğitim Örnek sayısı	Çekirdek Fonksiyon	Parametreler		
			C	Gamma	Coef0
1	447	RBF	0.1	10.942	-
2	313	RBF	451.600	0.1225	-
3	201	RBF	3.684	15.0266	-
4	447	Sigmoid	135.72	0.0368	1.668
5	313	Sigmoid	1502.665	0.0368	0.215
6	201	Sigmoid	0.1	0.001	0.

Yapılan çalışmada, RBF çekirdek fonksiyonu için C parametresi [0.1-5000], gamma parametresi [0.001-50], sigmoid çekirdek fonksiyonu için C parametresi [0.1-5000], gamma parametresi [0.001-50] ve coef0 parametresi [0-100] aralığında değerler verilmiştir. Tablo 2.8’de verilen değerler ile o modele ait en iyi sonucu veren parametre değerlerini göstermektedir. Sonuç olarak SVM modellerinin kitle tespiti için duyarlılığının (sensitivity) için oldukça düşük olduğunu söyleyebiliriz. Bu nedenle sınıflama için YSA yöntemi de uygulanmıştır.

Yapılan tez çalışmasında, kitle tespiti için literatürde daha önce kullanılmayan özgün bir kitle tespiti algoritması geliştirilmiştir. Geliştirilen algorithmada iki farklı YSA kullanılmaktadır ve algoritmaya ait şema aşağıda verilmiştir.



Şekil 2.24. Kitle tespiti için geliştirilen algoritma

Şekil 2.24’de verilen kitle tespiti için geliştirilen algorithmada, ANN\_1 ve ANN\_2 olmak üzere iki tane çok katmanlı ağ kullanılmıştır. Burada, ANN\_1 ile sınıflama sonucu kitle değil kararı verilen ROI bölgeleri için belli bir şüpheli piksel sayısı içerenler (kuvvetli kitle adayı bölge) ANN\_2 ile tekrar sınıflanarak kitle içerip içermediği kararı verilir. Böylece, ANN\_1 ile kaçırılan kitle bölgeleri ANN\_2 ile tespit edilebilir. Tablo 2.2.’de verildiği gibi veritabanında toplam 58 kitle bulunmaktadır. Buna göre, algorithmada geliştirilen ağların eğitim performansı sonuçları aşağıdaki gibidir.

Tablo 2.9. Kitle tespiti için geliştirilen ağlara ait eğitim performansı sonuçları

	ANN_1			ANN_2		
	Kitle	Normal	Tümü	Kitle	Normal	Tümü
<b>Toplam</b>	35	278	313	26	76	102
<b>Doğru</b>	35	278	313	26	70	96
<b>Yanlış</b>	0	0	0	0	6	6
<b>Eğitim Performansı</b>	<b>%100</b>	<b>%100</b>	<b>%100</b>	<b>%100</b>	<b>%92.1</b>	<b>%94.1</b>

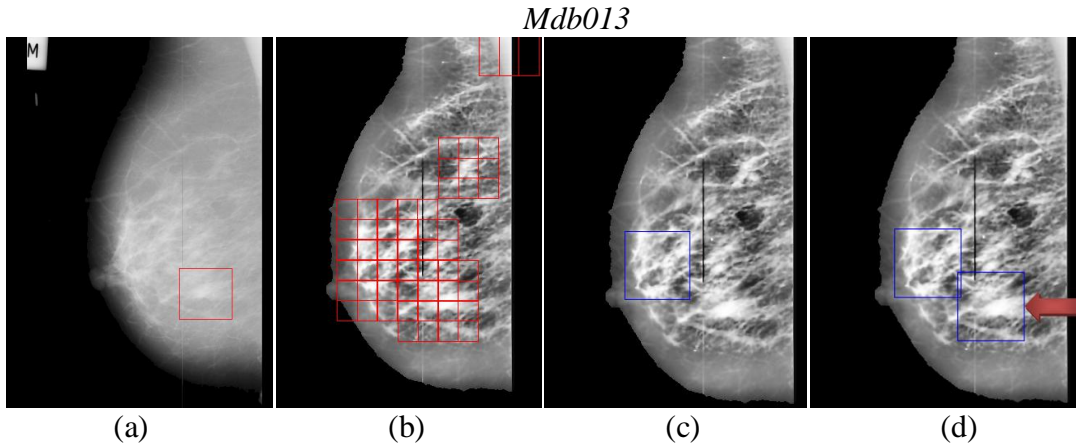
Tablo 2.9’da görüldüğü gibi geliştirilen sinir ağlarının eğitim performansları oldukça başarılıdır. Bu yüzden kitle tespitinde sınıflama işlemi için YSA kullanılmıştır. Kullanılan ağlara ilişkin parametreler aşağıdaki tabloda verilmiştir.

Tablo 2.10. Kitle tespiti için geliştirilen YSA’lara ait parametreler

YSA	Giriş katmanı nöron sayısı	Gizli katmanı nöron sayısı	Çıkış katmanı nöron sayısı	Parametreler			
				Eğitim algoritması	Hata fonksiyonu	Gizli katman aktivasyon fonksiyonu	Çıkış katmanı aktivasyon fonksiyonu
ANN_1	17	30	2	BFGS	Entropi	Tanh	Softmax
ANN_2	17	17	2	BFGS	Entropi	Tanh	Softmax


Yapılan tez çalışmasında yukarıda belirtilen ağlar geliştirilirken gizli katmandaki nöron sayısı [5,100] aralığında, hata fonksiyonu için kareler toplamı ve entropi fonksiyonları, gizli katman için ise lojistik, tanh, üstel hata fonksiyonları denenerak eğitilen 30.000 ağ içinden en iyisi seçilmiştir.

Geliştirilen ağlara ait test sonuçları da oldukça başarılıdır ve bir sonraki bölümde istatistiksel olarak detaylı bir biçimde verilecektir. Geliştirilen algoritma ile ANN\_1 ağının kaçırdığı bazı kitle bölgeleri ANN\_2 ile yakalanmaktadır. Buna ilişkin örnekler aşağıda verilmiştir.



Şekil 2.25. (a) Orijinal görüntü (b) Şüpheli kitle aday bölgelerin belirlenmesi (c) ANN\_1 ile sınıflama sonucu (d) Önerilen algoritma sonucu

Şekil 2.25'in devamı




Sınıflama işlemi sonucunda üst üste gelen çerçeveler de olabilmektedir. Bunun için de bir çerçeve birleştirme algoritması geliştirilmiştir.

Çerçeve Birleştirme Algoritması:

Adım 1. Sınıflama sonucunda kitle bölgesi olarak tespit edilen bölgeler;


- Aynı satırda ise sütun değerleri arasındaki mesafe pencere boyutunun yarısına eşit ya da daha az ise
- Aynı sütunda ise satır değerleri arasındaki mesafe pencere boyutunun yarısına eşit ya da daha az ise
- Aynı satır ve sütunda değil ise satır ve sütun değerleri arasındaki mesafe pencere boyutunun yarısına eşit ya da daha az ise bu bölgeler üst üste gelen bölgeler olarak etiketlenir,

Adım 2. Üst üste gelen bu bölgelerden en büyük şüpheli piksel sayısına sahip olan bölge seçilip tek bölgeye indirgenir ve çerçeve birleştirme işlemi tamamlanır.



Şekil 2.26. (a) Kitle tespiti sınıflama sonucu üst üste gelen bölgeler (b) Çerçeve birleştirme algoritması sonucu elde edilen bölge

Veritabanındaki bazı örneklere ilişkin algoritma sonuçları aşağıdaki gibidir.



Şekil 2.27. (a) Orijinal mamogram (çerçeve kitle bölgesini göstermektedir) (b) Kitle tespiti sonucu



Şekil 2.27’de verilen örneklerde kitle tespiti program çıktıları görülmektedir. Burada TP gerçekte de kitle bölgesi olan doğru tespit edilen bölgeyi, FP gerçekte kitle olmayan ancak kitle olarak tespit edilen bölgeyi göstermektedir. Sonuçlara göre duyarlılığı düşürmeden FP bölgelerin biraz daha azaltılması için yanlış pozitif indirgeme işlemi gerçekleştirilmiştir.

#### 2.4.4. Kitle Tespiti Yanlış Pozitif İndirgeme

Burada, kitle tespit duyarlılığı düşürülmeden FP bölgelerin sayısının azaltılması için tespit sonucu elde edilen bölgelere özellik çıkarma ve sınıflama işlemi uygulanmıştır. Bunun için istatistiksel ve dalgacık özellikleri ile olasılıklı sinir ağı kullanılmıştır.

Çıkarılan Özellikler:

- Küme önemi (Tablo 1.1)
- Enerji (Tablo 1.1)
- Korelasyon bilgi ölçüsü (Tablo 1.1)
- Yerel homeopati (formül (1.109))
- Çarpıklık (Tablo 1.3)
- Basıklık (Tablo 1.3)
- Dalgacık 1.seviye ayrıştırma yatay ve dikey detay katsayıları enerjileri (formül (1.110, 1.111))
- Dalgacık 2.seviye ayrıştırma yatay, dikey ve çapraz detay katsayıları enerjileri (formül (1.110-1.112))

Dalgacık özellikleri için biortogonal dalgacık (biortogonal 3.1) ile 2 seviyeli ayrıştırma işleminin ardından elde edilen dalgacık katsayılarının enerjileri ile toplam 5 özellik elde edilir. İstatistiksel özellikler ile beraber toplam 11 özellik elde edilmiştir.

A	B	C	D	E	F	G	H	I	J	K	L	
Küme önemi	Enerji	Korelasyon bilgisi	Yerel homeopati	Çarpıklık	Baskınlık	Dalgacık 1.seviye yatay katsayı enerji	Dalgacık 1.seviye dikey katsayı enerji	Dalgacık 2.seviye yatay katsayı enerji	Dalgacık 2.seviye dikey katsayı enerji	Dalgacık 2.seviye çapraz katsayı enerji	İstenen Sonuç	
1	109763534,3	0,00062	0,21279	-0,67056	0,60159	1,93136	6553,563	26296,2422	287,06964	518,9791	23,88894	1
2	512807313,8	0,04136	0,33191	-0,74446	14,56194	225,5643	1759,97859	42660,17037	203,11542	13881,45453	11148,88597	0
3	55407485,46	0,00067	0,21207	-0,6517	0,42516	1,62342	10466,00737	2923,11344	10730,75457	7377,04852	48,68957	1
4	256313102,5	0,00051	0,21407	-0,71949	0,00618	1,5281	47600,09248	11153,55749	5729,0515	3352,82694	16,88063	0
5	50106003,85	0,0007	0,24021	-0,64377	0,76898	2,37524	36598,7976	2497,83247	31566,82798	4169,22819	20,69066	0
6	263553427,8	0,00076	0,23792	-0,67664	1,43101	6,16252	63751,24023	497,70954	86577,11938	3206,02595	437,50668	1
7	1191702009	0,02789	0,30955	-0,73923	14,18296	217,6735	2465,30074	200093,029	6727,65059	190608,4593	194,29932	0
8	412367353,8	0,00104	0,24369	-0,72069	1,04085	9,28929	132950,1232	64992,60787	8382,72534	2835,70012	51,57396	0
9	491926583,1	0,00156	0,20449	-0,71663	4,37093	46,88043	5725,13654	153266,7645	7309,47924	2932,87777	4850,346	0
10	464402354,4	0,00178	0,24038	-0,7714	3,62222	29,41243	6535,58017	25009,61361	245,87566	136,02386	121,86204	0
11	235109246,4	0,00039	0,15924	-0,64788	-0,19972	1,71524	343,54619	123805,9064	14755,4813	951,3233	1339,62286	1
12	419497049,3	0,00109	0,16315	-0,72201	2,51552	23,16267	13716,90752	46024,5298	478,96808	55666,91704	28,92552	0
13	145141404,1	0,0003	0,11506	-0,57752	-0,02418	1,68377	40781,24427	12191,1683	99995,53523	167026,697	4199,50031	0
14	446415394,6	0,00033	0,1504	-0,69244	0,26471	3,38872	295644,499	55642,73454	644,61847	1047,64702	67,43986	1
15	724939109	0,03355	0,34827	-0,78401	14,27201	219,4586	97694,42873	110596,1668	35266,12438	1488,90261	8431,62605	0
16	416799191,6	0,00092	0,1722	-0,68623	1,89358	19,18066	130743,9846	11714,86224	1590,52728	197,68385	334,1424	0
17	167760886,3	0,00039	0,14389	-0,62007	-0,03732	1,52326	45104,30313	2794,8682	1075,12387	43883,91531	86,40803	0
18	198440972,1	0,00041	0,17366	-0,66603	-0,11009	1,6822	108390,7789	147134,6147	8491,51476	371,64131	245,29024	1
19	151502643,2	0,00042	0,16325	-0,63939	0,04834	1,48922	35713,84964	19201,35303	40401,74785	248,17618	933,75123	0
20	418155933,2	0,00039	0,17892	-0,72384	0,38661	3,01151	13018,83199	883,72529	60328,15031	1195,3724	484,97377	1
21	478958485,4	0,00059	0,17099	-0,71157	0,64209	9,86248	16740,4315	48217,58392	33547,62645	84934,22408	1240,79218	0
22	581774037	0,00029	0,12029	-0,68225	-0,465	3,1025	731,9623	64955,01386	4648,62512	4409,8224	5908,0255	0
23	127923477,7	0,00048	0,20166	-0,67246	0,25956	2,05717	5973,76744	225,65528	18898,36179	6552,50384	208,44953	0
24	662101050,7	0,00281	0,17508	-0,7437	10,31015	144,4172	24775,86796	464,53134	139,54734	642,70813	15,18158	0
25	343230737,7	0,00032	0,13584	-0,66911	-0,48286	2,11318	16208,5506	58346,12908	6284,29093	251,5701	3590,89682	0
26	219778220,4	0,00034	0,14496	-0,6454	-0,27358	1,74339	19929,9018	41217,41022	5333,35056	1918,29542	385,72312	0
27	394980800,3	0,00043	0,17037	-0,70344	0,27533	2,17944	714,01396	94105,34623	4428,91459	4038,04374	413,36466	1
28	312320450,6	0,00033	0,13294	-0,65601	-0,1027	2,19422	26,87992	4482,8212	26858,6876	223,19531	355,68308	0

Şekil 2.28. Kitle tespiti FP indirgeme eğitim örneklerine ait elde edilen özellikler

Özelliklerin çıkarılmasının ardından sınıflama işlemi için PNN kullanılmıştır. Geliştirilen olasılıklı sınır ağının eğitim performansı aşağıdaki tabloda verilmiştir.

Tablo 2.11. Kitle tespiti FP indirgeme için geliştirilen ağa ait eğitim performansı sonucu


	PNN		
	Kitle	Normal	Tümü
<b>Toplam</b>	46	62	108
<b>Doğru</b>	46	62	108
<b>Yanlış</b>	0	0	0
<b>Eğitim Performansı</b>	<b>%100</b>	<b>%100</b>	<b>%100</b>

Yukarıdaki tabloya göre oldukça başarılı bir eğitim performansı elde edildiği görülmektedir. Geliştirilen ağa ilişkin parametreler aşağıda verilmiştir.

Tablo 2.12. Kitle tespiti FP indirgeme için geliştirilen ağa ilişkin parametreler


PNN	Çekirdek Fonksiyon	Parametreler		
		Min. Sigma	Max. Sigma	Araştırma adımı
	Çift taraflı (Reciprocal)	0.0001	10	50

Böylece yanlış pozitif indirgeme işlemi ile kitle tespiti tamamlanmıştır. Veritabanındaki bazı örneklere ait kitle tespiti program çıktıları aşağıdaki gibidir.




Şekil 2.29. (a) Orijinal görüntü (b) ANN\_1 ve ANN\_2 ile kitle tespit sonucu (c) (b)+PNN ile FP indirgeme sonucu

Şekil 2.29’da görüldüğü gibi ANN\_1 ve ANN\_2 ile elde edilen kitle tespiti sonuçlarındaki FP bölgelerin büyük bir kısmı kitle tespiti duyarlılığı korunarak PNN yöntemi ile indirgenmiştir. Böylece kitle tespiti işlemi tamamlanmıştır. Pektoral kas çıkarılarak ve çıkarılmayarak elde edilen kitle tespiti sonuçları aşağıdaki gibi karşılaştırılmıştır.



Şekil 2.30. (a) Orijinal görüntü (b) Şüpheli kitle bölgelerinin belirlenmesi (pektoral kas çıkarılmış görüntüden) (c) (b)+Kitle tespiti sonucu (d) Şüpheli kitle bölgelerinin belirlenmesi (pektoral kas çıkarılmamış görüntüden) (e) (d)+Kitle tespiti sonucu

Şekil 2.30'un devamı



Şekil 2.30'da görüldüğü gibi kitle tespiti için geliştirilen algoritmada daha önceden belirtildiği gibi pektoral kas çıkarıldığında ve çıkarılmadığında da sonuç değişmemektedir. Bu da pektoral kas çıkarma işlemini gereksiz kıldığından bu işlem tespit algoritmasından çıkarılmıştır. Sonuçlara bakıldığında oldukça başarılı bir kitle tespit algoritması geliştirildiğini söyleyebiliriz. Sonuçlara ilişkin detaylı istatistiksel değerlendirme bir sonraki bölümde anlatılacaktır.

#### 2.4.5. Kitle İyi Huylu/Kötü Huylu Değerlendirilmesi

Burada, tespit edilen kitle bölgelerinin iyi huylu (benign-selim) veya kötü huylu (malign-habis) olma olasılığı belirlenmektedir. Buna göre, öncelikle iyi huylu ve kötü huylu kitle özellik vektörü oluşturularak ardından sınıflama yöntemi uygulanmıştır. Kitle tespitinde çıkarılan 11 özellik ile dalgacık 1.seviye çapraz katsayı enerji özelliği birlikte toplam 12 özellik kullanılarak eğitim performansı değerlendirilmiş ve bunun sonucunda en başarılı sonuç aşağıdaki özellikler ile elde edilmiştir.

Çıkarılan Özellikler:

- Yerel homeopati (formül (1.109))
- Basıklık (Tablo 1.3)
- Dalgacık 1.seviye ayrıştırma yatay detay katsayısı enerjisi (formül (1.110))
- Dalgacık 2.seviye ayrıştırma dikey ve çapraz detay katsayıları enerjileri (formül (1.111-1.112))

Bazı kitle bölgesi örneklerine ilişkin elde edilen özellikler aşağıdaki gibidir.

	A	B	C	D	E	F
	Yerel homeopati	Basıklık	Dalgacık 1.seviye yatay katsayı enerji	Dalgacık 2.seviye dikey katsayı enerji	Dalgacık 2.seviye çapraz katsayı enerji	İstenen Sonuç
1						
2	0,17892	3,01151	13018,83199	60328,15031	1195,3724	1
3	0,17037	2,17944	714,01396	4428,91459	4038,04374	1
4	0,17623	2,5636	6182,21989	255,0576	30572,49142	1
5	0,36033	212,4308	64322,7364	9079,52674	102,8045	1
6	0,21691	7,29579	1524,29551	38525,57153	31237,76181	2
7	0,22276	2,89788	7130,89078	70552,23001	48296,11001	1
8	0,21986	2,04721	11086,344	745,59425	13893,42339	2
9	0,13002	2,22012	395,63296	2923,16412	33111,32822	1
10	0,22999	2,93022	18893,17672	37164,77637	193,75653	1
11	0,14813	1,98461	14472,74419	6865,83371	894,62215	2
12	0,20457	1,6858	183,0929	13113,24317	18813,70835	1
13	0,15372	1,78617	18078,18791	28025,40893	10140,16773	1
14	0,3535	201,7426	77295,22428	13240,67599	250,28377	1
15	0,12343	2,42884	78292,82675	2072,78475	412,78698	1
16	0,21878	92,894	107733,6204	279494,4738	8256,07118	1
17	0,2041	2,02265	987,63571	8482,35952	1611,19113	2
18	0,21293	108,3931	7939,35827	328,14481	13699,9508	2
19	0,15678	2,07249	25310,99884	44847,24045	3388,31375	1
20	0,29645	227,168	3178809,797	330182,6049	2519,0725	1
21	0,14416	1,85072	11334,67488	27673,16919	10776,61496	2
22	0,16813	2,41602	16077,16579	38900,17207	14352,54996	1
23	0,17215	2,64693	62364,12807	2631,75132	2147,98841	2
24	0,1672	2,72974	432,85919	47970,2113	1177,23384	1

Şekil 2.31. Kitle iyi huylu/kötü huylu değerlendirmesi eğitim örneklerine ait elde edilen özellikler

Böylece iyi huylu ve kötü huylu kitle sınıflaması için yukarıdaki 5 özellik kullanılmıştır. Sınıflama işlemi için K-ortalama algoritması ile tekli karar ağacı yöntemlerinin hibrid kullanımı gerçekleştirilmiştir. Tablo 2.2’de belirtildiği gibi veritabanında 38 iyi huylu ve 20 kötü huylu kitle bulunmaktadır. Kitle tespitinde kullanılan 12 özellik ile yukarıda belirtilen 5 özelliğe ait eğitim performansı sonuçları aşağıdaki tabloda verilmiştir.

Tablo 2.13. Kitle iyi huylu/kötü huylu değerlendirme özelliklere göre eğitim performansı sonuçları

	K_Ortalama (12 özellik)			K_Ortalama (5 özellik)			Tekli Karar Ağacı (12 özellik)			Tekli Karar Ağacı (5 özellik)		
	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü
<b>Toplam</b>	19	11	30	19	11	30	19	11	30	19	11	30
<b>Doğru</b>	12	8	20	19	11	30	13	11	24	13	11	24
<b>Yanlış</b>	7	3	10	0	0	0	6	0	6	6	0	6
<b>Eğitim Performansı</b>	<b>%63.15</b>	<b>%72.72</b>	<b>%66.66</b>	<b>%100</b>	<b>%100</b>	<b>%100</b>	<b>%68.42</b>	<b>%100</b>	<b>%80</b>	<b>%68.42</b>	<b>%100</b>	<b>%80</b>

Tablo 2.13’de görüldüğü gibi iyi huylu/kötü huylu sınıflamasında K-ortalama yöntemi için 5 özellik daha iyi sonuç vermektedir. Bu nedenle, yapılan tez çalışmasında iyi huylu/kötü huylu değerlendirmesinde yukarıda verilen 5 özellik kullanılmıştır. Bununla birlikte, bu özellikler kullanılarak SVM ve olasılıklı sinir ağı yöntemleri de denenmiştir ve aşağıdaki sonuçlar elde edilmiştir.

Tablo 2.14. Kitle iyi huylu/kötü huylu değerlendirme yöntemlerin eğitim performansı sonuçları

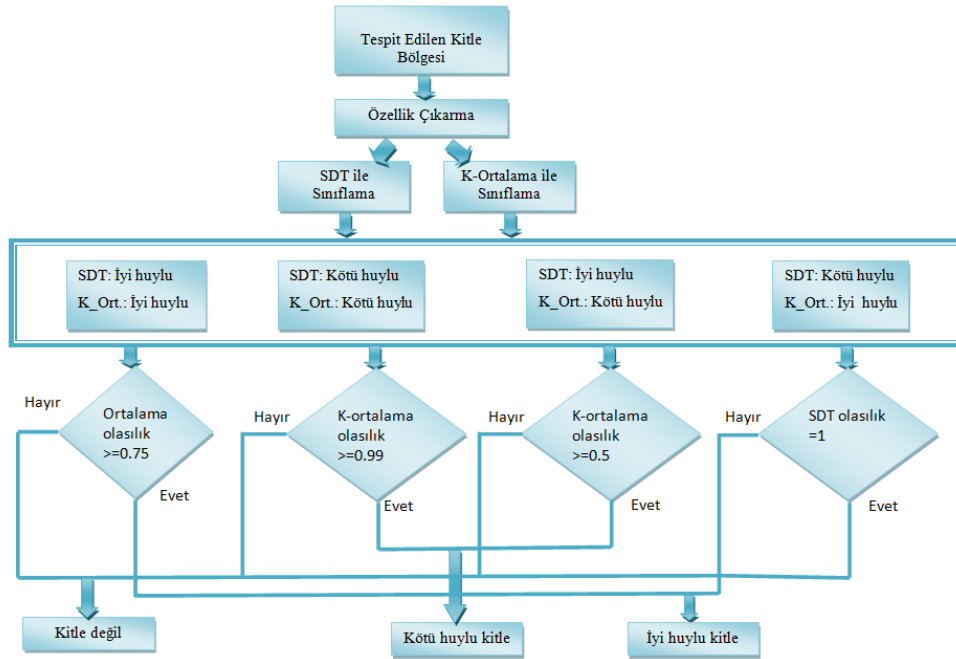
	K_Ortalama (5 özellik)			Tekli Karar Ağacı (5 özellik)			SVM_RBF kernel (5 özellik)			SVM_Sigmoid kernel (5 özellik)			Olasılıklı Sinir Ağı (5 özellik)		
	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü
<b>Toplam</b>	19	11	30	19	11	30	19	11	30	19	11	30	19	11	30
<b>Doğru</b>	19	11	30	13	11	24	0	0	0	0	0	0	0	9	9
<b>Yanlış</b>	0	0	0	6	0	6	19	11	30	19	11	30	19	2	21
<b>Eğitim Performansı</b>	%100	%100	%100	%68.42	%100	%80	%0	%0	%0	%0	%0	%0	%0	%81.81	%30

Tablo 2.14'deki sonuçlara bakıldığında SVM yönteminin hiç öğrenemediği, PNN yönteminin ise kötü huylu kitleleri öğrenebildiği görülmektedir. Literatürde, kitle iyi huylu/kötü huylu sınıflamasında yapılan çalışmalarda contourlet ve Gabor filtre özellikleri ile SVM yönteminin birlikte kullanımlarından bahsedilmiştir. Yapılan çalışmada, SVM ve PNN yöntemlerinin kullanılan özellikler ve eğitim kümesi için başarısız olduğu söylenebilir. Bunun sonucunda, iyi huylu/kötü huylu değerlendirmesinde K-ortalama ve SDT yöntemleri kullanılmıştır. SDT verilen bu 5 özellikten yerel homeopati ve dalgacık 2.seviye dikey katsayı enerji özelliklerini seçmiştir. Tespit edilen kitle bölgeleri sonuçlarından bazılarına ait K-ortalama ve SDT iyi huylu/kötü huylu sınıflama sonuçları aşağıdaki tabloda verilmiştir.

Tablo 2.15. Kitle iyi huylu/kötü huylu değerlendirme yöntemlere ait bazı sonuçlar

Kitle olarak tespit edilen bölge	Tekli Karar Ağacı		K-Ortalama		Gerçek Sonuç
	Sonuç	Olasılık	Sonuç	Olasılık	
1	İyi huylu	1	İyi huylu	0.79	İyi huylu
2	İyi huylu	0.8	İyi huylu	0.99	İyi huylu
3	İyi huylu	0.8	Kötü huylu	0.99	Kötü huylu
4	Kötü huylu	1	Kötü huylu	0.99	Kötü huylu
5	Kötü huylu	0.75	İyi huylu	0.99	İyi huylu
6	Kötü huylu	1	İyi huylu	0.74	Normal
7	İyi huylu	0.8	Kötü huylu	0.54	Kötü huylu
8	İyi huylu	1	İyi huylu	0.99	İyi huylu
9	İyi huylu	0.8	İyi huylu	0.5	Normal
10	Kötü huylu	0.75	Kötü huylu	0.99	Kötü huylu


Yukarıdaki tabloda gerçek sonucu normal olan bölgeler yanlış pozitif kitle bölgelerini göstermektedir. Veritabanı sonuçları incelendiğinde iyi huylu/kötü huylu değerlendirilmesi için aşağıdaki algoritma geliştirilmiştir.



Şekil 2.32. Kitle İyi huylu/kötü huylu değerlendirmesi için geliştirilen algoritma

Şekil 2.32’ye bakıldığında yöntemler farklı sonuçlar ürettiğinde daha başarılı bir eğitim performansı veren K-ortalama yönteminin sonucu alınmaktadır. Bunun için de kararın olasılığına bakılmaktadır. Bununla birlikte bazı yanlış pozitif kitle bölgelerinin de elemine edilmesi gerçekleştirilmektedir. Kitle iyi huylu/kötü huylu değerlendirme için geliştirilen algoritmanın program çıktıları şekil 2.33’de verilmiştir.


*Mdb265(kötü huylu kitle)*



Şekil 2.33. (a) Orijinal görüntü (b) ANN\_1 ve ANN\_2 sonucu (c) (b)+PNN sonucu (d) (c)+İyi huylu/kötü huylu değerlendirme sonucu (TP bölgesi; 0.875olasılıkla kötü huylu)




Şekil 2.33'de iyi huylu/kötü huylu değerlendirme algoritması sonucu FP bölgesi elenmiştir ve TP bölgesi için de 0.875 olasılıkla kötü huylu kararı verilmiştir. Böylece FP oranı biraz daha indirgenmiş olur. Kitle tespiti ve iyi huylu/kötü huylu değerlendirme algoritmasına ait program çıktıları aşağıdaki gibidir.



Şekil 2.34. (a) Orijinal görüntü (b) Kitle tespiti ve iyi huylu/kötü huylu değerlendirme için önerilen sistem sonucu

Şekil 2.34'ün devamı



Şekil 2.34'de kitle tespiti ve iyi huylu/kötü huylu değerlendirme için önerilen sistem sonuçlarına bakıldığında oldukça başarılı bir sistem geliştirildiği görülmektedir. Bununla birlikte, daha fazla sonuç ve istatistiksel değerlendirme bir sonraki bölümde verilecektir. Böylece kitle tespiti ve iyi huylu/kötü huylu değerlendirme kısmı tamamlanmıştır. Bundan sonra mikrokalsifikasyonların tespiti ve değerlendirilmesi ele alınacaktır.


## 2.5. Mikrokalsifikasyonların Tespiti ve İyi Huylu/Kötü Huylu Değerlendirmesi

Bu kısım, daha önceden belirtildiği gibi mikrokalsifikasyonların tespiti için görüntünün iyileştirilmesi, şüpheli mikrokalsifikasyon bölgelerinin belirlenmesi,

mikrokalsifikasyonların tespiti ve iyi huylu/kötü huylu değerlendirilmesi aşamalarını kapsamaktadır. Bu aşamalara ilişkin detaylar aşağıda verilmiştir.


### 2.5.1. Mikrokalsifikasyonların Tespiti için Görüntünün İyileştirilmesi

Önceki bölümde belirtildiği gibi burada iyileştirme işlemi için sadece top-hat dönüşümü kullanılmıştır. Dalgacık tabanlı eşikleme ve CLAHE yöntemleri de denenmiştir. Ancak, bunların sonucunda mikrokalsifikasyonların görünürlüğü bozulmuştur.




Şekil 2.35. (a) Orijinal görüntü (Mdb209) LogAMEE=37.19 (b) Top-hat dönüşümü LogAMEE=48.58 (c) Dalgacık tabanlı iyileştirme LogAMEE=76.13 (d) CLAHE LogAMEE=84.45

Şekil 2.35'deki çerçeve kalsifikasyon bölgesini göstermektedir (manuel çizilmiştir) ve farklı yöntem sonuçları karşılaştırılmıştır. Burada LogAMEE değerinin gittikçe arttığı görülmektedir ancak bu kontrast yani görüntüdeki karışıklığın iyileştiğini ve görüntüdeki karanlık kısımların aydınlatıldığını göstermektedir. Kitle, daha büyük ve dokusal yapıda olduğundan bu ölçüt kitle tespiti için görüntü iyileştirme kısmında kullanılmıştır. Ancak, mikrokalsifikasyonlar çok küçük nokta şeklinde gürültüye benzer yapıda olduklarından görünürlükleri bozulmaktadır. Bu nedenle, sonuçlara bakıldığında mikrokalsifikasyonların görünürlüğünün en iyi top-hat dönüşümünde elde edildiği görülmektedir. Bu yöntemlerin ard arda kullanımı ile elde edilen karşılaştırma sonuçları aşağıdaki gibidir.




Şekil 2.36. (a) Orijinal görüntü (Mdb209) (b) Top-hat dönüşümü (c) (b)+ Dalgacık tabanlı iyileştirme (d) (c)+CLAHE

Şekil 2.36’da görüldüğü gibi mikrokalsifikasyonların görünümü dalgacık tabanlı iyileştirme ile biraz bulanıklaşırken, CLAHE yöntemi ile iyice görünmez hale gelmektedir. Bunların sonucunda, mikrokalsifikasyonların görüntüsünün iyileştirilmesi için sadece top-hat dönüşümü kullanılmıştır. Buna ilişkin program çıktıları aşağıdaki gibidir.



Şekil 2.37. (a) Orijinal görüntü (b) İyileştirilmiş ve bölütlenmiş görüntü

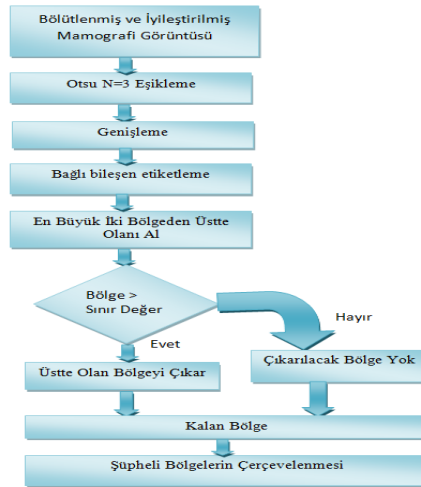
Şekil 2.37'nin devamı



Şekil 2.37'deki sonuçlara bakıldığında mikrokalsifikasyonların görünürlüğünün iyileştirildiği görülmektedir. Bundan sonraki adımda şüpheli mikrokalsifikasyon bölgeleri belirlenecektir.


### 2.5.2. Şüpheli Mikrokalsifikasyon Bölgelerinin Belirlenmesi

Elde ettiğimiz meme bölgesi bölütlenmiş ve mikrokalsifikasyonların görünürlüğü iyileştirilmiş görüntüde MC arama alanını daraltmak ve tespit başarısını arttırmak için şüpheli mikrokalsifikasyon bölgelerinin belirlenmesi aşaması gerçekleştirilmiştir. Burada şüpheli MC bölgelerinin belirlenmesinde aşağıdaki algoritma kullanılmıştır.



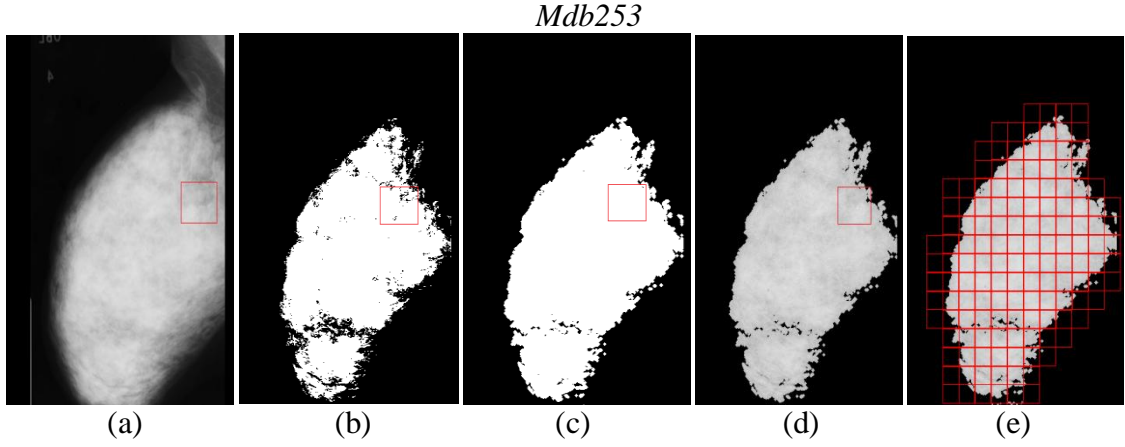
Şekil 2.38. Şüpheli mikrokalsifikasyon bölgelerinin belirlenmesi için önerilen algoritma

Şekil 2.38’de verilen şüpheli mikrokalsifikasyon bölgelerinin belirlenmesi algoritmasına bakarsak pektoral kas çıkarma algoritmasına benzediğini söyleyebiliriz. Ancak, burada Otsu N=3 eşikleme kullanılmış, ardından mikrokalsifikasyonlar çok küçük yapıda olduklarından görüntüde çok kaybolmamaları için genişleme işlemi ile güçlendirilmiştir sonra da üstte kalan bölge belirtilen piksel sayısının üstünde ise bu bölge çıkarılarak kalan eşiklenmiş ve genişletilmiş bölge şüpheli bölge olarak alınmıştır. Pektoral kas çıkarımında üst bölge için sınır piksel sayısı önceden belirtildiği gibi 21.000 pikseldi, burada genişleme işlemi uygulandığından bu değer 22.000 piksel olarak alınmıştır. Algoritmanın adım adım program çıktıları aşağıdaki gibidir.



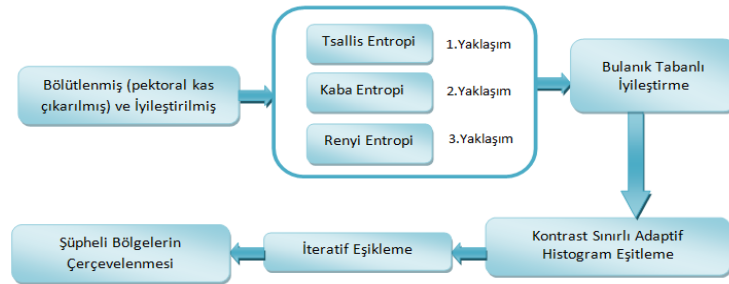
Şekil 2.39. (a) Bölütlenmiş ve iyileştirilmiş görüntü (b) Otsu N=3 eşikleme (c) (b)+Genleşme (d) Üstte kalan bölgenin çıkarılması (e) Şüpheli bölgelerin çerçevesi

Şekil 2.39'un devamı




Şekil 2.39'da görüldüğü gibi Mdb213 ve Mdb219 için üst bölge sınır piksel değerinin üstünde olduğundan çıkarılmış ancak Mdb253 için üst bölge sınır değerinin altında olduğundan herhangi bir bölge çıkarımı yapılmamıştır. Bu şekilde bölge çıkarma işlemi yapıldığından önceden de belirtildiği gibi pektoral kas çıkarımına gerek kalmamıştır. Daha sonra elde edilen şüpheli bölgelerin çerçevesi için şüpheli kitle bölgelerinin çerçevesine benzer şekilde 50x50 boyutlu kareler ile pencere kenarının yarısı adımlarla ilerlenerek (bölgenin yerini daha doğru tespit etmek için) taranır. Mikrokalsifikasyonlar çok küçük olduğundan belli bir şüpheli piksel sayısına bakılmaksızın taranan her bölge şüpheli MC bölgesi olarak alınır.

Şüpheli MC bölgelerinin belirlenmesi için önerilen algoritma dışında Tsallis (Havrda&Charvat), Renyi ve kaba entropi tabanlı bölütleme ve bulanık tabanlı MCs iyileştirme ile iteratif eşikleme [163] yöntemleri de denenmiştir. Burada bu yöntemleri içeren farklı yaklaşımlar gerçekleştirilmiştir.



Şekil 2.40. Şüpheli MC bölgelerinin belirlenmesi için entropi ve bulanık tabanlı yaklaşımlar


Şekil 2.40'daki yaklaşımlara bakıldığında öncelikle bu algoritma pektoral kas çıkarılmış görüntüye uygulanmaktadır. Algoritmada bulanık tabanlı iyileştirme işleminden sonra karışıklık çok düşük olduğundan iteratif eşikleme öncesi CLAHE uygulanmıştır. Aksi takdirde eşikleme sonucu mikrokalsifikasyonlar tamamen kaybolmaktadır. Bununla birlikte, Tsallis, kaba ve Renyi entropi olmak üzere üç farklı yaklaşım denenmiştir.



Şekil 2.41. (a) Bölütlenmiş ve iyileştirilmiş görüntü (Mdb213) (b) Tsallis entropi ve bulanık tabanlı iyileştirme (c) (b)+İteratif eşikleme sonucu

Şekil 2.41'de görüldüğü gibi karışıklık iyileştirilmeden iteratif eşikleme yapılıncı hemen hemen tüm görüntü sıfırlanmış olmaktadır. Bu nedenle iteratif eşikleme CLAHE yöntemi ile karışıklık iyileştirildikten sonra gerçekleştirilmiştir.

#### 1.Yaklaşım (Tsallis entropi ile)




Şekil 2.42. (a) Bölütlenmiş ve iyileştirilmiş görüntü (Mdb213) (b) Entropi ile bulanık tabanlı iyileştirme (c) (b)+ CLAHE (d) (c)+İteratif eşikleme (e) Şüpheli MC bölgelerinin çerçevesi




Şekil 2.42'nin devamı

*2.Yaklaşım (Kaba entropi ile)*




*3.Yaklaşım (Renyi entropi ile)*




Şekil 2.42'de verilen üç farklı yaklaşıma bakıldığında kaba entropi kullanılan yaklaşımda bölütlemenin daha çok olduğu görülmektedir. Tsallis ve Renyi entropilerinin kullanıldığı yaklaşımlarda sonuçlar hemen hemen aynıdır. Pektoral kas çıkarılmamış görüntü için sonuçlar Şekil 2.43'de verilmiştir. Burada Tsallis ve Renyi entropi sonuçları karşılaştırılmıştır ve Tsallis entropi ile bulanık tabanlı iyileştirme sonucunda karşıtlığın biraz daha iyi olduğu görülmektedir.

1.Yaklaşım (Tsallis entropi ile)



3.Yaklaşım (Renyi entropi ile)



Şekil 2.43. (a) Bölütlenmiş ve iyileştirilmiş görüntü (Mdb238) (b) Entropi ile bulanık tabanlı iyileştirme (c) (b)+ CLAHE (d) (c)+İteratif eşikleme

Yukarıdaki şekilde kara çerçeve MC bölgesini, yuvarla çerçeve ise Renyi entropi kullanılan yaklaşım ile Tsallis entropi kullanılan yaklaşım farklarını göstermektedir. Tsallis entropi sonucunda MC bölgesi aynen korunmuş ve diğer kısımlar biraz daha iyi elemine edilmiştir. Şüpheli MC bölgelerin belirlenmesi için önerilen algoritma, entropi ile bulanık tabanlı iyileştirme algoritmasına göre işlem karmaşıklığı daha azdır ve ortalama koşma süreleri aşağıdaki tabloda karşılaştırılmıştır.

Tablo 2.16. Şüpheli MC bölgelerinin belirlenmesi için uygulanan yaklaşımların karşılaştırılması

Şüpheli MC Bölgelerinin Belirlenmesi Ortalama koşma süresi	Önerilen algoritma	Entropi kullanılarak bulanık tabanlı iyileştirme
		33 sn

Tablo 2.16’da görüldüğü gibi önerilen algoritmanın ortalama koşma süresi daha azdır. Bununla birlikte, mikrokalsifikasyonların tespiti kısmında sonuçlar da karşılaştırılacaktır. Bundan sonraki adımda elde edilen ROI bölgesine ait özellik çıkarma ve sınıflama işlemleri gerçekleştirilerek bölgenin mikrokalsifikasyon içerip içermediği kararı verilerek mikrokalsifikasyonların tespiti işlemi tamamlanacaktır.

### 2.5.3. Özellik Çıkarma ve Sınıflama

Mikrokalsifikasyonların tespiti için literatürde de yaygın kullanılan Tablo 1.3’de verilen istatistiksel özellikler ile Tablo 1.1’de verilen GLCM özelliklerinden bazıları kullanılmıştır. Kontrast, küme önemi, korelasyon bilgi ölçüsü, normalize ters fark momenti, çarpıklık, basıklık, ortalama ve varyans olmak üzere toplam 9 özellik çıkarılmıştır. Bazı örneklere ait çıkarılan özellikler aşağıda verilmiştir.

	A	B	C	D	E	F	G	H	I	J
	Küme Önemi	Enerji	Korelasyon bilgi ölçüsü	Normalize ters fark momenti	Çarpıklık	Basıklık	Kontrast	Ortalama	Varyans	İstenen Sonuç
1										
2	253321329	0,0026	-0,8435	0,9991	3,1036	23,0086	58,7306	116,7633	2896,471	0
3	8958734,636	0,0025	-0,5695	0,9994	3,6231	18,1857	38,1408	131,9845	401,3891	0
4	115664326,5	0,0011	-0,7869	0,9993	1,1026	3,866	44,1045	130,4294	2033,8	0
5	12892910,66	0,0022	-0,5377	0,9993	3,2575	13,9599	45,7	127,7865	415,7287	0
6	4232742,807	0,0017	-0,5598	0,9994	2,0958	7,3931	40,9588	187,1151	360,657	1
7	439844671,1	0,0436	-0,9135	0,9988	14,2375	218,5062	83,0388	88,7286	3692,199	0
8	1311432,093	0,0021	-0,4866	0,9995	2,4067	8,4153	31,969	171,289	193,1834	0
9	455278621,7	0,0078	-0,8435	0,9986	8,9497	114,4069	94,6339	118,4624	3797,591	0
10	1449703,806	0,0018	-0,4941	0,9995	2,1678	6,9177	33,6576	185,4094	199,272	0
11	1722284,009	0,0021	-0,5082	0,9995	2,4996	8,7545	32,5253	196,4069	207,0013	0
12	2343697,673	0,0013	-0,4845	0,9992	1,8979	5,5497	49,3163	178,2486	269,2831	0
13	1173943,803	0,0025	-0,5268	0,9996	2,6019	9,6736	25,5633	197,4686	201,2417	0
14	2246794,561	0,0016	-0,5063	0,9994	2,1989	7,0631	40,9829	171,4824	243,7574	1
15	2081498,202	0,0018	-0,4598	0,9994	2,5848	9,1399	40,3931	158,7747	200,6423	1
16	488219861	0,0648	-0,9078	0,9989	14,9214	232,9552	74,4118	86,8347	4200,309	0
17	8985143,241	0,0015	-0,6262	0,9996	1,7285	5,1424	29,2318	175,4139	469,0034	0
18	2254319,91	0,0017	-0,5178	0,9995	2,2321	7,0478	35,0657	171,4049	239,2475	0
19	6357032,59	0,0033	-0,6851	0,9998	2,6893	10,1648	14,6233	181,98	344,7069	0
20	6313528,096	0,0019	-0,6209	0,9996	1,9451	6,3077	27,2212	155,318	485,1556	0
21	1098906124	0,1217	-0,7228	0,9935	14,134	215,7176	518,2424	113,9763	7200,718	0
22	2110102,924	0,0019	-0,4786	0,9992	2,7938	11,1735	50,3318	153,0453	219,3649	1
23	3717042,974	0,0016	-0,5748	0,9995	1,5424	3,9206	31,8996	148,4914	347,4793	0
24	2229092,197	0,0019	-0,5388	0,9994	2,1422	6,7711	36,018	146,7861	272,9053	0
25	75883968,85	0,0013	-0,7931	0,9994	1,2732	4,091	40,2914	106,8143	1445,301	0
26	908441,1857	0,0028	-0,4558	0,9995	3,3385	14,9725	29,3641	162,9273	136,1213	0
27	323097012,3	0,0246	-0,8315	0,9991	12,6334	185,7058	61,7551	97,689	3200,805	0
28	1252464,788	0,0027	-0,495	0,9996	3,1766	14,4078	28,2127	157,4196	169,7423	0
29	230112722,1	0,5182	-0,9633	0,9938	15,7208	249,7418	511,5408	18,1833	1309,176	0

Şekil 2.44. Bazı örneklere ait mikrokalsifikasyon tespiti için çıkarılan özellikler

Özellikler çıkarıldıktan sonra diğer sınıflama işlemlerinde olduğu gibi STATISTICA 12©StatSoft ve DTREG 10©PhilSherrod paket programlarından yararlanılarak mikrokalsifikasyonların tespiti için YSA ve SVM yöntemleri uygulanmıştır.

Farklı eğitim örnek sayıları ve çekirdek fonksiyonlarına ait geliştirilen SVM modellerinin eğitim performans sonuçları aşağıdaki tabloda verilmiştir.

Tablo 2.17. MCs tespiti için geliştirilen SVM modellerine ait eğitim performansı sonuçları

	Model 1			Model 2			Model 3			Model 4			Model 5			Model 6		
	MCs	Normal	Tümü	MCs	Normal	Tümü	MCs	Normal	Tümü	MCs	Normal	Tümü	MCs	Normal	Tümü	MCs	Normal	Tümü
<b>Toplam</b>	20	213	233	20	140	160	20	65	85	20	213	233	20	140	160	20	65	85
<b>Doğru</b>	0	213	213	0	140	140	8	65	73	0	213	213	0	140	140	2	63	65
<b>Yanlış</b>	20	0	20	20	0	20	12	0	12	20	0	20	20	0	20	18	2	20
<b>Eğitim Performansı</b>	%0	%100	%91.4	%0	%100	%87.5	%40	%100	%85.8	%0	%100	%91.4	%0	%100	%87.5	%10	%96.9	%76.4

Tablo 2.17'deki sonuçlara göre MC örneklerinin eğitimin çoğunlukla başarısız olduğu görülmektedir. Literatürde, MCs tespiti için dalgacık özellikleri ile SVM yönteminin birlikte kullanımı önerilmiştir. Yapılan çalışmada, geliştirilen SVM modellerinin, önerilen doku ve istatistiksel özellikler ile kullanılan eğitim kümeleri için başarısız olduğu söylenebilir. Geliştirilen SVM modellerine ilişkin parametreler aşağıdaki tabloda verilmiştir.

Tablo 2.18. MCs tespiti için geliştirilen SVM modellerine ait parametreler

Model no	Eğitim Örnek sayısı	Çekirdek Fonksiyon	Parametreler		
			C	Gamma	Coef0
1	233	RBF	0.1	0.001	-
2	160	RBF	0.1	0.001	-
3	85	RBF	3.684	15.026	-
4	233	Sigmoid	0.1	0.001	0.
5	160	Sigmoid	0.1	0.001	0.
6	85	Sigmoid	1502.66	1.357	1.668

Yapılan çalışmada, önceden de belirtildiği gibi RBF çekirdek fonksiyonu için C parametresi [0.1-5000], gamma parametresi [0.001-50], sigmoid çekirdek fonksiyonu için C parametresi [0.1-5000], gamma parametresi [0.001-50] ve coef0 parametresi [0-100] aralığında değerler verilmiştir. Tablo 2.18'de verilen değerler ile o modele ait en iyi sonucu veren parametre değerlerini göstermektedir. Burada MC örneklerinin eğitiminin tamamen başarısız olduğu durumlarda parametrelerin belirli bir aynı değerde olduğu görülmektedir. Sonuç olarak SVM modellerinin MCs tespiti için duyarlılığının (sensitivity) için oldukça düşük olduğunu söyleyebiliriz. Veritabanındaki MC anormalliklerinin sayısı 28'dir ancak MC anormalliklerinin dağınık yerleşiminin görüldüğü bölgeler ile toplam 31 MC bölgesi elde edilir. Bu sayı MC olmayan normal doku bölge sayısına göre oldukça düşük olduğundan eğitim güçleşmektedir.

MCs tespiti için SVM modellerinin başarısız olması sebebiyle YSA yöntemi uygulanmıştır.

Tablo 2.19. MCs tespiti için geliştirilen ağa ait eğitim performansı sonucu

	ANN		
	MCs	Normal	Tümü
<b>Toplam</b>	20	213	233
<b>Doğru</b>	20	213	233
<b>Yanlış</b>	0	0	0
<b>Eğitim Performansı</b>	<b>%100</b>	<b>%100</b>	<b>%100</b>

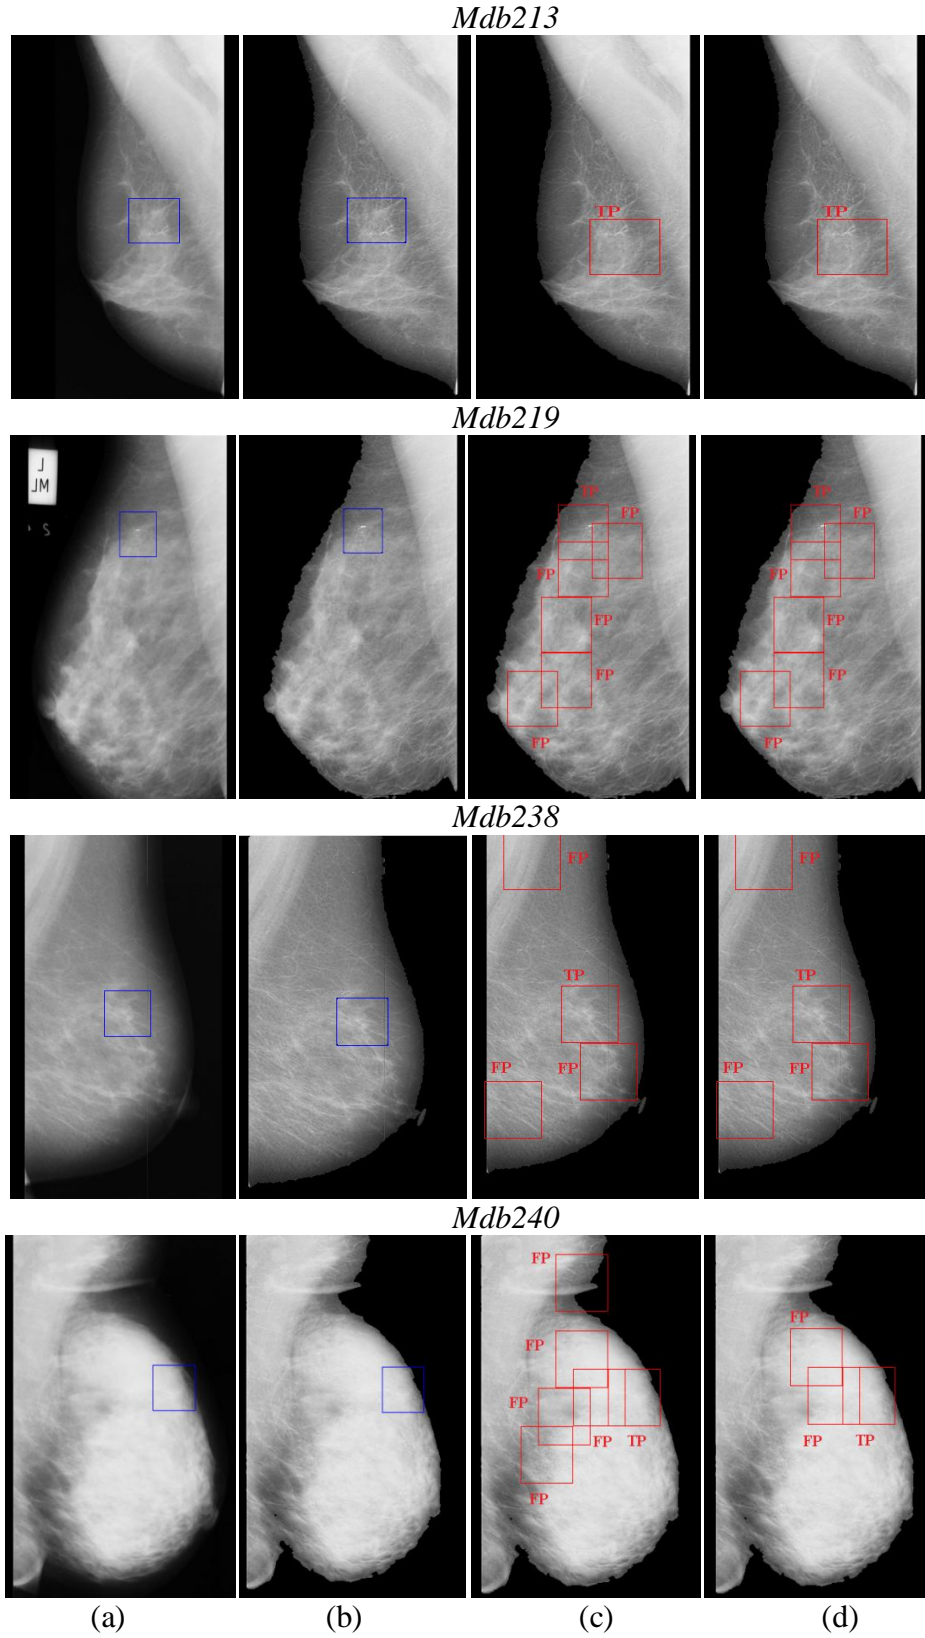
Tablo 2.19’da görüldüğü gibi geliştirilen sinir ağı eğitimi %100 başarıyla gerçekleştirilmiştir. Bu yüzden yapılan tez çalışmasında MCs tespiti için tespitinde sınıflama işlemi için YSA kullanılmıştır. Kullanılan ağa ilişkin parametreler aşağıdaki tabloda verilmiştir.

Tablo 2.20. MCs tespiti için geliştirilen YSA’ya ait parametreler

YSA	Giriş katmanı nöron sayısı	Gizli katmanı nöron sayısı	Çıkış katmanı nöron sayısı	Parametreler			
				Eğitim algoritması	Hata fonksiyonu	Gizli katman aktivasyon fonksiyonu	Çıkış katmanı aktivasyon fonksiyonu
ANN	9	21	2	BFGS	Entropi	Lojistik	Softmax

Yapılan tez çalışmasında yukarıda elde edilen ağ geliştirilirken gizli katmandaki nöron sayısı [5,100] aralığında, hata fonksiyonu için kareler toplamı ve entropi fonksiyonları, gizli katman için ise lojistik, tanh, üstel hata fonksiyonları denenerek eğitilen 100.000 ağ içinden en iyisi seçilmiştir.

Geliştirilen ağa ait test sonuçları da oldukça başarılıdır ve bir sonraki bölümde istatistiksel olarak detaylı bir biçimde verilecektir. Sınıflama işlemi sonucunda üst üste gelen çerçeveler de olabilmektedir. Bunun için daha önce kitle tespitinde bahsedilen çerçeve birleştirme algoritması kullanılmıştır. Sonuç olarak MCs tespiti, belirtilen 5 özellik çıkarıldıktan sonra geliştirilen ANN ağı ile sınıflanarak işlem gerçekleştirilmektedir. Buna göre, veritabanındaki bazı örneklere ilişkin MCs tespit algoritma sonuçları aşağıdaki gibidir.



Şekil 2.45. (a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (c) Tsallis entropi ile bulanık tabanlı şüpheli bölgelerin belirlenmesi ve MCs tespit sonucu (d) Önerilen algoritma ile şüpheli bölgelerin belirlenmesi ve MCs tespit sonucu

Şekil 2.45’de şüpheli bölgelerin belirlenmesinde bahsedilen Tsallis entropi ile bulanık tabanlı iyileştirme yaklaşımının MCs tespiti algoritması sonucu ile şüpheli bölgelerin belirlenmesinde önerilen algoritma ile MCs tespiti sonuçları verilerek karşılaştırılmıştır. Buna göre, şüpheli bölgelerin belirlenmesinde önerilen algoritma ile MCs tespiti sonucunun daha iyi olduğu görülmektedir. Bununla birlikte, MCs tespiti için önerilen algoritmanın da performansının oldukça iyi olduğu görülmektedir (örneğin Mdb240’da görüldüğü gibi yoğun meme dokusundan mikrokalsifikasyonlar hiç görülmemektedir). Mikrokalsifikasyonların tespitinin yapı gereği oldukça zor olması nedeniyle yanlış pozitiflerin de biraz fazla görülmesi oldukça normaldir. Bu nedenle MCs tespit duyarlılığını düşürmeden yanlış pozitif bölgelerin biraz daha azaltılması için yanlış pozitif indirgeme işlemi gerçekleştirilmiştir.

#### **2.5.4. MCs Tespiti Yanlış Pozitif İndirgeme**

Burada, mikrokalsifikasyonların tespit duyarlılığı düşürülmeden FP bölgelerin sayısının azaltılması için tespit sonucu elde edilen bölgelere özellik çıkarma ve sınıflama işlemi uygulanmıştır. Bunun için bazı istatistiksel ve GLRLM özellikleri ile kademeli korelasyon sinir ağı kullanılmıştır.

Çıkarılan Özellikler:

- Çarpıklık (Tablo 1.3)
- Varyans (Tablo 1.3)
- Homojenlik (Tablo 1.1)
- Kısa ilkel vurgusu-SRE (Tablo 1.4)
- Uzun ilkel vurgusu-LRE (Tablo 1.4)
- İlkel uzunluk farklılığı-RLNU (Tablo 1.4)
- İlkel yüzdesi-RPC (Tablo 1.4)

Bu şekilde toplam 7 özellik elde edilmiştir. Bazı örneklere ait çıkarılan özellikler aşağıda verilmiştir.

	A	B	C	D	E	F	G	H
1	<b>Çarpıklık</b>	<b>Varyans</b>	<b>Homojenlik</b>	<b>SRE</b>	<b>IRE</b>	<b>RINU</b>	<b>RPC</b>	<b>İstenen Sonuç</b>
2	1,5032	565,0451	0,3137	0,78613	1,34141	1337947	0,87379	1
3	3,45583	301,6544	0,28484	0,79743	1,31267	1362110	0,88158	0
4	2,20515	236,3114	0,29839	0,81472	1,29311	1396230	0,89249	1
5	1,94217	276,5399	0,31047	0,78731	1,33518	1340633	0,87465	1
6	1,92538	459,8628	0,29421	0,8133	1,28722	1396239	0,89249	0
7	1,87685	1133,435	0,37207	0,71111	1,42642	1177826	0,82012	1
8	2,1699	424,459	0,30092	0,81063	1,30367	1390764	0,89075	0
9	1,73891	455,8151	0,27081	0,83901	1,23563	1450776	0,90963	0
10	3,38496	154,8315	0,32707	0,76851	1,35803	1310321	0,86479	0
11	2,52518	228,1483	0,33113	0,76436	1,3847	1297124	0,86046	0
12	11,92724	4890,491	0,45911	0,61784	1,299	873265,9	0,7062	0
13	2,28569	244,4139	0,392	0,69781	1,51575	1165555	0,81596	1
14	2,25891	264,6487	0,37847	0,72056	1,47161	1210834	0,83154	0
15	11,1792	6125,744	0,4923	0,5469	1,05713	686068	0,62587	0
16	1,60006	587,7558	0,31469	0,78287	1,33102	1336364	0,87327	1
17	13,05604	5276,711	0,48442	0,56939	1,00796	718957,1	0,64058	0
18	1,39354	414,4953	0,2732	0,82788	1,27233	1424194	0,90132	0
19	1,25856	1055,231	0,27263	0,81889	1,27233	1409358	0,89664	0
20	6,05728	3944,569	0,42934	0,65794	1,41084	598524	0,75519	1
21	7,6091	4418,821	0,41775	0,65947	1,23927	973101,3	0,74533	0
22	2,01706	449,8915	0,349	0,75307	1,40339	1273589	0,85267	1
23	3,69432	119,4692	0,36112	0,73098	1,42313	1234832	0,83968	0
24	3,70843	177,9709	0,44751	0,63762	1,63269	1045687	0,7792	0
25	11,86517	5831,232	0,49223	0,56677	1,04259	711535	0,63729	0
26	1,49928	1412,014	0,33802	0,7812	1,34938	1323653	0,86911	1
27	1,89306	1659,237	0,35953	0,75348	1,39404	1276713	0,8537	0
28	2,27215	211,5664	0,35159	0,75666	1,38158	1284565	0,8563	1
29	2,86619	149,725	0,30725	0,78963	1,32064	1352398	0,87846	0
30	2,42125	716,7452	0,30063	0,79884	1,31077	1366955	0,88314	0

Şekil 2.46. MCs tespiti FP indirgeme eğitim örneklerine ait elde edile özellikler

Özelliklerin çıkarılmasının ardından sınıflama işlemi için CCNN kullanılmıştır. Geliştirilen CCNN'nin eğitim performansı aşağıdaki tabloda verilmiştir.

Tablo 2.21. MCs tespiti FP indirgeme için geliştirilen ağa ait eğitim performansı sonucu

	CCNN_1			CCNN_2			CCNN_3		
	MCs	Normal	Tümü	MCs	Normal	Tümü	MCs	Normal	Tümü
<b>Toplam</b>	14	30	44	14	30	44	14	30	44
<b>Doğru</b>	12	27	39	9	27	36	10	27	37
<b>Yanlış</b>	2	3	5	5	3	8	4	3	7
<b>Eğitim Performansı</b>	<b>%85.7</b>	<b>%90</b>	<b>%88.63</b>	<b>%64.28</b>	<b>%90</b>	<b>%81.81</b>	<b>%71.42</b>	<b>%90</b>	<b>%84.09</b>

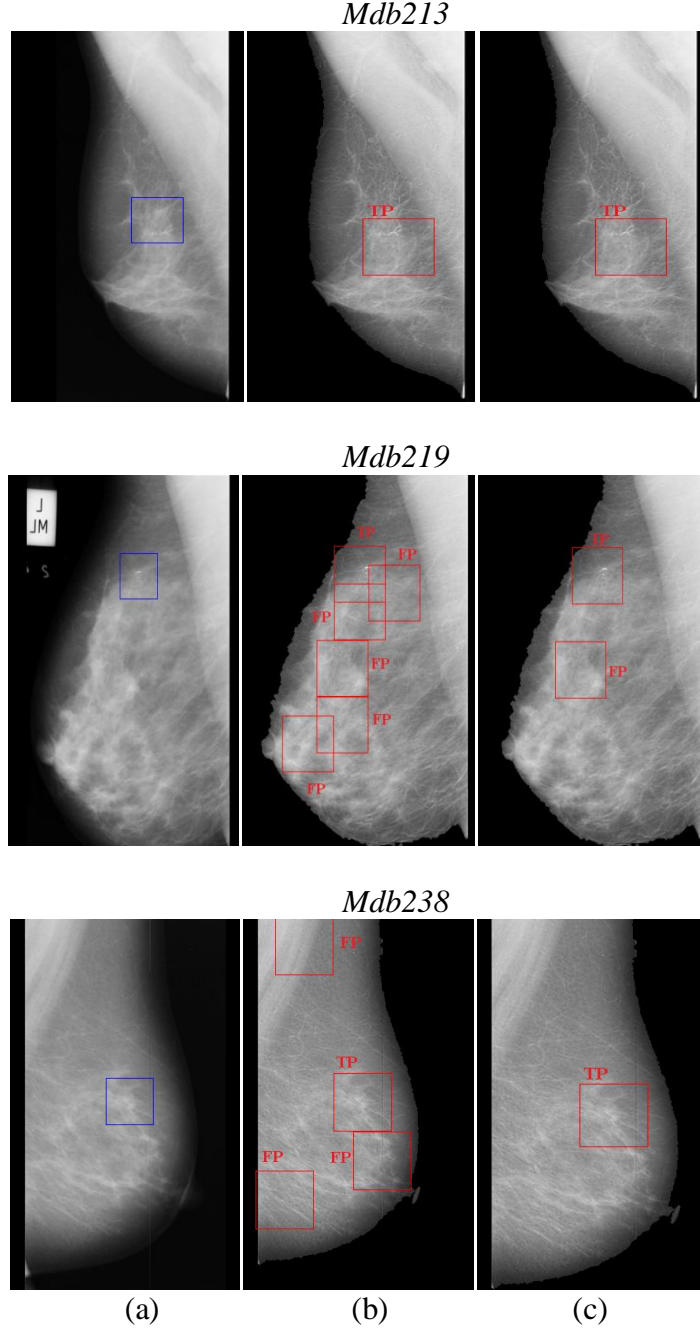
Tablo 2.21'de görüldüğü gibi gizli katman çekirdek fonksiyonu değiştirilerek üç farklı CCNN modeli geliştirilmiş ve yukarıdaki eğitim performans sonuçları elde edilmiştir. Buna göre, geliştirilen en başarılı ağı CCNN\_1 olduğu görülmektedir. Geliştirilen CCNN modellerine ait parametreler aşağıdaki tablodaki gibidir.

Tablo 2.22. Mcs tespiti FP indirgeme için geliştirilen ağlara ilişkin parametreler

Model no	Gizli Katman Çekirdek Fonksiyon	Parametreler		
		Gizli katman nöron sayısı	Gizli katman min. ve maks. ağırlıklar	Çıkış katmanı min. ve maks. ağırlıklar
CCNN_1	Gauss	3	-7.156, 34.722	-6.687, 5.822
CCNN_2	Sigmoid	1	-105.541, 93.643	-7.227, 8.602
CCNN_3	Sigmoid&Gauss	2	-9.066, 13.08	-10.471, 11.628




Buna göre, en başarılı ađın gizli katman çekirdek fonksiyonunun Gauss olduđu görölmektedir. Böylece yanlış pozitif indirgeme işlemi ile MCs tespiti tamamlanmıştır. Veritabanındaki bazı örneklere ait MCs tespiti program çıktıları aşığıdaki gibidir.

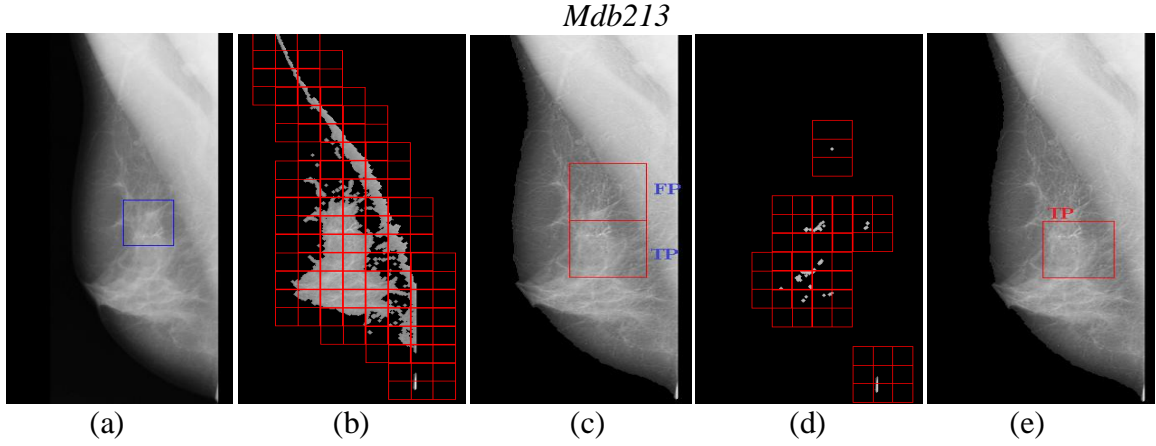


Şekil 2.47. (a) Orijinal görüntü (b) MCs tespit sonucu (c) (b)+CCNN\_1 ile FP indirgeme sonucu

Şekil 2.47'nin devamı




Şekil 2.47'de görüldüğü gibi MCs tespiti sonucu elde edilen FP bölgelerin büyük bir kısmı MCs tespiti duyarlılığı korunarak CCNN yöntemi ile indirgenmiştir. Böylece MCs tespiti işlemi tamamlanmıştır. Pektoral kas çıkarılarak ve çıkarılmayarak elde edilen MCs tespiti sonuçları aşağıdaki gibi karşılaştırılmıştır.



Şekil 2.48. (a) Orijinal görüntü (b) Şüpheli MCs bölgelerinin belirlenmesi (pektoral kas çıkarma algoritması uygulanmış görüntü) (c) (b)+MCs tespiti sonucu (d) Şüpheli MCs bölgelerinin belirlenmesi (pektoral kas çıkarma algoritması uygulanmamış görüntü) (e) (d)+MCS tespiti sonucu

Şekil 2.48'in devamı



Şekil 2.48'de görüldüğü gibi MCs tespiti için geliştirilen algoritmada pektoral kas çıkarıldığında FP bölgelerin daha fazla olduğu görülmektedir. Bu nedenle pektoral kas çıkarma işlemi tespit algoritmasından çıkarılmıştır. Sonuçlara bakıldığında oldukça başarılı bir MCs tespit algoritması geliştirildiğini söyleyebiliriz. Sonuçlara ilişkin detaylı istatistiksel değerlendirme bir sonraki bölümde anlatılacaktır.

### 2.5.5. Mikrokalsifikasyon İyi Huylu/Kötü Huylu Değerlendirilmesi

Burada, tespit edilen mikrokalsifikasyon bölgelerinin iyi huylu veya kötü huylu olma olasılığı belirlenmektedir. Buna göre, öncelikle iyi huylu ve kötü huylu mikrokalsifikasyon özellik vektörü oluşturularak ardından sınıflama yöntemi uygulanmıştır. Doku, istatistiksel (Tablo 1.1 ve Tablo 1.3) ve GLRL (Tablo 1.4) matrisi özellikleri çıkarılarak değerlendirilmiş ve bunlar içerisinde en başarılı sonuç veren aşağıdaki 9 özellik kullanılmıştır.

Çıkarılan Özellikler:

- Çarpıklık (Tablo 1.3)
- Kontrast (Tablo 1.1)
- Ortalama (Tablo 1.3)
- Homojenlik (Tablo 1.1)
- Uzun ilkel vurgusu – LRE (Tablo 1.4)
- Düşük gri seviye ilkel vurgusu – LGRE (Tablo 1.4)
- Yüksek gri seviye ilkel vurgusu – HGRE (Tablo 1.4)
- Kısa ilkel yüksek gri seviye vurgusu – SRHGE (Tablo 1.4)
- İlkel yüzdesi – RPC (Tablo 1.4)

Bazı MC bölgesi örneklerine ilişkin elde edilen özellikler aşağıdaki gibidir.

	A	B	C	D	E	F	G	H	I	J
1	<b>Çarpıklık</b>	<b>Kontrast</b>	<b>Ortalama</b>	<b>Homojenlik</b>	<b>LRE</b>	<b>LGRE</b>	<b>HGRE</b>	<b>SRHGE</b>	<b>RPC</b>	<b>İstenen Sonuç</b>
2	1,5032	46,18333	173,9172	0,3137	1,34141	0,00003	26709,64	23912,49	0,87379	2
3	2,20515	41,32263	164,5372	0,29839	1,29311	0,00003	24316,75	22212,1	0,89249	2
4	1,94217	41,73491	147,4586	0,31047	1,33518	0,00004	19308,82	17439,18	0,87465	2
5	1,87685	47,03404	129,6505	0,37207	1,42642	0,00006	15088,05	13138,8	0,82012	1
6	2,28569	21,32193	184,7375	0,392	1,51575	0,00002	27972,6	23813,8	0,81596	1
7	1,60006	49,22596	150,3839	0,31469	1,33102	0,00004	20311,5	18207,67	0,87327	1
8	6,05728	32,39667	143,4486	0,42934	1,41084	0,00008	18528,99	15381,46	0,75519	1
9	2,01706	28,28772	160,2842	0,349	1,40339	0,00003	22393,68	19787,5	0,85267	1
10	1,43928	36,64316	155,1391	0,33802	1,34938	0,00005	21707,53	19160,19	0,86911	2
11	2,27215	24,92544	171,2202	0,35159	1,38158	0,00003	25278,95	22314,59	0,8563	1
12	3,2266	41,93246	143,3358	0,33136	1,37639	0,00004	17920,9	15945,43	0,8589	2
13	2,23999	45,89509	161,7702	0,29086	1,27961	0,00004	23786,3	21778,2	0,89647	2
14	2,63399	28,76281	180,0616	0,34118	1,37535	0,00003	27896,28	24769,32	0,86202	1
15	2,52071	32,75702	175,1368	0,32547	1,34903	0,00003	26927,99	24102,26	0,87136	1
16	2,76716	41,75439	132,8447	0,32726	1,38816	0,00005	15435,45	13801,96	0,85769	2
17	0,7743	115,7126	133,5702	0,25326	1,24359	0,00007	17397,66	16102,73	0,90824	2
18	2,84178	39,35842	195,6807	0,32873	1,38296	0,00002	33102,11	29293,8	0,85959	1

Şekil 2.49. MCs iyi huylu/kötü huylu değerlendirmesi eğitim örneklerine ait elde edilen özellikler

Böylece iyi huylu ve kötü huylu MCs sınıflaması için yukarıdaki 9 özellik kullanılmıştır. Sınıflama işlemi için SVM ile diskriminant analizi yöntemlerinin hibrid kullanımı gerçekleştirilmiştir. Tablo 2.2’de belirtildiği gibi veritabanında 13 iyi huylu ve 15 kötü huylu MC bulunmaktadır ancak dağınık yerleşimden dolayı bu bölge sayısı olarak biraz daha artabilir. MCs iyi huylu/kötü huylu değerlendirmesi için yukarıda çıkarılan 9 özelliğin SVM, diskriminant analiz, YSA ve tekli karar ağacı yöntemlerine ait eğitim performansı sonuçları aşağıdaki tabloda verilmiştir.

Tablo 2.23. MCs iyi huylu/kötü huylu değerlendirme yöntemlerin eğitim performansı sonuçları

	Diskriminant Analizi			Tekli Karar Ağacı			SVM_RBF kernel			SVM_Sigmoid kernel			Yapay Sinir Ağı		
	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü	İyi huylu	Kötü huylu	Tümü
<b>Toplam</b>	8	9	17	8	9	17	8	9	17	8	9	17	8	9	17
<b>Doğru</b>	7	8	15	5	9	14	7	8	15	6	8	14	5	9	14
<b>Yanlış</b>	1	1	2	3	0	3	1	1	2	2	1	3	3	0	3
<b>Eğitim Performansı</b>	<b>%87.5</b>	<b>%88.88</b>	<b>%88.23</b>	<b>%62.5</b>	<b>%100</b>	<b>%82.35</b>	<b>%87.5</b>	<b>%88.88</b>	<b>%88.23</b>	<b>%75</b>	<b>%88.88</b>	<b>%82.35</b>	<b>%62.5</b>	<b>%100</b>	<b>%82.35</b>

Tablo 2.23’deki sonuçlara bakıldığında öğrenme işleminin tüm yöntemler için genelde başarılı olduğunu söyleyebiliriz. Bunlar arasından diskriminant analizi ve SVM (RBF çekirdek fonksiyonlu) yöntemleri biraz daha öne çıkmaktadır. Buna göre, yapılan tez çalışmasından tespit edilen MC bölgelerinin iyi huylu/kötü huylu değerlendirmesi için diskriminant analizi ve SVM yöntemleri kullanılmıştır. SVM yöntemine ait parametre değerleri aşağıdaki gibidir.

Tablo 2.24. MCs iyi huylu/kötü huylu değerlendirmede kullanılan SVM yöntemine ait parametreler

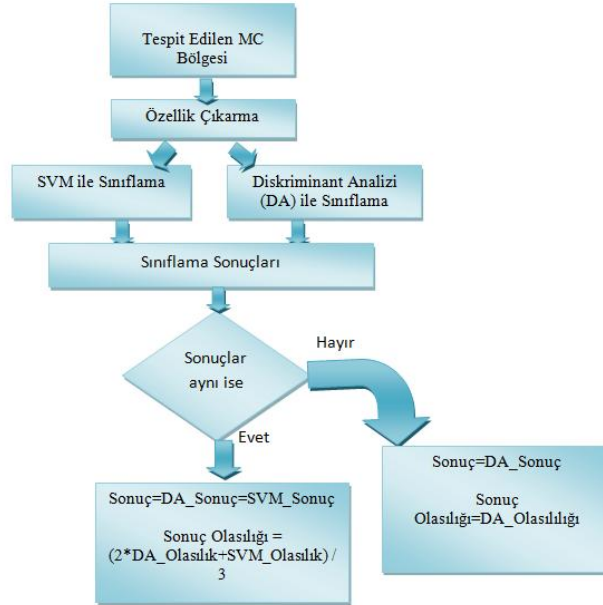
Yöntem	Çekirdek Fonksiyon	Parametreler	
		C	Gamma
<b>SVM</b>	<b>RBF</b>	<b>40.788</b>	<b>4.516</b>

Tespit edilen MC bölgelerinin bazılarına ait iyi huylu/kötü huylu sınıflama sonuçları aşağıdaki tabloda verilmiştir.

Tablo 2.25. MCs iyi huylu/kötü huylu değerlendirme yöntemlere ait bazı sonuçlar

MCs olarak tespit edilen bölge	Diskriminant Analizi		SVM_RBF		Gerçek Sonuç
	Sonuç	Olasılık	Sonuç	Olasılık	
1	Kötü huylu	0.7	İyi huylu	0.68	Kötü huylu
2	İyi huylu	0.64	İyi huylu	0.75	İyi huylu
3	İyi huylu	0.81	İyi huylu	0.70	İyi huylu
4	İyi huylu	0.57	Kötü huylu	0.56	İyi huylu
5	Kötü huylu	0.88	Kötü huylu	0.84	Kötü huylu
6	Kötü huylu	0.69	Kötü huylu	0.94	Kötü huylu


Sonuçlar incelendiğinde, diskriminant analiz ve SVM yöntemlerinin çıktıları farklı olduğunda diskriminant analiz sonucunun doğru olduğu görülmektedir. Buna göre, MCs iyi huylu/kötü huylu değerlendirilmesi için aşağıdaki algoritma geliştirilmiştir.




Şekil 2.50. MCs İyi huylu/kötü huylu değerlendirmesi için geliştirilen algoritma

Veritabanı sonuçlarına göre önerilen yöntemler genellikle aynı sonuç vermektedir, bazı durumlarda farklı sonuçlar verdiğinde DA sonucu doğru olmaktadır. Bu nedenle, aynı sonuçları verdiklerinde DA sonucuna x2 ve SVM sonucunda da x1 ağırlık verilerek son karar elde edilir. Bu şekilde, daha sağlıklı bir sınıflama gerçekleşmiş olur. MCs iyi huylu/kötü huylu değerlendirilmesi için geliştirilen algoritmanın program çıktıları aşağıdaki gibidir.


*Mdb213(Kötü huylu mikrokalsifikasyon)*



*Mdb219(İyi huylu mikrokalsifikasyon)*



*Mdb238(Kötü huylu mikrokalsifikasyon)*

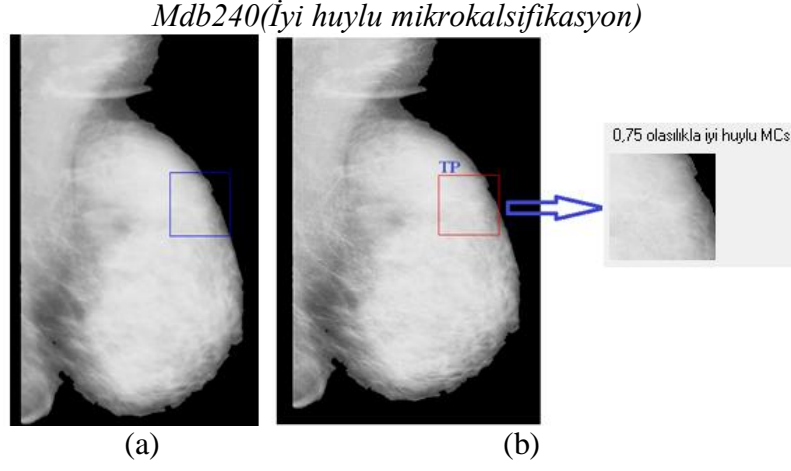


(a)

(b)

Şekil 2.51. (a) Orijinal görüntü (b) Mikrokalsifikasyonların tespiti ve iyi huylu/kötü huylu değerlendirme için önerilen sistem sonucu

Şekil 2.51'in devamı



Şekil 2.51'de MCs tespiti ve iyi huylu/kötü huylu değerlendirme için önerilen sistem sonuçlarına bakıldığında oldukça başarılı bir sistem geliştirildiği görülmektedir. Böylece MCs iyi huylu/kötü huylu değerlendirme aşaması ile birlikte bu bölüm tamamlanmıştır. Bununla birlikte, daha fazla sonuç ve istatistiksel değerlendirme bir sonraki bölümde verilecektir.



### 3. BULGULAR VE İRDELEME

Bu bölümde yapılan tez çalışmasına ait bulgular ve bunların istatistiksel değerlendirmeleri verilecektir. Bununla birlikte, literatürdeki çalışmalara ait sonuçlarla kıyaslanması gerçekleştirilerek, avantajları ve dezavantajları irdelenecektir.

#### 3.1. Kitle Tespiti Sonuçları ve İstatistiksel Değerlendirme

Kullanılan veritabanında Tablo 2.2’de belirtildiği gibi 209 normal ve 55 kitle tespit edilen mamografi görüntüsü bulunmaktadır. Anormal olan 55 görüntü toplam 58 kitle bölgesi içermektedir. Kitle tespiti için geliştirilen algoritmaya ait performans sonuçları aşama aşama aşağıdaki tabloda verilmiştir.

Tablo 3.1. Kitle tespiti sonuçları

Görüntü Sayısı	Normal		Kitle	
	209		55(58 kitle bölgesi)	
Bulunan Şüpheli Kitle Bölgeleri (ROIs)	TP	FP	TN	FN
	54	13821	-	4
ANN_1&ANN_2 Sınıflama	50	746	13075	8
PNN ile FP İndirgeme	49	171	13650	9
Kitle İyi Huylu/Kötü Huylu Değerlendirme Algoritması ile FP İndirgeme	49	67	13754	9

Tablo 3.1.’de kitle tespiti için yapılan işlemlere ait test değerlendirme sonuçları verilmiştir. Burada;


- TP: Doğru tespit edilen hasta bölgeleri
- FP: Yanlış (hasta olarak) tespit edilen hasta olmayan bölgeleri
- TN: Doğru tespit edilen hasta olmayan bölgeleri
- FN: Yanlış (hasta olmayan olarak) tespit edilen hasta bölgeleri göstermektedir.

Buna göre, bu değerler kullanılarak doğru tespit edilen hasta bölgelerin oranı yani duyarlılığı ve yanlış pozitif oranı (FPR) aşağıdaki formüller kullanılarak hesaplanmıştır.

$$\text{Duyarlılık (Sensitivity)} = \frac{TP}{TP+FN} \quad (3.1)$$

$$\text{FP Oranı (FPR)} = \frac{FP}{FP+TN} \quad (3.2)$$

Tablo 3.1.'deki algoritmalara ait istatistiksel değerlendirme sonuçları aşağıdaki gibidir.



Şekil 3.1. Kitle tespiti aşamalarına ait istatistiksel değerlendirme sonuçları

Şekil 3.1'e bakıldığında kitle tespiti için önerilen algoritmanın aşamalarında duyarlılığın çok değişmediği ve bununla birlikte FP oranının oldukça iyileştirildiği görülmektedir. FP oranının düşük olması hasta olmadığı halde hasta olarak yanlış tespit edilen bölgelerin sayısının az olması yani sistemin özgüllüğünün yüksek olması anlamına gelmektedir.


$$\text{Özgüllük (Specificity)} = \frac{TN}{FP+TN} \quad (3.3)$$

$$\text{Görüntü başına FP değeri (FPpI)} = \frac{FP}{\text{Görüntü Sayısı}} \quad (3.4)$$


Kitle tespiti için önerilen algoritmaya ait duyarlılık, özgüllük ve FPpI (False Positive per Image) değerleri ve ROC (Receiver Operating Characteristics), FROC (Free-Response ROC) eğrileri aşağıdaki gibidir. ROC eğrileri @MedCalc programı kullanılarak elde edilmiştir.

Tablo 3.2. Kitle tespiti için önerilen algoritmaya ait performans sonuçları

ROI Sayısı	Normal		Kitle
	13821		58
Kitle Tespiti için Önerilen Algoritma	Duyarlılık	Özgüllük	FPpI
	% 84.5	% 99.5	0.254



Şekil 3.2. Kitle tespiti için önerilen algoritmaya ait ROC eğrisi ve AUC (Area Under ROC Curve veya Az (matematikte))



Şekil 3.3. Kitle tespiti için önerilen algoritmaya ait FROC eğrisi

Sonuç olarak kitle tespiti için geliştirilen algoritma ile oldukça tatmin edici duyarlılık, özgüllük ve FPpI değerleri elde edilmiştir. Yapılan tez çalışmasında kitle tespiti için önerilen algoritmanın literatürdeki benzer çalışmalarla [54, 73, 164-168] karşılaştırma sonuçları aşağıdaki tabloda verilmiştir.

Tablo 3.3. Kitle tespiti literatür benzer çalışmalar karşılaştırma sonuçları

<i>Yöntemler</i>	<i>Veritabanı</i>	<i>Duyarlılık (%)</i>	<i>Özgüllük(%)</i>	<i>Doğruluk(%)</i>	<i>Az</i>	<i>FPpI</i>
<b>Samma, et al. 2010</b> [54] Şekil ile dalgacık enerji özel. ve GA-SVM	MIAS (19 kitle -19 normal görüntü)	88.9	-	-	-	0.79
<b>Nithya, et al. 2011</b> [73] GLCM özel. ve YSA	DDSM (25 kitle -25 normal görüntü)	100	93	96	-	-
<b>Moayedi, et al. 2010</b> [164] Contourlet dönüşüm özel. ve <i>SEL weighted SVM</i> <i>SVFNN</i> <i>Kernel SVM</i>	MIAS (30 kitle -60 normal görüntü)	-	-	96.6 91.5 82.1	-	-
<b>Mohanty, et al. 2011</b> [165] Kitle şekil modeli	MIAS (42 kitle -11 normal görüntü)	93	-	-	-	1.3
<b>Basheer, et al. 2013</b> [166] Doku özel. ve adaptif medyan filtreleme	MIAS ( 36 kitle görüntüsü)	92.3	80.6	-	0.86	2.75
<b>Khuzi, et al. 2009</b> [167] GLCM özel. ve eşikleme	MIAS (20 kitle -20 normal görüntü)	70	100	-	0.84	-
<b>Agrawal, et al. 2014</b> [168] Fourier, dalgacık entropi, parlaklık, doku, istatistiksel, GLRL özel. ve SVM	MIAS ( 55 kitle görüntü)	-	-	-	0.89	2-3
<b>Önerilen Algoritma</b>	<b>MIAS</b> <b>( 55 kitle -209 normal görüntü)</b>	<b>84.5</b>	<b>99.5</b>	<b>99.4</b>	<b>0.92</b>	<b>0.254</b>

Tablo 3.3. sonuçlarına bakıldığında önerilen algoritmada kullanılan veritabanının en fazla görüntü sayısına ve en yüksek doğruluğa ya da en düşük FPpI oranına sahip olduğu görülmektedir. Belirlenen şüpheli bölgelerin önerilen algoritma ile tespiti sonucunda kullanılan veritabanı için elde edilen duyarlılık, özgüllük, doğruluk ve FPpI değerlerinin oldukça başarılı olduğu söylenebilir.

### 3.2. Kitle İyi Huylu/Kötü Huylu Değerlendirme Sonuçları ve İstatistiksel Değerlendirme

Kullanılan veritabanında 55 kitle görüntüsü toplam 58 kitle içermektedir. Tablo 2.2.'de belirtildiği gibi bunların 38'i iyi huylu, 20'si kötü huylu kitledir. Yapılan tez çalışmasından kitle tespiti sonucunda 58 kitle bölgesinden 49'u tespit edilmiştir. Tespit

edilen 49 kitlenin 29'u iyi huylu, 20'si kötü huyludur. Burada, yapılan tez çalışmasında önerilen kitle iyi huylu/kötü huylu değerlendirme algoritmasının performans sonucu aşağıdaki gibidir.

Tablo 3.4. Kitle iyi huylu/kötü huylu değerlendirme algoritmasına ait performans sonuçları


	Tespit Edilen Kitle Bölgesi	Kitle İyi Huylu/Kötü Huylu Değerlendirme Algoritması Sonucu	Doğru Sınıflama
<b>İyi Huylu</b>	29	26	%89.7
<b>Kötü Huylu</b>	20	20	%100
<b>Toplam</b>	49	46	%93.9

Tablo 3.4.'de görüldüğü gibi tespit edilen 49 kitle bölgesinin 46'sı doğru sınıflanmıştır. Yanlış sınıflanan 3 kitle bölgesindeki kitleler iyi huyludur.

Kitle görüntüleri üzerinden kanser tespiti değerlendirmesini ele alırsak kötü huylu kitleler kanser, iyi huylu kitleler kanser değil olarak ifade edilebilir. Buna göre, kitle bölgeleri üzerinden kanser tespiti istatistiksel değerlendirme sonuçları aşağıdaki gibidir.

Tablo 3.5. Kitle bölgeleri üzerinden kanser tespiti performans sonuçları

	TP	FP	TN	FN
<b>Kitle Bölgeleri Üzerinden Kanser Tespit Başarısı</b>	20	3	26	0
	<b>Duyarlılık</b>		<b>Özgüllük</b>	
	% 100		% 89.7	



Variable	TEST					
Classification variable	DIAGNOSE					
Sample size	49					
Positive group : DIAGNOSE = 1	20					
Negative group : DIAGNOSE = 0	29					
Disease prevalence (%)	unknown					
<b>Area under the ROC curve (AUC)</b>						
Area under the ROC curve (AUC)	0.948					
Standard Error <sup>a</sup>	0.0288					
95% Confidence interval <sup>b</sup>	0.845 to 0.991					
z statistic	15.578					
Significance level P (Area=0.5)	<0.0001					
<sup>a</sup> DeLong et al., 1988						
<sup>b</sup> Binomial exact						
<b>Youden index</b>						
Youden index J	0.8966					
Associated criterion	>0					
Sensitivity	100,00					
Specificity	89,66					
<b>Criterion values and coordinates of the ROC curve [Hide]</b>						
Criterion	Sensitivity	95% CI	Specificity	95% CI	+LR	-LR
≥0	100,00	83,2 - 100,0	0,00	0,0 - 11,9	1,00	
>0	100,00	83,2 - 100,0	89,66	72,6 - 97,8	9,67	0,00
>1	0,00	0,0 - 16,8	100,00	88,1 - 100,0		1,00

Şekil 3.4. Kitle kanser tespitine ait ROC eğrisi ve AUC

Yapılan çalışmada kitle iyi huylu/kötü huylu sınıflaması için önerilen algoritmanın literatürdeki benzer çalışmalarla [4, 86, 119, 169, 170] karşılaştırılmasına ilişkin tablo aşağıda verilmiştir.

Tablo 3.6. Kitle iyi huylu/kötü huylu sınıflama literatür benzer çalışmalar karşılaştırma sonuçları

<i>Yöntemler</i>	<i>Veritabanı</i>	<i>İyi Huylu Kitle Doğru Sınıflama (%)</i>	<i>Kötü Huylu Kitle Doğru Sınıflama (%)</i>	<i>Az</i>
<b>Jasmine, et al. 2011</b> [119] Contourlet dönüşüm özel. ve SVM	MIAS (37 iyi huylu, 19 kötü huylu kitle)	94.59	78.95	-
<b>Islam, et al. 2010</b> [86] İstatistiksel doku özel. ve YSA	MIAS (38 iyi huylu, 20 kötü huylu kitle)	90.91	83.87	-
<b>Mudigonda, et al. 2001</b> [4] GLCM özel. ve LDA	MIAS (19 iyi huylu, 13 kötü huylu kitle)	-	-	0.79
<b>Loka, et al. 2013</b> [169] Bulanık tekton özel. ve SVM	MIAS (13 iyi huylu, 16 kötü huylu kitle)	69.2	93.8	-
<b>Kumar, et al. 2013</b> [170] Dalgacık özel. (stokastik komşu gömülmesi ile azaltılmış) ve <i>KNN Classifier</i> <i>SVM Classifier</i>	MIAS (12 iyi huylu, 13 kötü huylu kitle)	97.3 100	89.47 84.21	- -
<b>Önerilen Algoritma</b>	<b>MIAS</b> (29 iyi huylu, 20 kötü huylu kitle)	<b>89.7</b>	<b>100</b>	<b>0.95</b>

Tablo 3.6’da görüldüğü gibi önerilen algoritmada kitle tespiti sonucunda 49 kitle tespit edilebildiğinden 29 iyi huylu ve 20 kötü huylu olmak üzere 49 kitle kullanılmıştır. Tabloya bakıldığında genelde kötü huylu kitle tespit başarısının daha düşük olduğunu söyleyebiliriz, önerilen algoritma sonucunda ise kötü huylu kitlelerin %100 doğru sınıflandığı görülmektedir. Sonuç olarak, kitle bölgelerinin iyi huylu/kötü huylu sınıflamasının çalışılan veritabanında oldukça tatmin edici sonuçlar verdiğini söyleyebiliriz.


### 3.3. Mikrokalsifikasyon Tespiti Sonuçları ve İstatistiksel Değerlendirme

Kullanılan veritabanında Tablo 2.2’de belirtildiği gibi 209 normal ve 28 mikrokalsifikasyon içeren toplam 23 MC görüntüsü vardır. Mikrokalsifikasyonların tespiti için geliştirilen algoritmaya ait performans sonuçları aşama aşama aşağıdaki tabloda verilmiştir.

Tablo 3.7. MCs tespiti sonuçları

Görüntü Sayısı	Normal		MCs	
	209		23(28 MCs bölgesi)	
Bulunan Şüpheli MCs Bölgeleri (ROIs)	TP	FP	TN	FN
	28	15715	-	0
ANN ile Sınıflama	24	1107	14608	4
CCNN ile FP İndirgeme	24	270	15445	4

Buna göre, bu değerler kullanılarak doğru tespit edilen hasta bölgelerin oranı yani duyarlılığı ve yanlış pozitif oranı hesaplanarak istatistiksel değerlendirme sonuçları aşağıdaki grafikte verilmiştir.




Şekil 3.5. MCs tespiti aşamalarına ait istatistiksel değerlendirme sonuçları


Şekil 3.5'e bakıldığında MCs tespiti için önerilen algoritmanın aşamalarında duyarlılığın aynı kaldığı ve bununla birlikte FP oranının iyileştirildiği görülmektedir. Bu da sistemin özgülüğü arttırmaktadır. MCs tespiti için önerilen algoritmaya ait duyarlılık, özgülük ve FPpI değerleri ve ROC, FROC grafikleri aşağıdaki gibidir.

Tablo 3.8. MCs tespiti için önerilen algoritmaya ait performans sonuçları

ROI Sayısı	Normal		MCs
	15715		28
MCs Tespiti için Önerilen Algoritma	<b>Duyarlılık</b>	<b>Özgüllük</b>	<b>FPpI</b>
	% 86	% 98.3	1.163



Şekil 3.6. MCs tespiti için önerilen algoritmaya ait ROC eğrisi ve AUC



Şekil 3.7. MCs tespiti için önerilen algoritmaya ait FROC eğrisi

Şekil 3.7'de belli bir görüntü sayısına kadar normal görüntü olduğu yani mikrokalsifikasyon içermediği için duyarlılık sıfırdır ve daha sonra MC içeren görüntülere geçildiğinden duyarlılık değer kazanmaya başlamıştır. Sonuç olarak MCs tespiti için geliştirilen algoritma ile oldukça tatmin edici duyarlılık, özgüllük ve FPpI değerleri elde edilmiştir. Yapılan tez çalışmasında MCs tespiti için önerilen algoritmanın literatürdeki



benzer çalışmalarla [65, 104, 107, 108, 171, 172] karşılaştırılma sonuçları aşağıdaki tabloda verilmiştir.

Tablo 3.9. MCs tespiti literatür benzer çalışmalar karşılaştırma sonuçları

<i>Yöntemler</i>	<i>Veritabanı</i>	<i>Duyarlılık (%)</i>	<i>Özgüllük (%)</i>	<i>Doğruluk (%)</i>	<i>Az</i>	<i>FPpI</i>
<b>Anuradha, et al. 2013</b>						
[104]	MIAS					
Dalgacık dönüşümü özel. ve SVM	(23 MC -26 normal görüntü)	75.6	81.25	79.58	-	-
ANN		98.08	100	99.04		
<b>Jelvehfard, et al. 2013</b>						
[107]	MIAS					
Dalgacık dönüşümü özel. ve SVM	(23 MC -26 normal görüntü)	88.11	92	-	-	-
<b>Halkiotis, et al. 2007</b>						
[108]	MIAS					
Matematiksel morfoloji tabanlı özel. ve YSA	(23 MC -30 normal görüntü)	94.70	-	-	-	0.27
<b>Vivona, et al. 2014</b>						
[171]	MIAS					
Şekil ve parlaklık özel. ve Bulanık kümeleme	(20 MC görüntü)	82	-	94	-	4
<b>Mohanalin, et al. 2010</b>						
[65]	MIAS					
Tsalis entropi ile bulanık tabanlı iyileştirme ve iteratif eşikleme	(23 MC -18 normal görüntü)	93.75	-	-	-	0.52
<b>Diaz-Huerta, et al. 2014</b>						
[172]	MIAS					
Uzaysal, doku ve spektral özel. ve SVM	(22 MC içeren görüntü)	86.6	84.36	-	-	0.59
<b>Önerilen Algoritma</b>	<b>MIAS</b> <b>(23 MC -209 normal görüntü)</b>	<b>86</b>	<b>98.3</b>	<b>98.25</b>	<b>0.92</b>	<b>1.163</b>

Tablo 3.9. sonuçlarına bakıldığında önerilen algoritmada kullanılan veritabanının en fazla görüntü sayısına ve en yüksek özgüllük değerlerinden birine sahip olduğu görülmektedir. Bu da oldukça önemlidir çünkü düşük özgüllük değeri hasta olmadığı halde hasta olarak tespit edilen FP değerinin yüksek olması anlamına gelmektedir. Yapılan çalışmada kullanılan görüntü sayısı benzer çalışmalardakine göre çok daha fazla olduğundan FPpI oranı daha yüksek çıkmıştır. Ancak kullanılan görüntü sayısına göre elde edilen özgüllük, duyarlılık ve FPpI değerlerinin oldukça başarılı olduğu söylenebilir.

#### 3.4. Mikrokalsifikasyon İyi Huylu/Kötü Huylu Değerlendirme Sonuçları ve İstatistiksel Değerlendirme

Kullanılan veritabanında 13 iyi huylu ve 15 kötü huylu olmak üzere 28 mikrokalsifikasyon bölgesi bulunmaktadır. 28 MC bölgesinin 24'ü tespit edildiğinden bu

bölgelerin iyi huylu/kötü huylu değerlendirilmesi gerçekleştirilmiştir. Kaçırılan 4 MCs bölgesi de iyi huyludur. Buna göre önerilen algoritmanın performans sonucu aşağıdaki gibidir.

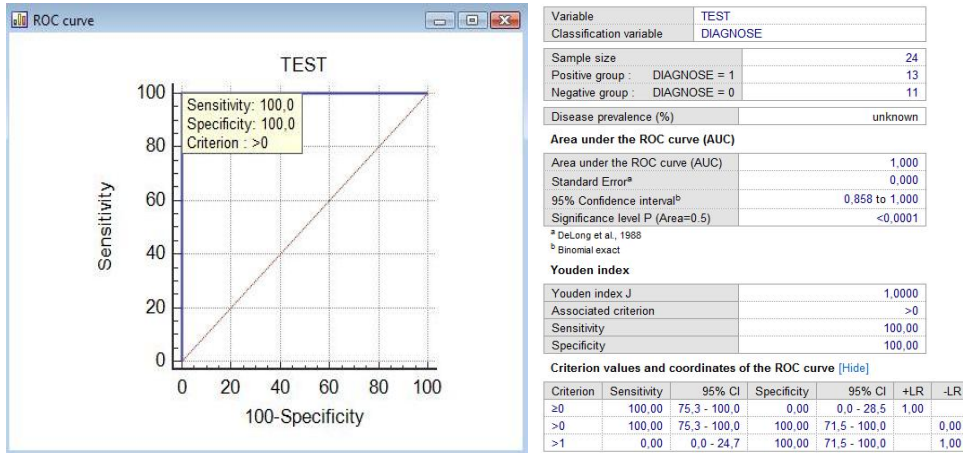
Tablo 3.10. MCs iyi huylu/kötü huylu değerlendirme algoritmasına ait sonuçlar

	Tespit Edilen MCs Bölgesi	MCs İyi Huylu/Kötü Huylu Değerlendirme Algoritması Sonucu	Doğru Sınıflama
<b>İyi Huylu</b>	11	11	% 100
<b>Kötü Huylu</b>	13	13	% 100
<b>Toplam</b>	24	24	% 100

Tablo 3.10’da görüldüğü gibi tespit edilen 24 MC bölgesinin hepsi doğru sınıflanmıştır. Mikrokalsifikasyon görüntüleri üzerinden kanser tespiti değerlendirmesini ele alırsak kötü huylu MCs kanser, iyi huylu MCs kanser değil olarak ifade edilebilir. Buna göre, MCs bölgeleri üzerinden kanser tespiti istatistiksel değerlendirme sonuçları aşağıdaki gibidir.

Tablo 3.11. MCs bölgeleri üzerinden kanser tespiti performans sonuçları

MCs Bölgeleri Üzerinden Kanser Tespit Başarısı	TP	FP	TN	FN
	13	0	11	0
	Duyarlılık		Özgüllük	
	% 100		% 100	



Şekil 3.8. MCs kanser tespitine ait ROC eğrisi ve AUC

Yapılan çalışmada MCs iyi huylu/kötü huylu sınıflaması için önerilen algoritmanın literatürdeki benzer çalışmalarla [104, 173-176] karşılaştırılmasına ilişkin tablo aşağıda verilmiştir.


Tablo 3.11. MCs iyi huylu/kötü huylu sınıflama literatür benzer çalışmalar karşılaştırma sonuçları

<i>Yöntemler</i>	<i>Veritabanı</i>	<i>İyi Huylu MC Doğru Sınıflama (%)</i>	<i>Kötü Huylu MC Doğru Sınıflama (%)</i>	<i>Az</i>
<b>Anuradha, et al. 2013</b> [104] Dalgacık dönüşümü özel. ve SVM ANN	MIAS (15 iyi huylu, 11 kötü huylu MC)	76.67 96.66	65.16 95.45	-
<b>Lee, et al. 2004</b> [173] İstatistiksel özel. ve Bulanık tabanlı genetik algoritma	MIAS (13 iyi huylu, 12 kötü huylu MC)	77	100	0.95
<b>Strange, et al. 2014</b> [174] Sürekli mereotopoloji ile modelleme	MIAS (11 iyi huylu, 9 kötü huylu MC)	100	90	0.79
<b>Jasmine, et al. 2013</b> [175] Contourlet dönüşüm özel. ve SVM	MIAS (12 iyi huylu, 13 kötü huylu MC)	91.67	100	-
<b>Rajesh, et al. 2014</b> [176] Dalgacık atom dönüşümü özel. ve SVM	MIAS (12 iyi huylu, 13 kötü huylu MC)	100	100	1
<b>Önerilen Algoritma</b>	<b>MIAS</b> <b>(11 iyi huylu, 13 kötü huylu MC)</b>	<b>100</b>	<b>100</b>	<b>1</b>

Tablo 3.11’de görüldüğü gibi önerilen algoritmada MCs tespiti sonucunda 24 MCs tespit edilebildiğinden 11 iyi huylu ve 13 kötü huylu olmak üzere 24 MCs kullanılmıştır. Tabloya bakıldığında, önerilen algoritma sonucunda iyi huylu ve kötü huylu mikrokalsifikasyonların %100 doğru sınıflandığı ve literatürdeki benzer çalışmalara göre başarısının daha yüksek olduğu görülmektedir.

### 3.5. Kitle Tespiti Algoritmasının MCs Görüntülerinde Test Sonuçları

Kitle tespiti için önerilen algoritma MCs içeren mamografi görüntüleri üzerinde de test edilmiştir. 23 MCs içeren görüntü için kitle tespiti algoritmasına ait sonuçlar aşağıdaki grafikte verilmiştir.




Şekil 3.9. MCs görüntülerinde kitle tespiti algoritması sonuçlarına ait grafik

Şekil 3.9'daki grafikte kitle tespiti sonucunda elde edilen FP sayısı çoğunlukla 0'dır, bunun dışında da 1 ya da 2 olduğu görülmektedir. Bununla birlikte görüntü başına düşen FP sayısı yani FpI değeri 0.57'dir. Bu da kitle tespiti algoritmasının oldukça başarılı olduğunu göstermektedir.

### 3.6. MCs Tespiti Algoritmasının Kitle Görüntülerinde Test Sonuçları

MCs tespiti için önerilen algoritma kitle içeren mamografi görüntüleri üzerinde de test edilmiştir. 55 kitle içeren görüntü için MCs tespiti algoritmasına ait sonuçlar aşağıdaki grafikte verilmiştir.



Şekil 3.10. Kitle görüntülerinde MCs tespiti algoritması sonuçlarına ait grafik

Şekil 3.10'daki grafikte 55 kitle görüntüsünün MCS tespiti algoritması sonucu bulunan FP bölgelerin sayıları görülmektedir. Buna göre, sadece bir görüntü için FP değeri en yüksek 8 olarak görülmektedir ve bunun dışında çok daha düşüktür. Bununla birlikte

görüntü başına düşen FP sayısı yani FPPI değeri 1.44'dür. Bu oranın da kitle görüntülerinde MCs tespiti algoritması sonuçları için oldukça başarılı olduğu söylenebilir.

### 3.7. Önerilen Algoritmaların Koşma Sürelerine İlişkin Değerlendirme

Bu bölümde son olarak kitle ve mikrokalsifikasyonların tespiti ve iyi huylu/kötü huylu değerlendirilmesi için önerilen iki algoritmaya ilişkin koşma süreleri aşağıdaki tablolarda verilmiştir. Bununla birlikte, çalışmada kullanılan bilgisayar i7-2760QM CPU @ 2.40 GHz ve 4.00 GB RAM özelliklerine sahiptir.

Tablo 3.12. Kitle tespiti ve iyi huylu/kötü huylu değerlendirme algoritmasına ait koşma süreleri

Görüntü	Kitle tespiti ve iyi huylu/kötü huylu değerlendirme algoritması koşma süresi (dk)
1	1.13
2	1.07
3	1.19
4	1.11
5	1.32
6	1.24
7	1.35
8	1.28
9	1.19
10	0.51
11	1.24
12	1.48
<b>Ortalama</b>	<b>1.18</b>

Tablo 3.12'de kitle tespiti ve kanser olasılığı değerlendirme algoritmasına ilişkin 12 görüntüye ait koşma süreleri ve bunların ortalaması verilmiştir. Buna göre yaklaşık 1.2 dk olduğu görülmektedir. Bu da yapılan işlemler göz önüne alındığında oldukça makul bir süredir.

Tablo 3.13. Mcs tespiti ve iyi huylu/kötü huylu değerlendirme algoritmasına ait koşma süreleri

Görüntü	MCs tespiti ve iyi huylu/kötü huylu değerlendirme algoritması koşma süresi (dk)
1	0.55
2	1.19
3	1.15
4	0.53
5	1.13
6	0.59
7	1.11
8	1.20
9	1.16
10	1.21
11	1.13
12	1.26
<b>Ortalama</b>	<b>1.02</b>

Tablo 3.13’de MCs tespiti ve kanser olasılığı değerlendirme algoritmasına ilişkin 12 görüntüye ait koşma süreleri ve bunların ortalaması verilmiştir. Buna göre yaklaşık 1 dk olduğu görülmektedir. Bu değerın yapılan işlemler için oldukça makul olduğu söylenebilir.

#### 4. SONUÇLAR

Meme kanseri, meme hücrelerinde gelişen kötü huylu tümör anlamına gelir. Akciğer kanserinden sonra, dünyada görülme sıklığı en yüksek olan kanser türüdür. Her 8 kadından birinin hayatının belirli bir zamanında meme kanserine yakalanacağı bildirilmektedir. Erkeklerde de görülmekle beraber, kadın vakaları erkek vakalarından 100 kat fazladır. Meme kanserine karşı en iyi koruyucu yöntem erken teşhistir. Bu sebeple, erken teşhisi arttıracak çeşitli yöntemler geliştirilmektedir. Bilgisayar destekli tespit ve tanı, tıbbi görüntülerin yorumlanmasında doktorlara yardımcı olarak kullanılan sistemlerdir. Dijital radyolojik görüntülerde (mamografi, MRI, ultrason vb.), matematiksel ve istatistiksel analiz yöntemlerini kullanarak radyolog için aşikar olmayan alanları (hedef tanıları veya patolojileri) belirler. CAD, yardımcı bir tanı sistemidir, son karar radyoloğa aittir.

Son zamanlarda, CAD sistemleri Amerika Birleşik Devletlerinde tarama merkezleri ve hastanelerde mamogramlar üzerinden meme kanseri tespiti için yapılan rutin klinik çalışmalarının bir parçası haline gelmiştir. Bu da CAD sistemlerinin farklı görüntüleme yöntemlerinden elde edilmiş medikal görüntülerdeki birçok farklı anormalliklerin tespit ve teşhisinde yaygın olarak uygulanmaya başlanacağını göstermektedir [8]. Bunların sonucunda, yapılan tez çalışmasında meme kanseri karar destek sistemi geliştirilmiştir. Çalışmada meme kanserindeki en önemli iki anormallik olan kitle ve mikrokalsifikasyonlar ele alınmıştır. Geliştirilen MKKDS kitle ve mikrokalsifikasyonların tespitini ve bunların iyi huylu/kötü huylu değerlendirmesini içeren oldukça geniş ve kompleks bir sistemdir. Sistem her iki anormallik için de görüntü iyileştirme, bölütleme, özellik çıkarma, sınıflama, FP indirgeme gibi birçok aşamayı kapsamaktadır. Geliştirilen MKKDS'ne ilişkin sonuçlar kısaca aşağıdaki şekilde özetlenebilir.

##### Meme Bölgesinin Bölütlenmesi:

- Bu aşama her iki anormalliğin tespitinden önce gerçekleştirilen ortak bir işlemdir. Burada meme bölgesi dışındaki etiket, gürültü vb. kısımların elemine edilerek hedef bölgenin bölütlenmesi gerçekleştirilmiştir.

Meme sınırı da kaba bir biçimde elde edilmiştir. Ayrıca çalışmada, pektoral kas çıkarma işlemi de gerçekleştirilmiştir. Fakat bu kısma çok yakın hatta yapışık bir biçimde kitle olabileceğinden, anormalliklerin tespiti aşamasında bu alandaki şüpheli bölgeler elendiğinden bölgenin irdelenmesine gerek kalmamıştır.

#### Kitle Tespiti:

- Kitle görüntülerinin iyileştirilmesi için farklı yöntemlerin hibrid kullanılmasıyla özgün bir ToWaCAD algoritması geliştirilmiştir. Geliştirilen ToWaCAD algoritması ile farklı medikal görüntüler üzerinde de oldukça iyi sonuçlar elde edilmiştir.
- Şüpheli kitle bölgelerinin belirlenmesi için önerilen algoritmada Havrda&Charvat entropisine dayalı bölütlemede  $\alpha$  parametresinin dinamik hesaplanması için formül (2.1) geliştirilmiştir. Böylece her görüntü için dinamik bir  $\alpha$  parametresi üretilmesi sağlanmıştır [161]. Ayrıca etkili bir yöntem olan Otsu N eşikleme kullanılarak şüpheli bölgeler başarılı bir şekilde belirlenmiştir.
- Şüpheli bölgeler içerisinde kitle bölgelerinin tespitinde GLCM özellikleri iki aşamalı YSA modelinde kullanılarak özgün bir algoritma ile sınıflama işlemi gerçekleştirilmiştir. Ardından FP bölgelerin indirgenmesi için olasılıklı sinir ağı kullanılmıştır. Ayrıca iyi huylu/kötü huylu sınıflaması aşamasında tekrar FP indirgeme yapılmıştır. Önerilen kitle tespiti yaklaşımına göre elde edilen sonuçlar, literatürdeki benzer çalışmalara [54, 73, 163-167] kıyasla 55 kitle (58 kitle içeren), 209 normal olmak üzere toplam 264 görüntü ile oldukça yüksek test görüntü sayısına sahiptir. Buna göre, %84.5 duyarlılık, %99.5 özgüllük değerlerine sahiptir ve benzer çalışmalara kıyasla en düşük 0.254 FpI (görüntü başına düşen FP bölge sayısı) değeri ile en yüksek Az=0.92 ve doğruluk=%99.4 değerleri elde edilmiştir.

#### Kitle İyi huylu/Kötü huylu Değerlendirmesi:

- Tespit edilen kitle bölgelerinin iyi huylu/kötü huylu olasılıklarının belirlenmesinde dalgacık dönüşümü katsayıları enerji ve doku özellikleri kullanılarak K-ortalama ve SDT yöntemleri ile sınıflama işlemi yapılmıştır.



Bunun sonucunda 29 iyi huylu ve 20 kötü huylu olmak üzere tespit edilen 49 kitleden 46'sı (26 iyi huylu ve 20 kötü huylu) doğru sınıflanmıştır. İyi huylu ve kötü huylu kitlelerin doğru sınıflanma duyarlılıkları sırasıyla %89.7 ve %100 olarak elde edilmiştir. Literatürdeki benzer çalışmalarla [4, 86, 119, 168, 169] kıyaslandığında performansın değerlendirildiği görüntü sayısı hemen hemen aynı olmakla birlikte kötü huylu kitlelerin doğru sınıflanmasında %100 başarı ile en yüksek duyarlılığa ve en yüksek  $Az=0.95$  değerine sahiptir.

#### Mikrokalsifikasyonların (MCs) Tespiti:

- Mikrokalsifikasyonlar, çok küçük, gürültüye benzer yapıda olduklarından görünürlüklerinin bozulmaması için MC görüntülerinin iyileştirilmesinde top-hat dönüşümü kullanılmıştır. Böylece kontrast artırılarak gürültü azaltılır.
- Şüpheli MCs bölgelerinin belirlenmesinde Otsu N eşikleme ile bağlı bileşen etiketleme yöntemleri kullanılmıştır.
- Şüpheli bölgeler içerisinde MC bölgelerinin tespiti için GLCM özellikleri ile istatistiksel özellikler kullanılarak YSA modeli ile sınıflama işlemi gerçekleştirilmiştir. Ardından FP indirgeme için kademeli korelasyon ağı kullanılmıştır. Geliştirilen MCs tespiti sistemi literatürdeki benzer çalışmalara [65, 104, 107, 108, 170, 171] kıyasla 23 mikrokalsifikasyon (28 MCs içeren), 209 normal olmak üzere toplam 232 görüntü ile benzer çalışmalara göre oldukça yüksek test görüntü sayısına sahiptir. Buna göre, %86 duyarlılık, %98.3 özgüllük değerleri elde edilmiştir. Benzer çalışmalara kıyasla %98.25 ile en yüksek doğruluk değerlerinden birine sahiptir.

#### Mikrokalsifikasyonların İyi huylu/Kötü huylu Değerlendirmesi:

- Bu kısımda, tespit edilen MCs bölgelerinin iyi huylu/kötü huylu olasılıkları belirlenmektedir. Doku, istatistiksel, GLRL matrisi özellikleri kullanılarak SVM ve LDA yöntemleri yardımıyla sınıflama işlemi gerçekleştirilmiştir. Bunun sonucunda 11 iyi huylu ve 13 kötü huylu olmak üzere tespit edilen 24 mikrokalsifikasyon bölgesinin hepsi doğru sınıflanmıştır. Buna göre, iyi huylu ve kötü huylu kitlelerin doğru sınıflanma duyarlılıkları sırasıyla %100 ve %100 olarak elde edilmiştir. Literatürdeki benzer çalışmalarla [104, 172-

175] kıyaslandığında performansın değerlendirildiği görüntü sayısı hemen hemen aynı olmakla birlikte iyi huylu ve kötü huylu mikrokalsifikasyonların sınıflanmasında en yüksek duyarlılıklara sahip çalışmalardan biridir.

Sonuç olarak yapılan tez çalışmasında, farklı yöntemlerin birlikte kullanımını gerçekleyen özgün algoritmalar geliştirilerek komplike bir meme kanseri karar destek sistemi gerçekleştirilmiştir. Ayrıca, Havrda&Charvat entropi tabanlı eşikleme yöntemi için dinamik bir alfa değeri üreten formül geliştirilmiştir [161]. Benzer çalışmalar, sistemde yer alan aşamalara ilişkin parçalar şeklindedir. Geliştirilen sistem oldukça kapsamlı olduğundan literatürde bu şekilde bütün bir çalışmaya rastlanmamıştır. Ancak yurt dışında Siemens, R2 Technologies gibi firmalar tarafından ticari olarak benzer sistemler geliştirilmektedir. Kitle tespiti, iyi huylu/kötü huylu değerlendirmesi ve MCs tespiti, iyi huylu/kötü huylu değerlendirmesi sistemlerine ait ortalama koşma süreleri sırasıyla 1.18 ve 1.02'dir. Çalışmada önerilen yaklaşımlar Microsoft Visual C# ortamında geliştirilmiştir.

## 5. ÖNERİLER

Mamografi göğsü incelemek için düşük doz X-ışını sistemi kullanan özel bir görüntüleme türüdür ve kliniksel olarak aşikar olmadan önce meme kanserinin tespitinde şu anda en etkili yöntemdir. Meme kanserine karşı en iyi koruyucu yöntem erken teşhistir. Bu sebeple, erken teşhisi arttıracak çeşitli yöntemler geliştirilmektedir. Tıbbi görüntülerin yorumlanmasına ilişkin bilgisayarlı tespit ve teşhis sistemleri, doktorlara yardımcı olarak kullanılan akıllı sistemlerdir. Dijital radyolojik görüntülerde (mamografi, MRI, ultrason vb.), matematiksel ve istatistiksel analiz yöntemlerini kullanarak radyolog için aşikar olmayan alanları (hedef tanıları veya patolojileri) belirler ve karar verebilir. Böylece gözden kaçan ya da görünmeyen kanser olabilecek meme anormalliklerinin tespiti ile erken teşhis sağlanarak hastaların hayatta kalma oranı arttırılabilir.

Geliştirilen MKKD sistemi, meme kanserine işaret eden en önemli iki anormallik olan kitle ve mikrokalsifikasyonları ele almıştır, bunların dışında mimari bozukluk ve çift yönlü asimetri anormallikleri için de genişletilebilir. Ayrıca, geliştirilen sistem temel alınarak hastanın öyküsü (anamnez), yaşı, yaşam tarzı ve coğrafi konumu dikkate alınarak bir uzman sistem geliştirilebilir. Çalışma sırasında, dijital mamografi görüntüleri bulunmadığından benzeri çalışmalarda kabul gören MIAS uluslararası veritabanı zorunlu olarak kullanılmıştır. Bu nedenle, ulusal bir dijital mamografi veritabanı oluşturulabilir. Bununla birlikte, benzer şekilde akciğer, kolon, beyin, karaciğer kanserleri için de bilgisayar destekli tespit ve tanı sistemleri de geliştirilebilir.

## 6. KAYNAKLAR

1. The Patient Education Institute, Breast Cancer (1995-2013), NIH MedlinePlus, Yayın No:9, 2, USA, 2014.
2. Stewart, B. W. ve Wild, C. P., World Cancer Report 2014. World Health Organization Press, İsviçre, 2014.
3. Cheng, H. D., Shi, X. J., Min, R., Hu, L. M., Cai, X. P. ve Du, H. N., Approaches for Automated Detection and Classification of Masses in Mammograms, Pattern Recognition, 39 (2006) 646 – 668.
4. Mudigonda, N. R., Rangayyan, R. M. ve Desautels, J. E. 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.
5. Karssemeijer, N., Otten, J. D., Verbeek, A. L., Groenewoud, J. H., De Koning, H. J., Hendriks, J. H. ve Holland, R., Computer-Aided Detection versus Independent Double Reading of Masses on Mammograms, Radiology, 227,1 (2003) 192-200.
6. Sankar, D. Ve Thomas, T., Breast Cancer Detection Using Entropy based Fractal Modeling of Mammograms, International Journal of Recent Trends in Engineering, 1,3 (2009) 171-175.
7. Cheng, H. D., Cai, X., Chen, X., Hu, L. ve Lou, X., Computer-Aided Detection and Classification of Microcalcifications in Mammograms: A Survey, Pattern Recognition, 36 (2003) 2967 – 2991.
8. Doi, K., Computer-Aided Dagnosis in Medical Imaging: Historical Review, Current Status and Future Potential, Computerized Medical Imaging and Graphics, 31 (2007) 198–211.
9. Kuş, P. ve Karagöz, İ., Mamogramlarda Piksel Yoğunluğu Tabanlı Meme Bölgesi Bölütleme, IEEE 17. Sinyal İşleme ve İletişim Uygulamaları, Nisan 2009, Antalya, Bildiriler Kitabı, 916-919.
10. Kallergi, M., Woods, K., Clarke, L. P., Qian,W. ve Clark, R. A., Image Segmentation in Digital Mammography. Comparison of Local Thresholding and Region Growing Algorithms, Computerized Medical Imaging and Graphics, 16 (1992) 323–331.
11. Yin, F. F., Giger, M. L., Doi, K. C., Vyborny, J. ve Schmidt, R. A., Computerized Detection of Masses in Digital Mammograms: Automated Alignment of Breast Images and its Effect on Bilateral-Subtraction Technique, Medical Physics, 21 (1994) 445–452.

12. Bick, U. ve Giger, M., Automated Segmentation of Digitized Mammograms, Academic Radiology, 2 (1995) 1–9.
13. Masek, M. ve Attikiouzel, Y., Skin-Air Interface Extraction from Mammograms Using An Automatic Local Thresholding Algorithm, The 15th Biennial International Conference Biosignal, Haziran 2000, Çek Cumhuriyeti, Bildiriler Kitabı, 204–206.
14. Masek, M., Hierarchical Segmentation of Mammograms Based on Pixel Intensity, Doktora Tezi, Batı Avustralya Üniversitesi, Avustralya, 2003.
15. Shahedi, M., Amirfattahi, R., Torkamani Azar, F. ve Sadri, S., Accurate Breast Region Detection in Digital Mammograms Using a Local Adaptive Thresholding Method, 8th International Workshop on Image Analysis for Multimedia Interactive Services (WIAMIS'07), Haziran 2007, Yunanistan, Bildiriler Kitabı, 26-29.
16. Yapa, R. D. ve Harada, K., Breast Skin-Line Estimation and Breast Segmentation in Mammograms Using Fast-Marching Method, International Journal of Biological, Biomedical and Medical Sciences, 3,1 (2008) 54-62 .
17. Wirth, M., Nikitenko, D. ve Lyon, J., Segmentation of Breast Region in Mammograms Using A Rule-Based Fuzzy Reasoning Algorithm, ICGST-GVIP Journal, 5,2 (2005) 45-54.
18. Raba, D., Oliver, A., Mart'ı, J., Peracaula, M. ve Espunya, J., Breast Segmentation with Pectoral Muscle Suppression on Digital Mammograms, Lecture Notes in Computer Science, 3523 (2005) 471–478.
19. Shyr-Shen, Y., Chung-Yen, T. ve Chen-Chung, L., A Breast Region Extraction Scheme for Digital Mammograms Using Gradient Vector Flow Snake, 4th International Conference on New Trends in Information Science and Service Science, Mayıs 2010, Kore, Bildiriler Kitabı, 715-720.
20. Auckland Üniversitesi, Ders Notları, Image filtering, Yeni Zelanda, 2010.
21. Serra, J., Image Analysis and Mathematical Morphology, Academic Press, New York, 1982.
22. Karhan, M., Oktay, M. O., Karhan, Z. ve Demir, H., Morfolojik Görüntü İşleme Yöntemleri ile Kayıslarda Yaprak Delen (Çil) Hastalığı Sonucu Oluşan Lekelerin Tespiti, 6th International Advanced Technologies Symposium (IATS'11), Mayıs 2011, Elazığ, Bildiriler Kitabı, 172-176 .
23. Samet, H. ve Tamminen M., Efficient Component Labeling of Images of Arbitrary Dimension Represented by Linear Bintrees, IEEE Transactions on Pattern Analysis and Machine Intelligence, 10,4 (1988) 579-586.

24. Wirth, M. ve Lyon, J., The Effect of Mamogram Databases on Algorithm Performance, Proceedings of the 17th IEEE Symposium on Computer-Based Medical Systems (CBMS'04), Haziran 2004, USA, Bildiriler Kitabı, 15-20.
25. Malagelada, A. O., Automatic Mass Segmentation in Mammographic Images, Doktora Tezi, Girona Üniversitesi, İspanya, 2007.
26. Hong, B. ve Sohn, B., Segmentation of Regions of Interest in Mammograms in A Topographic Approach, IEEE Transactions on Information Technology in Biomedicine, 14,1 (2010) 129-139.
27. Deepa, S. ve Bharathi, S., Efficient ROI Segmentation of Digital Mammogram Images Using Otsu's N Thresholding Method, International Journal of Engineering Research & Technology, 2,1 (2013) 1-6.
28. Dabour, W., Improved Wavelet Based Thresholding for Contrast Enhancement of Digital Mammograms, International Conference on Computer Science and Software Engineering, Aralık 2008, Çin, Bildiriler Kitabı, 948-951.
29. Alhadidi, B., Zu'bi, M. H. ve Suleiman, H. N., Mammogram Breast Cancer Image Detection Using Image Processing Functions, Information Technology Journal, 6,2 (2007) 217-221.
30. Yan, Z., He X., Liu, S. ve Lu, D., An Approximation-Weighted Detail Contrast Enhancement Filter for Lesion Detection on Mammograms, Proc. 23rd Annual Conference, Ekim 2001, İstanbul, Bildiriler Kitabı, 2472-2475.
31. Lopez, Y., Novoa, A., Guevara, M. A., Quintana, N. ve Silva, A., Computer Aided Diagnosis System to Detect Breast Cancer Pathological Lesions, Lecture Notes in Computer Science, 5197 (2008) 453-460.
32. Mutihac, R., Bayesian Maximum Entropy Based Algorithm for Digital X-Ray Mammogram Processing, Algorithms Journal, 2 (2009) 850-878.
33. Bhateja, V. ve Devi, S., A Novel Framework for Edge Detection of Microcalcifications Using A Non-Linear Enhancement Operator and Morphological Filter, 3rd International Conference on Electronics Computer Technology, Nisan 2011, Hindistan, Bildiriler Kitabı, 419-429.
34. Mencattini, A., Salmeri, M., Lojacono, R., Frigerio, M. ve Caselli, F., Mammographic Images Enhancement and Denoising for Breast Cancer Detection Using Dyadic Wavelet Processing, IEEE Transactions On Instrumentation and Measurement, 57,7 (2008) 1422-1430.
35. Papadopoulou, A., Fotiadis, D. I. ve Costaridou, L., Improvement of Microcalcification Cluster Detection in Mammography Utilizing Image Enhancement Techniques. Computers in Biology and Medicine, 38 (2008) 1045 - 1055.

36. Meyer, F., Iterative Image Transformations for An Automatic Screening of Cervical Smears, Journal of Histochemistry and Cytochemistry, 27,1 (1979) 128-135.
37. Weaver, J. B., Yansun, X., Healy, D. M. ve Cromwell, L. D., Filtering Noise from Images with Wavelet Transforms, Magnetic Resonance in Medicine, 21,2 (1991) 288–295.
38. Gangal A., İşaret ve Görüntü İşlemede Dalgacık Tabanlı Yöntemler, Ders notları, Trabzon, 2008.
39. Jin, Y., Angelini, E. ve Laine, A., Wavelets in Medical Image Processing: Denoising, Segmentation, and Registration, Handbook of Biomedical Image Analysis, Springer, New York, 2005.
40. Yoon, H., Han, Y. ve Hahn, H., Image Contrast Enhancement Based Sub-Histogram Equalization Technique without Over-Equalization Noise, International Journal of Computer Science and Engineering, 3,2 (2009) 132-138.
41. Teo, C. K., Digital Enhancement of Night Vision and Thermal Images, Yüksek Lisans Tezi, Singapur Üniversitesi, Singapur, 2003.
42. Reza, M. A., Realization of The Contrast Limited Adaptive Histogram Equaliation (CLAHE) for Real-Time Image Enhancement, Journal of VLSI Signal Processing, 38 (2004) 35–44.
43. Weickert, J., Anisotropic Difusion in Image Processing, Teubner, Stuttgart, 1998.
44. Teeyapan, K., Image Smoothing Techniques.  
[http://users.ece.gatech.edu/~kteeyapan3/docs/pde\\_proj.pdf](http://users.ece.gatech.edu/~kteeyapan3/docs/pde_proj.pdf) , 14 Haziran 2014.
45. Panetta, K., Wharton, E. J. ve Aгаian, S. S., Human Visual System Based Image Enhancement and Logarithmic Contrast Measure, IEEE Tran. Systems, Man, and Cybernetics, Part B: Cybernetics, 38,1 (2008) 174-188.
46. Panetta, K., Wharton, E. ve Aгаian, S., Parameterization of Logarithmic Image Processing Models, IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans, 41,2 (2011) 460-473.
47. Sameti, M., Morgan-Parkes, J., Ward, R. K. ve Palcic, B., Classifying Image Features in The Last Screening Mammograms Prior to Detection of A Malignant Mass, Computational Imaging and Vision, 13 (1998) 127-134.
48. Gedik, N. ve Atasoy, A., A Computer-Aided Diagnosis System For Breast Cancer Detection By Using A Curvelet Transform. Turkish Journal of Electrical Engineering & Computer Sciences, 21 (2013) 1002 – 1014.

49. Gedik, N. ve Atasoy, A., Performance Evaluation of The Wave Atom Algorithm to Classify Mammographic Images, Turkish Journal of Electrical Engineering & Computer Sciences, 22 (2014) 957-969.
50. Mencattini, A., Salmeri, M., Rabottino, G. ve Salicone, S., Metrological Characterization of A CADx System for The Classification of Breast Masses in Mammograms, IEEE Transactions on Instrumentation and Measurement, 59,11 (2010) 2792-2799.
51. Elter, M. ve Held, C., Semiautomatic Segmentation for The Computer Aided Diagnosis Of Clustered Microcalcifications, Proceedings of SPIE Medical Imaging, 6915 (2008) 1-8.
52. Hadjiski, L., Filev, P., Chan, H., Ge, J., Sahiner, B., Helvie, M. A. ve Roubidoux, M. A., Computerized Detection and Classification of Malignant and Benign Microcalcifications on Full Field Digital Mammograms, Lecture Notes in Computer Science, 5116 (2008) 336–342.
53. Eddaoudi, F., Regragui, F, Mahmoudi, A. ve Lamouri, N., Masses Detection Using Svm Classifier Based on Textures Analysis, Applied Mathematical Sciences, 5,8 (2011) 367 -379.
54. Samma, H., Lim, C. P. ve Samma, A. A., Computer-Aided Detection System for Automatic Mammography Mass Identification, Lecture Notes in Computer Science, 6444 (2010) 226–233.
55. Samala, R. K., Efficient Suspicious Region Segmentation Algorithm for Computer Aided Diagnosis of Breast Cancer Based on Tomosynthesis Imaging, Yüksek Lisans Tezi, Güney Florida Üniversitesi, USA, 2006.
56. Eltoukhy, M. M., Faye, I. ve Samir, B. B., Automatic Detection of Breast Masses in Digital Mammograms Using Pattern Matching, IEEE EMBS Conference on Biomedical Engineering & Sciences (IECBES 2010), Kasım 2010, Malezya, Bildiriler Kitabı, 73 - 76.
57. Moayyedi, F., Boostani, R., Kazemi, A. ve Katebi, S. D., Subclass Fuzzy-SVM Classifier As An Efficient Method to Enhance The Mass Detection in Mammograms, Iranian Journal of Fuzzy Systems, 7,1 (2010) 15–31.
58. Pharwaha, A. P. S. ve Khehra, B. S., Shannon and Non-Shannon Measures of Entropy for Statistical Texture Feature Extraction in Digitized Mammograms, Lecture Notes in Engineering and Computer Science, 2179 (2009) 1-6.
59. Khehra, B. S. ve Pharwaha, A. P. S., Digital Mammogram Segmentation Using Non-Shannon Measures of Entropy, Proceedings of the World Congress on Engineering, Temmuz 2011, Londonra, Bildiriler Kitabı, 719-725.



60. Mohanalin, L., Kalra, P. K. ve Kumar, N., An Automatic Method To Enhance Microcalcifications Using Normalized Tsallis Entropy, Signal Processing, 90 (2010) 952-958.
61. Tsallis, C., Possible Generalization of Boltzmann-Gibbs Statistics, Journal of Statistical Physics, 52 (1998) 479-487.
62. Guan, Q., Zang, J., Chen, S. Ve Pokropek, A. T., Automatic Segmentation of Microcalcification Based on SIFT in Mammograms, International Conference on Biomedical Engineering and Informatics, Mayıs 2008, Sanya, Bildiriler Kitabı, 13-17.
63. Kumar, S. V., Lazarus, M. N. ve Nagaraju, C., A Novel Method for The Detection of Microcalcifications Based on Multi-Scale Morphological Gradient Watershed Segmentation Algorithm, International Journal of Engineering Science and Technology, 2 (2010) 2616-2622.
64. Balakumaran, T., Vennila, I. L. A. Ve Shankar, C. G., Detection of Microcalcification in Mammograms Using Wavelet Transform and Fuzzy Shell Clustering, International Journal of Computer Science and Information Security, 7 (2010) 121-125.
65. Mohanalin, J., Beenamol, M., Kalra, P. K. ve Kumar, N., A Novel Automatic Microcalcification Detection Technique Using Tsallis Entropy & Type II Fuzzy Index, Computers and Mathematics with Applications, 60 (2010) 2426-2432.
66. Pal, S. K., Shankar, U. ve Mitra, P., Granular Computing, Rough Entropy and Object Extraction, Pattern Recognition Letters, 26 (2005) 2509-2517.
67. Tsumoto, S., Slowinski, R., Komorowski, J. ve Gryzmala-Busse J. W., Rough Sets and Current Trends in Computing, Springer, Almanya, 2004.
68. 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.
69. Eltoukhy, M. M, Faye, I. ve Samir, B. B., A Statitcal Based Feature Extraction Method for Breast Cancer Diagnosis in Digital Mammogram Using Multi Resolution Representation, Computers in Biology and Medicine, 42 (2012) 123 - 128.
70. Llado, X., Oliver, A., Freixenet, J., Marti, R. ve Marti, J., A Textural Approach for Mass False Positive Reduction in Mammography, Computerized Medical Imaging and Graphics, 33 (2009) 415-422.
71. Meenalosini, S. ve Janet, J., Computer Aided Diagnosis of Malignancy in Mammograms, European Journal of Scientific Research, 72,3 (2012) 360-368.

72. Cheng, H. D. ve Cui, M., Mass Lesion Detection with A Fuzzy Neural Network, Pattern Recognition, 37 (2004) 1189 – 1200.
73. Nithya, R. ve Santhi, B., Classification of Normal and Abnormal Patterns in Digital Mammograms for Diagnosis of Breast Cancer, International Journal of Computer Applications 28,6 (2011) 21-25.
74. Meenalosini, S. ve Janet, J., Detection of Malignancy in Mammograms Using Region Growing and GLCM Features, International Conference on Computing and Control Engineering, Nisan 2012, Chennai, Bildiriler Kitabı, 1-7.
75. Mohanty, A. K., Swain, S. K., Champati, P. K. ve Lenka, S. K., Image Mining for Mammogram Classification by Association Rule Using Statistical and GLCM Features, International Journal of Computer Science, 8,3 (2011) 309-318.
76. Mohanty, A. K., Senapati, M. R. ve Lenka, S. K., A Novel Image Mining Technique for Classification of Mammograms Using Hybrid Feature Selection, Neural Computing & Applications, 22 (2013) 1151–1161.
77. Abdalla, M. M., Dress, S. ve Zaki, N., Detection of Masses in Digital Mammogram Using Second Order Statistics and Artificial Neural Network, International Journal of Computer Science & Information Technology, 3,3 (2011) 176-186.
78. Sampaio, W. B., Diniz, E. M., Silva, A. C., Paiva, A. C. ve Gattass, M., Detection of Masses in Mammogram Image Using CNN, Geostatistic Functions and SVM, Computers in Biology and Medicine, 41 (2011) 653-664.
79. Basheer, N. M. ve Mohammed, M. H., Segmentation of Breast Masses in Digital Mammograms Using Adaptive Median Filtering and Texture Analysis, International Journal of Recent Technology and Engineering, 2,1 (2013) 39-43.
80. Khuzi, M. A., Besar, R., Zaki, W. W. ve Ahmadi, N. N., Identification of Masses in Digital Mammogram Using Gray Level Co-Occurrence Matrices, Biomedical Imaging and Intervention Journal, 5,3 (2009) 1-13.
81. Nithya, R. ve Santhi, B., Mammogram classification Using Maximum Difference Feature Selection Method, Journal of Theoretical and Applied Information Technology, 33,2 (2011) 197-204.
82. Nithya, R. ve Santhi, B., Comparative Study on Feature Extraction Method for Breast Cancer Classification, Journal of Theoretical and Applied Information Technology, 33,2 (2011) 220-226.
83. Albregtsen, F., Statistical Texture Measures Computed from Gray Level Coocurrence Matrices.  
<http://www.uio.no/studier/emner/matnat/ifi/INF4300/h08/undervisningsmateriale/glcm.pdf> 7 Temmuz 2014

84. Haralick, R. M., Shanmugam, K. Ve Dinstein, I., Texture Feature for Image Classification, IEEE Transaction on System, Man and Cybernetics, 3,6 (1973) 610-621.
85. Wong, M. T., He, X., Nguyen, H. ve Yeh, W., Mass Classification in Digitized Mammograms Using Texture Features and Artificial Neural Network, Lecture Notes in Computer Science, 7667 (2012) 151-158.
86. Islam, M. J., Ahmadi, M. ve Sid-Ahmed, M. A., An Efficient Automatic Mass Classification Method In Digitized Mammograms Using Artificial Neural Network, International Journal of Artificial Intelligence & Applications, 1,3 (2010) 1-13.
87. Görgel, P., Sertbaş, A. ve Uçan, O. N., A Comparative Study of Breast Mass Classification Based on Spherical Wavelet Transform using ANN and KNN Classifiers, International Journal of Electronics, Mechanical and Mechatronics Engineering , 2,1 2011 79-85.
88. Apostolopoulos, G., Koutras, A., Christoyianni, I. ve Dermatas, E., Computer Aided Classification of Mammographic Tissue Using Shapelets and Support Vector Machines, Lecture Notes in Computer Science, 8445 (2014) 510-520.
89. Kulkarni, S. R. ve Harman, G., Statistical Learning Theory: A Tutorial.  
<http://www.princeton.edu/~harman/Papers/SLT-tutorial.pdf> 16 Temmuz 2014
90. Burgers, C. J. C., A tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery, 2,2 (1998) 121-167.
91. Kurt, B., Bilgisayar ile Psikolojik Durum Değerlendirilmesi, Yüksek Lisans Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon, 2007.
92. Dennis, J. E. ve Schnabel, R. B., Numerical Methods for Unconstrained Optimization and Nonlinear Equations, Society for Industrial and Applied Mathematics, Philadelphia, 1996.
93. Nocedal, G. ve Wright, S., Numerical Optimization, Second Edition, Springer, USA, 2006.
94. Gougam, L. A., Taibi, H., Chikhi, A. ve Mekideche-Chaf, F., Efficient Second Order Algorithms for Function Approximation with Neural Networks, Application to sextic potentials, Proceedings of the 7th Conference on Nuclear and Particle Physics, Kasım 2009, Sharm El-Sheikh, Bildiriler Kitabı, 335-342.
95. Specht, D. F., Probabilistic Neural Networks, Neural Networks, 3 (1990) 109–118.
96. Pan, G., Yan, G., Qiu, X. Ve Cui, J., Bleeding Detection in Wireless Capsule Endoscopy Based on Probabilistic Neural Network, Journal of Medical Systems, 35 (2011) 35 1477–1484.

97. Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y. X., Chang, Y. F. ve Xiang, Q. L., A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network, IEEE International Symposium on Signal Processing and Information Technology, Temmuz 2007, yer, Bildiriler Kitabı, 1-6.
98. Othman, M. F. ve Basri, M. A. M., Probabilistic Neural Network for Brain Tumor Classification, 2nd International Conference on Intelligent Systems, Modelling and Simulation, Phnom Penh 2011, yer, Bildiriler Kitabı, 136-138.
99. Muniz, A. M. S., Liu, H., Lyons, K. E., Pahwac, R., Liu, W., Nobre, F. F. ve Nadal, J., Comparison Among Probabilistic Neural Network, Support Vector Machine and Logistic Regression for Evaluating The Effect of Subthalamic Stimulation in Parkinson Disease on Ground Reaction Force During Gait, Journal of Biomechanics, 43 (2010) 720–726.
100. Sankaria, Z. ve Adelib, H., Probabilistic Neural Networks for Diagnosis of Alzheimer's Disease Using Conventional and Wavelet Coherence, Journal of Neuroscience Methods, 197 (2011) 165–170.
101. Kıyan, T. ve Yıldırım, T., Breast Cancer Diagnosis Using Statistical Neural Networks, Journal of Electrical & Electronics Engineering, 4,2 (2004) 1149-1153.
102. Bird, R. G., Wallace, T. W. ve Yankaskas, B. C., Analysis of Cancers Missed at Screening Mammography, Radiology, 184 (1992) 613-617.
103. Martins, L. O., Santos, A. M., Silva, A. C. ve Paiva, A. C., Classification of Normal, Benign and Malignant Tissues Using Co-occurrence Matrix and Bayesian Neural Network in Mammographic Images, Proceedings of the 9th Brazilian Symposium on Neural Networks, Ekim 2006, Ribeirao Preto, Bildiriler Kitabı, 24-29.
104. Phadke, A. C. ve Rege, P. P., Detection and Classification of Microcalcifications Using Discrete Wavelet Transform, International Journal of Emerging Trends & Technology in Computer Science, 2,4 (2013) 130-134.
105. Sabu, A. M., Ponraj, D. N. ve Poongodi, R., Textural Features Based Breast Cancer Detection: A Survey, Journal of Emerging Trends in Computing and Information Sciences, 3,9 (2012) 1329-1334.
106. Herwanto, D. ve Arymurthy, A. M., Association Technique Based on Classification for Classifying Microcalcification and Mass in Mammogram, International Journal of Computer Science, 10,2 (2013) 252-259.
107. Jelvehfard, E., Faez, K. ve Laluie, A., Microcalcification Detection in Mammography Images Using 2D Wavelet Coefficients Histogram, Computer Science and Information Technology, 1,3 (2013) 178-184.

108. Halkiotis, S., Botsis, T. ve Rangoussi, M., Automatic Detection of Clustered Microcalcifications in Digital Mammograms Using Mathematical Morphology and Neural Networks, Signal Processing, 87 (2007) 1559–1568.
109. Jasmine, J. S. L., Govardhan, A. ve Baskaran, S., Microcalcification Detection in Digital Mammograms Based on Wavelet Analysis and Neural Networks, International Conference on Control, Automation, Communication and Energy Conservation, Haziran 2009, Perundurai, Bildiriler Kitabı, 1-6.
110. Pal, N. R., Bhowmick, B., Patel, S. K., Pal, S. ve Das, J., A Multi-Stage Neural Network Aided System for Detection of Microcalcifications in Digitized Mammograms, Neurocomputing, 71 (2008) 2625–2634.
111. Press, W. H., Teukolsky, S. A., Vetterling, W. T. ve Flannery, B. P., Numerical Recipes In C: The Art Of Scientific Computing, Cambridge University Press, New York, 1992.
112. Fahlman, S. E. ve Lebiere, C., The Cascade-Correlation Learning Architecture, Advances in Neural Information Processing Systems 2, Morgan Kaufmann, San Francisco, 1990.
113. Sharma, N. ve Om, H., Cascade Correlation Neural Network Model for Classification of Oral Cancer, Wseas Transactions on Biology And Biomedicine, 11 (2014) 45-51.
114. Gao, X. Z., Wang, X. ve Ovaska, S. J., Fusion of Clonal Selection Algorithm and Differential Evolution Method in Training Cascade–Correlation Neural Network, Neurocomputing 72 (2009) 2483–2490.
115. Kovalishyn, V. V., Tetko, I. V., Luik, A. I., Kholodovych, V. V., Villa, A. E. P. ve Livingstone, D. J., Neural Network Studies. 3. Variable Selection in the Cascade-Correlation Learning Architecture, Journal of Chemical Information and Computer Sciences, 38 (1998) 651-659.
116. Chandra, B. ve Varghese, P. P., Applications of Cascade Correlation Neural Networks for Cipher System Identification, International Journal of Computer, Information, Systems and Control Engineering, 1,2 (2007) 343-346.
117. <http://www.mammoimage.org/signs-of-disease/> Mammographic Image Analysis Homepage, Sign of Disease. 18 Haziran 2014.
118. Eltoukhy, M. M., Faye, I. ve Samir, B. B., A Comparison of Wavelet and Curvelet for Breast Cancer Diagnosis in Digital Mammogram, Computers in Biology and Medicine, 40 (2010) 384–391.
119. Jasmine, J. S. L., Baskaran, S. ve Govardhan, A., An Automated Mass Classification System in Digital Mammograms using Contourlet Transform and Support Vector Machine, International Journal of Computer Applications, 31,9 (2011) 54-61.

120. Hussain, M., Khan, S., Muhammad, G., Ahmad, I. ve Bebis, G., Effective Extraction of Gabor Features for False Positive Reduction and Mass Classification in Mammography, Applied Mathematics & Information Sciences, 6,1 (2012) 29-33.
121. Padmanabhan, S. ve Sundararajan, R., Texture and Statistical Analysis of Mammograms: A Novel Method to Detect Tumor in Breast Cells, International Conference on Machine Vision and Image Processing, Aralık 2012, Taipei, Bildiriler Kitabı, 157-160.
122. Mohanty, A. K., Senapati, M. R. ve Lenka, S. K., An Improved Data Mining Technique for Classification and Detection of Breast Cancer from Mammograms, Neural Computing and Applications, 22 (2013) 303–S310.
123. Haralick, R. M., Shanmugam, K. ve Dinstein, I., Textural Features for Image Classification, IEEE Transactions on Systems, Man and Cybernetics, 3,6 (1973) 610–621.
124. Dua, S., Singh, H. ve Thompson, H. W., Associative Classification of Mammograms Using Weighted Rules, Expert Systems with Applications, 36 (2009) 9250–9259.
125. Malek, J., Sebri, A., Mabrouk, S., Torki, K. ve Tourki, R., Automated Breast Cancer Diagnosis Based on GVF-Snake Segmentation, Wavelet Features Extraction and Fuzzy Classification, Journal of Signal Processing Systems, 55 (2009) 49–66.
126. Mousa, R., Munib, Q. ve Moussa, A., Breast Cancer Diagnosis System Based on Wavelet Analysis and Fuzzy-Neural, Expert Systems with Applications, 28 (2005) 713–723.
127. Kılıç, N., Görgel, P., Uçan, O. N. ve Sertbaş, A., Mammographic Mass Detection Using Wavelets as Input to Neural Networks, Journal of Medical Systems, 34 (2010) 1083–1088.
128. Sebri, A., Malek, J. ve Tourki, R., Automated Breast Cancer Diagnosis Based on GVF-Snake Segmentation, Wavelet Features Extraction and Neural Network Classification, Journal of Computer Science, 3,8 (2007) 600-607.
129. Nascimento, M. Z., Martins, A. S., Neves, L. A., Ramos, R. P., Flores, E. L. ve Carrijo, G. A., Classification of Masses in Mammographic Image Using Wavelet Domain Features and Polynomial Classifier, Expert Systems with Applications, 40 (2013) 6213–6221.
130. Orhan, U., Hekim, M. ve Ozer, M., EEG Signals Classification Using The K-Means Clustering and A Multilayer Perceptron Neural Network Model, Expert Systems with Applications, 38 (2011) 13475–13481.
131. Mitchell, T. M., Machine Learning, McGraw-Hill Inc., New York, 1997.

132. Maimon, O. ve Rokach, L., *Data Mining and Knowledge Discovery Handbook*, Second Edition, Springer, New York, 2010.
133. Dureja, H., Gupta, S. ve Madan, A. K., Topological Models for Prediction of Pharmacokinetic Parameters of Cephalosporins using Random Forest, Decision Tree and Moving Average Analysis, *Scientia Pharmaceutica*, 76 (2008) 377–394.
134. Schietgat, L., Vens, C., Struyf, J., Blockeel, H., Kocev, D. ve Džerosk, S., Predicting Gene Function Using Hierarchical Multi-Label Decision Tree Ensembles, *BMC Bioinformatics*, 11,2 (2010) 1-14.
135. Saimurugan, M., Ramachandran, K. I., Sugumaran, V. ve Sakthivel, N. R., Multi Component Fault Diagnosis of Rotational Mechanical System Based on Decision Tree And Support Vector Machine, *Expert Systems With Applications*, 38 (2011) 3819–3826.
136. Lavanya, D. ve Rani, K. U., Performance Evaluation of Decision Tree Classifiers on Medical Dataset, *International Journal of Computer Applications*, 26,4 (2011) 1-4.
137. Quinlan, J. R., Induction of Decision Trees, *Journal of Machine Learning*, 1 (1986) 81-106.
138. Quinlan, J. R., *C4.5: Programs for Machine Learning*, Morgan Kaufmann Publishers, USA, 1992.
139. Breiman, L., Friedman, J. H., Olshen, R. A. ve Stone, C. G., *Classification and Regression Trees*, Wadsworth International Group, California, 1984.
140. Thangavel, K. ve Mohideen, A. K., Classification of Microcalcifications Using Multi-Dimensional Genetic Association Rule Miner, *International Journal of Recent Trends in Engineering*, 2,2 (2009) 233-235.
141. Karahaliou, A., Skiadopoulos, S., Boniatis, I., Sakellaropoulos, P., Likaki, E., Panayiotakis, G. ve Costaridou, L., Texture Analysis of Tissue Surrounding Microcalcifications on Mammograms for Breast Cancer Diagnosis, *The British Journal of Radiology*, 80 (2007) 648-656.
142. Tirtajaya, A. ve Santika, D. D., Classification of Microcalcification Using Dual-Tree Complex Wavelet Transform and Support Vector Machine, Second International Conference on Advances in Computing, Control, and Telecommunication Technologies, Aralık 2010, Jakarta, Bildiriler Kitabı, 164-166.
143. Vibha, L., Harshavardhan, G. M., Pranaw, K., Shenoy, P. D., Venugopal, K. R. ve Patnaik, L. M., Classification of Mammograms Using Decision Trees, 10th International Database Engineering and Applications Symposium, Aralık 2006, Delhi, Bildiriler Kitabı, 263-266.

144. Mohanty, A. K., Beberta, S. ve Lenka, S. K., Classifying Benign and Malignant Mass Using GLCM and GLRLM Based Texture Features from Mammogram, International Journal of Engineering Research and Applications, 1 (2011) 687-693.
145. Ergen, B. ve Baykara, M., İstatistiksel Uzaysal Alan Metotlarının İçerik Tabanlı Tıbbi Görüntü Erişimi için Bir Uygulama, Fırat Üniv. Mühendislik Bilimleri Dergisi, 23,2 (2011) 87-93.
146. Radhakrishnan, M. ve Kuttiannan, T., Comparative Analysis of Feature Extraction Methods for the Classification of Prostate Cancer from TRUS Medical Images, International Journal of Computer Science, 9,2 (2012) 171-179.
147. Xu, D., Kurani, A. S., Furst, J. D. ve Raicu, D. S., Run-Length Encoding for Volumetric Texture, The IASTED International Conference on Visualization, Imaging, and Image Processing, Eylül 2004, Marbela, Bildiriler Kitabı, 6-8.
148. Fisher, R., The Use of Multiple Measurements in Taxonomic Problems, Annals of Eugenics, 7 (1936) 179–188.
149. Balakrishnama, S. ve Ganapathiraju, A., Linear Discriminant Analysis - A Brief Tutorial.  
[http://www.isip.piconepress.com/publications/reports/1998/isip/lda/lda\\_theory\\_v1.1.pdf](http://www.isip.piconepress.com/publications/reports/1998/isip/lda/lda_theory_v1.1.pdf) 10 Nisan 2014
150. Li, T., Zhu, S. ve Ogihara, M., Using Discriminant Analysis for Multi-Class Classification: An Experimental Investigation, Knowledge and Information Systems, 10,4 (2006) 453–472.
151. [http://tr.wikipedia.org/wiki/Meme\\_kanseri](http://tr.wikipedia.org/wiki/Meme_kanseri) Meme Kanseri. 20 Temmuz 2014.
152. <http://kanser.gov.tr/daire-faaliyetleri/kanser-istatistikleri.html> T.C. Sağlık Bakanlığı Türkiye Halk Sağlığı Kurumu Kansere Daire Başkanlığı, 2009 Kansere İnsidansları. 20 Ağustos 2014.
153. [http://www.wcrf.org/cancer\\_statistics/data\\_specific\\_cancers/breast\\_cancer\\_statistics.php](http://www.wcrf.org/cancer_statistics/data_specific_cancers/breast_cancer_statistics.php) World Cancer Research Fund International, Breast Cancer Statistics. 20 Ağustos 2014.
154. Tang, J., Rangayyan, R. M., Xu, J., Naqa, I.E. ve Yang Y., Computer-Aided Detection and Diagnosis of Breast Cancer with Mammography: Recent Advances, IEEE Transactions on Information Technology in Biomedicine, 13,2 (2009) 236-251.
155. Nishikawa, R. M., Current Status and Future Directions of Computer-Aided Diagnosis in Mammography, Computerized Medical Imaging and Graphics, 31 (2007) 224–235.



156. [http://en.wikipedia.org/wiki/Computer-aided\\_diagnosis](http://en.wikipedia.org/wiki/Computer-aided_diagnosis) Computer-Aided Diagnosis. 25 Haziran 2014.
157. <http://peipa.essex.ac.uk/info/mias.html> University of Essec, Mamographic Image Analysis Society. 20 Şubat 2012.
158. Kurt, B., Nabiyeve, V. V. ve Turhan, K., Contrast Enhancement and Breast Segmentation of Mammograms, 2nd World Conference on Information Technology, Kasım 2011, Antalya, Bildiriler Kitabı, 26-31.
159. Kurt, B., Nabiyeve, V. V. ve Turhan, K., Comparison of Enhancement Methods for Mammograms with Performance Measures, Studies in Health Technology and Informatics, 205 (2014) 486-490.
160. Kurt, B., Nabiyeve, V. V. ve Turhan, K., Medical Images Enhancement by Using Anisotropic Filter and CLAHE, IEEE Innovations in Intelligent Systems and Applications International Symposium, Temmuz 2012, Trabzon, Bildiriler Kitabı, 1-4.
161. Kurt, B., Nabiyeve, V. V. ve Turhan, K., A Novel Automatic Suspicious Mass Regions Identification Using Havrda & Charvat Entropy and Otsu's N Thresholding, Computer Methods and Programs in Biomedicine, 114,3 (2014) 349-360.
162. Kurt, B., Nabiyeve, V. V. ve Turhan, K., Mamografide Şüpheli Kitle Adayı Bölgelerin Belirlenmesi, IX. Ulusal Tıp Bilişimi Kongresi, Kasım 2012, Antalya, Bildiriler Kitabı, 40-49.
163. Kurt, B., Nabiyeve, V. V. ve Turhan, K., Automatic Microcalcification Segmentation Using Rough Entropy and Fuzzy Approach, Lecture Notes in Computer Science, 8060 (2013) 103-105.
164. Moayedı, F., Azimifar, Z., Boostani, R. ve Katebi, S., Contourlet-Based Mammography Mass Classification Using The SVM Family, Computer in Biology and Medicine, 40 (2010) 373-383.
165. Mohanty, A. S., Pradhan, A., Sahoo, S. ve Lenka, S. K., Detection of Masses from Mammograms Using Mass Shape Pattern, International Journal of Computer Technology Applications, 2,4 (2011) 1131-1139.
166. Basheer, N. M. ve Mohammed, M. H., Segmentation of Breast Masses in Digital Mammograms Using Adaptive Median Filtering and Texture Analysis, International Journal of Recent Technology and Engineering, 2,1 (2013) 39-43.
167. Khuzi, M. A., Besar, R., Zaki, W. W. ve Ahmadi, N. N., Identification of Masses in Digital Mammogram Using Gray Level Co-Occurrence Matrices, Biomedical Imaging and Intervention Journal, 5,3 (2009) 1-13.

168. Agrawal, P., Vatsa, M. ve Singh, R., Saliency Based Mass Detection from Screening Mammograms, Signal Processing, 99 (2014) 29-47.
169. Loka, V. R. D. ve Putheti, S., Classification of Normal, Benign and Malignant Tissues Using Fuzzy Texton and Support Vector Machine in Mammographic Images, International Journal of Computer Applications, 82,15 (2013) 36-39.
170. Kumar, S. M. ve Balakrishnan, G., The Performance Evaluation of The Breast Mass Classification CAD System Based on DWT, SNE AND SVM, International Journal of Emerging Technology and Advanced Engineering, 3 (2013) 581-587.
171. Vivona, L., Cascio, D., Fauci, F. ve Raso, G., Fuzzy Technique for Microcalcifications Clustering in Digital Mammograms, BMC Medical Imaging, 14,23 (2014) 1-18.
172. Diaz-Huerta, C. C., Felipe-Riveron, E. M. ve Montaña-Zetina, L. M., Quantitative Analysis of Morphological Techniques for Automatic Classification of Microcalcifications in Digitized Mammograms, Expert Systems with Applications, 41 (2014) 7361–7369.
173. Lee, Y. ve Tsai, D., Computerized Classification of Microcalcifications on Mammograms Using Fuzzy Logic and Genetic Algorithm, Proceedings of SPIE Medical Imaging, 5370 (2004) 952-959.
174. Strange, H., Chen, Z., Denton, E. R. E., Zwiggelaar, R., Modelling Mammographic Microcalcification Clusters Using Persistent Mereotopology, Pattern Recognition Letters, 47 (2014) 157–163.
175. Jasmine, J. S. L., Baskaran, S. ve Govardhan, A., A Robust Approach to Classify Microcalcification in Digital Mammograms Using Contourlet Transform and Support Vector Machine, American Journal of Engineering and Applied Sciences, 6,1 (2013) 57-68.
176. Rajesh, A. ve Ellappan, M., Classification of Microcalcification Based on Wave Atom Transform, Journal of Computer Science, 10,8 (2014) 1543-1547.

## 7. EKLER

### Ek-1. İyileştirme Algoritmasının Farklı Medikal Görüntülere ait Sonuçları


Burada, kitle görüntüleri için geliştirilen algoritma farklı medikal görüntüler üzerinde de test edilmiştir ve başarılı bir şekilde karışıklığın iyileştirildiği görülmektedir. Bununla birlikte orijinal ve iyileştirilmiş görüntülere ait iyileştirme ölçüsü LogAMEE değerleri de verilmiştir.



LogAMEE=46.314



LogAMEE=109.396



LogAMEE=39.947

(a)



LogAMEE=69.163

(b)

(a) Orijinal görüntü (b) İyileştirilmiş görüntü


Ek-1'in devamı




LogAMEE=60.279



LogAMEE=114.769



LogAMEE=30.803



LogAMEE=62.791



LogAMEE=51.146




LogAMEE=122.980

## Ek-2. Statik ve Dinamik $\alpha$ Değerlerine ait Program Çıktıları


Önceden de bahsedildiği gibi statik  $\alpha$  değeri kullanıldığında HC kriter fonksiyonu sonuç değerlerinin birbirine daha yakın çıktığı ve bunlara karşılık gelen eşik değerlerinin ise daha uzak olduğu görülmektedir. Dinamik  $\alpha$  değeri kullanıldığında ise HC kriter fonksiyonunun maksimum değeri tepe yaptığından buna yakın olan değerlere karşılık gelen eşik değerleri de birbirine yakındır. Örnek bir görüntüye ait sonuçlar aşağıdaki tabloda verilmiştir.

<i>Mdb265 için</i>	Statik $\alpha=0.2$ için HC kriter fonksiyonu değeri ve eşik değerleri		Dinamik $\alpha=0.49$ için HC kriter fonksiyonu değeri ve eşik değerleri	
	HC	<i>t</i>	HC	<i>t</i>
	0.986	167	0.90	150
	<b>1</b>	<b>183</b>	<b>1</b>	<b>151</b>
	0.984	192	0.93	152

Tabloda da görüldüğü gibi dinamik  $\alpha$  değeri kullanıldığında HC kriter fonksiyon değerinin en yakın olduğu değerlerde eşik değeri pek değişmemektedir. Statik  $\alpha$  değeri kullanıldığında ise HC kriter fonksiyonunun yakın olduğu değerlere karşılık gelen eşik değerleri oldukça farklıdır. Buna ilişkin program çıktıları aşağıdaki gibidir.



## Ek-2'nin Devamı



(a) Orijinal görüntü (b) Bölütlenmiş ve iyileştirilmiş görüntü (çerçeve kitle bölgesini göstermek için manuel çizilmiştir) (c) Dinamik  $\alpha=0.49$ , HC=1 ve t=**151** (d) Statik  $\alpha=0.2$ , HC=0.986 ve t=**167** (e) Statik  $\alpha=0.2$ , HC=1 ve t=**183** (d) Statik  $\alpha=0.2$ , HC=0.984 ve t=**192**

Yukarıdaki şekilde görüldüğü gibi statik  $\alpha$  kullanıldığında yakın olan HC kriter fonksiyon değerlerine karşılık gelen eşik değerleri ile eşikleme sonuçlarında kitle bölgesi gittikçe erimektedir. Buna karşılık dinamik  $\alpha$  için HC kriter fonksiyonu değerleri çok daha uzaktır. Maksimuma en yakın olanlar ise seçilen eşik değerine çok yakın olduğundan eşikleme sonucunu pek etkilemez ve bunun sonucunda daha hassas, daha doğru bir eşikleme gerçekleştirdiği söylenebilir.

## ÖZGEÇMİŞ

Burçin KURT; 1981 yılında Trabzon'da doğdu. İlköğrenimini 100.Yıl İlköğretim Okulu'nda, orta ve lise öğrenimini Trabzon Kanuni Anadolu Lisesi'nde sırasıyla 1992, 1996 ve 1999 yıllarında Trabzon'da tamamladı. 2000 yılında, üniversite sınavı ile yerleştirildiği Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü'nü İngilizce hazırlık ile birlikte 2005 yılında bitirdi. 2007 yılında aynı bölümde yüksek lisansını tamamladı. 2007 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı'nda doktora çalışmalarına başladı. 2009 yılında Öğretim Görevlisi olarak atandığı KTÜ Tıp Fakültesi Biyoistatistik ve Tıp Bilişimi Anabilim Dalı'nda halen çalışmaya devam etmektedir. Doktora çalışması, Türkiye Cumhuriyeti Bilim, Teknoloji ve Sanayi Bakanlığı ile AKGÜN Yazılım tarafından 01009.STZ.2011-2 proje kodu ile SANTEZ projesi olarak desteklenmiştir. Yabancı dil olarak İngilizce bilmektedir. Başlıca yayınları aşağıda verilmiştir.

**Kurt, B**, Nabiyev, V.V. ve Turhan, K., "A Novel Automatic Suspicious Mass Regions Identification using Havrda & Charvat Entropy and Otsu's N Thresholding", *Computer Methods and Programs in Biomedicine*, 114:3, 3 (2014) 49-60.