



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

**GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK,
2-BOYUTLU MAMOGRAFİK VERİLERDE KANSERLİ
BÖLGE TANISI**

**Bilgisayar Yük.Müh. Pelin GÖRGEL
Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman
Prof.Dr. Ahmet SERTBAŞ
Prof. Dr. Osman N. UÇAN (İkinci Danışman)**

Mart, 2011

İSTANBUL



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

**GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK,
2-BOYUTLU MAMOGRAFİK VERİLERDE KANSERLİ
BÖLGE TANISI**

**Bilgisayar Yük.Müh. Pelin GÖRGEL
Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman
Prof.Dr. Ahmet SERTBAŞ
Prof. Dr. Osman N. UÇAN (İkinci Danışman)**

Mart, 2011


İSTANBUL

Bu çalışma 28/03/2011 tarihinde ařağıdaki jüri tarafından Bilgisayar Mühendisliğı Anabilim Dalı Bilgisayar Mühendisliğı programında Doktora Tezi olarak kabul edilmiştir.


Tez Jürisi


Prof. Dr. Ahmet SERTBAŞ (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi


Prof. Dr. Aydın AKAN
İstanbul Üniversitesi
Mühendislik Fakültesi


Prof. Dr. Sabri ARIK
İstanbul Üniversitesi
Mühendislik Fakültesi


Prof. Dr. Serhat ŞEKER
İstanbul Teknik Üniversitesi
Elektrik Elektronik Fakültesi


Prof. Dr. A. Halim ZAİM
İstanbul Ticaret Üniversitesi
Mühendislik Fakültesi

Bu alıřma İstanbul Üniversitesi Bilimsel Arařtırma Projeleri Yürütücü Sekreterlięi'nin 2477 numaralı projesi ile desteklenmiřtir.

ÖNSÖZ

Doktora tez dönemim boyunca beni en güzel şekilde yönlendiren, çalışmalarımı teşvik eden ve her yönden destekleyen, ayrıca akademik hayatımın ilerlemesinde büyük katkıları olan değerli hocalarım Sayın Prof. Dr. Ahmet SERTBAŞ'a ve Sayın Prof. Dr. Osman Nuri UÇAN'a, tez izleme komitesinde yer alarak tezime katkıda bulunan Sayın Prof. Dr. Aydın AKAN ve Sayın Prof. Dr. Serhat ŞEKER'e yardımlarından dolayı sonsuz teşekkürlerimi sunarım.

Medikal görüntülerin temini ve değerlendirilmesi konusunda bana ayırdığı vakit ve verdiği destek için Sayın Radyolog Dr. Şükrü ŞANLI'ya, ayrıca tezime vermiş olduğu maddi destekten ötürü İstanbul Üniversitesi Bilimsel Araştırmalar Fonu'na teşekkür ederim.

Tez süresince desteğini esirgemeyen değerli eşim Turgay GÖRGEL'e ve hayatımın her döneminde sevgisini eksik etmeyerek fedakarlık gösteren, bu günlere gelmemde büyük katkıları olan ve her zaman koca bir çınar gibi arkamda duran sevgili anne ve babama şükranlarımı sunuyor, bu tez çalışmasını oğlum Kerem'e ithaf ediyorum.

Mart, 2011

Pelin GÖRGEL

İÇİNDEKİLER

ÖNSÖZ.....	i
İÇİNDEKİLER	ii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	ix
SEMBOL LİSTESİ	x
ÖZET	xii
SUMMARY	xiv
1. GİRİŞ.....	1
2. GENEL KISIMLAR	5
2.1. MEME ANATOMİSİ	5
2.2. MEME HASTALIKLARI.....	6
2.2.1. Memede Görülen Benign Hastalıklar	6
2.2.1.1. <i>Fibrokistik Hastalık</i>	7
2.2.1.2. <i>Fibroadenom</i>	7
2.2.1.3. <i>Juvenil Fibroadenom</i>	7
2.2.1.4. <i>Sistosarkoma Filloides</i>	7
2.2.1.5. <i>İntraduktal Papillom</i>	7
2.2.1.6. <i>Lipom</i>	7
2.2.1.7. <i>Fibroadenolipom</i>	8
2.2.1.8. <i>Memenin Yağ Nekrozu</i>	8
2.2.1.9. <i>Mastit ve Abse</i>	8
2.2.1.10. <i>Galaktosel</i>	8
2.2.1.11. <i>Fibrom ve leomyoma</i>	8
2.2.1.12. <i>Duktal Ektazi (Plazma Hücreli Mastit)</i>	8

2.2.2. Memede Görülen Malign Hastalıklar	8
2.2.2.1. Duktal Karsinoma	9
2.2.2.2. Lobüler Karsinoma	9
2.2.2.3. İnfiltratif Duktal Karsinom.....	9
2.2.2.4. İnfiltratif Lobüler Karsinom.....	9
2.2.2.5. Meduller Karsinom	9
2.2.2.6. Kolloid Karsinom	10
2.2.2.7. Tubüler Karsinom	10
2.2.2.8. İnfiltratif Papiller Karsinom	10
2.2.2.9. Paget Hastalığı (Meme başı karsinomu).....	10
2.2.2.10. İnflamatuvar Meme Kanseri	10
2.2.2.11. Sarkomlar	10
2.2.2.12. Metastatik Meme Lezyonları.....	11
2.2.3. Meme Kanseri	11
2.3. MEME GÖRÜNTÜLEME TEKNOLOJİLERİ	12
2.3.1. X-Işınları.....	12
2.3.2. Mamografi (1924(2))	13
2.3.2.1. Konvansiyonel Mamografi.....	14
2.3.2.2. Dijital Mamografi.....	14
2.3.4. Meme Ultrasonografisi	16
2.3.5. Magnetik rezonans görüntüleme	16
2.4. MEME KANSERİYLE İLGİLİ BİLGİSAYAR DESTEKLİ TANI	
ÇALIŞMALARI.....	17
3. MALZEME VE YÖNTEM.....	21
3.1. FOURIER DÖNÜŞÜMÜ	21
3.1.1. Tek Boyutlu (One Dimensional) Fourier Dönüşümü	21
3.1.2. İki Boyutlu Ayırık Fourier Dönüşümü ve Frekans Alanında Filtreleme	22
3.2. HOMOMORFİK FİLTRELEME	23
3.3. DALGACIK DÖNÜŞÜMÜ	24
3.3.1. Altband Kodlama (Subband Coding)	25
3.3.2. Çoklu Çözünürlükte Ölçekleme (Scaling) ve Dalgacık (Wavelet)	
Fonksiyonları.....	26

3.3.3. Dalgacık Serisi Açılımları ve Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform).....	28
3.3.4. Sürekli Dalgacık Dönüşümü (SDD) (Continuous Wavelet Transform)	29
3.3.5. Hızlı Dalgacık Dönüşümü (HDD) (Fast Wavelet Transform)	29
3.3.6. İki Boyutlu Dalgacık Dönüşümü (2-D Wavelet Transform).....	30
3.4. GAUSS-LAPLACE MODELLEME	32
3.5. KÜRESEL DALGACIK DÖNÜŞÜMÜ (KDD) (SPHERICAL WAVELET TRANSFORM).....	34
3.5.1. Kutupsal Koordinatlar ve Küre Denklemleri	34
3.5.2. Kitlelere Küresel Dalgacık Dönüşümü (KDD) Uygulanması.....	38
3.6. ÖZNİTELİK ÇIKARMA (FEATURE EXTRACTION)	39
3.7. DESTEK VEKTÖR MAKİNELERİ (DVM) (SUPPORT VECTOR MACHINES)	43
3.7.1. Doğrusal Olmayan Destek Vektör Makineleri	46
3.7.2. Sınıflandırmada Destek Vektör Makineleri (DVM) Kullanımı.....	47
3.8. MAMOGRAFİ VERİTABANI VE MAMOGRAFİ AYGITI ÖZELLİKLERİ.....	48
4. BULGULAR	50
4.1. GÖRÜNTÜ İYİLEŞTİRME (ENHANCEMENT).....	51
4.2. GÖRÜNTÜ BÖLÜTLEME (SEGMENTATION).....	66
4.2.1 Merkezden Bölge Büyütme (MBB) (Seed Region Growing) Yöntemi ..	66
4.2.1.1. Lokal Merkezden Bölge Büyütme (LMBB) Yöntemi.....	67
4.2.2. LMBB ile Elde Edilen Sonuçların Değerlendirilmesi	92
4.3. MEME KİTLELERİNİN SINIFLANDIRILMASI	93
4.3.1. Kitle-Doku Sınıflandırması ve Elde Edilen Sonuçların Değerlendirilmesi	94
4.3.2. Malign-Benign Sınıflandırması ve Elde Edilen Sonuçların Değerlendirilmesi	97
5. TARTIŞMA VE SONUÇ.....	122
KAYNAKLAR.....	127
ÖZGEÇMİŞ	134

ŞEKİL LİSTESİ

Şekil 1.1	: Kadınlarda görülen kanser tiplerinin sıklık oranları.....	3
Şekil 2.1	: Meme anatomisi 1) Göğüs duvarı, 2) Kas dokusu, 3) Süt bezleri, 4) Meme ucu, 5) Areola, 6) Süt kanalları, 7) Yağ dokusu, 8) Cilt [6].....	5
Şekil 2.2	: Dijital mamografi cihazı [27]	15
Şekil 3.1	: Homomorfik filtre blok diyagramı	24
Şekil 3.2	: Altbant kodlama	25
Şekil 3.3	: Bir işaretin altbantlarına ayrılması: A: Yaklaşıklık (approximation), D: Ayrıntı (detail) katsayıları	26
Şekil 3.4	: HDD blok diyagramı	32
Şekil 3.5	: HDD uzaysal gösterim.....	32
Şekil 3.6	: Kürede kutupsal koordinat gösterimi	34
Şekil 3.7	: KDD algoritması akış şeması	39
Şekil 3.8	: Meme kitle örnekleri: Üst sıradaki kitleler; malign, orta sıradaki kitleler; benign, alt sıradaki kitleler; normal doku	43
Şekil 3.9	: İki sınıfa ait verilerin DVM ile ayrılması	45
Şekil 3.10	: Öznitelik uzayına dönüşüm	46
Şekil 4.1	: Önerilen BDT sisteminin akış diyagramı	50
Şekil 4.2	: Görüntü iyileştirme akış diyagramı	52
Şekil 4.3	: Orjinal MLO mamogram.....	55
Şekil 4.4	: 1. seviye HDD ile elde edilen yaklaşıklık ve ayrıntı görüntüleri	56
Şekil 4.5	: 2. seviye HDD ile elde edilen yaklaşıklık ve ayrıntı görüntüleri	56
Şekil 4.6	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	57
Şekil 4.7	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	58
Şekil 4.8	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	60
Şekil 4.9	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş	

	mammogram c) b mamogramının adaptif eşiklenmiş şekli	60
Şekil 4.10	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	61
Şekil 4.11	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	62
Şekil 4.12	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	63
Şekil 4.13	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	64
Şekil 4.14	: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli	65
Şekil 4.15	: MBB yöntemi için şekilsel gösterim	66
Şekil 4.16	: LMBB algoritmasının akış şeması	71
Şekil 4.17	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	72
Şekil 4.18	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	73
Şekil 4.19	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	74
Şekil 4.20	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	75
Şekil 4.21	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	76
Şekil 4.22	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	77
Şekil 4.23	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	78
Şekil 4.24	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	79
Şekil 4.25	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	80
Şekil 4.26	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	81

Şekil 4.27	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	82
Şekil 4.28	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	83
Şekil 4.29	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	84
Şekil 4.30	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	85
Şekil 4.31	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	86
Şekil 4.32	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	87
Şekil 4.33	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	88
Şekil 4.34	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	89
Şekil 4.35	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	90
Şekil 4.36	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	91
Şekil 4.37	: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü	91
Şekil 4.38	: Sınıflandırma akış şeması	94
Şekil 4.39	: ROC performans eğrisi	97
Şekil 4.40	: ROC performans eğrisi	97
Şekil 4.41	: ROC performans eğrisi	100
Şekil 4.42	: ROC performans eğrisi	101
Şekil 4.43	: ROC performans eğrisi	101
Şekil 4.44	: ROC performans eğrisi	103
Şekil 4.45	: ROC performans eğrisi	104
Şekil 4.46	: ROC performans eğrisi	104
Şekil 4.47	: ROC performans eğrisi	106
Şekil 4.48	: ROC performans eğrisi	107

Şekil 4.49	: ROC performans eğrisi.....	107
Şekil 4.50	: ROC performans eğrisi.....	109
Şekil 4.51	: ROC performans eğrisi.....	111
Şekil 4.52	: ROC performans eğrisi.....	111
Şekil 4.53	: ROC performans eğrisi.....	112
Şekil 4.54	: ROC performans eğrisi.....	114
Şekil 4.55	: ROC performans eğrisi.....	114
Şekil 4.56	: ROC performans eğrisi.....	115
Şekil 4.57	: ROC performans eğrisi.....	117
Şekil 4.58	: ROC performans eğrisi.....	117
Şekil 4.59	: ROC performans eğrisi.....	118
Şekil 4.60	: ROC performans eğrisi.....	119
Şekil 4.61	: ROC performans eğrisi.....	121

TABLO LİSTESİ

Tablo 4.1	: LMBB yöntemiyle elde edilen sonuçlar	93
Tablo 4.2	: Kitle-doku sınıflandırma doğruluğu.....	95
Tablo 4.3	: Kitle-doku sınıflandırmada GP, GN, YP, YN sayıları.....	96
Tablo 4.4	: Doğrusal çekirdek fonksiyonu ile İTF veritabanında elde edilen sonuçlar	99
Tablo 4.5	: Karesel çekirdek fonksiyonu ile İTF veritabanında elde edilen sonuçlar	102
Tablo 4.6	: RTF çekirdek fonksiyonu ile İTF veritabanında elde edilen sonuçlar	105
Tablo 4.7	: Doğrusal, karesel ve RTF den İTF veritabanındaki en yüksek ikişer performans.....	108
Tablo 4.8	: Doğrusal çekirdek fonksiyonu ile MIAS veritabanında elde edilen sonuçlar	109
Tablo 4.9	: Karesel çekirdek fonksiyonu ile MIAS veritabanında elde edilen sonuçlar	112
Tablo 4.10	: RTF çekirdek fonksiyonu ile MIAS veritabanında elde edilen sonuçlar	115
Tablo 4.11	: Doğrusal, karesel ve RTF den MIAS veritabanındaki en yüksek ikişer performans.....	118
Tablo 4.12	: Tablo 4.7 ile Tablo 4.11 birleşimi.....	120
Tablo 5.1	: Önerilen yöntem ile diğer yöntemlerin karşılaştırılması	126

SEMBOL LİSTESİ

$h_0(n)$	: Alçak geçiren ayrıştırma (decomposition) filtresi
$h_1(n)$	: Yüksek geçiren ayrıştırma (decomposition) filtresi
$g_0(n)$	: Alçak geçiren yeniden oluşturma (reconstruction) filtresi
$g_1(n)$	: Yüksek geçiren yeniden oluşturma (reconstruction) filtresi
j	: Ölçekleme fonksiyonunun x eksenini boyunca olan genişliği
k	: Ölçekleme fonksiyonunun x eksenini üzerindeki yeri
$\phi_{j,k}(x)$	: Ölçekleme fonksiyonu
$\psi_{j,k}(x)$	: Dalgacık fonksiyonu
$W_\phi(j_0, k)$	: Ölçekleme fonksiyonu katsayıları
$W_\psi(j, k)$	: Dalgacık fonksiyonu katsayıları
τ	: Sürekli dalgacık dönüşümü öteleme değişkeni
s	: Sürekli dalgacık dönüşümü ölçekleme değişkeni
W_ψ^Y	: Yatay ayrıntı katsayısı
W_ψ^D	: Dikey ayrıntı katsayısı
W_ψ^{DY}	: Diyagonal ayrıntı katsayısı
$\eta^i(x)$	: Dalgacık daraltma fonksiyonu
l	: Harmonik seviyesi
m	: Harmonik sırası
P_l^m	: Legendre polinomları
ϕ	: Kutupsal koordinatlarda yatay açı
θ	: Kutupsal koordinatlarda düşey açı
$Y_l^m(\theta, \phi)$	: Küresel harmonik fonksiyonu
$\hat{\phi}_j$	: Küresel dalgacık dönüşümü ölçekleme fonksiyonu katsayıları
$\hat{\psi}_j$	: Küresel dalgacık dönüşümü dalgacık fonksiyonu katsayıları
c_j	: Küresel dalgacık dönüşümü yaklaşıklık katsayıları
w_j	: Küresel dalgacık dönüşümü ayrıntı katsayıları
$\hat{h}_j(l, m)$	: Küresel dalgacık dönüşümü alçak geçiren filtre katsayıları
$\hat{g}_j(l, m)$	: Küresel dalgacık dönüşümü yüksek geçiren filtre katsayıları
α_i	: Destek vektör makineleri Lagrange çarpanları
$\ w\ $	: Destek vektör makineleri ağırlık vektörü normu
$L(\alpha)$	: Lagrange fonksiyonu

$K(x, x_i)$	: Destek vektör makineleri çekirdek fonksiyonu
γ_H	: Homomorfik filtre yüksek geçiren filtre sınırı
γ_L	: Homomorfik filtre alçak geçiren filtre sınırı
r	: Homomorfik filtre eğimi
σ_{lokal}	: Lokal standart sapma
m_{lokal}	: Lokal ortalama
tol	: Tolerans indis değeri
T_{lokal}	: Lokal eşik değeri
TBY	: Tespit başarı yüzdesi
YP_{kitle}	: Görüntü başına düşen yanlış pozitif kitle sayısı
A	: Alan özniteliği
Mr_x	: Merkez özniteliğinin x koordinatı
Mr_y	: Merkez özniteliğinin y koordinatı
$\mathcal{CK}_y$	: Çevreleyen kutu özniteliğinin yüksekliği
$\mathcal{CK}_g$	: Çevreleyen kutu özniteliğinin genişliği
$E\mathcal{C}$	: Eşdeğer çap özniteliği
BEU	: Büyük eksen uzunluğu özniteliği
KEU	: Küçük eksen uzunluğu özniteliği
ORU	: Ortalama radyal uzunluk özniteliği
SS	: Standart sapma özniteliği

ÖZET

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK, 2-BOYUTLU MAMOGRAFİK VERİLERDE KANSERLİ BÖLGE TANISI

Meme kanseri kadınlarda en çok hayati tehlike arz eden kanser tiplerinden biridir. Buna karşın, düzenli mamografik tarama ve görüntüleme teknolojileri yardımıyla erken tanı konduğu takdirde tedavi edilebilen bir hastalıktır. Dijital mamografi tarama metodu, meme kanseri teşhisinde kullanılan ve son yıllarda gelişen bir teknolojidir. Bu teknoloji ile uzman radyologlar tarafından incelenen mamogramlarda kansere sebep olup malign (kötü huylu) özellik gösteren kitleler saptanabilir. Ancak boyutu küçük veya benign (iyi huylu) karakteristiğe sahip gibi gözükken kanserli kitleleri tanımak kimi zaman zor olmaktadır. Normal şartlarda; kendine özgü yapısı, boyutu, geometrik şekli, kenar kontürü ve yoğunluğu olan malign kitleler gözden kaçtığından yanlış tanıya sebebiyet verir. Hızlı ve doğru teşhisi koyabilmek içinse her vakada çok tecrübeli bir uzman radyolog tarafından, optimum kontrasta sahip, yüksek çözünürlüklü ve hiçbir artefakt içermeyen mamografi çekimlerinin incelenmesi gerekmektedir. Ne yazık ki, görüntüleme teknolojileri günümüzde oldukça gelişmiş olsa da, bazı durumlarda yanlış tanı konabilmektedir. Yanlış tanı, gereksiz yere biyopsi istenmesi veya ölüme sebebiyet veren kanserli bölgenin gözden kaçırılmasıdır.

Bilgisayar Destekli Tanı (BDT) sistemleri radyoloğa ikinci bir göz sağlayarak medikal görüntülerde kanserli bölgelerin tespiti, yorumlanması ve tanısına yardımcı olan bilgisayar programlarıdır. Bu tez çalışmasında önerilen BDT sistemi ile öncelikle mamogramlarda kontrast iyileştirilmiş, şüpheli bölgeler tespit edilmiş ve bu bölgelerde kitle-doku ayrımı yapılmıştır. Sonrasında ise gerçek kitleler malign-benign olarak ayrılmışlardır. Son olarak tüm aşamaların performansları hesaba katılarak BDT sisteminin tanı doğruluğu ortaya konmuştur.

Bu çalışmada İstanbul Üniversitesi Tıp Fakültesi (İTF) Hastanesi'nden alınan, sadece bu çalışma için kullanılmış mamogramlardan meydana gelen ve İTF olarak adlandırılan bir veritabanı oluşturulmuştur. Ayrıca, sınıflandırma performansını karşılaştırmak için ücretsiz erişim yetkisi veren MIAS (Mammographic Image Analysis Society) mamogram veritabanı da kullanılmıştır. Görüntü iyileştirmede Hızlı Dalgacık Dönüşümü, Homomorfik Filtreleme, Gauss-Laplace modelleme ve adaptif eşikleme yöntemlerinden faydalanılmıştır. Kitleleri tespit etmek içinse Merkezden Bölge Büyütme yöntemi temel alınarak Lokal Merkezden Bölge Büyütme (LMBB) algoritması geliştirilmiştir. Sınıflandırmanın ilk aşamasında, tespit edilen ilgili alanlar (ROIs) kitle veya doku olarak birbirlerinden ayrılmıştır. Bu aşamada öncelikle ilgili alanlara Küresel Dalgacık Dönüşümü (KDD) uygulanarak katsayılar elde edilmiş, daha sonra bu katsayılardan öznitelikler (features) çıkarılmıştır. Çıkarılan öznitelikler, kitlelerin tipik karakteristiklerini belirleyen boyut, geometrik şekil, kontür ve piksel

değerleriyle ilgilidir. Öznitelik matrisleri, Destek Vektör Makineleri (DVM) kullanılarak sınıflandırılmışlardır.

İTF veritabanında kitle-doku sınıflandırması sonuçlarına göre en yüksek sınıflandırma doğruluğu %96 ve görüntü başına düşen YP kitle sayısı (YP_{kitle}) 0.05'tir. En yüksek duyarlılık %88, en yüksek seçicilik ise %98'dir. MIAS veritabanında ise en yüksek sınıflandırma doğruluğu %95 ve YP_{kitle} değeri 0.12'dir. En yüksek duyarlılık %92, en yüksek seçicilik %96'dır.

Sınıflandırmanın ikinci aşaması kitleler arasında malign-benign ayrımıdır. Bu aşamada KDD yönteminin avantajlarını göstermek için tespit edilen ilgili alanlara ayrıca Hızlı Dalgacık Dönüşümü de (HDD) uygulanmıştır. İTF veritabanına KDD metodu uygulanarak elde edilen sonuçlara göre en yüksek malign-benign sınıflandırma doğruluğu %94 olup; doğrusal (lineer) çekirdek fonksiyonu kullanılarak son ölçek katsayıları (Sk) (w_5, c_5) ve en yüksek iki ölçek katsayılarıyla (EYİK) (w_4, w_5, c_5), RTF (Radyal Tabanlı Fonksiyon) kullanılarak ise EYİK katsayılarıyla sağlanmıştır. MIAS veritabanına KDD metodu uygulanarak elde edilen sonuçlara göre, en yüksek malign-benign sınıflandırma doğruluğu ise %93 olup; karesel çekirdek fonksiyonu kullanılarak son ölçek katsayılarıyla (Sk) (w_5, c_5) sağlanmıştır. İTF veritabanına uygulanan HDD metodu ile ulaşılan sonuçlara göre ise en yüksek malign-benign sınıflandırma doğruluğu %85 olup doğrusal çekirdek fonksiyonu kullanılarak son yaklaşıklık ile ortalama ayrıntı katsayılarıyla ($Yk\&Oak$) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) sağlanmıştır. Son olarak MIAS veritabanına HDD metodu uygulanarak elde edilmiş sonuçlara göre, en yüksek malign-benign sınıflandırma doğruluğu %87 olup, karesel çekirdek fonksiyonu kullanılarak $Yk\&Oak$ katsayılarıyla sağlanmıştır.

İTF veritabanı kullanılarak, doğrusal çekirdek fonksiyonu ve KDD-Sk ile karesel çekirdek fonksiyonu ve KDD-EYİK katsayılarıyla en yüksek duyarlılık %100; RTF çekirdek fonksiyonu ve KDD-EYİK katsayılarıyla en yüksek seçicilik %95 olarak bulunmuştur. MIAS veritabanı ile doğrusal çekirdek fonksiyonu kullanılarak KDD-Sk katsayılarıyla en yüksek duyarlılık %100; doğrusal çekirdek fonksiyonu kullanılarak KDD-EYİK ve HDD-Tk (tüm katsayılar) katsayılarıyla, karesel çekirdek fonksiyonu kullanılarak ise KDD-Sk ve KDD-EYİK katsayılarıyla en yüksek seçicilik %88 olarak elde edilmiştir. Son olarak; önerilen BDT algoritmasının İTF veritabanı kullanılarak elde edilen en yüksek tanı doğruluğu KDD ile %90.2, HDD ile %81.6, MIAS veritabanı kullanılarak KDD ile %88.4 ve HDD ile %82.7 olarak bulunmuştur. BDT tanı doğruluğu, öznitelik çıkarma öncesinde herhangi bir KDD veya HDD uygulamadan İTF veritabanında %72, MIAS veritabanında %69.4'tür.

SUMMARY

CANCER REGION DIAGNOSIS OF 2-DIMENSIONAL MAMMOGRAPHIC DATA USING IMAGE PROCESSING TECHNIQUES

Breast cancer is one of the most human life threatening cancer types among women. On the other hand, it is curable when early diagnosis is possible with the help of regular mammographic screening and imaging technologies. Digital mammography screening method that is used in breast cancer diagnosis is a recently developing technology. Based on this technology, the masses having the malignant features can be detected in the mammograms investigated by expert radiologists. However sometimes it is hard to diagnose the cancerous masses if they are small in size or seem to have benign features. Normally, when the malign masses which have unique structure, size, geometric shape, edge contour and density are missed, it causes wrong diagnosis. For an accurate and true diagnosis; mammography shootings that have no artifacts, optimum contrast and high resolution should be investigated by a very experienced radiologist in each case. Nevertheless; although imaging technologies have recently been developing fast, sometimes false diagnosis is made. The false diagnosis can be an unnecessary biopsy request or missing the cancerous region causing mortality.

Computer Aided Diagnosis (CAD) systems are computer programs that help detection of cancerous regions, interpretation and diagnosis in medical images providing a second eye to the radiologists. In this thesis study firstly the contrast in mammograms is enhanced, the suspicious regions are detected and classification of those regions as mass or tissue is implemented by the proposed CAD system. Next the true positive masses are seperated as malign or benign. Finally the diagnosis accuracy of the CAD system is put forward taking into account the performances of all steps.

In this study, a database is constituted that is made up with original mammograms which are acquised from Istanbul University Faculty of Medicine Hospital and used only for this study. Also, MIAS (Mammographic Image Analysis Society) mammogram database which gives free access authorization is also used to compare the classification performance. In image enhancement; Discrete Wavelet Transform, Homomorphic Filtering, Gaussian-Laplacian modelling and adaptive thresholding methods are utilized. For mass detection Local Seed Region Growing (LSRG) method is developed based on the Seed Region Growing method. In the first step of classification, the detected Region of Interests (ROIs) are distinguished each other as mass or tissue. In this step, firstly the coefficients are obtained by applying Spherical Wavelet Transform (SWT) to the region of interests and secondly the features are extracted from those coefficients. The extracted features are related to size, geometric shape, border contour and pixel value which specify typical characteristics of the masses. The feature matrices are classified by using Support Vector Machines (SVM).

According to the mass-tissue classification in the İTF database, the classification accuracy is 96% and the number of the false positives per image (YP_{kitle}) is 0.05. The highest sensitivity is 88% and specificity is 98%. In the MIAS database the classification accuracy is 95% and YP_{kitle} is 0.12. The highest sensitivity is 92% and specificity is 96%.

Second step of the classification is separation of the masses as malign-benign. In this step also Fast Wavelet Transform (FWT) is applied to the detected ROIs to demonstrate the advantages of SWT. According to the results obtained by applying SWT method to the İTF database, the highest malign-benign classification accuracy is reached to 94% using linear kernel function with last scale coefficients (Sk) (w_5, c_5) and the two highest scales coefficients (EYİk) (w_4, w_5, c_5), also using RBF (Radial Basis Function) with EYİk coefficients. According to the results obtained by applying SWT method to the MIAS database, the highest malign-benign classification accuracy is reached to 93% using quadratic kernel function with last scale coefficients (Sk) (w_5, c_5). According to the results obtained by applying FWT method to the İTF database, the highest malign-benign classification accuracy is reached to 85% using linear kernel function with last scale approximation coefficients and mean of the detail coefficients (Yk&Oak) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$). Finally according to the results obtained by applying FWT method to the MIAS database, the highest malign-benign classification accuracy is achieved as 87% using quadratic kernel function with Yk&Oak coefficients.

By using the İTF database, the best sensitivity is computed as 100% with linear kernel function and SWT-Sk and with quadratic kernel function and SWT-EYİk coefficients; the best specificity is computed as 95% with RBF kernel function and SWT-EYİk coefficients. With MIAS database the highest sensitivity is obtained as 100% by using linear kernel function and SWT-Sk coefficients; the best specificity is obtained as 88% by using linear kernel function and SWT-EYİk and FWT-Tk (all coefficients) and also using quadratic kernel function and SWT-Sk and SWT-EYİk coefficients. Finally, the best diagnosis accuracy of the proposed CAD algorithm using the İTF database is computed as 90.2% with SWT and 81.6% with FWT and it is computed as 88.4% with SWT and 82.7% with FWT using the MIAS database. In the condition of neither SWT nor FWT is used before feature extraction, the CAD diagnosis accuracy is 72% for İTF database and 69.4% for MIAS database.

1. GİRİŞ


Meme kanseri kadınlarda kanserden kaynaklanan ölüm nedenlerinin başında gelmektedir. Dünya Sağlık Örgütü'nün (WHO) 1990 yılında yaptığı çalışmada, 796.000 yeni meme kanserli olgu ve 314.000 meme kanserinden ölüm saptanmışken, yine WHO'ya bağlı Uluslararası Kanser Araştırma Birimi'nin (IARC) 2002 yılındaki değerlendirmesinde; 1.152.000 yeni meme kanserli olgu ve 411.000 meme kanseri kaynaklı ölüm hesaplanmıştır. Bu süre içerisinde meme kanserine yakalanma sıklığı ve ölüm (mortalite) oranlarında %25'lik artış görülmektedir.

Ülkemizde toplum tabanlı kanser kayıt merkezi çalışmalarına 1991 yılında İzmir'de başlanmıştır. Bu çalışmalar ilerleyen yıllarda bölgelerini temsil edebileceği düşünülen bazı pilot illerde de yaygınlaştırılmıştır. Bu iller Ankara, Antalya, Edirne, Erzurum, Eskişehir, İzmir, Samsun, Trabzon olup tamamı Türkiye nüfusunun %19.71'ini oluştururken, Türkiye'de görülen kanserlerin %36.82'si bu illerde meydana gelmektedir. Bu nedenle, Sağlık Bakanlığı tarafından sözkonusu 8 il üzerinde yapılan çalışmanın Türkiye'deki rakamları temsil etme özelliğine sahip olduğu kabul edilmiştir [1]. Sekiz kanser kayıt merkezinin 2004, 2005 ve 2006 yılı verileri ile bir veri havuzu oluşturulmuş, bu veriler işlenerek kanser istatistiği analizleri yapılmıştır. Bu yıllar arasında veri havuzuna 41438 erkek, 27709 kadın olmak üzere toplam 69147 olgu alınmıştır [2].

Sağlık Bakanlığı veri havuzuna göre tüm insanlarda en sık görülen kanser tipi akciğer kanseridir. İkinci sıklıkta görülen meme kanseri ise gerek gelişmiş gerekse gelişmekte olan ülkelerde en sık görülen kadın kanseridir. Şekil 1.1 deki pasta grafik kadınlarda görülen kanser tiplerinin sıklık oranlarını vermektedir. En sık görülen kanser tipi %47.2 oranla meme kanseri olup, ikinci en sık görülen tip %23.8 oranla uterus korpusu (rahim) kanseridir.

Dünya Sağlık Örgütü verilerine göre meme kanserli hastalarda tüm evrelere göre 5 yıllık sağkalım oranları, gelişmiş ülkelerde %73 iken, gelişmekte olan ülkelerde %53 olarak bildirilmektedir [3]. Aradaki bu önemli fark, gelişmiş olan ülkelerdeki görüntüleme ve tarama teknolojisi mamografi sayesinde erken tanı ve daha iyi tedavi olanakları ile açıklanabilir. Klasik (conventional) mamografi ve dijital mamografi son yıllarda hızlı gelişim gösteren meme görüntüleme yöntemleridir. Her iki teknoloji de meme kitlelerini göstermede başarılı sonuçlar vermektedir. Bunun yanısıra meme kanseri görüntülemeye ultrason gibi yöntemlerden de faydalanılmaktadır.

Bir toplumda kanserle ilgili en önemli mücadele, kanserin erken evrede yakalanabilmesidir. Bunun sağlanabildiği toplumlarda, kanserden kaynaklanan ölüm oranı (mortalite) daha düşüktür. Kanser erken evrede yakalandığı zaman tedavi imkanlarına çok daha olumlu yanıt verilmektedir. Böylece organ kaybı ile sonuçlansa dahi hasta kanseri tamamen yenebilmektedir. Erken tanıyı sağlamada görüntü teknolojilerinin gelişmiş olmasının yanında Bilgisayar Destekli Tanı (BDT) sistemleri de etkindir. BDT, bilgisayar sistemleri aracılığıyla dijital radyolojik görüntülerde, matematiksel ve istatistiksel analiz yöntemleri kullanılarak radyolog için tanımlanması zor alanları (hedef tanıları veya patolojileri) belirleyen ikincil ve yardımcı ek bir tanı yöntemi olup, radyoloğun daha çok kanser vakası yakalamasını sağlar [4,5]. BDT, radyoloğun tanısını tasdik etme yöntemi değildir, son karar radyoloğa aittir. Bu özellikler değerlendirmeyi kolaylaştırır ve daha doğru tanı koymayı sağlar.



Şekil 1.1: Kadınlarda görülen kanser tiplerinin sıklık oranları


Bu tez çalışmasında literatürdeki çalışmalara alternatif olabilecek, mamografik verilerde kitle tespit ederek kanser tanısı koyma çalışması için yeni bir BDT geliştirilmiştir. Önerilen BDT, üç bölümden oluşmaktadır. Bunlar görüntü iyileştirme, kitle tespiti ve sınıflandırma aşamalarıdır. Görüntü iyileştirme bölümünde görüntü öncelikle Hızlı Dalgacık Dönüşümü'ne tabi tutulur. Dönüşüm ile elde edilen yaklaşıklık ve ayrıntı katsayılarına farklı işlemler uygulanır. Ayrıntı katsayıları yatay dikey ve diyagonal olmak üzere üç farklı katsayı grubundan oluşmaktadır. Yaklaşıklık (approximation) katsayılarına Homomorfik Filtreleme, ayrıntı katsayılarına ise Gauss-Laplace dağılımları ile gürültü-ayrıntı modellemenin uygulandığı dalgacık daraltma metodları kullanılmıştır. Son olarak Ters Dalgacık Dönüşümü (Inverse Wavelet Transform) ile katsayılarından yeniden oluşturulan görüntüler, geliştirilmiş olan adaptif eşikleme uygulanarak iyileştirilmiştir. İkinci bölümde benzerlik özelliğini kullanan bölge tabanlı (region based) Merkezden Bölge Büyütme - MBB (Seed Region Growing) bölütleme yöntemi kullanılmıştır. Bu yöntemin uygulanmasından önce merkez (seed) olacak pikseller geliştirilen algoritma ile otomatik olarak bulunur. Bu işlem için piksel hem lokal hem de global alanda incelenmiştir. Bu merkezler referans alınarak ve belli kurallar tanımlanarak merkez pikselin komşuları tek tek kontrol edilmiştir. Önceden belirlenmiş benzerlik kriterine göre merkeze uyan komşular merkezin temsil ettiği bölgeye (region) dahil edilmiştir. Sonuç olarak; MBB ile mamogramlar üzerindeki kitle

olabilecek şüpheli bölgeler çıkarılmıştır. Bu bölgelerde hem gerçek pozitif (GP) kitleler, hem de yanlış pozitif (YP) meme dokusu bulunmuştur. En doğru tanıyı koyabilmek için, üçüncü bölümde sınıflandırmaya geçilmiştir. Öncelikle tespit edilen tüm kitleler Küresel Dalgacık dönüşümünden (KDD) geçirilmiştir. Daha sonra kitlelerin kendi öznelilikleriyle KDD katsayı öznelilikleri birleştirilerek öznelilik matrisleri oluşturulmuştur. Sınıflandırmanın ilk aşaması kitle-doku sınıflandırmadır. Sonraki aşama ise kitleler arasındaki malign-benign sınıflandırmadır. Sınıflandırma işlemi için 3 farklı çekirdek fonksiyonu kullanılarak Destek Vektör Makineleri (DVM) kullanılmıştır. Geliştirilen BDT ile malign-benign sınıflandırması sonucu vakanın kanser olup olmadığı hakkında bir yorum yapılabilmektedir. Ayrıca deneysel sonuçlar ile farklı katsayı gruplarının özneliliklerini kullanmanın sisteme katkısı araştırılmıştır.

2. GENEL KISIMLAR

2.1. MEME ANATOMİSİ

Kadınlarda bebeklerini beslemek için süt yapımında görev alan meme organı kendine özgü bir anatomiye sahiptir. Meme dokusu; süt bezleri, üretilen sütü meme ucuna taşıyan kanallar (duktuslar), bu kanalların arasındaki kas ve destek dokuları, yağ, sinirler, kan ve lenf damarlarından oluşur (Şekil 2.1). Bir araya gelerek toplanmış süt bezleri lobülleri, lobüller de lobları oluştururlar. Her memede yaklaşık 20 adet lob adı verilen bölüm vardır. Bu loblar üzüm salkımına benzetilebilir. İnce süt kanalları lob, lobül ve süt keseciklerini birbirine bağlamaktadır. Bu kanallar meme başına doğru birleşerek memenin tam ortasında areola denilen koyu renkli bölgede meme başına açılırlar. Yağ dokusu, memeye yumuşaklık ve fiziksel görünüm verir.



Şekil 2.1: Meme anatomisi 1) Göğüs duvarı, 2) Kas dokusu, 3) Süt bezleri, 4) Meme ucu, 5) Areola, 6) Süt kanalları, 7) Yağ dokusu, 8) Cilt [6]

Kas dokusu meme içinde olmayıp, meme arkasında bir adet göğüs kası (pektoral) olarak bulunmaktadır. Meme dokusu içinde damar sistemleri de bulunur [7]. Bunlar; memeyi

besleyen kan damarları ve memedeki lenf sistemi damarlarıdır. Lenf, insanda bağışıklık hücrelerini taşıyan renksiz bir sıvıdır. Meme dokusunda bulunan enfeksiyon yada kötü huylu tümörler bu lenf sistemi ile taşınır.

2.2. MEME HASTALIKLARI

Memedede görülen hastalıklar genel olarak oluşum lokalizasyonlarına göre gruplandırılırlar [8]. Meme derisinde gelişen hastalıkların başlıcaları epidermal ve sebase kistler, nörofibromatozis, mondor, steatositoma multipleks, inflamatuvar karsinoma, deri nekrozu, piyoderma gangrenozum, candidal intertrigo, herpes zoster enfeksiyonu (zona), sifiliz ve melanomdur. Meme başında (areola) görülen hastalıklar; dermatit, meme başı adenomu, hidradenitis süpürativa, leomyom, paget hastalığıdır. Galaktosel, fibroadenomlar ve kompleks fibroadenomlar, tubüler adenom, sklerozan adenozis juvenil papillomatozis, filloides tümör, lobüler neoplaziler ve invaziv lobüler karsinom meme lobüllerinde gelişen hastalıklardandır. Majör subareoler duktuslarda görülen hastalıklar duktal ektazi, soliter papillomlar, papiller karsinomlar, terminal duktuslarda görülen hastalıklar ise duktal hiperplaziler, multiple periferik papillomlar, radyal skar, duktal adenom, duktal insitu karsinom, invaziv duktal karsinom, tubüler karsinom, müsinöz karsinom, meduller karsinom, invaziv kribriform karsinom, adenoid kistik karsinom, yassı hücreli kanser, metaplastik karsinom ve sekretuar karsinomdur. Ayrıca memenin stromasında ise yağ nekrozu, lipom, sütür kalsifikasyonu, mastit ve meme absesi, fibroadenolipom (hamartom), fibrozis, pseudoanjioimatöz stromal hiperplazi, anjiosarkom, hemanjiom, diabetik fibröz meme hastalığı, lenfoma, ekstraabdominal desmoid tümör ve metastatik meme hastalıkları görülür. Meme hastalıkları aynı zamanda kanser hastalıklarına dahil olma açısından da benign (iyi huylu) ya da malign (kötü huylu) olarak gruplandırılabilir.

2.2.1. Memede Görülen Benign Hastalıklar

Tüm meme hastalıklarının yaklaşık olarak %90' ını benign meme hastalıkları oluştururlar. Benign meme hastalıkları kanser özellikleri göstermediğinden dolayı iyi huylu olarak adlandırılırlar. Benign gruba giren meme hastalıkları aşağıda kısaca anlatılmıştır.

2.2.1.1. Fibrokistik Hastalık

Fibrokistik hastalık en yaygın olarak görülen meme hastalığıdır. Memede değişik boyutlarda ağrı veya hassasiyet verici kitle görülebilmektedir. Kistler radyolojik olarak düzgün, yuvarlak, oval ve keskin kontürlüdür. Çok sayıda küçük kist, epitelial ve fibröz proliferasyonla birleşerek nodüler bir pattern oluştururlar. Kistlerin duvarında yarımay biçiminde kalsifikasyonlar izlenebilir [9].

2.2.1.2. Fibroadenom

Fibrokistik meme hastalıklarından sonra en sık görülen meme hastalığıdır. Fibroadenomlar 30'lu yaşlardan önce ortaya çıkan östrojene duyarlı yavaş büyüyen benign tümörlerdir. Mamografilerde fibroadenomlar düzgün ve keskin kontürlüdür. Küçük fibroadenomlar yuvarlaktır ve kistlerden ayrılamazlar. Daha büyük boyutlu fibroadenomlar ise nodüler, oval veya lobüle kontürlüdür.

2.2.1.3. Juvenil Fibroadenom

Çok hızlı büyüyen dev fibroadenomlardır. Histolojik ve radyolojik olarak diğer fibroadenomlara benzer. Bazen çok büyük boyutlara ulaşip tüm memeyi kaplayabilirler, hızlı büyümelerine rağmen malign potansiyel taşımazlar .

2.2.1.4. Sistosarkoma Filloides

Malign potansiyel taşıyan, büyük, lobüle keskin sınırlı, homojen-heterojen eko yapısında solid kitledir. Fibroadenom ile farkı boyut ve hücre sayısına sahiptir. Çoğu benign karakterde olup %5 den az oranda malign transformasyon gelişebilir.

2.2.1.5. İntraduktal Papillom

Meme neoplazmı papillomu sıkça görülmekte olup benign nitelik taşır. Soliter intraduktal papillom çoğunlukla meme başı akıntısıyla ortaya çıkar ve memenin yaygın benign neoplazmıdır. İleri seviyede duktal dilatasyon kist ve intrakistik papillom formasyonuna neden olabilmektedir. Papillomlar bazen küçük kalsifikasyonlar içerirler. Bu küçük kalsifikasyonlar malign mikrokalsifikasyonlarla karışabilir.

2.2.1.6. Lipom

Lipomlar, yavaş büyüyen, düzgün kontürlü, mobil kitlelerdir. Mammografide ince yoğun bir kapsül ile çevrili düzgün kontürlü lezyon olarak görülür. Tamamen yağlı memelerde lipomun görülebilmesi zordur. Lipomlarda kalsifikasyon çok nadir izlenir. Biçimsel olarak düzgün ve keskin kontürlü, orta derecede homojen yapıda lezyonlardır.

2.2.1.7. Fibroadenolipom

Fibroadenolipomlar ince bir kapsülle çevrilidir. Ultrasonografik olarak yuvarlak veya oval, keskin sınırlı ve düzgün kontürlü, nonhomojen meme lezyonlarıdır. Ultrasonografide kontürleri düzgün, içerdiği yağ ve glandüler bileşenlere bağlı olarak heterojen paternde kitleler olarak izlenirler.

2.2.1.8. Memenin Yağ Nekrozu

Biyopsi veya başka türlü operasyon geçirmiş memede sıklıkla görülüp yağ içeren bir kavite ve etrafında fibröz doku oluşturur. Yağ nekrozu farklı mammografik görüntü verebilir. Kontür yapısı kimi zaman düzgün, kimi zamansa düzensizdir.

2.2.1.9. Mastit ve Abse

Akut mastit bir çeşit meme enfeksiyonudur. Abse mamografik olarak düzensiz kontürlü, çevresinde distorsiyon ve cilt kalınlaşması görülen kitledir. Ultrasonografide abse düzensiz kontürlü, solid ve kistik bileşenler içeren gölgelenme veren, heterojen yapıda bir lezyondur.

2.2.1.10. Galaktosel

İçerisinde süt dolu olan meme kistleridir. Süt veren veya hamile kadınlarda kitle şeklinde görülür. Mammografide farklı yoğunlukta düzgün yuvarlak kitleler şeklinde izlenirken ultrasonografide iyi sınırlı anekoik kist görünümündedir.

2.2.1.11. Fibrom ve leomyoma

Fibromalar iyi huylu ve düzgün kontürlüdür ve memenin glandüler dokusunda yer alırlar. Meme başında gelişen damar çeperinde yada derideki düz kaslardan gelişir.

2.2.1.12. Duktal Ektazi (Plazma Hücreli Mastit)

Memenin toplayıcı kanallarının dilatasyonu ve etrafında iltihabi reaksiyon ve fibrozis oluşmasıdır. Meme başında koyu ve renkli bir akıntı oluşturarak belirti verir.

2.2.2. Memede Görülen Malign Hastalıklar

Memede görülen malign hastalıklar meme kanserine yol açarlar. Meme kanserinin karakteristik görünümü, düzensiz ve belirsiz kontürlü, solid kitle şeklindedir. Bazen fibroadenomdan ayırt edilemeyecek düzeyde benign görünümlü de olabilir. Malign gruba giren meme hastalıkları aşağıda kısaca anlatılmıştır.

2.2.2.1. Duktal Karsinoma

Duktal karsinoma tüm meme kanserlerinin %0.8-5' ini oluşturur. Mamografide kümeleşen mikrokalsifikasyonlar ile saptanabilirler. Epitel hücrelerindeki farklılıklara göre üçe ayrılırlar. Komedo, kribriform ve papiller tip. Komedokarsinoma en malign tiptir. Tarama mammografilerinin yaygın olarak kullanıma geçmesi ile duktal karsinomaların tesbitinde artış görülmüştür.

2.2.2.2. Lobüler Karsinoma

Bu hücreler oval veya yuvarlak çekirdekli hücrelerdir. Lobüler karsinoma çoğunlukla benign veya malign bir lezyona yönelik yapılan meme biyopsilerinde tesadüfen saptanır. Tüm kanserlerin %1-6' sını noninvaziv kanserlerin %30' unu oluşturur. Bilateral özellik gösterip genellikle mammografik ve klinik bulgu vermez.

2.2.2.3. İnfiltratif Duktal Karsinom

Bu meme hastalığı bazal membranı tahrip edip geçtiğinde infiltratif karsinom olarak adlandırılır. Meme kanserlerinin %65-75' inden fazlasını oluşturur. Seyri en kötü olan meme kanseridir. Mammografik görünümü spiküler uzantıları bulunan kitle lezyonu şeklindedir. İnfiltratif duktal karsinom görünümüne göre genel olarak ikiye ayrılır; Stellat ve sınırlı. Stellat (yıldız şeklinde) karsinomlarda doku içerisine girinti yapmıştır. İnfiltratif duktal karsinomlar düzensiz ve belirsiz kontürlüdür.

2.2.2.4. İnfiltratif Lobüler Karsinom

Meme malignitelerinin % 7-10' unu oluşturur. Mamografilerde parankim yapısında bozukluk izlenir. Özellikle belirgin kontür çizmeyen asimetrik kitleler şeklinde görülmekle beraber silik düzensiz sınırlı tümöral kitleler olarak da karşımıza çıkabilirler. Kimi zaman mammografik olarak bulgu saptanamayabilir. Bu gibi durumlarda ultrasonografi veya dijital mamografi tabanlı bilgisayar destekli tanı gibi diğer teknikler kullanılmalıdır.

2.2.2.5. Meduller Karsinom

Tüm meme kanserlerinin %5-7' sini oluştururlar ve mamografide iyi sınırlı kitle görünümündedir. Duktal kanserlere göre daha genç hasta grubunda görülür. 35 yaşından genç kadınlarda görülen meme tümörlerinin %11' i meduller kanserdir. Genellikle mammografik olarak yuvarlak ve oval, lobüle kontürlü, kalsifikasyon içermeyen homojen dansitede kitlelerdir.

2.2.2.6. *Kolloid Karsinom*

Genellikle ileri yaş kadınlarda görülmekle birlikte tüm meme kanserlerinin %1-7' sini oluşturur. Tümör yavaş büyür ve gelişir, seyri iyidir ve lenf nodu metastazı hemen hemen hiç görülmez. Mammografilerde oldukça iyi sınırlı kitleler şeklinde görülür. Kalsifikasyon veya desmoplastik reaksiyon göstermeyen düzgün kontürlü kitlelerdir. Kolloid kanser kitleleri ultrasonografide düzgün veya hafif düzensiz kontürlü lezyonlardır.

2.2.2.7. *Tübüler Karsinom*

Meme kanserlerinin %2' sini oluşturur. Tümör dokusunun %75' i tübüler yapılardan oluşan infiltrate duktal karsinomalardır. Tümör içerisinde tübül formasyonu izlenir. Seyri oldukça iyidir. Uzun mikrokalsifikasyonlar içeren küçük tümörlerdir ve yaklaşık olarak ortalama 1 cm boyutundadırlar.

2.2.2.8. *İnfiltratif Papiller Karsinom*

Tüm meme kanserlerinin %1-2' sini oluşturur. Ortalama yaş 63-67 dir. Mammografide büyük ve iyi sınırlı kitleler halinde izlenirler, makrolobülasyon izlenebilir, tek veya çoklu sahalarda mikrokalsifikasyonlar sıktır. Ultrasonografide ise kompleks bir kistik kitle gibi görülür.

2.2.2.9. *Paget Hastalığı (Meme başı karsinomu)*

Paget hastalığı tüm meme kanserlerinin %1-5' i oranında izlenir .Meme başında yanma, kaşınma ve ağrı ile başlar. İleri yaşlarda daha sık olarak görülür. Mamografi verilerinde meme başı ve areolada kalınlaşma, subareoler kitle, meme başında kalsifikasyonlar izlenir.

2.2.2.10. *İnflamatuvar Meme Kanseri*

Bu kanser türünün belirtileri memede ağrı veren kitle ve kitlenin üzerindeki ciltte renk değişikliği olarak tanımlanmıştır. Primer ve sekonder olmak üzere iki çeşittir. En belirgin mamografik görünümü memede diffüz olarak artmış doku yoğunluğudur, ciltte ve cildin altındaki dokularda kalınlık artışı izlenir.

2.2.2.11. *Sarkomlar*

Sarkomlar en sık görülen meme sarkomlarıdır. Fibroadenoma benzerler, fakat düzensiz kontürlü ve çok hızlı büyüyen kitlelerdir.

2.2.2.12. Metastatik Meme Lezyonları

Metastazlar, meme malignitelerinin çok azını oluşturur. Mamografik görünümleri fibroadenoma benzeyen iyi sınırlı kitlelerdir. Memeye en sık; karşı memeden, lenfomadan, granülositik sarkomadan, akciğer bronş karsinomu , mide, prostat, yumurtalık ve serviks malignitelerinin metastazları görülür. Metastazlar en sık katı ve düzensiz kontürlü kitleler şeklinde görülür.

2.2.3. Meme Kanseri

Meme kanseri tüm toplumlarda görülme sıklığı giderek artan ve hayati tehlikesi en fazla olan meme hastalığıdır. Özellikle son yıllarda kadınlarda görülen kanser türleri arasında ilk sırada yer almaktadır. Meme dokusunda bulunan epitelyal kökenli hücrelerin oluşturduğu malign tümörlerin tümü meme kanseri olarak adlandırılmaktadır. ABD’de, tüm yaşamı boyunca her 8 kadında 1’inin, Avustralya’da 13 kadında 1’inin, Japonya’da 50 kadında 1’inin, meme kanserinden etkilenme olasılığı bulunmaktadır. Türkiye’de ise resmi kayıtlara göre meme kanserinden yılda 3000 ölüm olmaktadır [10-14]. Meme kanseri genel olarak uzun bir zaman diliminde gelişir. Çoğu hastada ilk malign hücrenin oluşmasından, 1 cm çapında bir hacime ulaşana kadarki süre 7-8 yıldır. Meme içindeki kötü huylu hücrelerin yayılarak civardaki dokulara yerleşmesi süt kanalları boyunca ve meme lenfatikleri yoluyla oluşur. Memedeki süt kanallarından kaynaklanan kansere duktal karsinom, lobüllerden kaynaklanan kansere ise lobüler karsinom denir. Kanserin memede olduğu bölge genelde üst dış kadrandır. Bunun sebebi bu kadranda daha fazla meme dokusunun olmasıdır. Meme kanserindeki risk faktörleri aşağıda sıralanmıştır [15].

Genetik faktörler:

- Cinsiyet
- Yaş
- Ailede meme kanseri öyküsü

Üreme ile ilgili faktörler:

- Menarş yaşı
- Menapoz yaşı
- İlk hamilelik yaşı

Hormonal faktörler:

- Östrojen tedavisi
- Memenin iyi huylu lezyonları

Yaşam şekli ve çevresel faktörler:

- Alkol ve sigara kullanımı
- Sosyoekonomik seviyenin yüksekliği
- Radyasyona maruz kalma

Meme kanserinin en yaygın belirtisi meme dokusunda rastlanan kitlelerdir. Nadiren görülen bir belirti ise genellikle kanlı olan meme başı akıntısıdır. Kanser ilerleyen safhalarında ise ağrı hissedilir. Meme kanserinde tanı; fizik muayene, mamografi ve biyopsi yardımıyla konur. Meme kanserine erken aşamada tanı konması, tedavi seçeneklerinin sayısını, tedavinin sonuç vermesi ve hayatta kalma şansını önemli oranda artırır. Fizik muayenede memelerin büyüklüğü, simetrisi, üzerinin ve kenarlarının görünümü, deride renk değişikliği, ödem ve meme başlarına bakılır. Mamografi ise memeye uygulanan röntgen tekniğidir. Biyopsi alanını belirler. Biyopsi ile meme hastalıklarında kesin teşhis konulur. Biyopsi; meme dokusundan hücreler alınıp laboratuvar ortamında incelemesidir.

2.3. MEME GÖRÜNTÜLEME TEKNOLOJİLERİ

Meme hastalıklarının görüntülenmesinde bugün rutin uygulamalarda en sık kullanılan yöntemler; mamografi, ultrasonografi ve son yıllarda daha çok uygulama alanı bulan manyetik rezonans görüntülemesidir. Mamografi günümüzde yüksek teknolojiye sahip diğer görüntüleme yöntemlerine rağmen meme kanserinin erken tanısında en iyi görüntüleme yöntemidir [16].

2.3.1. X-Işınları

Görüntüleme yöntemlerinin kaynağını oluşturan X-ışınları ilk kez 1895 yılında Alman fizikçi Wilhelm Conrad Röntgen tarafından ortaya çıkarılmıştır. Böylece radyoloji adında yeni bir bilim dalı doğmuştur. X-ışınının özelliği, maddeyi geçebilme yani penetrasyondur. X-ışınlarının meydana getirildiği insan yapısı aygıtlara X-ışını tüpleri ya da röntgen tüpü adı verilmektedir. Bu tüplerin; havası boşaltılmış cam bir kap, ısıtılan bir katot, elektronların çarptırıldığı hedef anot ve elektronların eksi uçdan artı

uca gitmesini sağlayan yüksek gerilimli çevrimden oluşan bileşenleri bulunmaktadır. X-ışını tüplerinde eksi uçtan salınan elektronların gitmesi gereken artı uç X-ışını tüpünün pozitif tarafını oluşturur. Artı uç, yüksek erime noktası ve atom numarasına sahip maddelerden yapılmış olup bu amaçla genellikle Tungsten seçilir. Tungsten X-ışınının daha güçlü üretilmesi, daha yüksek ısı iletimi, daha fazla elektron içermesi için gereklidir [17]. Mamografi cihazlarında ise daha yumuşak X-ışını gerektiğinden artı uça Molibden ya da Rhodium kullanılmıştır.

2.3.2. Mamografi

Mamografi, meme kanseri taraması için kullanılan, konvansiyonel ve dijital olmak üzere iki ayrı tipi bulunan bir görüntüleme yöntemidir. Memenin yumuşak dokusunu ve değişikliklerini ortaya çıkarmaktadır. Röntgen tabanlı olan mamografi cihazları memeyi X-ışınları göndererek incelerler.

Meme kanserlerinde görülen mamografik bulgular genel olarak kitle, mikrokalsifikasyonlar, cilt ve meme başında olan değişiklikler, yoğun, büyük ve yuvarlak şekilli lenf nodlarıdır. Kitleler şekil, dansite (yoğunluk) ve kenar gibi özellikleriyle kategorize edilirler. Şekilleri yuvarlak, oval, yuvarlak çıkıntılı ve düzensiz olabilir. Yoğunlukları yüksek yoğunluklu, düşük yoğunluklu, eşit yoğunluklu ve yağ içerikli olabilir. Kenarlar düzgün kenarlı (circumscribed) veya tırtıklı olabilir [18]. Bu kategoriler radyoloji uzmanlarının kitlelerin benign veya malign oldukları konusunda karar vermelerini kolaylaştırır. Genellikle düzgün kontür iyi huyluluğu, tırtıklı (düzensiz - spiküler) kontür ise kötü huyluluğu işaret eder [19].

Mamografi farklı pozisyonlarda çekilmektedir [20-24]. Kraniokaudal (CC) pozisyon, memenin standart transvers pozisyonudur. Mediolateral- Oblik (LO) pozisyonda, pectoralis major kası, memenin alt kısmı ve kuyruk kısmı görüntülenebilir. Böylece memenin arka kısımlarının en iyi şekilde görüntülenmesi sağlanır [22,24]. Medio-Lateral (ML) pozisyonda ise memenin arka ve kuyruk kısımları tam olarak görüntülenmez. Ancak ML pozisyonda lezyon ile glandüler dokunun pozisyonu ayırt edilir. ML görüntü üst- iç kadranın üst kısımlarındaki lezyonları oblik pozisyonundan daha iyi gösterir.

2.3.2.1. Konvansiyonel Mamografi

Konvansiyonel mamografide görüntü düşük enerjili röntgen ışınları ve kompresyon yardımıyla röntgen filmi üzerine düşürülür. Kompresyon radyasyonun saçılımını azaltmada önemli bir faktördür. Kompresyonla dokular birbirinden ayrılır ve parankimdeki küçük lezyonlar daha kolay ayırdedilir. Ayrıca kompresyon memeye gelen radyasyon dozunu da azaltır [16]. Memeyi oluşturan yumuşak dokular arasındaki dansite farklılıkları, röntgen ışınının farklı absorpsiyonuna neden olur. Sert dokular ışını daha fazla tuttuğu için filmde daha beyaz gözüktürler. Yumuşak dokular ise ışını daha fazla geçirdiği için daha koyu renkte gözüktürler. Mamografik görüntü almada normal röntgen tüpünden farklı olarak anod materyali Molibden olan X- Ray tüpleri kullanılır. Yüksek çözünürlük gerektiği için fokal spot büyüklüğünün özel önemi vardır. Bu büyüklük bulanıklaşmayı azaltmak için olabildiğince küçük tutulur. Aynı şekilde meme ile görüntü reseptörü arasındaki uzaklık da olabildiğince küçük olmalıdır [16,25]. Konvansiyonel mamografi dijital mamografiye göre daha ucuzdur. Fakat çeşitli dezavantajları bulunmaktadır. Bunlardan en sık ortaya çıkanı, filmlerin hem dedektör hem de görüntüleme ortamı olması sebebiyle film ve banyoya ait teknik aksaklıkların kontrast ve uzaysal çözünürlüğü direkt etkilemesidir. Görüntünün bir kez oluşturulduktan sonra değiştirilememesi de bir dezavantajdır.

2.3.2.2. Dijital Mamografi

Dijital mamografide dijital teknoloji ile dedektör, görüntüleme ve depolama fonksiyonları birbirinden bağımsız olarak gerçekleştirilir. Böylece bu fonksiyonlar birbirinden bağımsız olarak optimize edilebilir. Analog görüntülerde hastadan elde edilen X-ışını demeti, hem şiddeti hem de uzaysal boyutları devamlılık (continuous) gösteren bir şekilde kaydedilir. Dijital görüntüde ise görüntüyü oluşturan değerler belirli uzaysal aralıklarda ve şiddetlerde kaydedilir. Görüntü kaydı devamlılık göstermez, kesintilidir. Dijital görüntü sabit boyutlarda piksellerden oluşur ve karesel iki boyutlu bir matris şeklinde ortaya çıkar. Bu pikseller birleştiklerinde esas görüntüyü oluşturmak üzere birer görüntü değeri taşır [26]. Dijital dedektör X-ışınlarını absorbe ederek her bir piksel için bir elektronik sinyal oluşturur ve bu elektrik sinyal analog- dijital çeviricide (ADC) yani dönüştürücüde dijital (sayısal) bir değere çevrilir. Daha sonra bu dijital değerler bilgisayar sistemlerinde depolanır. Depolanan dijital değerlerle görüntü oluşur. Her bir değer farklı bir gri-seviye renge denk gelir. Oluşturulan dijital görüntü istendiği

zaman hafızadan geri çağrılabilir. Şekil 2.2 de bir dijital mamografi cihazı görülmektedir.



Şekil 2.2: Dijital mamografi cihazı [27]

Dijital mamografinin en önemli avantajı, görüntülerin değerlendirilmesi esnasında kontrast ve çözünürlüğün radyolog tarafından istenildiği gibi ihtiyaca uygun olarak değiştirilebilmesidir. Ayrıca en küçük kontrast farklılıkları bile kolayca saptanıp amplifiye edilebilir, dijital alıcıların üzerine düşen ışıkla (exposure) ilgili hataları en aza indirilebilir. Görüntüler daha kolay depolanır ve merkezler arasında transfer edilebilir. Hastanın maruz kaldığı radyasyon %30 ile %50 oranında daha azdır. Ayrıca bilgisayar destekli tanıya (computer aided diagnosis) imkan sağlar. Buna karşın dijital mamografinin dezavantajları da bulunmaktadır. Bu dezavantajlar arasında uzaysal çözünürlüğün sınırlı olması ve birbirine komşu ve kontrast farkı fazla olan yapıların görüntülenmesinde artefakt oluşması vardır. Ayrıca kitlelerin sınırlarını, mikrokalsifikasyonları ve bunların karakterlerini saptamak için gereken yüksek çözünürlük, dijital mamografi cihazlarında yeterince sağlanamamaktadır [26,28]. Meme görüntüleme ile ilgili tüm çalışmalar, meme kanserinin erken tanısına katkıda

bulunmayı ve bunu yaparken hastalara verilebilecek radyasyonun minimal olmasını amaçlamaktadır. Dijital mamografi bilgisayar destekli tanıya olanak sağladığı için erken tanıya çok büyük katkı sağlamaktadır.

2.3.4. Meme Ultrasonografisi

Ultrasonografi (US), meme hastalıklarının tanısında kullanılan önemli bir görüntüleme yöntemidir. US, vücuda yüksek frekanslı ses dalgaları gönderip, farklı doku yüzeylerinden yansımalarını saptama temeline dayanır. Mekanik enerji halindeki ultrases insan işitme sisteminin duyabileceğinden (20 kilohertz) daha fazla frekansa sahiptir. Bir transdüser tarafından oluşturulan kısa süreli bu ultrases, görüntülenmek istenen dokuyla direkt temas ettirilir. Bu transdüserler uzaysal çözünürlükten ödün vermeden 4-5 cm derinliğinde doku penetrasyonu sağlayabilmektedir. Dokuya ulaşan ses vücuttaki yapılardan yansır ve ekolar oluşturur. Yansıyan ses dalgaları transdüsera ulaşır ve transdüserde bulunan elemanları titretir. Bu titreşim elektrik darbelerine dönüşür, bu darbeler işlenir ve bir ultrasonik görüntüye dönüştürülür. Ultrason tarayıcısı görüntünün oluşturulabilmesi için elde edilen ekodan görüntüdeki hangi pikselin açık renk, hangisinin de koyu renkte olacağına karar verir. US, genellikle mamografide şüpheli bulgu varsa, yüzeye yakın kitlelerin içinde sıvı olup olmadığını anlamak için yapılır.

2.3.5. Magnetik rezonans görüntüleme

Magnetik rezonans görüntüleme (MR) bir kesit görüntüleme yöntemidir [29]. Manyetik alanda magnetin gönderdiği Radyofrekans (RF) olarak isimlendirilen radyo dalgalarının hücreleri uyarak hidrojen atomlarının enerji üretmesi ile oluşur. Üretilen bu enerji sargı arabirimleri tarafından sayılara dönüştürüldükten sonra bilgisayar tarafından işlenip görüntüye dönüştürülür. MR yönteminin önemli bir avantajı hastanın pozisyonunu değiştirmeden her düzlemde görüntü alabilmesidir. Ayrıca yüksek yumuşak doku kontrastına sahiptir ve ionize radyasyon içermemektedir [30]. MR, mamografi, US veya fizik muayene bulguları arasında uyumsuzluk olan ya da bu yöntemler ile kesin olarak karar verilemeyen olgularda, memede kanıtlanmış malignite olduğunda, yüksek riskli hastalarda tarama amacıyla, kanser, kalp ve damar rahatsızlıkları, eklem ve kas-iskelet düzensizlikleri gibi patolojik durumlarda geniş bir kullanım alanına sahiptir. MR ile kemiklerin yakınındaki ve çevresindeki yumuşak

dokuların çok temiz görüntülerini elde etmek mümkün olduğu için özellikle diz, omuz ve bilek gibi eklemlerin etkilendiği spor yaralanmalarında kullanılmaktadır [30]. Kısaca MR, diğer görüntüleme yöntemleri ile görülemeyecek bazı vücut yapılarının değerlendirilmelerine imkan sağlar.

2.4. MEME KANSERİYLE İLGİLİ BİLGİSAYAR DESTEKLİ TANI ÇALIŞMALARI

Mamografi görüntüleme teknolojilerinin gelişmesi ve dijital mamografinin yaygınlaşması ile son yıllarda meme kanserini tespit etme ve tanı koyma amaçlı birçok BDT çalışması geliştirilmiştir. Kullanılan yöntemler çok çeşitli olup amaç radyoloğa yardımcı olacak ikinci bir araç geliştirmektir.

Sankar ve ark. [31] mamografilerde meme kitlelerini tespit etmek için Kalman filtreleri ve Geri Yayılımlı Yapay Sinir Ağları (Back Propagation Neural Networks) yöntemlerini birleştirmişlerdir. Kitle tespit performansı yeterli olmakla birlikte görüntü başına düşen yanlış pozitif (YP) oranı 3.15'in altına inememiştir. Dalgacık Dönüşümü yöntemi ortaya atıldığından bu yana dijital mamografi alanında görüntü işlemede etkili çözümler üretmiştir [32-35]. 2008 yılında Karahaliou ve ark. [32] dijital mamogramlarda mikrokalsifikasyon kümelerinin (microcalcification clusters) dokusal yapılarını incelemişlerdir. Çalışmada, Tarama Mamografisi Dijital Veritabanı'ndan 85 yoğun mamografik görüntü alınmıştır. Bunlardan 46'sı benign yapıdadır. Temel amaç meme kanseri tanısı için ilgili alanları (Region of Interests) arka plandan ayırmaktır. Bunun için üç seviye Dalgacık Dönüşümü metodu kullanılmıştır. Elde edilen katsayı matrisleri öznitelik kümeleri olarak kullanılmış ve Yapay Sinir Ağları'na (YSA) verilmiştir. Sonuç olarak mamogramlardaki mikrokalsifikasyonların benign veya malign olduğuna karar verilmiştir. Geliştirilen sistemin sınıflandırma başarısı %86 olarak hesaplanmıştır. 2005 yılında Hwang ve ark. [33] mamografik verilerde öznitelik çıkarımından önce Haar Dalgacık Dönüşümü'nü uygulamışlardır. İstatistiksel ayrıştırma çözümlemesi (discriminant analysis), YSA ve SVM yöntemlerinin kombinasyonunun kullanıldığı çalışmada en yüksek performans %91'e ulaşmıştır. Ancak yöntem karmaşıklığından dolayı sistemin hızı nispeten düşük çıkmıştır.

2007 yılında Kom ve ark. [36] mamografik görüntülerde kitle tespit etme çalışması geliştirmişlerdir. Mamogramlar, kitle tespitinden önce görüntü ön işleme ve bölütleme aşamalarından geçmiştir. Kullandıkları 61 adet mamogramdan oluşan veritabanında kitleler uzman radyologlar tarafından önceden belirlenmiştir. Bu çalışmada öncelikle doğrusal filtre kullanılarak piksellerin lokal kontrastları güncellenerek görüntü iyileştirme yapılmıştır. Daha sonra orjinal görüntüden iyileştirilmiş görüntü çıkarılarak mamogramlar bölütlenmiştir. Son olarak da lokal adaptif eşikleme kullanılarak kitleler tespit edilmiş, medyan filtre ile gürültü temizlenmiştir. Elde edilen sonuçlarda; %95.91 duyarlılık, %93.87 seçicilik ve 0.946 ROC puanı elde edilmiştir. 2006 yılında Yu ve ark. [37] MIAS veritabanını kullanarak dijital mamogramlarda mikrokalsifikasyon kümelerinin tespitini gerçekleştirmişlerdir. Çalışma üç aşamalı olup, 20 mamogram kullanılmıştır. İlk aşamada şüpheli bölgeleri bulmak için Dalgacık Dönüşümü ve iki eşik değeri kullanılmıştır. İkinci aşamada Markov Rasgele Alanı yöntemiyle dokusal öznitelikler çıkarılarak mikrokalsifikasyonlar tespit edilmiştir. Üçüncü aşamada ise bulunan mikrokalsifikasyonların GP mi yoksa YP mi olduğuna dair sınıflandırmadır. Bunun için Geriye Yayılımlı Sinir Ağları (Backpropagation Neural Network) kullanılır. Elde edilen sonuçlarda; 0.87 ROC puanı elde edilirken, YP_{kitle} 0.65'in altına düşmemiştir. 2011 yılında Hu ve ark. [38] MIAS veritabanından aldıkları 170 mamogramı kullanarak kitle tespit etme çalışması geliştirmişlerdir. Geliştirilen çalışmada Dalgacık dönüşümleri ile adaptif global ve adaptif lokal eşikleme ile bölütleme yapılmıştır. Öncelikle Dalgacık Dönüşümü'nden geçirilmiş orjinal mamogramlara ait olasılık yoğunluk fonksiyonu eğrilerinin global olarak minimumlarına bakılarak eşik değeri belirlenmiştir. Histogram tabanlı adaptif global eşikleme algoritması ile bölütleme gerçekleştirilmiştir. Daha sonra mamogramın bölütlenmiş hali ile morfolojik filtreleme uygulanarak iyileştirilmiş hali arasında konvolüsyon yapılmıştır. Bir sonraki adımda ise bölütleme, pencere kullanılarak adaptif lokal eşikleme ile optimum hale getirilmiştir. Elde edilen sonuçlara göre görüntü başına düşen YP kitle sayısı (YP_{kitle}) 0.71, duyarlılık %91.3'tür. 2011 yılında Fraschini [39], Güney Florida Üniversitesi'ne ait Dijital Tarama Veritabanı (Digital Database for Screening Mammography - DDSM) [40] mamogramlarından alınan 72'si malign, 52'si benign olmak üzere toplam 124 kitle üzerinde malign-benign sınıflandırma çalışması yapmışlardır. Bu çalışma sinyal seçme (boyut azaltma), öznitelik çıkarma ve sınıflandırmadan ibarettir. Sinyal seçme ile ilgili alanlardan (ROIs) tek boyutlu

sinyaller almaktan ibarettir. Bu tek boyutlu sinyallerden oluşan ve görüntüyü temsil eden matrisler öznitelik çıkarma aşamasında Dalgacık Dönüşümü'nden geçirilmişlerdir. Elde edilen yaklaşıklık ve ayrıntı katsayıları öznitelik olarak kullanılmış, sınıflandırma aşamasında da Yapay sinir Ağları yönteminden faydalanmışlardır. Sonuç olarak; %94.4 duyarlılık, %84.6 seçicilik ve 0.91 ROC puanı elde etmişlerdir.

Son yıllarda Küresel Dalgacık Dönüşümü (KDD) ile ilgili yeni çalışmalar ortaya çıkmıştır. Ancak yeni bir teknoloji olmasından dolayı KDD çalışmaları sayı bakımından yetersizdir. Biyomedikal görüntü işleme uygulama alanındaki çalışmalardan ilki 2001 yılında Greenshields'in [41] geliştirdiği çalışma olarak gösterilebilir. Bu çalışmada pelvis kemiği görüntülerine KDD uygulanmış, ve altbantlar elde edilmiştir. Burada amaç ayrıştırma (decomposition) yardımıyla kemik üzerinde şekil analizi yapmaktır. 2007 yılında Nain ve ark. [42] parametrik olmayan permütasyon testlerinin kullanımı ve KDD tabanlı, istatistiksel yüzeye bağlı şekil ve yapı ölçümü (mofometri) ile ilgili bir çalışma geliştirmişlerdir. Uygulamada 56 şizofren hastanın beyin görüntüleriyle 26 sağlıklı hastanın beyin görüntüleri incelenmiştir. Amaç; sağlıklı ve sağlıklı olmayan vakalarda beyin yapısını hipokampus ve caudatum olmak üzere iki ayrı bölgede yapısal olarak karşılaştırmaktır. Elde edilen sonuçlara göre KDD'nin ölçek-uzay (scale-space) ayrıştırması, çeşitli ölçek ve uzaysal bölge farklılıklarını tanımlayan birtakım şekilsel öznitelikleri ortaya çıkarır. Bu öznitelikler noktasal dağılım modeli (PDM) ile elde edilen lokal özniteliklere ek olarak kullanılmış ve yapısal ayırmda etkin sonuçlar ürettiği görülmüştür. 2007 yılında Peng Yu ve ark. [43] manyetik rezonans (MR) görüntülerini kullanarak KDD ile beynin kortikal yüzeyine ait öznitelikler çıkarmışlardır. Öznitelikler üzerinde Temel Bileşen Analizi (Principal Component Analysis-PCA) uygulanmıştır. KDD ile ölçek darlaştıkça yani ayrıştırma (decomposition) seviyesi arttıkça MR görüntülerindeki ayrıntılar ön plana çıkmış, şekil üzerindeki farklılık ve sapmaların yeri saptanabilmiştir. 2009 yılında Seghouane ve ark. [44] 117 tane BT (bilgisayarlı tomografi) kolon görüntüsü kullanarak çoklu çözünürlüklü görüntü işleme uygulaması geliştirmişlerdir. Amaç kıvrımlı (curvature) kolon bölgelerinde öznitelik çıkarımı yaparak polip tespit etmektir. Kolon duvarlarındaki konveks şekiller polioplere benzediği için yanlış pozitif (YP) sayısı fazla olabilmektedir. Kullanılan KDD ile bu YP polip sayısını azaltmak hedeflenmiştir. Elde edilen sonuçlara göre 10 mm den büyük polioplere seçicilik (specificity) %93'e

çıkarılırken, 5 ile 10 mm arasındaki poliplerde %96'ya çıkarılmıştır. 2010 yılında Kezele ve ark. [45] fiber yönlenmelerini doğru olarak saptamak ve Yönlenme Dağılım fonksiyonunu (Orientation Distribution Function-ODF) elde etmek amacıyla bir çalışma geliştirmişlerdir. Yayılımın karmaşıklığına bağlı olarak; farklı yayılım bölgeleri, HARDI sinyali çoklu frekans bantlarına dağıtan farklı frekans işaretlerini içerebilirler. Bundan dolayı taban fonksiyonları yardımıyla Funk-Radon dönüşümü ile KDD yöntemini kombine eden çoklu ölçek analizi yapılmıştır. KDD yöntemi önce fiber geçidi görevi üstlenen ve fiziksel dokunun elektrik ve termal özelliklerini taşıyan deney malzemesi fantomlara (phantom), daha sonra gerçek beyin görüntülerine uygulanmıştır. Çalışmada, gerçek beyin görüntüler analizi farklı açısız frekansların farklı bilgiler taşıyabileceğini göstermiştir. SWT yöntemiyle yeniden oluşturma sonuçları hem fantom hem de beyin görüntülerinde karşılaştırılmıştır. Elde edilen sonuçlara göre; Yönlenme Dağılım fonksiyonuna ait KDD ayrıştırmasının, filtreleme kullanılarak yüksek frekans bölgelerinde ihtiyaç duyulan keskinliğin sağlandığı görülmüştür. Sadece Yönlenme Dağılım fonksiyonunu (ODF) kullanmak bu konuda yeterli olmamıştır. Sonuç olarak KDD yüksek seviye veri sıkıştırma, gürültü azaltma ve keskinlik sağlamıştır. 2003 yılında Starck ve ark. [46] astronomik görüntülerde Gauss olmayan verinin tespiti ve ayrılması çalışmasını geliştirmiştir. KDD yönteminin astronomide de sıklıkla yer alan küresel şekil görüntülerinde etkin sonuçlar ürettiği görülmüştür.

3. MALZEME VE YÖNTEM

3.1. FOURIER DÖNÜŞÜMÜ

Bu tezde Fourier Dönüşümü (FD) homomorfik filtrelemede kullanılmıştır. FD, Fransız matematikçi Jean Baptiste Joseph Fourier tarafından 1768 yılında geliştirilmiş olup, zaman (uzaysal) alanında bulunan görüntülerin frekans alanına taşınmasını sağlayan matematiksel bir dönüşümdür. Fourier dönüşümü ile periyodik olarak kendini tekrarlayan bir fonksiyon farklı frekanslardaki ve herbiri farklı katsayılarla çarpılmış sinüs ve kosinüslerin toplamlarıyla ifade edilebilir. Fourier dönüşümü de orjinal sinyal gibi periyodiktir. Dönüşüm sonucunda orijinal görüntüde (fonksiyonda) yer alan farklı frekans değerleri hesaplanabilir.

3.1.1. Tek Boyutlu (One Dimensional) Fourier Dönüşümü

Tek değişkenli bir $f(x)$ fonksiyonunun Fourier dönüşümü $F(u)$, aşağıdaki gibi ifade edilir.

$$F(u) = \int_{-\infty}^{\infty} f(x) e^{-j2\pi ux} dx \quad (3.1)$$

Yukarıdaki denklemde $j = \sqrt{-1}$ dir. Ters Fourier Dönüşümü' nde (Inverse Fourier Transform) $F(u)$ kullanılarak $f(x)$ elde edilir.

$$f(x) = \int_{-\infty}^{\infty} F(u) e^{j2\pi ux} du \quad (3.2)$$

Fourier dönüşümü aşağıdaki denklemde görüldüğü gibi doğrusallık özelliği gösterir.

$$\mathfrak{F}[af_1(x) + bf_2(x)] = aF_1(u) + bF_2(u) \quad (3.3)$$

Görüntü işlemede kullanılan Fourier dönüşümü iki boyutlu dönüşüm olup, $f(x, y)$ görüntüsünün Fourier dönüşümü aşağıdaki gibidir.

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j2\pi(ux+vy)} dx dy \quad (3.4)$$

Fourier dönüşümünü bilgisayar ortamında hesaplayabilmek için ayrı olarak elde etmek gerekmektedir. Tek değişkenli M boyutlu bir $f(x), x = 0, 1, 2, \dots, M-1$ fonksiyonun Ayrık Fourier Dönüşümü (AFD) (Discrete Fourier Transform) denklemi aşağıda görüldüğü gibi farklı toplamlardan oluşur.

$$F(u) = \frac{1}{M} \sum_{x=0}^{M-1} f(x) e^{-j2\pi ux/M} \quad u = 0, 1, 2, \dots, M-1 \quad (3.5)$$

Başlangıç olarak üstel terimdeki $u = 0$ alınır ve tüm x değerleri için toplam bulunur ve $u = M-1$ olana kadar işlem devam ettirilerek AFD hesaplanmış olur. Üstel terimin hesaplanmasında Euler formülü kullanıldığında Fourier dönüşümünün kosinüs ve sinüs toplamlarından oluştuğu görülmektedir. Euler formülü:

$$e^{j\theta} = \cos \theta + j \sin \theta \quad (3.6)$$

Euler formülü AFD'de yerine konulursa,

$$F(u) = \frac{1}{M} \sum_{x=0}^{M-1} f(x) [\cos 2\pi ux/M - j \sin 2\pi ux/M] \quad (3.7)$$

elde edilir. Denklem 3.7 deki kosinüs ve sinüsler farklı frekanslardadır.

3.1.2. İki Boyutlu Ayrık Fourier Dönüşümü ve Frekans Alanında Filtreleme

İki boyutlu bir $f(x, y)$ görüntüsünün AFD denklemi aşağıda verilmiştir.

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi(ux/M + vy/N)} \quad (3.8)$$

Fourier dönüşümünü $M/2, N/2$ merkezine taşımak için dönüşümden önce $f(x, y)$ fonksiyonu $(-1)^{x+y}$ ile çarpılır. Bilindiği gibi, $M \times N$ boyutlu $f(x, y)$ ve $h(x, y)$ fonksiyonlarının konvolüsyonu,

$$f(x, y) * h(x, y) = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f(m, n) h(x-m, y-n) \quad (3.9)$$

şeklinde ifade edilir. Uzaysal alanda hesaplanan bu konvolüsyon işlemi AFD kullanılarak da gerçekleştirilebilir.

$$f(x, y) * h(x, y) = \mathfrak{F}^{-1}[F(u, v)H(u, v)] \quad (3.10)$$

Yukarıdaki formülde çarpma işlemi birbirine karşılık gelen matris elemanlarının çarpılması olup; $H(u, v)$, $h(u, v)$ filtresine Fourier dönüşümü uygulanmış şeklidir. Ters Fourier dönüşümü ile $f(x, y)$ görüntüsü frekans alanında filtrelenmiş olur.

3.2. HOMOMORFİK FİLTRELEME

Bu tezde Homomorfik Filtreleme (HF) görüntü iyileştirmede kullanılmıştır. HF ile bir $f(x, y)$ görüntüsü i aydınlık (illumination) ve r yansıtma (reflectance) bileşenleri ile incelenir. i görüntüdeki alçak frekansı, r ise yüksek frekansı temsil eder [47].

$$f(x, y) = i(x, y)r(x, y) \quad (3.11)$$

$f(x, y)$ görüntüsünün Fourier dönüşümü;

$$F\{f(x, y)\} \neq F\{i(x, y)\}F\{r(x, y)\} \quad (3.12)$$

olduğundan, aydınlık ve yansıtmanın ayrı ayrı Fourier dönüşümü için logaritmadan faydalanılır.

$$\begin{aligned} z(x, y) &= \ln f(x, y) \\ \ln f(x, y) &= \ln i(x, y) + \ln r(x, y) \end{aligned} \quad (3.13)$$

Logaritması alınan görüntünün Fourier dönüşümü $Z(u, v)$ 'dir. Bu dönüşüm bir $H(u, v)$ homomorfik filtresi ile filtrelendiğinde $S(u, v)$ elde edilir. $S(u, v)$ fonksiyonuna ters Fourier uygulandığında ise $s(x, y)$ 'ye ulaşılır.

$$Z(u, v) = F_i(u, v) + F_r(u, v) \quad (3.14)$$

$$S(u, v) = H(u, v).F_i(u, v) + H(u, v).F_r(u, v) \quad (3.15)$$


$$s(x, y) = F^{-1}\{H(u, v).F_i(u, v)\} + F^{-1}\{H(u, v).F_r(u, v)\} \quad (3.16)$$

Denklem 3.16 daki toplamlardan birine $i'(x, y)$, diğerine $r'(x, y)$ yazıldığında aşağıdaki eşitliğe ulaşılır.

$$s(x, y) = i'(x, y) + r'(x, y) \quad (3.17)$$

Filtrelenmiş görüntü $g(x, y)$ olup, $s(x, y)$ fonksiyonunun ters logaritması alınarak bulunur. Denklem 3.18 de görüldüğü gibi, aydınlık ve yansıtma bileşenlerine bağlı bir $g(x, y)$ görüntü fonksiyonu elde edilir. Şekil 3.1 de homomorfik filtrelemenin blok diyagramı gösterilmiştir.

$$\begin{aligned} g(x, y) &= e^{s(x, y)} \\ &= e^{i'(x, y)} \cdot e^{r'(x, y)} \end{aligned} \quad (3.18)$$



Şekil 3.1: Homomorfik filtre blok diyagramı


3.3. DALGACIK DÖNÜŞÜMÜ

Bu tezde Dalgacık Dönüşümü görüntü iyileştirme ve malign-benign sınıflandırmada kullanılmıştır. Dalgacık dönüşümü, Fourier dönüşümünden sonra geliştirilmiş olup görüntü sıkıştırma, iletim ve analiz işlemlerinin daha kolay yapılmasını sağlayan bir teknolojidir. Sinüsoidlerden oluşan Fourier dönüşümünden farklı olarak, farklı frekans ve sonlu süreli dalgacıklardan oluşur. Dalgacık dönüşümünde yalnızca işaretlerin frekans bilgisi değil, frekansın oluştuğu zamana ait bilgi de korunmuş olur. Dalgacık fonksiyonları ilk kez 1987’de Mallat tarafından geliştirilen çoklu çözünürlük (Multiresolution) teorisi adı altında ortaya atılmıştır [48]. Çoklu çözünürlük, adından da anlaşılacağı gibi görüntü veya işaretlerin birden fazla çözünürlükte analiz edilmesidir. Bunun başlıca nedeni belli çözünürlükte tespit edilemeyen bir görüntü özelliğinin farklı çözünürlüklerde ortaya çıkabilmesidir. Eğer görüntüde küçük boyutta nesneler varsa veya düşük kontrast mevcutsa, ayrıntıyı yakalamak için yüksek çözünürlük, tersi bir durumun varlığında ise alçak çözünürlük kullanılmalıdır. Ancak tüm gerçek zamanlı

görüntülerde olduğu gibi aynı anda hem küçük hem de büyük objeler yada düşük ve yüksek kontrast varolabilir. Bu durumda çoklu çözünürlük ile analiz yapılması gerekir. Çoklu çözünürlük analizi (Multiresolution Analysis) bir görüntünün çeşitli boyutlardaki yaklaşıklıklarını (approximation) hesaplamak için ölçekleme fonksiyonlarını kullanır.


3.3.1. Altband Kodlama (Subband Coding)

Altband kodlama çoklu çözünürlük analizi ile ilintili bir görüntü işleme tekniğidir. Bu teknik ile altbantlar bant geçiren filtreleme (bandpass filtering) ile elde edilirler ve orijinal görüntüden daha küçük boyuta sahiptirler. Şekil 3.2 de şematik olarak altbant kodlama, Şekil 3.3 de ise ayrıştırma ağacı (decomposition tree) gösterilmektedir. $h_0(n)$ alçak geçiren, $h_1(n)$ yüksek geçiren ayrıştırma (decomposition) filtreleridir. $h_0(n)$ filtresi ile $x(n)$ işaretinin yaklaşıklığı (approximation), $h_1(n)$ ile de ayrıntı (detail) hesaplanır. $g_0(n)$ ve $g_1(n)$ filtreleri ise sırasıyla alçak geçiren ve yüksek geçiren yeniden oluşturma (reconstruction) filtreleridir. Birbirlerinden bağımsız olarak elde edilemeyen bu filtreler dalgacık dönüşümü ve çoklu çözünürlükte kullanılan dördün yansımali filtreler (Quadrature Mirror Filters - QMFs) olup Denklem 3.19 daki kuralı sağlarlar. $n = 0,1,2,\dots,N$ için $x(n)$ ayrık zamanlı işaretinin çıkışı $\hat{x}(n)$ olarak ifade edilmiştir. $\hat{x}(n)$ çıkışı, elde edilen $y_0(n)$ ve $y_1(n)$ ara çıkışları toplanarak elde edilir.



Şekil 3.2: Altband kodlama

$$\begin{aligned} g_0(n) &= (-1)^n h_1(n) \\ g_1(n) &= (-1)^{n+1} h_0(n) \end{aligned} \quad (3.19)$$



Şekil 3.3: Bir işaretin altbantlarına ayrılması: A: Yaklaşıklık (approximation), D: Ayrıntı (detail) katsayıları

3.3.2. Çoklu Çözünürlükte Ölçekleme (Scaling) ve Dalgacık (Wavelet) Fonksiyonları

Çoklu çözünürlükte, bir görüntünün birbirinden ikinin katları kadar büyük veya küçük yaklaşıklıklarını oluşturmak için ölçekleme fonksiyonları (scaling functions) kullanılırken, yaklaşıklıklar arasındaki farkı hesaplamak için dalgacık fonksiyonları (wavelet functions) kullanılır. Ölçekleme fonksiyonu $\varphi(x)$ ile gösterilir:

$$\varphi_{j,k}(x) = 2^{j/2} \varphi_{0,0}(2^j x - k) \quad (3.20)$$

Yukarıdaki denklemde k ; ölçekleme fonksiyonunun x eksenindeki yerini, j ; x eksenini boyunca olan genişliğini, $2^{j/2}$ ise genliğini (amplitude) belirler. Herhangi bir $f(x)$ fonksiyonu Denklem 3.21 deki gibi, açılım fonksiyonlarının doğrusal (linear)

kombinasyonu şeklinde yazılabiliyorsa $\varphi_k(x)$ fonksiyonlarına $f(x)$ in taban (basis) fonksiyonları denir. Bu fonksiyonlar bir V uzayı oluşturlar ($f(x) \in V$).

$$f(x) = \sum_k \alpha_k \varphi_k(x) \quad (3.21)$$

Mallat'ın geliştirmiş olduğu teoreme göre yüksek çözünürlük fonksiyonlarını içeren V altuzayı, kendisinden daha alçak tüm çözünürlük fonksiyonlarını kapsar [48]. Dalgacık Dönüşümü tek bir ana dalgacığı genişleterek işareti farklı ölçeklerde farklı seviyelerde çözünürlüklere ayırıştırıp çoklu çözünürlük analizi sağlar. Tek boyutlu 2^j çözünürlüklü $f(x) \in L^2(R)$ işaretinin çoklu çözünürlüğü V_{2^j} altuzayında $L^2(R)$ 'ye ait bir işaretin ortogonal bir izdüşümü olarak tanımlanır [49].

$$\begin{aligned} V_j &\subset V_{j+1} \\ V_{-\infty} &\subset \dots \subset V_{-1} \subset V_0 \subset V_1 \dots \subset V_{\infty} \end{aligned} \quad (3.22)$$

j arttıkça V_j alt uzayının boyutu artarken, $\varphi_{j,k}(x)$ ölçek fonksiyonu daralır. Buna göre; V_j alt uzayının açılım fonksiyonları, V_{j+1} alt uzayının açılım fonksiyonlarının ağırlıklı toplamları şeklinde yazılabilir.

$$\varphi_{j,k}(x) = \sum_n \alpha_n \varphi_{j+1,n}(x) \quad (3.23)$$

Yukarıdaki eşitlikte α_n yerine ölçekleme fonksiyonu katsayısı $h_{\varphi}(n)$ yazılıp, Denklem 3.20 ye göre $\varphi_{j+1,n}(x)$ açıldığında aşağıdaki eşitliğe ulaşılır.

$$\varphi_{j,k}(x) = \sum_n h_{\varphi}(n) 2^{(j+1)/2} \varphi_{0,0}(2^{j+1}x - n) \quad (3.24)$$

$\varphi(x) = \varphi_{0,0}(x)$ kabul edildiğinde Denklem 3.24, dalgacık dönüşümünün temeli olan çoklu çözünürlük genel denklemine dönüşür.

$$\varphi(x) = \sum_n h_{\varphi}(n) \sqrt{2} \varphi(2x - n) \quad (3.25)$$

Dalgacık fonksiyonları $\psi(x)$ ile gösterilir ve herhangi V_j ile V_{j+1} alt uzayları arasındaki kümesel farkı verir. Bir V uzayı tek bir başlangıç ölçekleme fonksiyonu alt uzayı ile dalgacık fonksiyonlarının alt uzaylarından oluşur. Aşağıdaki eşitlikte $\oplus$ işareti birleşme işaretidir.

$$\begin{aligned} V_{j+1} &= V_j \oplus W_j \\ V &= V_0 \oplus W_0 \oplus W_1 \oplus W_2 \oplus \end{aligned} \quad (3.26)$$

$$\psi_{j,k}(x) = 2^{j/2} \psi_{0,0}(2^j x - k) \quad (3.27)$$

3.3.3. Dalgacık Serisi Açılımları ve Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform)

V uzayına ait bir $f(x)$ fonksiyonu Denklem 3.26 ya göre aşağıdaki şekilde yazılabilir.

$$f(x) = \sum_k c_{j_0}(k) \varphi_{j_0,k}(x) + \sum_{j=j_0}^{\infty} \sum_k d_j(k) \psi_{j,k}(x) \quad (3.28)$$

Burada; j_0 başlangıç ölçeği, $c_{j_0}(k)$ ve $d_j(k)$ değerleri ise sırasıyla ölçekleme ve dalgacık fonksiyonu katsayılarıdır. Bu katsayılar görüntü fonksiyonu $f(x)$ ile ölçekleme ve dalgacık fonksiyonlarının integrali alınarak hesaplanabilir.

$$\begin{aligned} c_{j_0}(k) &= \int f(x) \varphi_{j_0,k}(x) dx \\ d_j(k) &= \int f(x) \psi_{j,k}(x) dx \end{aligned} \quad (3.29)$$

Yukarıdaki integral çifti toplamalar şeklinde yazıldığında;

$$W_\varphi(j_0, k) = \frac{1}{\sqrt{M}} \sum_x f(x) \varphi_{j_0,k}(x) \quad (3.30)$$

$$W_\psi(j, k) = \frac{1}{\sqrt{M}} \sum_x f(x) \psi_{j,k}(x) \quad (3.31)$$

elde edilir. Bu denklemler ayırık dalgacık dönüşümü denklemleridir. Denklem 3.29 daki $c_{j_0}(k)$ ve $d_j(k)$ yerine $W_\varphi(j_0, k)$ ve $W_\psi(j, k)$ yazılmıştır.

3.3.4. Sürekli Dalgacık Dönüşümü (SDD) (Continuous Wavelet Transform)

Sürekli Dalgacık Dönüşümü, dalgacığın ölçeğinin değiştirilip, zamanda ötelenmesiyle gerçekleşir. SDD ile sürekli bir sinyal, öteleme (τ) ve ölçekleme (s) değişkenleri ile ifade edilen bir fonksiyona dönüşür. Böylece işaretin veya görüntünün zaman-frekans analizi etkin şekilde yapılabilir. Sürekli dalgacık dönüşüm formülü Denklem 3.32 ve 3.33 de verilmiştir.

$$W_{\psi}(s, \tau) = \int_{-\infty}^{\infty} f(x) \psi_{s, \tau}(x) dx \quad (3.32)$$

$$\psi_{s, \tau}(x) = \frac{1}{\sqrt{s}} \psi\left(\frac{x - \tau}{s}\right) \quad (3.33)$$

3.3.5. Hızlı Dalgacık Dönüşümü (HDD) (Fast Wavelet Transform)

Bu tez çalışmasında dalgacık dönüşümü HDD ile gerçekleştirilmiştir. Amaç sistem kaynaklarını en etkin ve hızlı şekilde kullanmak ve dönüşümü yazılımsal olarak gerçekleştirmektir. Yukarıdaki genel dalgacık dönüşümü formüllerinden faydalanarak çeşitli adımlar gerçekleştirildikten sonra dalgacık dönüşümünün bir filtreleme ve aşağı örneklemeden (downsampling) ibaret olduğu görülür. Buna Hızlı Dalgacık Dönüşümü adı verilmiştir.

Denklem 3.25 de ölçekleme fonksiyonu 2^j kadar ölçeklenip, k kadar ötelendiğinde ve n yerine $m - 2k$ yazıldığında Denklem 3.34 elde edilir [50].

$$\varphi(2^j x - k) = \sum_m h_{\varphi}(m - 2k) \sqrt{2} \varphi(2^{j+1} x - m) \quad (3.34)$$

Aynı işlemler dalgacık fonksiyonu için de uygulanırsa,

$$\psi(2^j x - k) = \sum_m h_{\psi}(m - 2k) \sqrt{2} \varphi(2^{j+1} x - m) \quad (3.35)$$

elde edilir. Denklem 3.31 deki dalgacık fonksiyonu $\psi_{j,k}(x)$ yerine Denklem 3.27 yazılırsa, aşağıdaki eşitliğe ulaşılır.

$$W_{\psi}(j, k) = \frac{1}{\sqrt{M}} \sum_x f(x) 2^{j/2} \psi(2^j x - k) \quad (3.36)$$

Denklem 3.36 da $\psi(2^j x - k)$ yerine ise Denklem 3.35 eşitliği yazılıp düzenlenirse,

$$W_{\psi}(j, k) = \sum_m h_{\psi}(m - 2k) \left[\frac{1}{\sqrt{M}} \sum_x f(x) 2^{j+1/2} \varphi(2^{j+1} x - m) \right] \quad (3.37)$$

$$W_{\psi}(j, k) = \sum_m h_{\psi}(m - 2k) W_{\varphi}(j + 1, m) \quad (3.38)$$

Denklem 3.38, Denklem 3.39 da verilen konvolüsyon eşitliklerine benzer.

$$\begin{aligned} h_0(n) * x(n) &= y(n) \\ y(n) &= \sum_k h_0(n - k) x(k) \end{aligned} \quad (3.39)$$

Böylece HDD katsayı denklemleri elde edilmiş olur.

$$\begin{aligned} W_{\psi}(j, k) &= h_{\psi}(-n) * W_{\varphi}(j + 1, n) \\ W_{\varphi}(j, k) &= h_{\varphi}(-n) * W_{\varphi}(j + 1, n) \end{aligned} \quad (3.40)$$

3.3.6. İki Boyutlu Dalgacık Dönüşümü (2-D Wavelet Transform)

İki boyutlu dalgacık dönüşümünü ayırık olarak gerçeklemek için 2 boyutlu ölçekleme fonksiyonları $\varphi(x, y)$ ile dikey, yatay ve diyagonal dalgacık fonksiyonları $\psi^D(x, y)$, $\psi^Y(x, y)$ ve $\psi^{DY}(x, y)$ elde edilmelidir [51]. Bunun için aşağıdaki çarpımlar kullanılır.

$$\begin{aligned} \varphi(x, y) &= \varphi(x) \cdot \varphi(y) \\ \psi^Y(x, y) &= \psi(x) \cdot \varphi(y) \\ \psi^D(x, y) &= \varphi(x) \cdot \psi(y) \\ \psi^{DY}(x, y) &= \psi(x) \cdot \psi(y) \end{aligned} \quad (3.41)$$

İki boyutlu ölçekleme ve dalgacık fonksiyonları aşağıda verilmiştir. m satırları, n ise sütunları temsil etmektedir.

$$\begin{aligned}\varphi_{j,m,n}(x,y) &= 2^{j/2} \varphi(2^j x - m, 2^j n - y) \\ \psi_{j,m,n}(x,y) &= 2^{j/2} \psi^i(2^j x - m, 2^j n - y), i = Y, D, DY.\end{aligned}\quad (3.42)$$


İki boyutlu ayrık dalgacık dönüşümü ölçekleme ve dalgacık fonksiyonu katsayıları Denklem 3.43 de verilmiştir.

$$\begin{aligned}W\varphi(j_0, m, n) &= \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \varphi_{j_0, m, n}(x, y) \\ W_{\psi}^i(j, m, n) &= \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \psi_{j, m, n}^i(x, y)\end{aligned}\quad (3.43)$$

Bu katsayılar 2-D ayrık dalgacık dönüşümünü ifade ederler. Bilinen katsayılar ile yeniden oluşturma (reconstruction) işlemi yapılarak orjinal görüntü elde edilir. Bu işlem Ters Dalgacık Dönüşümü (TDD) (Inverse Wavelet Transform) olarak adlandırılır. TDD, Denklem 3.44 de gösterilmiştir.


$$f(x, y) = \frac{1}{\sqrt{MN}} \sum_m \sum_n W\varphi(j_0, m, n) \varphi_{j_0, m, n}(x, y) + \frac{1}{\sqrt{MN}} \sum_{i=Y, D, DY} \sum_{j=j_0}^0 \sum_m \sum_n W_{\psi}^i(j_0, m, n) \psi_{j, m, n}^i(x, y) \quad (3.44)$$

2-D ayrık dalgacık dönüşümünü HDD şeklinde gerçeklemek için filtreler ve aşağı örnekleme (downsampling) kullanılır. Orjinal görüntüde herhangi bir ölçek ile başlanan dönüşüm, istenen adım sayısı kadar devam ettirilir. Görüntünün her aşamada yaklaşıklık ve detay katsayılarını hesaplama işlemine ayrıştırma (decomposition) denir. İstenen adım sayısı J ise ve başlangıç ölçeği j_0 olup, hesaplanan ölçekler $j_0 - 1, j_0 - 2, \dots, j_0 - J$ ile gösterilir. İki boyutlu görüntülerdeki HDD blok diyagramı ve uzaysal gösterimi sırasıyla Şekil 3.4 ve Şekil 3.5 de verilmiştir. $h_{\psi}(-n)$, $h_{\varphi}(-n)$, V_j ve W_j sırasıyla yüksek geçiren filtre, alçak geçiren filtre, yaklaşıklık (approximation) katsayıları uzayı ve ayrıntı (detail) katsayıları uzayını göstermektedir.



Şekil 3.4: HDD blok diyagramı

Görüntü $(j+1)$. ölçekten j . ölçeğe geçtiğinde aşağı örneklemenin etkisiyle boyutları $M/2 \times N/2$ olur (Şekil 3.5).



Şekil 3.5: HDD uzaysal gösterim

3.4. GAUSS-LAPLACE MODELLEME

Gauss-Laplace modellemenin amacı, Dalgacık dönüşümü ile elde edilen katsayıları değiştirme yoluyla gürültü azaltma tekniğine dayanan dalgacık daraltmadır (Wavelet Shrinkage). Doğrusal olmayan bu teknik, gürültüyü azaltırken görüntüdeki kenar bilgisi gibi önemli olan kısımları da ön plana çıkarır. Dalgacık daraltma işlemi; $W_{\psi}^Y, W_{\psi}^D, W_{\psi}^{DY}$ ayrıştırma katsayılarının $\eta^i(x)$, $i = Y, D, DY$ daraltma fonksiyonuyla ayrı ayrı çarpımı ile

gerçeklenir. Böylelikle Denklem 3.45 de de görüldüğü gibi yeni katsayılar elde edilir $(\dot{W}_{\psi}^Y, \dot{W}_{\psi}^D, \dot{W}_{\psi}^{DY})$.

$$\begin{aligned}\dot{W}_{\psi}^Y &= W_{\psi}^Y \eta^Y(x) \\ \dot{W}_{\psi}^D &= W_{\psi}^D \eta^D(x) \\ \dot{W}_{\psi}^{DY} &= W_{\psi}^{DY} \eta^{DY}(x)\end{aligned}\tag{3.45}$$

Dalgacık dönüşümü ayrıntı katsayılarının, gürültü ve önemli kısımları aynı anda içerdiği farzedilerek bu katsayılar iki ayrı şekilde modellenir. İlk modelleme, gürültü denilen bozuk ve gereksiz kısımların σ_{noise} standart sapmalı Gauss dağılımına uygun olduğu kabul edilerek yapılan Gauss modellemesidir. Bu modellemede Denklem 3.46 da verilen Gauss olasılık yoğunluk fonksiyonu (Gaussian probability density function) $p(x | noise)$ kullanılmıştır.

$$p(x | noise) = \frac{1}{\sigma_{noise} \sqrt{2\pi}} e^{-x^2 / 2\sigma_{noise}^2}\tag{3.46}$$

İkinci modelleme; ayrıntı katsayılarında bulunan ve görüntüdeki boyutu küçük ancak kenar, kontür, parlaklık gibi önemli kısımları temsil eden bilginin Laplace dağılımına uygun olduğu kabul edilerek yapılan Laplace modellemesidir. Bu modellemede Denklem 3.47 de verilen Laplace olasılık yoğunluk fonksiyonu (Laplace probability density function) $p(x | edge)$ kullanılmıştır. Bu fonksiyonda N veri sayısını, μ medyanı, b ise maksimum olabilirlik kestirimini (maximum likelihood estimator) göstermektedir.

$$p(x | edge) = \frac{1}{2b} e^{\frac{-|x-\mu|}{b}}, \quad b = \frac{1}{N} \sum_{i=1}^N |x_i - \mu|\tag{3.47}$$

Bu iki olasılık yoğunluk fonksiyonu kullanılarak Bayesian teoremine uygun olarak dalgacık daraltma fonksiyonu oluşturulur.


$$\eta^i(x) = \frac{(1-\lambda)p(x | edge)}{(1-\lambda)p(x | edge) + \lambda p(x | noise)}, \quad i = Y, D, DY\tag{3.48}$$

3.5. KÜRESEL DALGACIK DÖNÜŞÜMÜ (KDD) (SPHERICAL WAVELET TRANSFORM)

Bu tezde Küresel Dalgacık Dönüşümü tespit edilen ilgili alanlara özneliklerini çıkarmadan önce uygulanmıştır. Dalgacık teknolojisinin günümüzde izotropik olmayan özellikler gösteren verileri analiz etmede yetersiz kalması, küresel dönüşümler gibi yeni nesil çoklu ölçekli ayrıştırma biçimlerinin geliştirilmesini sağlamıştır [46,52,53]. İlk olarak, J. Starck ve arkadaşlarının [46] çalışmasında küresel dönüşümün astronomik görüntülerde Gauss olmayan kısımları yakalama ve tespit etmede yararlı olabileceği gösterilmiştir. KDD yeni bir teknoloji olmakla birlikte biyomedikal görüntü işleme, bilgisayar grafikleri gibi küresel nesnelerin söz konusu olduğu alanlarda daha etkindir.

3.5.1. Kutupsal Koordinatlar ve Küre Denklemleri

İçi dolu küre üç boyutlu olup, bu kürenin yüzeyi iki boyutludur. Küresel fonksiyonlar, iki boyutlu S^2 birim küresi üzerindeki kare integral fonksiyonlar uzayı $L_2(S^2)$ 'de tanımlanır. Kutupsal koordinatlarda fonksiyonlar ϕ , θ açıları ile tanımlanır. θ açısı ($0 \leq \theta \leq \pi$) Şekil 3.6 da gösterildiği gibi, z eksenine ile yüzeydeki bir noktanın orjinle birleştirilmesinden oluşan doğru parçasının arasında kalan açıyı, ϕ açısı ($0 \leq \phi \leq 2\pi$) ise bu noktanın xy düzlemine izdüşümünün orjinle birleştirilmesinden oluşan doğru parçası ile x ekseninin arasında kalan açıyı göstermektedir.



Şekil 3.6: Kürede kutupsal koordinat gösterimi

Kutupsal koordinatların kartezyen koordinatlarına çevrilmesi Denklem 3.49 da verilmiştir.

$$\begin{aligned} x &\rightarrow \sin \theta \cos \phi \\ y &\rightarrow \sin \theta \sin \phi \end{aligned} \quad (3.49)$$

Küre yüzeyinde bir $f(\theta, \phi)$ fonksiyonu kare integralle aşağıdaki şekilde ifade edilebilir.

$$\int_0^{2\pi} \int_0^\pi f(\theta, \phi) \sin \theta \, d\theta \, d\phi \quad (3.50)$$

Küresel fonksiyonların küresel harmoniklerin doğrusal kombinasyonu halinde yazılması ile çoklu çözünürlüğe ulaşılır. Küresel harmoniklerin temeli P_l^m Legendre polinomlarına dayanır. Legendre polinomları $\{-1,1\}$ arasında tanımlı olup, ortogonal polinomların alt kümesi olan ortonormal taban fonksiyonları ailesine dahildir. l ve m ($0 < m < l$) parametreleri sırasıyla fonksiyon bantlarına bölünmüş polinomların bant seviyesini ve sırasını gösterir. 5. seviyeye kadar olan Legendre fonksiyonları aşağıda verilmiştir:

$$\begin{aligned} 1, & \quad l = 0 \\ x, & \quad l = 1 \\ \frac{1}{2}(3x^2 - 1), & \quad l = 2 \\ \frac{x}{2}(5x^2 - 3), & \quad l = 3 \\ \frac{1}{8}(35x^4 - 30x^2 + 3), & \quad l = 4 \\ \frac{1}{8}(63x^5 - 70x^3 + 15x), & \quad l = 5 \end{aligned} \quad (3.51)$$

$Y_l^m(\theta, \phi)$ ($l \in R^+$, $-l \leq m \leq l$) şeklinde gösterilen küresel harmonikler ortonormal bir taban oluştururlar. Küresel harmonikler döndürmeden bağımsız olup, $m = 0$ durumunda x eksenine göre simetriklerdir. Denklem 3.52, küresel harmonik genel denklemdir [54].

$$Y_l^m(\theta, \phi) = \begin{cases} \sqrt{2} K_l^m \cos(m\phi) P_l^m \cos(\theta), & m > 0 \\ \sqrt{2} K_l^m \sin(-m\phi) P_l^{-m} \cos(\theta), & m < 0 \\ K_l^0 P_l^0 \cos(\theta), & m = 0 \end{cases} \quad (3.52)$$

$$K_l^m = \sqrt{\frac{(2l+1)(l-|m|)!}{4\pi(l+|m|)!}} \quad (3.53)$$

Bu tez çalışmasında KDD 5. seviyeye kadar gerçekleşmiştir. Ölçekleme fonksiyonu φ_j^{lc} için Shannon [55] fonksiyonu S_n kullanılmıştır. l_c kırılma frekansını, $n = 5$ ise KDD seviyesini göstermektedir.

$$S_n(x) = |x|^{-n-1} \frac{2n+1}{4\pi} P_n^0(x) \quad (3.54)$$

$$\varphi_{j=0}^{lc} = \frac{3}{2} S\left(\frac{2l}{lc}\right) \quad (3.55)$$

Denklem 3.55 ilk seviyedeki ölçekleme fonksiyonuna ait olup, diğer seviyedekiler Denklem 3.20 ye göre hesaplanmıştır. Ölçekleme fonksiyonları Denklem 3.42 deki gibi, küresel harmoniklerin doğrusal kombinasyonu şeklinde yazılabilmektedir. $\hat{\varphi}_j$, ölçekleme fonksiyonu katsayılarını göstermektedir [56].

$$\varphi_{j=0}^{lc}(\theta, \phi) = \sum_{j=0}^n \hat{\varphi}_j^{lc}(l, 0) Y_{l=j, 0}(\theta, \phi) \quad (3.56)$$

$$\hat{\varphi}_j(l, 0) = \varphi_j(\theta, \phi) \cdot Y_{l=j, 0}(\theta, \phi) \quad j = 0, 1, \dots, 5 \quad (3.57)$$

Bilindiği gibi, Denklem 3.58 de verilen dalgacık fonksiyonları ardışık iki ölçekleme fonksiyonunun farkına eşittir [57]. Dalgacık fonksiyonları katsayıları ($\hat{\psi}_j$) da ölçekleme ile aynı şekilde hesaplanmaktadır.

$$\psi_j(x) = \varphi_{j+1}(x) - \varphi_j(x) \quad j = 0, 1, \dots, 5 \quad (3.58)$$

$$\hat{\psi}_j(l, 0) = \psi_j(\theta, \phi) \cdot Y_{l=j, 0}(\theta, \phi) \quad j = 0, 1, \dots, 5 \quad (3.59)$$

Küresel Dalgacık Dönüşümü, ölçekleme ve dalgacık fonksiyonları ile elde edilen yaklaşıklık c_j ve ayrıntı w_j katsayıları ile temsil edilir (Denklem 3.60).

$$f(\theta, \phi) = c_J(\theta, \phi) + \sum_{j=1}^J w_j(\theta, \phi) \quad (3.60)$$

Bu tez çalışmasında KDD sonrasında Denklem 3.60 a göre gerekli olan katsayı kümesi $\{w_1, w_2, w_3, w_4, w_5, c_5\}$ elde edilir. Bunun için öncelikle f görüntüsüyle ölçekleme fonksiyonu katsayılarının konvolüsyonundan faydalanılır.

$$c_0 = \hat{\phi}_{j=0} * f \quad (3.61)$$

Diğer katsayılar içinse HDD'yi anımsatan alçak ve yüksek geçiren filtreler kullanılır. $h_j, \hat{h}_j, g_j$ ve $\hat{g}_j$ sırasıyla alçak geçiren filtre, alçak geçiren filtre katsayıları, yüksek geçiren filtre ve yüksek geçiren filtre katsayılarını temsil etmektedirler.

$$h_j(l, m) = \begin{cases} \frac{\hat{\phi}_{j+1}(l, m)}{\hat{\phi}_j(l, m)}, & l < \frac{l_c}{2^{j+1}} \text{ ve } m = 0 \text{ ise} \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (3.62)$$

$$\hat{h}_j(l, m) = \sqrt{\frac{4\pi}{2l+1}} h_j(l, m) \quad (3.63)$$

Denklem 3.64 uygulanarak yaklaşıklik katsayıları aşağıdaki gibi iteratif yöntemle hesaplanır.

$$c_{j+1} = c_j * \hat{h}_j(l, m) \quad (3.64)$$

$$\begin{aligned} c_1 &= c_0 * \hat{h}_0(l, m) \\ c_2 &= c_1 * \hat{h}_1(l, m) \\ c_3 &= c_2 * \hat{h}_2(l, m) \\ c_4 &= c_3 * \hat{h}_3(l, m) \\ c_5 &= c_4 * \hat{h}_4(l, m) \end{aligned} \quad (3.65)$$

Denklem 3.66 da ise ayrıntı katsayılarının hesaplanmasında, yaklaşıklik katsayıları ile yüksek geçiren filtrenin konvolüsyonu alınır. Yüksek geçiren filtre ve katsayıları sırasıyla Denklem 3.67 ve 3.68 de verilmiştir.

$$w_{j+1} = c_j * \hat{g}_j(l, m) \quad (3.66)$$


$$g_j(l, m) = \begin{cases} \frac{\hat{\psi}_{j+1}(l, m)}{\hat{\phi}_j(l, m)}, & l < \frac{l_c}{2^{j+1}} \text{ ve } m = 0 \text{ ise} \\ 1, & l \geq \frac{l_c}{2^{j+1}} \text{ ve } m = 0 \text{ ise} \\ 0, & \text{Diğer durumlarda} \end{cases} \quad (3.67)$$

$$\hat{g}_j(l, m) = \sqrt{\frac{4\pi}{2l+1}} g_j(l, m) \quad (3.68)$$

3.5.2. Kitlelere Küresel Dalgacık Dönüşümü (KDD) Uygulanması

Bu tez çalışmasında Lokal Merkezden Bölge Büyütme (LMBB) segmentasyon metodu ile elde edilen her kitle KDD'den geçirilmiştir. Amaç, küresel yapıdaki meme kitlelerine uygun olan bu yöntemle farklı çözünürlüklerdeki görüntü bilgilerine ulaşabilmektir. Böylelikle gözden kaçan fakat önem arz eden bölgeler dönüşüm katsayıları ile temsil edilmiş olmaktadır. Bu tez çalışmasında KDD 5. seviyeye kadar uygulanmıştır. Dolayısıyla $\{w_1, w_2, w_3, w_4, w_5, c_5\}$ katsayı setini elde etmek yeterli olacaktır.

Önerilen KDD algoritmasının akış diyagramında da görüldüğü gibi (Şekil 3.7) ilk adım ölçekleme (ϕ) ve dalgacık (ψ) fonksiyonları ile katsayılarını bulmadır. Daha sonra bu fonksiyonlara göre alçak ve yüksek geçiren filtreler ile katsayıları hesaplanıp, konvolüsyon kullanılarak 5. seviyeye kadar yaklaşıklık (approximation) katsayıları (c) bulunur. Son olarak ayrıntı katsayıları (w) da hesaplandıktan sonra bu çalışmada KDD'yi temsil eden $\{w_1, w_2, w_3, w_4, w_5, c_5\}$ kümesine ulaşılır.



Şekil 3.7: KDD algoritması akış şeması

3.6. ÖZNİTELİK ÇIKARMA (FEATURE EXTRACTION)

Bu tez çalışmasında KDD ile elde edilmiş kitle katsayı matrislerinde öznitelik çıkarma işlemi gerçekleştirilmiştir. Öznitelik çıkarma işlemi tüm giriş görüntüsünü kullanmak yerine bu verinin yalnızca amaca uygun olan kısmıyla işlem yapabilme imkanı sağlar [58]. Bu çalışmada sınıflandırma için meme kitlelerine ve bu kitlelerin Küresel Dalgacık Dönüşümü ile elde edilen katsayılara ait boyut, geometrik şekil, kenar kontürü ve piksel değerleriyle ilgili bazı öznitelikler çıkarılmıştır [59]. Boyut ile ilgili olan öznitelikler [60,61]; alan (area), merkez (centroid), çevreleyen kutu (bounding box), eşdeğer çap (equiv diameter), yükseklik (height) ve genişliktir (weight). Geometrik şekil ve kenar kontürü ile ilgili olan öznitelikler; kapsayan konveks (convex hull), konveks alan (convex area), keskinlik (solidity), büyük ve küçük eksen uzunluğu (major and minor axis length) [62], çevre (perimeter), ortalama radyal uzaklık (mean radial distance), simetri (symmetry), ve eğriliktir (curvature). Piksel değeriyle ilgili öznitelikler ise;

ortalama ve standart sapmadır (standart deviation). Bu öznitelikler aşağıda açıklanmıştır:

- **Alan (A)**

Alan, en temel özniteliklerden birisidir. K_p kitlenin sahip olduğu piksel sayısını verir.

$$A = K_p \quad (3.69)$$

- **Merkez (Mr)**

Merkez özniteliği, $M \times N$ boyutlu kitlenin merkez noktası olup, Mr_x ve Mr_y bu noktanın koordinatlarını gösterir. $K_{n.sutun}$ kitlenin n . sütunundaki dolu piksel sayısını, $K_{m.satir}$ ise kitlenin m satırındaki dolu piksel sayısını temsil eder.

$$Mr_x = \frac{\sum_{n=1}^N n.K_{n.sutun}}{A}, \quad Mr_y = \frac{\sum_{m=1}^M m.K_{m.satir}}{A} \quad (3.70)$$

- **Çevreleyen Kutu (ÇK)**

Kitleyi çevreleyen en küçük boyutlu dikdörtgendir. K_y kitlenin yüksekliği, K_g kitlenin genişliğidir, ÇK_y çevreleyen kutunun yüksekliği, ÇK_g ise çevreleyen kutunun genişliğidir.

$$\begin{aligned} \text{ÇK}_y &= K_y \\ \text{ÇK}_g &= K_g \end{aligned} \quad (3.71)$$

- **Yükseklik (Y)**

Kitlenin sahip olduğu yüksekliktir. Görüntü işleme boyutunda düşünüldüğünde, kitlenin satır sayısıdır (M).

- **Genişlik (G)**

Kitlenin sahip olduğu genişliktir. Görüntü işleme boyutunda düşünüldüğünde, kitlenin sütun sayısıdır (N).

- **Eşdeğer Çap (EÇ)**

Kitle ile aynı alana sahip dairenin çapıdır.

$$EÇ = \sqrt{\frac{4A}{\pi}} \quad (3.72)$$

- **Kapsayan Konveks (KK)**

Kitleyi kapsayan en küçük poligondur.

- **Konveks Alan (KA)**

Kapsayan konveksin alanı, başka bir deyişle sahip olduğu piksel sayısıdır.

- **Büyüklik Oranı (BOr)**

Kitlenin alanının çevreleyen kutunun alanına oranıdır.

$$BOr = \frac{A}{ÇK} \quad (3.73)$$

- **Büyük ve Küçük Eksen Uzunluğu (BEU ve KEU)**

Alan, merkez ve eğimi kitlenin alan, merkez ve eğimiyle aynı olan elipsin büyük eksen uzunluğudur. a ve b elipsin içinde seçilen iki odak noktasının elipsin üzerindeki herhangi bir noktaya olan uzaklıklarıdır. f , bu iki noktanın birbirine olan uzaklığını verir.

$$\begin{aligned} BEU &= a + b \\ KEU &= \sqrt{(a + b)^2 - f^2} \end{aligned} \quad (3.74)$$

- **Çevre (Ç)**

Kitlenin kontür çizgisindeki toplam piksel sayısıdır.

- **Ortalama Radyal Uzaklık (ORU)**

Kitle merkezinin çevre piksellerine olan ortalama uzaklığıdır. $Mr_{x,y}$, kitlenin merkez noktasını, ζ , kontür pikseli indisini göstermektedir.

$$ORU = \frac{\sum_{\zeta=1}^{\zeta} uzaklik(Mr_{x,y}, K_{\zeta})}{\zeta} \quad (3.75)$$

- **Simetri (S)**

Kitle, merkezden enine ve boyuna olmak üzere dört bölgeye ayrıldığında, simetri bu bölgelerdeki dolu piksel sayısı oranlarını vermektedir.

- **Eğrilik (E)**

Eğrilik, alan ve çevre öznitelikleri ile birebir ilintilidir. Çevrenin karesinin alana oranı eğriliği verir.

$$E = \frac{\zeta^2}{A} \quad (3.76)$$

- **Ortalama (O)**

Kitlenin piksellerinin gri seviye değerlerinin ortalamasıdır.


$$O = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N K_{m,n} \quad (3.77)$$

- **Standart Sapma (SS)**

Kitlenin piksellerinin gri seviye değerlerinin standart sapmasıdır.

$$SS = \sqrt{\frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N (K_{m,n} - O)^2} \quad (3.78)$$

Hesaplanan tüm bu nümerik özellikler her kitle için ayrı bir öznitelik vektörü oluşturur. Bu vektörler DVM sistemine giriş olarak verilerek sistem tarafından öğrenilmesi sağlanmıştır. Şekil 3.8 de malign , benign ve YP kitlelere ait örnek görüntüler verilmiştir. Bu örneklerde görüldüğü gibi; boyut, geometrik şekil ve kenar kontürleri arasında farklılıklar bulunmaktadır.



Şekil 3.8: Meme kitle örnekleri: Üst sıradaki kitleler; malign, orta sıradaki kitleler; benign, alt sıradaki kitleler; normal doku

3.7. DESTEK VEKTÖR MAKİNELERİ (DVM) (SUPPORT VECTOR MACHINES)

Bu tezde Destek Vektör Makineleri (DVM) kitle-doku ve malign-benign sınıflandırma için kullanılmıştır. DVM; biyoinformatik, el yazısı tanıma, görüntü sınıflandırma, kestirim yapma gibi gerçek dünya problemlerinde sıkça kullanılan ve etkili sonuçlar üreten istatistiksel bir yöntemdir [63,64]. Bu tez çalışmasında tespit edilen şüpheli bölgelerin kitle mi yoksa normal doku mu olduğu veya kitlelerin iyi huylu mu (benign) yoksa kötü huylu mu (malign) olduğuna dair sınıflandırma DVM ile yapılmıştır. İlk olarak 1960'lı yılların sonunda Vapnik tarafından [65,66] teorik olarak ortaya konmuş, 1995 yılında ise yine Vapnik tarafından ilk kez sınıflandırma uygulamasında kullanılmıştır [67,68,69].

DVM sınıflandırması, iki ayrı sınıfa ait verilerin birbirinden ayrılması için en uygun ayırıcı aşırı-düzlemi (seperating hyperplane) kullanır. Bunun için de iki sınıf uzayını birbirinden olabildiğince uzakta temsil etmeye çalışır. İki sınıf arasında karar aralığı sınırları (margin) bulunmaktadır. Bu sınırlar birbirinden ne kadar uzaksa bulunan aşırı-düzlem o kadar uygundur (optimum). Sınırlar üzerindeki veri setine ait örneklerle destek vektörler denir. DVM'ler Yapay Sinir Ağları gibi öğrenme makinelerinin kullandığı Deneyisel Risk Minimizasyonu'na (DRM) (Empirical Risc Minimization) ek olarak Yapısal Risk Minimizasyonu'nu (YRM) (Structural Risc Minimization) da kullanırlar. DRM örnekler arasındaki hata oranını azaltmaya çalışırken YRM tüm veri setinin hata oranının üst sınırını azaltmaya çalışır [70].

DVM’de örnek veri seti (eğitim seti) doğrusal olarak bir ayırıcı aşırı-düzlemle ayrılamıyorsa bu örnekler giriş uzayından çok boyutlu öznelik uzayına (high dimensional feature space) geçirilir. Öznelik uzayında yüksek dereceli matematiksel işlem yükü, çekirdek (kernel) fonksiyonların kullanılmasıyla büyük ölçüde azaltılır.


n boyutlu uzayda -1 ve +1 etiketli iki sınıfa ait x_i ($i = 1, \dots, k$) veri seti girişleri doğrusal olarak birbirinden ayrılabiliriyorsa ayırıcı aşırı-düzlem Denklem 3.79 daki şekilde ifade edilir. y_i değerleri sınıf etiketini göstermektedir.

$$f(x) = w.x_i + b \quad (3.79)$$

$$\begin{aligned} w.x_i + b &\geq 1 \text{ ise, } y_i = 1 \\ w.x_i + b &\leq -1 \text{ ise, } y_i = -1 \end{aligned} \quad (3.80)$$

Burada w , n boyutlu ağırlık vektörü, b ise skaler bir sayıdır. Denklem 3.80, pozitif ve negatif sınıfları ayırmak için maksimum karar aralığı sınırlarını bulur. Bu aralık iki sınıfın da ayırıcı aşırı-düzleme olan en yakın uzaklıklarının toplamıdır. Bu toplamın maksimum olduğu düzlem en uygun (optimum) düzlemdir. Karar aralığı sınırları yalnızca destek vektörleri ile belirlenir. En uygun aşırı-düzlem için doğru denklemi aşağıdadır.

$$\begin{aligned} w.x + b &= 0 \\ y_i(w.x_i + b) &\geq 1 \quad i = 1, \dots, k \end{aligned} \quad (3.81)$$



Şekil 3.9: İki sınıfa ait verilerin DVM ile ayrılması

Şekil 3.9 da görülen d mesafesi $2/\|w\|$ ile gösterilir ve $\|w\|$, w 'nin normuna eşittir. Optimum aşırı-düzlem için d mesafesi en çoklanmalıdır (maximization) yani $\|w\|$ 'nin en azlanması (minimization) gerekir. Bunun için de Lagrange çarpanları yöntemine başvurulur. α_i , Lagrange çarpanları olup, $\alpha_i \geq 0$ 'dır. Lagrange fonksiyonu α değerleri en çoklanıp w ve b için en azlanarak çözülür. Bunun için, b ve w 'ye göre türevler sıfıra eşitlenir.

$$\min_{w,b} \max_{\alpha} \left\{ \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i [y_i (w \cdot x_i + b) - 1] \right\} \quad (3.82)$$

w ağırlık vektörü doğrusal kombinasyon formunda yazılırsa,

$$w = \sum_{i=1}^k \alpha_i y_i x_i, \quad \alpha_i \geq 0 \quad (3.83)$$

x_i değerleri karar aralığı sınırları üzerindeki destek vektörleri olup, Denklem 3.84 ü sağlarlar.

$$y_i (w \cdot x_i + b) = 1 \quad (3.84)$$

$\|w\|^2 = w.w$ ve w yerine Denklem 3.83 yazıldığında, istenen durum olan Lagrange fonksiyonunun en azlanması DVM'nin duali ile sağlanır [71].


$$L(\alpha) = \sum_{i=1}^k \alpha_i - \frac{1}{2} \sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (3.85)$$

Denklem 3.85 deki Lagrange çarpanlarının en çoklanması gerekmektedir. Çözüm, Denklem 3.86 kısıtına bağlı olarak gerçekleştirilir.

$$\sum_{i=1}^k \alpha_i y_i = 0 \quad (3.86)$$

3.7.1. Doğrusal Olmayan Destek Vektör Makineleri

Gerçek zamanlı uygulamaların çoğunda veri seti girişlerini sınıflandırmak doğrusal (lineer) bir şekilde yapılamamaktadır. Böyle durumlarda doğrusal DVM sınıflandırıcılardan doğrusal olmayan sınıflandırıcılara genişletme yapılır. Bunun için eğitim veri seti giriş uzayının çok boyutlu bir öznitelik uzayına dönüşmesi sağlanır [72]. Böylelikle veri seti doğrusal olarak ayırt edilebilmektedir (Şekil 3.10).



Şekil 3.10: Öznitelik uzayına dönüşüm

Doğrusal olmayan DVM için karar fonksiyonu aşağıdadır.

$$f(x) = w.\phi(x) + b \quad (3.87)$$

Denklem 3.87 de $\phi(x)$ öznitelik uzayını göstermektedir. Denklem 3.83 dönüştürülerek Denklem 3.88 e ulaşılır.

$$w = \sum_{i=1}^k y_i \alpha_i \phi(x_i) \quad (3.88)$$

Denklem 3.88, Denklem 3.87 de yerine yazılırsa;

$$f(x) = \sum_{i=1}^k y_i \alpha_i (\phi(x) \phi(x_i)) + b \quad (3.89)$$

elde edilir. Denklem 3.89 daki $\phi(x) \cdot \phi(x_i)$ yerine seçilen çekirdek (kernel) fonksiyonu yazılırsa Denklem 3.90 a ulaşılır.

$$f(x) = \sum_{i=1}^k y_i \alpha_i K(x, x_i) + b \quad (3.90)$$

Çekirdek fonksiyonlar farklı tiplerde olmaktadır [73]. Bu fonksiyonun seçimi uygulama için oldukça önemli olup, sistem performansını doğrudan etkiler. En çok kullanılan çekirdek fonksiyonları aşağıda verilmiştir.

- Polinom çekirdek fonksiyonu:

$$K(x, x_i) = (x \cdot x_i + 1)^p$$

$p = 1$ için fonksiyon doğrusal, $p = 2$ için kareseldir.

- Radyal tabanlı çekirdek fonksiyonu (RTF);

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2)$$

3.7.2. Sınıflandırmada Destek Vektör Makineleri (DVM) Kullanımı

Bu tez çalışmasında kitle sınıflandırma işlemi için DVM tercih edilmiştir. DVM sistemine giriş olarak her bir kitlenin ayrı ayrı temsil edildiği 16 skaler değere sahip öznitelik vektörleri verilmiştir. Bunun sebebi; KDD uygulanmış kitlelerden 16 tane öznitelik çıkarılmış olmasıdır. Kitle-doku sınıflandırması olan ilk aşamada, kitleler K,

dokular D ile etiketlenmişlerdir. Malign-benign sınıflandırması olan ikinci aşamada ise, malign kitleler M, benign kitleler B ile etiketlenmişlerdir.

Giriş öznitelik vektörleri k -katlı çapraz doğrulama yöntemi ile eğitime ve teste tabi tutulmuştur. k -katlı çapraz doğrulama (k -fold cross validation) ile DVM giriş seti k adet alt sete ayrılır. Eğitim ve test k adım kadar tekrar ettirilir. Her adımda $k-1$ adet set eğitim için, k adet set ise test için ayrılır [74,75]. Buna göre her veri seti bir kez test seti olarak, $k-1$ kez de eğitim seti olarak kullanılır [70,75]. Bu çalışmada her test için en yüksek performansı veren k değerleri kullanılmıştır. Bu değerler Tablo 4.4 - 4.6 ve 4.8 - 4.10 da verilmiştir. DVM'de çekirdek fonksiyonu olarak polinom ve radyal tabanlı çekirdek fonksiyonları (RTF) kullanılmıştır.

3.8. MAMOGRAM VERİTABANI VE MAMOGRAFİ AYGITI ÖZELLİKLERİ


Bu tez çalışmasında özgün ve daha önce herhangi bir çalışma için kullanılmamış bir mammogram veritabanı (İTF veritabanı) hazırlanmıştır. Bunun için İstanbul Üniversitesi Tıp Fakültesi Hastanesi Radyoloji Anabilim Dalı biriminde dijital mamografi cihazı taramasından geçen hastaların görüntülerinden faydalanılmıştır. Kullanılan cihaz mamografik tarama ve kanser tanısı alanlarında etkin ve modern teknolojiyi kullanan Giotto Image SDL Full Field dijital mamografi cihazıdır. Cihaz, ikinci nesil Amorf Selenyum (Amorphous Selenium, a-Se) 24x30 cm boyutunda dijital dedektöre ve hastanın maruz kaldığı radyasyonu azaltan Özel Tunsten Anot X-ışın Tüpüne (Special Tungsten Anode X-Ray Tube) sahiptir. Filtre özellikleri 50 μ m rhodium olup, piksel büyüklüğü 85 μ m, piksel boyutu 2816 $\times$ 3584'tür. İTF mamogram veritabanını oluşturan hastaların tümü bayan olup, yaşları 31 ile 70 arasında değişmektedir. Toplam 30 hastaya ait 30 sağ meme MLO görüntüsü, 30 sağ meme CC görüntüsü, 30 sol meme MLO görüntüsü ve 30 sol meme CC görüntüsü alınmıştır. Bu görüntülerin 60'ında kitle mevcut olup toplam 78 tane kitleden 36 tanesi malign özellik gösterirken 42 tanesi benign özellik göstermektedir. Mamogramlar uzman radyolog tarafından incelenmiş şüpheli bölgeler ve meme kitleleri işaretlenmiştir.

İTF veritabanıyla elde edilen sonuçları karşılaştırmak amacıyla; internet ortamında ücretsiz olarak erişilebilen, genel kullanıma açık, İngiliz çalışma grubuna ait MIAS

(Mammographic Image Analysis Society) veritabanı mamogramları da test edilmiştir. MIAS verileri UK Uluslararası Meme Tarama Programı (UK National Breast Screening Programme) tarafından sağlanmıştır [76]. Mamogramlar 0-3.2 optik yoğunluk aralığında doğrusal optik aygıt özelliği gösteren Joyce-Loebl tarama mikrodensitometresi ile piksel kenarı 50 mikron olacak şekilde dijitalleştirilmiştir. Mamogramlar üzerindeki kitle tespiti uzman radyologlar tarafından yapılmıştır [77]. Bu tez çalışması için 60 hastaya ait 60 adet mamogram alınmıştır. Bu mamogramlardan 35 tanesinde benign kitle, 25 tanesinde ise malign kitle saptanmıştır.

4. BULGULAR

Bu tez çalışmasında mamografik görüntülerde bilgisayar destekli tanıya dayalı meme kanseri tespiti için sırasıyla; görüntü iyileştirme, görüntü bölütleme ve kitle tespiti, KDD (Küresel Dalgacık Dönüşümü) tabanlı çoklu çözünürlük analizi, öznitelik çıkarma, kitle-doku sınıflandırma ve malign-benign sınıflandırma işlemleri uygulanmıştır (Şekil 4.1).



Şekil 4.1: Önerilen BDT sisteminin akış diyagramı


4.1. GÖRÜNTÜ İYİLEŞTİRME (ENHANCEMENT)

Görüntü iyileştirme işlemi, görüntüyü birtakım işlemlerden geçirerek istenen amaca daha uygun hale getirmektir [78]. Görüntü iyileştirme teknikleri, görüntünün ait olduğu düzlemi ifade eden uzaysal alan (spatial domain) ve Fourier dönüşümüyle elde edilen frekans alanı (frequency domain) olmak üzere temel iki alanda uygulanır. Görüntü iyileştirme algoritmalarının performansı görüntünün niteliğine bağlı olarak değiştiğinden, her görüntü için en iyi sonuçları veren belli bir algoritma öngörülemez. Performans değerlendirmesi, belirli bir kritere dayanmaksızın araştırmacının tecrübesine bağlı olarak yapılır. Bu çalışmada görüntü iyileştirmenin genel anlamda amacı, mamogramları kitle tespit etme ve sınıflandırma öncesinde optimum netlikte görüntü elde ederek YP (Yanlış Pozitif) oranını azaltırken, GP (Gerçek Pozitif) oranını artırmaktır. GP; gerçekte pozitif olup sistemin de pozitif olarak sınıflandırdığı verileri, YP; gerçekte negatif olup sistemin pozitif olarak sınıflandırdığı verileri, GN (Gerçek Negatif); gerçekte negatif olup sistemin de negatif olarak sınıflandırdığı verileri, YN (Yanlış Negatif) ise gerçekte pozitif olup sistemin negatif olarak sınıflandırdığı verileri temsil etmektedir.

Bu çalışmada ham mamografi görüntülerinde kitle tespitinden önce görüntü iyileştirme yapılmıştır. Amaç, farklı nedenlerden kaynaklanan bulanıklık, kontrast veya gürültü gibi görüntü netliğini bozucu etkilerden dolayı kitle tespit etme (detection) işleminin etkin biçimde yapılamaması, kitlelerin gözden kaçması veya yanlış kitle tespitini engellemektir. Uygulanan metodun akış diyagramı Şekil 4.2 de verilmiştir. Görüntü öncelikle Hızlı Dalgacık Dönüşümü'ne tabi tutulur. Dönüşüm ile elde edilen yaklaşıklık ve ayrıntı katsayılarına farklı işlemler uygulanır. Ayrıntı katsayıları Bölüm 3.3.6 da da bahsedildiği gibi, yatay dikey ve diyagonal olmak üzere üç farklı katsayı grubundan oluşmaktadır. Mamogramdaki gürültü tüm katsayılara dağılmıştır. Yaklaşıklık (approximation) katsayılarına Homomorfik Filtreleme, ayrıntı katsayılarına ise Gauss-Laplace dağılımları ile gürültü-ayrıntı modellemenin uygulandığı dalgacık daraltma metodları kullanılmıştır. Daraltma fonksiyonunda λ ağırlığı $0 \leq \lambda \leq 1$ aralığında seçilir (Bu çalışmada $\lambda = 0.2$ olarak seçilmiştir). Homomorfik filtrelemede ise Denklem 4.1 de verilen Gauss Alçak Geçiren Homomorfik Filtre $H(u, v)$ fonksiyonu kullanılmıştır.

$$H(u, v) = (\gamma_H - \gamma_L) \left[e^{-r(D^2(u, v) / D_0^2)} \right] + \gamma_L \quad (4.1)$$

Burada γ_H ve γ_L , $\gamma_H > 1$ ve $\gamma_L < 1$ şartını sağlayacak şekilde sırasıyla yüksek ve alçak filtre sınırlarını gösterirler (Bu çalışmada $\gamma_H = 2$ ve $\gamma_L = 0.5$ olarak seçilmiştir). r filtre eğimini, D_0 ve $D(u, v)$ ise frekans dönüşümünün merkezini ve merkeze olan uzaklığı temsil eder. HF uygulamasının etkisi Gauss-Laplace modellemesine göre daha fazladır. Ancak iki işlemin de uygulanmasının mamogramdaki şüpheli ve gözden kaçabilecek nitelikteki bölgelerde netlik sağlaması açısından faydaları görülmektedir. Bu işlemlerle güncellenen katsayılar Ters Dalgacık Dönüşümü'nden geçirilir. Böylelikle orjinal mamograma göre çok daha az gürültü içeren bir görüntü elde edilir. Son olarak; gürültü etkisi azaltılmış tüm mamogramlarda bu çalışma için geliştirilmiş olan adaptif eşikleme uygulanarak görüntüler iyileştirilir (Şekil 4.2).



Şekil 4.2: Görüntü iyileştirme akış diyagramı

Görüntü iyileştirme işlemi aslında doğrusal olmayan lokal kontrast iyileştirmedir. Meme kitlelerini tespit etmede önem arz eden kenar bölgeleri bulanıklaştırılmadan, düşük kontrasta sahip bölgeler yüksek kontrasta sahip bölgelerden daha fazla keskinleştirilir. Lokal Adaptif Eşikleme (Local Adaptive Thresholding) global eşiklemeden daha etkin sonuçlar vermektedir. Bunun nedeni lokal incelemede piksel hem global olan tüm kitleye ait özelliklerle hem de kendi yakın komşuluğu içerisinde değerlendirilir [79]. Lokal eşikleme yapılırken iki parametre dikkate alınır; bunlardan biri komşuluk matrisinin boyutu diğeri ise eşik değeridir.

Lokal adaptif eşiklemede tüm pikseller 5×5 komşulukları içerisinde değerlendirilmiştir. Her x katsayı pikseli için kendi komşuluğunun m_{lokal} lokal ortalama ve σ_{lokal} lokal standart sapma değeri hesaplanmıştır. x değerinin lokal ortalamadan büyük yada küçük olması durumu incelenmiştir. Bu değer daha küçükse ne kadar küçük olduğuna, daha büyük ise de ne kadar büyük olduğuna karar vermek için öncelikle 256 gri seviye aralığı 20 gruba ($g_i, i = 1, 2, \dots, 20$) ayrılmıştır. Sadece $x \geq m_{lokal}$ ve x in standart sapmasının ortalama standart sapmadan büyük olması ($\sigma_x \geq \sigma_{lokal}$), x değerinin ortalamaya göre çok büyük olduğunu göstermez. Bunun için ek bir kriter daha konulmuştur. $\sigma_x \geq \sigma_{lokal}$ ise $x^2 - m^2 \geq (\sigma_{lokal})^2$ şeklinde yazılır. Bu ifade $x \geq \sqrt{\sigma^2 + m^2}$ ifadesine denktir. Bu şartı sağlayan x değerlerinin hangi gri seviyeden başladığını bulmak için x in alabileceği en küçük değer ve bu değer ait olduğu gri seviye aralığının indisi (i) belirlenmiştir. Daha sonra bu indise bir tolerans indis değeri (tol) eklenmiştir (Bu çalışmada $tol = 2$ olarak seçilmiştir). Eğer x , bulunan yeni indisin gösterdiği aralığın ilk elemanından da fazlaysa ($x \geq g_{i+tol}(ilk)$) ‘çok çok büyük’ sayılmıştır. Bu durumda x ’in değeri değiştirilmemiştir. Az ise ($x < g_{i+tol}(ilk)$) ‘çok büyük’ kabul edilmiştir. x ’in standart sapması ortalama standart sapmadan küçükse sadece ‘büyük’ sayılmıştır. ‘Çok büyük’ ve ‘büyük’ olma durumlarında x ’e Donoho, Johnstone ve ark. [80] tarafından bulunan ve Denklem 4.2 de gösterilen T_{lokal} eşik değeri eklenmiştir ($x + T_{lokal}$). Buradaki $m \times n$ katsayı matrisinin boyutudur.

$$T_{lokal} = 2 \log(mn) \quad (4.2)$$

x 'in ortalamadan küçük ve standart sapmasının ortalama standart sapmadan küçük ($m^2 - x^2 < \sigma^2$) yani $x \geq \sqrt{m^2 - \sigma^2}$ olması durumunda x 'in alabileceği en büyük değerin denk geldiği aralığın indisi (j) bulunmuş ve yine bu indise bir tolerans indisi eklenmiştir. x , elde edilen yeni indisin gösterdiği ilk değerden büyükse ($x \geq g_{j+tol}(ilk)$) 'küçük', küçükse ($x < g_{j+tol}(ilk)$) 'çok küçük' kabul edilmiştir. Bu iki durumda x 'den T_{lokal} eşik değeri çıkarılmıştır ($x - T_{lokal}$). x 'in standart sapmasının ortalama standart sapmadan büyük olması 'çok çok küçük' sayılmış, bu durumda da değeri değiştirilmemiştir. tol sayısı belirlenirken $i + tol$ değerinin 20'yi, $j + tol$ değerinin ise ortalama değerin denk düştüğü aralığın indis numarasını geçmemesine dikkat edilmiştir. Yukarıda anlatılan koşullara uygun olarak geliştirilen Lokal Adaptif Eşikleme fonksiyonu $f(x)$, Denklem 4.3 de verilmiştir.


$$f(x) = \begin{cases} x, & Eger \begin{pmatrix} x \text{ 'cok cok büyük' veya} \\ x \text{ 'küçük' ise} \end{pmatrix} \\ x + T_{lokal}, & Eger \begin{pmatrix} x \text{ 'büyük' veya} \\ x \text{ 'cok büyük' ise} \end{pmatrix} \\ x - T_{lokal}, & Eger \begin{pmatrix} x \text{ 'cok küçük' veya} \\ x \text{ 'cok çok küçük' ise} \end{pmatrix} \end{cases} \quad (4.3)$$

Denklem 4.3 deki kriterler aşağıda sıralanmıştır:


- 'cok cok büyük' olma kriteri: $x \geq m_{lokal}$ ve $\sigma_x \geq \sigma_{lokal}$ ve $x \geq g_{(i+tol)}(ilk)$
- 'küçük' olma kriteri: $x < m_{lokal}$ ve $\sigma_x \geq \sigma_{lokal}$
- 'büyük' olma kriteri: $x \geq m_{lokal}$ ve $\sigma_x < \sigma_{lokal}$ veya
- 'cok büyük' olma kriteri: $x \geq m_{lokal}$ ve $\sigma_x \geq \sigma_{lokal}$ ve $x < g_{(i+tol)}(ilk)$
- 'cok küçük' olma kriteri: $x < m_{lokal}$ ve $\sigma_x < \sigma_{lokal}$ ve $x \geq g_{(j+tol)}(ilk)$
- 'cok çok küçük' olma kriteri: $x < m_{lokal}$ ve $\sigma_x < \sigma_{lokal}$ ve $x < g_{(j+tol)}(ilk)$

$f(x)$ fonksiyonu yüksek geçiren filtre gibi davranmaktadır. Homomorfik filtreleme ve Gauss-Laplace modelleme sonucunda ön plana çıkan kitleli bölge görüntü eşikleme ile daha belirgin olmuştur. Böylece gürültü azaltılırken kenar gibi önemli bilgi saklayan bölgeler vurgulanmış olmaktadır.


Görüntü iyileştirme işlemi için mamogramdan elde edilen matris öncelikle Hızlı Dalgacık Dönüşümü'nden (HDD) geçirilir. 1. seviye dönüşümde görüntü nispeten keskinleştirilmiş olduğundan gerekli piksellerin yanında gürültü de ön plana çıkabilmektedir. 3 veya daha yüksek seviyelerde ise görüntü istenmeyen şekilde bulanıklaşmakta ve gerekli detaylar yok olmaktadır. Bundan dolayı bu çalışmada, önceki çalışmalarda da [33,37,47,57,60] çoğunlukla tercih edilen 2. seviye dalgacık dönüşümü kullanılmıştır. Şekil 4.4 deki dörtlü resim, Şekil 4.3 deki orjinal mamograma ADD uygulanması sonucu elde edilmiş orjinal resim boyutunun yarısı boyuttaki yaklaşıklık (approximation), yatay (horizontal), dikey (vertical) ve diyagonal (diagonal) görüntüleri göstermektedir. Şekil 4.5 de ise 2. seviye ADD sonucu ve yaklaşıklık ve ayrıntı (detail) görüntüleri verilmiştir. Bu seviyede de boyut yarıya inmiştir. Yukarıda da anlatıldığı gibi yaklaşıklık görüntülerine homomorfik filtreleme, ayrıntı görüntülerine ise Gauss-Laplace modellemesi uygulanmıştır. Elde edilen güncellenmiş katsayılar ile yeniden oluşturma (reconstruction) işlemi gerçekleştirilmiştir. Son olarak sonuç görüntülerine Lokal Adaptif Eşikleme uygulanmış ve kitle bölütleme için gerekli olan ön işlemler tamamlanmıştır. Şekil 4.6-4.14 arasında gösterilen örneklerde hastaların orjinal ham mamogramları işlenerek iyileştirme yapılmıştır.




Şekil 4.3: Orjinal MLO mamogram



Şekil 4.4: 1. seviye HDD ile elde edilen yaklaşıklık ve ayrıntı görüntüleri




Şekil 4.5: 2. seviye HDD ile elde edilen yaklaşıklık ve ayrıntı görüntüleri




Şekil 4.6: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

Şekil 4.6.a da 48 yaşında bir hastanın sağ meme CC mamografi görüntüsü verilmektedir. Ok işareti ile gösterilen kitle malign özellik gösteren bir kitle olup kitlenin uzantıları meme dokusunun içine girmiştir. Geliştirilen görüntü iyileştirme yöntemi uygulandıktan sonra Şekil 4.6.c de görüldüğü gibi gürültü azaltılmış, kitle çok daha belirgin hale getirilmiştir. Şekil 4.6.b mamogramın adaptif eşikleme işleminden önceki halidir. Adaptif eşikleme ile kitle arka plandan ayrılmış, malign özellikler Şekil 4.6.b ye göre daha çok ön plana çıkmıştır. Şekil 4.7.a daki sol memeye ait MLO mamogram görüntüsü 55 yaşında bir kadına aittir. Memede yaşa bağlı olarak artan dansite (yoğunluk) göze çarpmaktadır. Dens memede açık gri seviye renkler hakim olduğundan kitleyi yakalayabilmek daha zordur. Görüntülemeye Şekil 4.7.a daki kitleler meme paterni içine yakalanması zor olacak şekilde gizlenmiştir. Şekil 4.7.b ve 4.7.c ye bakıldığında adım adım gürültünün ve dansitenin azaldığı ve meme paterninde bulunan ok işareti ile gösterilmiş iki adet meme dokusunun arasına yayılmış malign kitlenin tanıya kolaylık sağlayacak şekilde vurgulandığı görülmektedir.




Şekil 4.7: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

Şekil 4.8.a da 41 yaşında bir kadına ait sol meme CC mamogramı görülmektedir. Memede ok ile işaretlenmiş benign kitle görülmektedir. Şekil 4.8.b mamogramın dalgacık dönüşümünden sonra homomorfik filtreleme ve Gauss-Laplace modellemeyden geçirilmiş halini göstermektedir. Lokal kontrast artırılmış, görüntü bulanık halden kurtarılmıştır. Şekil 4.8.c de ise 4.8.b görüntüsüne lokal adaptif eşikleme uygulanmıştır. Böylece benign kitlelere ait düzgün kenar kontürü belirgin hale gelmiştir. Nokta öbekleri halindeki gürültü neredeyse yok olmuştur.




Şekil 4.8: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

Şekil 4.9.a da 50 yaşındaki bir hastanın sağ memesine ait büyükçe bir benign kitle içeren CC mamogramı görülmektedir. Bu vakada kitle, herhangi bir ön işleme ihtiyaç duymadan rahatça saptanmaktadır. Şekil 4.9.c de görüldüğü gibi, mamograma görüntü iyileştirme algoritması uygulandıktan sonra kitlenin üst kısmında fazlaca belirgin olmayan kenar kontürü arka plandan ayrılmış ve tamamen ortaya çıkmıştır.



Şekil 4.9: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b) b) mammogramının adaptif eşiklenmiş şekli


Şekil 4.10.a da 70 yaşında bir kadına ait sol meme CC mamogram görüntüsü verilmektedir. Meme dens bir yapıya sahip olup, kitleleri tespit etme ve tanı koyma açısından zor bir vakadır. Mamogramda iki adet benign özellik gösteren kitle bulunmaktadır. Şekil 4.10.b de görüldüğü gibi, bu çalışmada görüntü iyileştirmenin ilk aşaması olarak kullanılan homomorfik filtreleme ve Gauss-Laplace modelleme sonrasında bu kitleler saptanabilir hale gelmişlerdir. Uygulanan adaptif eşikleme ile Şekil 4.10.c de görüldüğü gibi lokal kontrast artırılmış, arka plandaki daha açık gri seviye değerleri koyuya çevrilerek kitlenin ve kenar kontürlerinin ortaya çıkması sağlanmıştır. Sonuç olarak genel meme dansitesi azalırken, kitlenin varolabileceği şüpheli bölgelerde parlaklık artırılmıştır.



Şekil 4.10: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

Şekil 4.11.a daki mamogram ise 45 yaşında bir hastaya ait sol meme CC görüntüsüdür. Mamografi görüntülemeye meme kitlesi belirgin olmakla birlikte kitlenin kenar kontürünün meme dokusu ile birleşik olduğu görülmektedir. Bu vakada bir tane kitle olup benign özellik taşımaktadır. Görüntü iyileştirme uygulanmış mamogram Şekil 4.11.c de verilmiştir. Kitleyi çevreleyen kısımlardaki gürültü azaltılmış, meme kontrastı artırılarak kitle ön plana çıkmıştır. Böylelikle vakayı inceleyen radyoloğun bu kitlenin benign kitle olduğu tanısını koyma ihtimali artmıştır. Şekil 4.12.a 44 yaşında bir kadına ait sol meme CC mamografi görüntüsü verilmiştir. Oldukça yoğun meme dokusunda iki tane malign özellik gösteren kitle bulunmaktadır. Kitlelerin teşhis edilmesi yetersiz kontrasttan dolayı zorlaşmıştır. Kitleler hem gözden kaçabilecek şekilde görüntülenmiş hem de kenar kontür belirginliği oldukça yetersizdir. Şekil 4.12.b dalgacık


dönüşümünden sonra uygulanan homomorfik filtreleme ve Gauss-Laplace modelleme sonucu gösterilmiştir. Gürültü genel anlamda azaltılmış, kitlenin etrafındaki kontrast artmıştır. Şekil 4.12.c ise elde edilen sonuca adaptif eşikleme uygulama sonucunu verilmiştir. Bu işlem ile malign kitlelerin gri seviye değerleri artırılmış, bu yolla kitleler bulanık görüntüden arındırılarak parlaklık kazanmıştır. Böylelikle kitleler fark edilecek düzeyde ön plana çıkarılmıştır.




Şekil 4.11: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

Şekil 4.13.a da 35 yaşında genç bir hastanın sağ meme CC mamografik görüntüsü yer almaktadır. Ok işareti ile gösterilen kitle malign özellikler taşımaktadır. Ancak dens meme yapısından dolayı bulanık (blur) bir görüntü vermesi kitlenin boyutu, sınırları ve tanısı ile ilgili kestirimi zorlaştırmaktadır. Şekil 4.13.c de iki aşamalı görüntü iyileştirme

tekniki ile normal meme dokusunun parlaklığı azaltılırken, kitlenin parlaklığı artırılmıştır. Böylelikle kitlenin görünümü keskinleştirilmiş, kenar kontürleri daha belirgin ve ilk bakışta saptanabilecek düzeye getirilmiştir.




Şekil 4.12: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli



Şekil 4.13: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

Görüntü iyileştirme örneklerine son olarak Şekil 4.14.a da yer alan 50 yaşındaki bir kadına ait sol meme CC mamografi görüntüsü verilmiştir. Orjinal mamogramda meme paterninde genel anlamda bir kontrast zayıflığı fark edilmektedir. Bu problem, mamogramda yer alan dört tane benign kitlenin doku içinde yakalanması için gri seviyelerinin keskinleştirilmesini gerektirir. Öte yandan mamogramdaki arka planın yani meme dokusunun bulanıklaştırılması diğer deyişle gri seviye değerlerinin azaltılması gerekmektedir. Şekil 4.14.b de görüldüğü gibi filtreleme ve modelleme ile bu sağlanmıştır. Şekil 4.14.c de ise adaptif eşikleme ile kitlelerin daha belirgin hale

getirildiği, kitle kontrastı artırılırken meme dokusunun parlaklığının azaltıldığı görülmektedir.




Şekil 4.14: Görüntü iyileştirme örneği a) Orjinal mammogram b) İyileştirilmiş mammogram c) b mamogramının adaptif eşiklenmiş şekli

4.2. GÖRÜNTÜ BÖLÜTLEME (SEGMENTATION)

Bölütleme görüntü işlemenin en önemli süreçlerinden biridir. Bölütleme işleminin başarısı nesne tanıma veya sınıflandırmanın performansını belirler. Bölütleme bir görüntünün alt bölgelere veya anlamlı nesnelere bölünmesidir. Bölütleme algoritmaları genel olarak görüntünün yoğunluk değerlerine bağlı iki temel özelliğe dayanır. Bunlardan biri süreksizlik (discontinuity) diğeri ise benzerliktir (similarity) [78]. Süreksizliğe bağlı bölütlemelerde bir görüntüdeki yoğunluk değerlerinin kenarlarda olduğu gibi ani bir şekilde değişimi esas alınırken benzerliğe bağlı bölütlemelerde görüntüyü önceden tanımlanmış kurallara uygun olarak bölgelere ayırma esas alınır. Bu tezde benzerlik özelliğini kullanan bölge tabanlı (region based) Merkezden Bölge Büyütme (Seed Region Growing) bölütleme yöntemi kullanılmıştır.

4.2.1 Merkezden Bölge Büyütme (MBB) (Seed Region Growing) Yöntemi

MBB, büyütme kuralına bağlı olarak uzaysal alandaki pikselleri veya alt bölgeleri daha büyük bir bölge oluşturacak şekilde gruplama tekniğidir. Öncelikle görüntü üzerinde merkez noktalar seçilir. Bu noktalardan başlanarak komşu pikseller tek tek kontrol edilir. Önceden tanımlı benzerlik kuralına uyan komşu pikseller merkez noktasının olduğu bölgeye dahil edilir. Uymayan pikseller ise dışarıda bırakılır ve arka plan olarak kabul edilir. Bu işlemin ne kadar devam ettirileceği kriteri de önem arz etmektedir. Genel olarak kurala uyan tek bir komşu piksel kalmayana kadar işlem sürdürülür. Benzerlik kuralları görüntüye göre değişmekte olup çoğunlukla gri seviye değer aralıklarıyla ilgilidir.



Şekil 4.15: MBB yöntemi için şekilsel gösterim

Şekil 4.15 de MBB yöntemi uygulamasına ait örnekler verilmiştir. Şekil 4.15.a da siyah pikseller bir bölgeyi göstermektedir. Bölgenin ortasındaki beyaz piksel merkez noktasıdır. Kenarlardaki açık gri pikseller bölgeye ait komşu piksellerdir. Koyu gri olan piksel bölgeye dahil olmaya aday noktadır. Eğer bölgenin özelliklerine uyarsa piksel bölgeye dahil edilerek bölge büyütülür, uymazsa dahil edilmez. Şekil 4.15.b de bu piksel siyaha boyanmıştır yani bölgeye katılmıştır. Buradaki koyu gri piksel aday piksel olup kriterlere uyduğu için Şekil 4.15.c de görüldüğü gibi siyaha boyanmıştır. 'X' işareti ile gösterilen pikseller ise yeni katılan pikselin komşuluğunda olup benzerlik kurallarına uymadıkları için arka plan olarak kalmışlardır.

B görüntüsünün n adet $B_1, B_2, \dots, B_n$ alt bölgelerinden oluştuğu varsayılırsa, MBB aşağıdaki özelliklere sahiptir:

$$(a) \bigcup_{i=1}^n B_i = B.$$

$$(b) B_i \cap B_j = \emptyset \quad \forall \quad i, j \text{ için, } i \neq j.$$

$$(c) H(B_i) = DOGRU, \quad i = 1, 2, \dots, n.$$

$$(d) H(B_i \cup B_j) = YANLIS, \quad B_i \text{ ve } B_j \text{ bölgeleri birleşikse.}$$

Yukarıdaki özelliklere göre bölgeler kesişmezler ve üst üste gelmezler. H , bölge içindeki homojenliği gösterir. MBB sonucu elde edilen herhangi bir bölge kendi içinde belirli özelliklere uygunluğu bakımından homojendir. Ancak herhangi iki bölgenin birleşimi eğer bölgeler birbirine bitişikse homojen değildir. Çünkü özellikler farklılık gösterdiği için bölgeler birbirinden ayrılmaktadır. Bundan dolayı komşu iki bölgenin birbiriyle homojen olmaması doğaldır. Bölgeler bitişik değilse birleşimleri tesadüfen homojen olabilir.

4.2.1.1. Lokal Merkezden Bölge Büyütme (LMBB) Yöntemi

Bu tezde klasik MBB yöntemi temel alınarak Lokal Merkezden Bölge Büyütme yöntemi (LMBB) geliştirilmiştir. LMBB yönteminde benzerlik kuralları belirlenirken, global görüntü özelliklerinin yanında aday piksellerin 3×3 komşulukları ve merkez noktası da göz önünde bulundurulmuştur. LMBB yönteminin algoritma adımları aşağıda sıralanmıştır:

- (1) Merkez noktası olmanın kriterinin belirlenmesi;

I : Görüntü,

$I(x, y)$: Aday merkez noktası ($AdMr$),

M_I : Görüntünün ortalaması ($M_I = \frac{1}{BOY \times EN} (\sum_{satir=1}^{BOY} \sum_{sutun=1}^{EN} I(satir, sutun))$),

S_I : Görüntünün standart sapması

$$(S_I = \sqrt{\frac{1}{BOY \times EN} \sum_{satir=1}^{BOY} \sum_{sutun=1}^{EN} (I(satir, sutun) - M_I)^2}),$$

E_I : Tüm görüntüye ait eşik değeri ($E_I = \frac{\max(I) + \min(I) + 2.ort(I)}{4}$),

$TK(I(x, y))$: $AdMr$ nin tüm 3×3 komşularının kümesi,

$S_{TK(I(x, y))}$: $TK(I(x, y))$ kümesinin standart sapması,

$$(S_{TK(I(x, y))} : \sqrt{\frac{1}{8} \sum_{satir=1}^3 \sum_{sutun=1}^3 (I(satir, sutun) - M_{TK(I(x, y))})^2}, satir \neq 2, sutun \neq 2)$$

$E_{TK(I(x, y))}$: $TK(I(x, y))$ kümesinin eşik değeri,

$$(E_{TK(I(x, y))} = \frac{\max(TK(I(x, y))) + \min(TK(I(x, y))) + 2.ort(TK(I(x, y)))}{4}),$$

$M_{TK(I(x, y))}$: $TK(I(x, y))$ kümesinin ortalaması

$$(M_{TK(I(x, y))} = \frac{1}{8} (\sum_{satir=1}^3 \sum_{sutun=1}^3 I(satir, sutun)), satir \neq 2, sutun \neq 2)$$

olmak üzere, merkez noktası olma kriteri ($MrKr$) belirlenir.

$$MrKr = |I(x, y) - M_I| \geq maksimum(E_I, S_I) \text{ ve}$$

$$|I(x, y) - M_{TK(I(x, y))}| \geq maksimum(E_{TK(I(x, y))}, S_{TK(I(x, y))})$$

- (2) Merkez noktalarının belirlenmesi:

i : Bölge numarası,

k : Pikselin bölgeye katılma sırasının indisi (merkez noktaları için 0' dır),

n : Görüntüdeki toplam bölge sayısı

olmak üzere, I görüntüsünü tarayarak $MrKr$ yi uygula ve görüntünün

$B_i^{(k)}$, $i = 1, \dots, n$ ile gösterilen merkez noktalarını bul.

(3) Bölge büyütme ve benzer bölgelerin bulunması:

Sırasıyla tüm merkez noktaları ($i = 1 : n$) için bölge büyüt:

(3.1) $B_i^{(0)}$: i . bölgenin merkez noktası,

$kSon$: Bölgeye son katılan komşu piksellerin indisleri,

$B_i^{(kSon)}$: Bölgeye en son katılan komşu pikseller,

$M_{(kSon, Mr)}$: Bölgeye en son katılan komşu pikseller ile merkez noktasının ortalaması,

n_1 : Bölgeye en son katılan komşu piksellerin sayısı,

$TK(kSon)$: Bölgeye son katılan tüm komşu piksellerin bütün 3×3 komşuları,

n_2 : $TK(kSon)$ kümesinin eleman sayısı,

M_{kSon} : Bölgeye son katılan komşu piksellerin ortalaması

olmak üzere; $kSon$ ve $M_{(kSon, Mr)}$ 'u belirle.

$$M_{(kSon, Mr)} = \frac{B_i^{(0)} + B_i^{(kSon)}}{n_1 + 1}$$

(3.2) Sırasıyla tüm $TK(kSon)$ elemanları ($j = 1 : n_2$) için benzerlik kriterine

($BnzKr$) uygunluk kontrolünü yap.

(3.2.1) $TK_j(kSon)$: $TK(kSon)$ kümesinin j . elemanı,

M_j : $TK_j(kSon)$ ile $M_{(kSon, Mr)}$ 'un ortalaması,

$BnzKr$: Benzerlik kriteri,

$S_{TK(j)}$: j . elemanın tüm komşularının standart sapması

olmak üzere, M_j ve $BnzKr$ belirle.

$$M_j = \frac{M_{(kSon, Mr)} + TK_j(kSon)}{2}$$

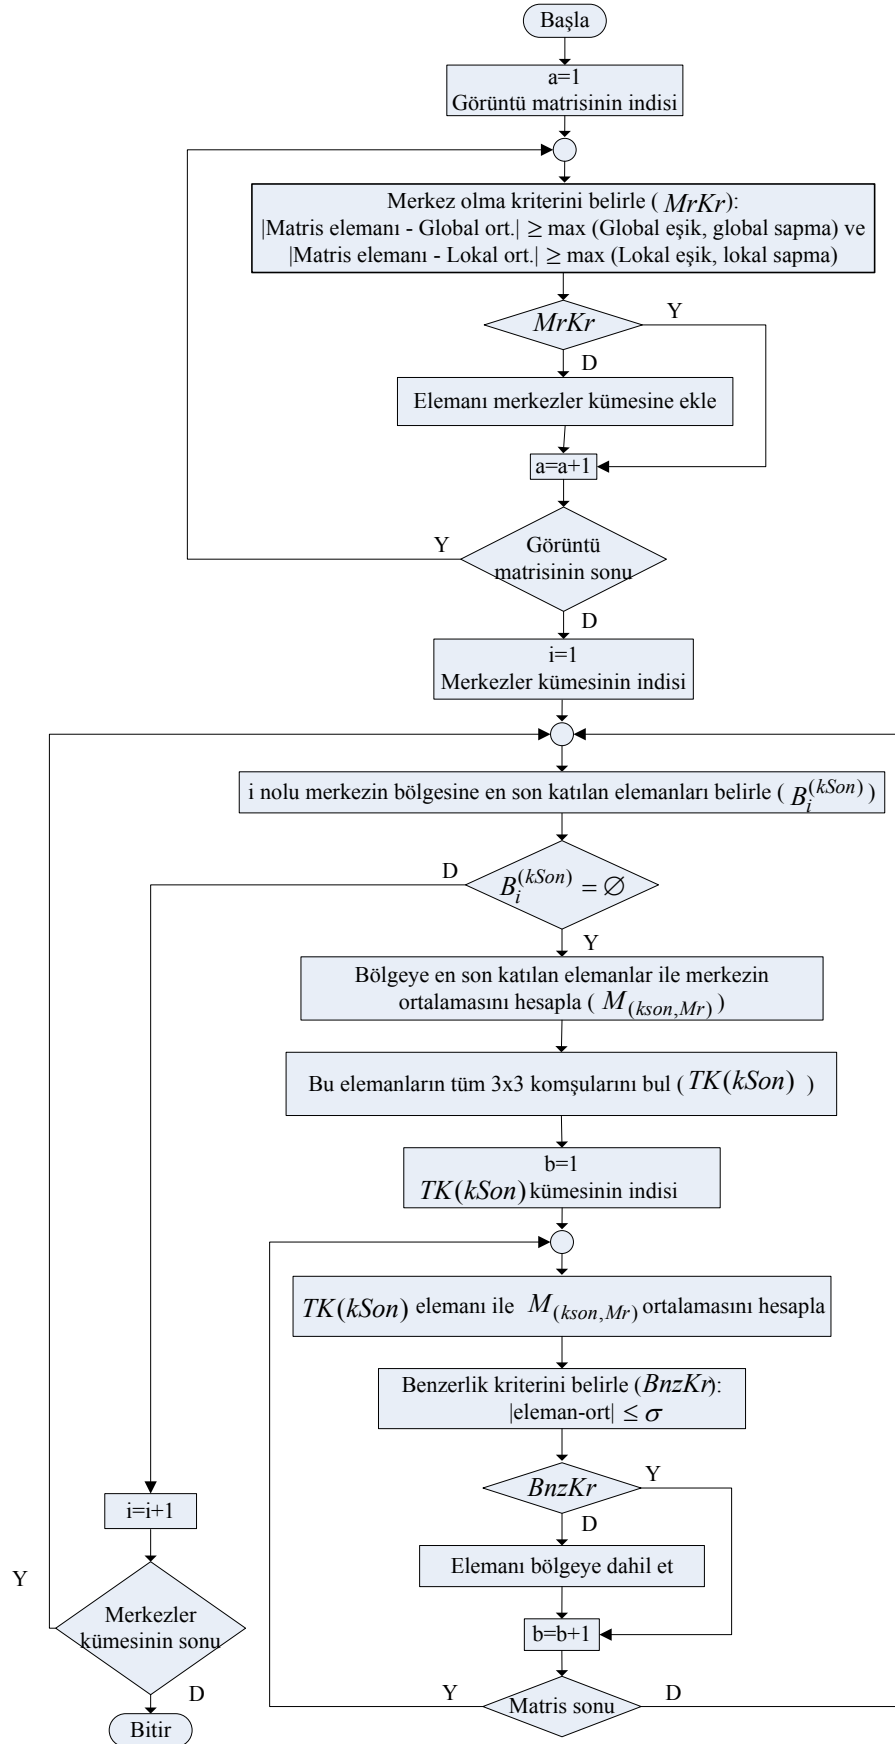
$$BnzKr = |M_j - TK_j(kSon)| \leq S_{TK(j)}$$

(3.2.2) $BnzKr = DOGRU$ ise,

I görüntüsünde j . elemanı gösteren piksel i . bölgeye katılır.


$$B_i = B_i \cup I(TK_j(kSon))$$

Görüntü işlemede bölütleme genel olarak ilgili bölgeyi tespit etme (Region of Interest (ROI) detection) işleminden önce yapılmaktadır. Amaç, tüm görüntü üzerinde tarama yapmak yerine bölgeyi küçülterek ve yerini tespit ederek sadece o alanda saptama yapmaktır. Bilindiği gibi meme kitleleri meme uç bölgesinden kolaltı dokusuna kadar her yerde olabilmektedir. Dolayısıyla kitle tespit etmeden önce bölütlenmesi gereken bir bölge kavramı yoktur. Bundan dolayı bu tezde, ilgili bölgelerin sadece kitlelerin kendi bölgelerinin olduğu düşünülerek bölütleme işlemi kitle tespit işlemi olarak kullanılmıştır. Şekil 4.16 da LMBB algoritmasının akış şeması gösterilmektedir.




Şekil 4.16: LMBB algoritmasının akış şeması

Şekil 4.17-4.37 ile gösterilen mamogramlarda LMBB bölütleme algoritması uygulanmış, GP ve YP kitleler tespit edilmiştir. Şekil 4.17.a da üst dış kadranda malign kitle içeren 41 yaşında bir kadına ait sol meme MLO görüntüsü verilmiştir. Şekil 4.17.b de geliştirilmiş olan filtreleme-modelleme ve adaptif eşikleme yöntemiyle iyileştirilmiş görüntü yer almaktadır. Şekil 4.17.c de ise bölütlenmiş görüntü verilmiştir. Beyaz ok malign özellik gösteren GP kitleyi, siyah oklar ise programın bulduğu YP kitleleri göstermektedir. Orjinal mamogramda kitle bazı bölgelerde meme dokusuyla bütünleşik bir görüntü sergilemekte olduğundan kenar kontürü belirgin değildir. Tanı koymanın zor olduğu bu örnekte geliştirilen BDT yöntemiyle kitle başarılı bir şekilde bulunmuş, kontürü belirginleştirilmiştir.



Şekil 4.17: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü


Şekil 4.18.a da üst kadranda orta hatta malign kitle içeren 47 yaşında bir kadına ait sağ meme CC görüntüsü verilmiştir. Şekil 4.18.b de geliştirilmiş olan filtreleme-modelleme ve adaptif eşikleme yöntemiyle iyileştirilmiş görüntü yer almaktadır. Şekil 4.18.c de ise bölütlenmiş görüntü verilmiştir. Beyaz ok malign özellik gösteren GP kitleyi, siyah oklar ise programın bulduğu YP kitleyi göstermektedir. Görüntü iyileştirme ile artırılan kitle kontrastı yardımıyla kitle tespit edilmiştir.



Şekil 4.18: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü


Şekil 4.19.a da üst dış kadranda malign kitle içeren 34 yaşında bir kadına ait sağ meme CC görüntüsü verilmiştir. Şekil 4.19.b de geliştirilmiş olan filtreleme-modelleme ve

adaptif eşikleme yöntemiyle iyileştirilmiş görüntü yer almaktadır. Şekil 4.19.c de ise bölütlenmiş görüntü verilmiştir. Beyaz ok malign özellik gösteren GP kitleyi, siyah oklar ise programın bulduğu YP kitleleri göstermektedir. Orjinal mamogram bulanık olup kitle bulma ve tanı koyma açısından yetersiz kalmaktadır. Geliştirilen yöntemle kitle başarılı bir şekilde tespit edilmiştir.




Şekil 4.19: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.20.a da üst dış kadranda iki tane benign kitle içeren 54 yaşında bir kadına ait sol meme CC görüntüsü verilmiştir. Şekil 4.20.b de geliştirilmiş olan filtreleme-modelleme ve adaptif eşikleme yöntemiyle iyileştirilmiş görüntü yer almaktadır. Şekil 4.20.c de ise bölütlenmiş görüntü verilmiştir. Beyaz oklar benign özellik gösteren GP kitleleri, siyah oklar ise programın bulduğu YP kitleleri göstermektedir.




Şekil 4.20: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.21.a da üst iç kadranda malign kitle içeren 40 yaşında bir kadına ait sol meme CC görüntüsü verilmiştir. Şekil 4.21.b de geliştirilmiş olan filtreleme-modelleme ve adaptif eşikleme yöntemiyle iyileştirilmiş görüntü yer almaktadır. Şekil 4.21.c de ise bölütlenmiş görüntü verilmiştir. Beyaz ok malign özellik gösteren GP kitleyi, siyah oklar ise programın bulduğu YP kitleleri göstermektedir.




Şekil 4.21: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.22.a daki mamogram 69 yaşında bir kadına ait sol meme CC görüntüsüdür. Memede ileri yaşa bağlı olarak artabilen dansite gözlemlenmektedir. Bundan dolayı alt iç kadranda bulunan ve benign özellik gösteren iki meme kitlesinin meme dokusundaki tespiti zorlaşmıştır. Şekil 4.22.c de görüldüğü gibi geliştirilen iyileştirme ve bölütleme işlemlerinden sonra kitleler tespit edilmiş ancak meme yapısı kaynaklı kontrast yetersizliğinden dolayı çok sayıda YP kitle de tespit edilmiştir. Beyaz oklar benign özellik gösteren GP kitleleri, siyah oklar ise programın bulduğu YP kitleleri göstermektedir.




Şekil 4.22: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.23.a da üst dış kadranda malign kitle içeren 35 yaşında bir kadına ait sol meme MLO görüntüsü verilmiştir. Şekil 4.23.b de geliştirilmiş olan filtreleme-modelleme ve adaptif eşikleme yöntemiyle iyileştirilmiş görüntü yer almaktadır. Mamogramın genel kontrastının yetersiz olması ve görüntüde yer alan gürültü nedeniyle YP sayısı daha fazla olmuştur. Geliştirilen yöntem ile Şekil 4.23.c de görüldüğü gibi GP kitle tespit edilmiş ve dolayısıyla tanı kolaylaşmıştır. Beyaz ok malign özellik gösteren GP kitleyi, siyah oklar ise programın bulduğu YP kitleleri göstermektedir.




Şekil 4.23: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.24.a da 44 yaşında bir kadına ait sol meme MLO görüntüsü yer almaktadır. Şekil 4.24.c de görüldüğü gibi memede dış kadranda orta hatta bulunan büyük boyuttaki benign kitle tanı konmak üzere tespit edilmiştir.




Şekil 4.24: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.25.a da 44 yaşında bir kadına ait sol meme CC mamogramı yer almaktadır. Orjinal görüntüde şüpheli bölge diğer bölgelere göre daha parlak renkte olduğu için belirgindir. Ancak benign kitlenin kenar kontürü tam olarak kestirilememektedir. Şekil 4.25.c de de görüldüğü gibi kitle arka plandan düzgün bir şekilde ayrılmış, üstündeki doku ise YP kitle olarak tespit edilmiştir. Bölütleme ile üç bölgeye ayrılan şüpheli kısım orjinal resimde bir bütün halinde görünmektedir. Şekil 4.25.c de beyaz ok benign özellik gösteren GP kitleyi, siyah oklar ise programın bulduğu YP kitleleri göstermektedir.




Şekil 4.25: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.26.a daki mamogram 43 yaşında bir kadın hastaya ait sol meme CC görüntüsüdür. Görüldüğü gibi; meme dens bir yapıya sahip olup üst dış kadranda iki tane malign kitle bulundurmaktadır. Bu kitlelerin herhangi bir ön işleminden geçmemiş orjinal mamogramda tespit edilip benign veya malign tanısının konulması güçtür. Görüntü iyileştirmenin ardından artırılan kontrast ile gerekli olan kenar verisi vurgulanırken, bulanıklığa sebep olan gürültü ve dansitenin parlaklığı azaltılmıştır. Şekil 4.26.c de görüldüğü gibi tek bir YP kitle ile tüm GP kitleler tespit edilmiştir. Beyaz oklar GP kitleleri, siyah ok ise YP kitleyi göstermektedir.




Şekil 4.26: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.27.a da görüldüğü gibi, 40 yaşında bir kadına ait sol meme MLO mamogramında üst dış kadranda ok işareti ile gösterilmiş benign kitle bulunmaktadır. Şekil 4.27.b de iyileştirilmiş görüntü verilirken, Şekil 4.27.c de geliştirilen sistemin tespit ettiği beyaz okla gösterilen benign GP kitle ve siyah oklar ile gösterilen YP kitleler verilmiştir.




Şekil 4.27: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.28.a 65 yaşında bir kadına ait sağ meme CC mamogramına ait görüntüdür. Üst dış kadranda malign kitle bulunmaktadır.




Şekil 4.28: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.29.a ise 52 yaşında bir kadına ait sol meme CC mamogramının görüntüsüdür. Alt iç kadranda malign özellik gösteren kitle bulunmaktadır. Şekil 4.28.c ve Şekil 4.29.c de beyaz oklar GP kitleleri, siyah oklar ise YP kitleleri göstermekte olup, geliştirilen bölütleme sistemi ile kitle ve kenar kontürlerinin arka plandan ayrılarak belirgin hale getirildiği görülmektedir.




Şekil 4.29: Görüntü bölütleme örneği a) Orjinal mammoqram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.30.a da görülen sol meme CC mamogramı 49 yaşında bir kadın hastaya ait olup üst dış ve alt iç kadranda çok sayıda benign karakterli kitle taşımaktadır. Görüntünün oldukça dens bir yapıya sahip olması ve kitlelerin çevresinde gürültünün artış göstermesi tespit ve tanıyı güçleştirmektedir. Şekil 4.30.b deki iyileştirilmiş görüntüde geliştirilen tekniğin kitle etrafındaki kontrastı artırarak kenar tespiti görevi üstlendiği görülmektedir. Böylece kitleler radyolog tarafından kolayca görülebilecek hale gelmiştir.




Şekil 4.30: Görüntü bölütleme örneği a) Orjinal mammoqram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.31.a da 58 yaşında bir kadın hastaya ait sol meme MLO mamogramı yer almıştır. Üst dış kadranda malign bir kitle bulunmaktadır. Kitle için kenar tespiti yapılırken diğer meme dokularının parlaklığı azaltılarak daha az belirgin hale getirilmiştir. Şekil 4.31.c de beyaz ok ile gösterilen GP kitledir.




Şekil 4.31: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.32.a da ise 41 yaşında bir kadına ait üst dış kadranda benign kitle barındıran sol meme MLO mamogram görüntüsü verilmiştir. Orjinal mamogramın genelinde parlaklığın fazla olması, meme dokusunun gri seviye açısından tek bir parça halinde gözükmesine yol açmıştır. Dolayısıyla kitlenin tespit ve tanısının güç olduğu bir vakadır. Şekil 4.32.c de görüldüğü gibi, önerilen görüntü iyileştirme ve bölütleme metodları ile mamogramdaki tek bir GP kitle bulunmuştur. Beyaz ok GP kitleyi, siyah ok ise YP kitleleri göstermektedir.




Şekil 4.32: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.33.a da 54 yaşında bir kadın hastaya ait sol meme CC görüntüsü görülmektedir. Meme üst dış kadranda bir adet malign kitle barındırmaktadır. Yüksek dansiteden dolayı kitlenin orjinal mamogramda ön işlemsiz olarak tespiti zorlaşmıştır. Şekil 4.33.c incelendiğinde GP kitle tespit edilirken kitleye yakın gri seviye renk değerine sahip diğer bölgelerin başarılı bir şekilde elimine edildiği görülmektedir. Şekil 4.33.c de beyaz ok GP kitleyi, siyah ok ise YP kitleyi göstermektedir.




Şekil 4.33: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.34.a, 57 yaşında bir kadına ait sol meme MLO mamogramını göstermektedir. Meme üst dış kadranda bulunan kitle benign özellik göstermektedir.




Şekil 4.34: Görüntü bölütleme örneği a) Orjinal mammoqram b) İyileştirilmiş görüntü
c) Bölütlenmiş görüntü

Şekil 4.35.a ise 55 yaşında bir hastaya ait mamografi görüntüsü olup, üst dış kadranda benign özellik taşıyan kitle bulunmaktadır. Şekil 4.34.c ve 4.35.c de görüldüğü gibi beyaz oklarla gösterilen GP kitleler başarılı bir şekilde tespit edilmiştir. Siyah oklar YP kitleleri temsil etmektedir.




Şekil 4.35: Görüntü bölütleme örneği a) Orjinal mammogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

Şekil 4.36.a ve 4.37.a online mamogram veritabanı MIAS'a aittir. MIAS veritabanında hasta yaşlarına yer verilmemiştir. Şekil 4.36.a ve 4.37.a da görüldüğü gibi kitleler yuvarlak çerçevelerin içine alınmış şekilde sunulmuşlardır. Şekil 4.36.a da sağ meme CC görüntüsünde orta hatta bulunan kitle malign özellik gösterirken, Şekil 4.37.a da alt kadranda bulunan kitle benign özellik göstermektedir. Şekil 4.36.c ve 4.37.c de görüldüğü gibi kitleler geliştirilen yöntem ile başarılı bir şekilde tespit edilmişlerdir. Beyaz oklar GP kitleleri gösterirken, siyah oklar YP kitleleri göstermektedir.



Şekil 4.36: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü



Şekil 4.37: Görüntü bölütleme örneği a) Orjinal mamogram b) İyileştirilmiş görüntü c) Bölütlenmiş görüntü

4.2.2. LMBB ile Elde Edilen Sonuçların Değerlendirilmesi

Malzeme ve Yöntem bölümünde de belirtildiği gibi bu tez çalışmasında iki farklı veritabanı kullanılmıştır. Sonuç değerlendirmesi iki veri seti için ayrı ayrı yapılmıştır. Önerilen LMBB tabanlı kitle tespit etme yönteminin başarısını ölçmek için Denklem 4.4 de belirtilen ve toplam görüntü başına düşen YP kitle sayısını gösteren YP_{kitle} değeri hesaplanmıştır. Yöntemin uygunluğu bu sayı değerinin küçüklüğü ile ilişkilidir. Diğer bir hesaplama ise Denklem 4.5 de verilen ve mamogramda bulunan GP kitleleri tespit edebilme başarısını gösteren (TBY) tespit başarı yüzdesidir. LMBB yönteminin etkinliği TBY değerinin büyük olmasına bağlıdır.

$$YP_{kitle} = \frac{\text{Tespit edilen YP kitle sayısı}}{\text{Değerlendirilen toplam görüntü sayısı}} \quad (4.4)$$

$$TBY = \frac{\text{Tespit edilen GP kitle sayısı}}{\text{Toplam GP kitle sayısı}} \times 100 \quad (4.5)$$

Bu çalışmada elde edilen İTF mamogram veritabanında; LMBB algoritması 60 mamogram üzerinde uygulanmıştır. Elde edilen sonuçlara göre; toplam 269 adet kitle bulunmuştur. Ancak bunlardan 191'i YP kitledir. Radyolog tarafından işaretlenen toplam 78 GP kitlenin hepsi tespit edilmiştir. Dolayısıyla Denklem 4.4 e göre tespit başarısı (TBY) %100'dür. Görüntü (mamogram) başına düşen toplam YP kitle sayısı (YP_{kitle}) yukarıdaki verilere göre 3.2 olarak (191/60) hesaplanmıştır.

MIAS veritabanı üzerinden oluşturulan veri setinde de; LMBB algoritması 60 mamogram üzerinde uygulanmıştır. Elde edilen sonuçlara göre; toplam 234 adet kitle bulunmuştur. Ancak bunlardan 174'ü YP kitledir. Radyolog tarafından işaretlenen toplam 60 GP kitlenin tamamı tespit edilebilmiştir. Bu durumda tespit başarısı (TBY) %100 olarak hesaplanabilir. Görüntü (mamogram) başına düşen toplam YP kitle sayısı (YP_{kitle}) ise 2.9 olarak (174/60) hesaplanır. YP_{kitle} değerinin optimum değeri 0'dır. YP kitlelerin varlığı istenmeyen bir durum olup yanlış tanıya sebebiyet verebildiğinden sonraki sınıflandırma aşamasının amaçlarından biri de bu değeri olabildiği kadar düşürmektir. Elde edilen sonuçlara göre YP_{kitle} değeri MIAS veritabanında daha düşük

çıkarken *TBY* değerleri her iki veritabanında da %100 bulunmuştur. Sonuçlar Tablo 4.1 de verilmiştir.


Tablo 4.1: LMBB yöntemiyle elde edilen sonuçlar

Mamogram veritabanı	Hasta sayısı	Mamogram sayısı	GP kitle sayısı	Tespit edilen GP kitle sayısı	Tespit edilen YP kitle sayısı	YP_{kitle}	<i>TBY</i>
İTF	30	60	78	78	191	3.2	%100
MIAS	60	60	60	60	174	2.9	%100

4.3. MEME KİTLELERİNİN SINIFLANDIRILMASI

LMBB yöntemi ile kitleleri tespit edip bilgisayar destekli tanıyı (BDT) tamamlamak mümkün değildir. Bunun sebebi LMBB ile GP kitlelerin yanında YP kitleler de tespit edilmiştir. Bu tezde BDT iki aşamada gerçekleştirilmiştir. İlk aşamada bulunan kitleler sınıflandırma sistemine sokularak kitle veya normal meme dokusu ayrımı yapılmıştır. Diğer sınıflandırma ise GP kitleler arasından malign veya benign kitle ayrımı için yapılmıştır. Malign kitleler kanseri sembolize ettiklerinden tanı koymada hasta kanserdir denilebilir.

Bu tezde kullanılan sınıflandırma işlemi akış şeması Şekil 4.38 de gösterilmiştir. Ayrıca başarı performansını gösteren kitle-doku sınıflandırma doğruluğu (classification accuracy), malign-benign sınıflandırma doğruluğu, tüm BDT sisteminin tanı doğruluğu, duyarlılık (sensitivity) ve seçicilik (specificity) yüzdeleri gibi parametre denklemleri de sırasıyla Denklem 4.6, 4.7, 4.8 ve 4.9 da verilmiştir.



Şekil 4.38: Sınıflandırma akış şeması

Kitle – doku ve

Malign – Benign

$$\text{Sınıflandırma Doğruluğu} = \frac{GP + GN}{\text{Toplam veri sayısı}} \times 100 \quad (4.6)$$

(1.ve 2.Sınıflandırma)

$$\text{Duyarlilik} = \frac{GP}{GP + YN} \times 100 \quad (4.7)$$

$$\text{Seçicilik} = \frac{GN}{GN + YP} \times 100 \quad (4.8)$$

$$\text{BDT Sınıflandırma Doğruluğu} = 1.\text{Sınıflandırma} \times 2.\text{Sınıflandırma} \times \frac{1}{100} \quad (4.9)$$

4.3.1. Kitle-Doku Sınıflandırması ve Elde Edilen Sonuçların Değerlendirilmesi

İTF veritabanında kitle-doku sınıflandırması sonuçlarına ulaşmak için DVM sistemine 269 giriş verilmiştir. Bu girişlerden 191'i YP kitle, 78'i ise GP kitledir. DVM sınıflandırmada ayrı ayrı doğrusal, karesel ve radyal tabanlı (RTF) çekirdek fonksiyonları kullanılmıştır. İstatistiksel sonuçları gösteren Tablo 4.2 ye göre kitleleri

normal doku bölgelerinden ayırmada Denklem 4.6 kullanılarak bulunan en yüksek başarı yüzdesini %96 ile doğrusal fonksiyon vermiştir. Karesel fonksiyon ile RTF'nin başarısı ise %92 olarak ölçülmüştür. Denklem 4.8 ile bulunan en yüksek duyarlılık %88 olup, doğrusal çekirdek fonksiyonu ile sağlanmıştır. Karesel çekirdek fonksiyonunda duyarlılık %81 iken RTF'de %85'tir. Denklem 4.9 ile bulunan en yüksek seçicilik %98 olup, doğrusal çekirdek fonksiyonu ile sağlanmıştır. Karesel çekirdek fonksiyonunda seçicilik %96 iken RTF'de %95'tir.

Tablo 4.2: Kitle-doku sınıflandırma doğruluğu

Mamogram veritabanı	Çekirdek fonksiyon tipi	Duyarlılık (%)	Seçicilik (%)	Kitle-doku sınıflandırma doğruluğu (%)
İTF	Doğrusal	88	98	96
	Karesel	81	96	92
	RTF	85	95	92
MIAS	Doğrusal	92	96	95
	Karesel	77	95	91
	RTF	88	95	93

Sınıflandırmada üç ayrı fonksiyonda bulunan GP ve YP sayıları ise ayrıntılı olarak Tablo 4.3 de listelenmiştir. Buna göre; İTF veritabanında doğrusal çekirdek fonksiyonu ile 78 tane kitleden 69 tanesi doğru tespit edilmiş kitle, 9 tanesi doku olarak sınıflandırılmış YN kitledir. 191 doku bölgesinden ise 188 tanesi doğru tespit edilmiş doku, 3 tanesi kitle olarak sınıflandırılmış YP dokudur. Karesel çekirdek fonksiyonu ile 78 tane kitleden 63 tanesi doğru tespit edilmiş kitle, 15 tanesi doku olarak sınıflandırılmış YN kitledir. 191 doku bölgesinden ise 184 tanesi doğru tespit edilmiş doku, 7 tanesi kitle olarak sınıflandırılmış YP dokudur. RTF ile 78 tane kitleden 66 tanesi doğru tespit edilmiş kitle, 12 tanesi doku olarak sınıflandırılmış YN kitledir. 191 doku bölgesinden ise 182 tanesi doğru tespit edilmiş doku, 9 tanesi kitle olarak sınıflandırılmış YP dokudur. MIAS veritabanında ise doğrusal çekirdek fonksiyonu ile 60 tane kitleden 55 tanesi doğru tespit edilmiş kitle, 5 tanesi doku olarak sınıflandırılmış YN kitledir. 174 doku bölgesinden ise 167 tanesi doğru tespit edilmiş doku, 7 tanesi kitle olarak sınıflandırılmış YP dokudur. Karesel çekirdek fonksiyonu ile 60 tane kitleden 46 tanesi doğru tespit edilmiş kitle, 14 tanesi doku olarak sınıflandırılmış YN kitledir. 174 doku bölgesinden ise 166 tanesi doğru tespit edilmiş doku, 8 tanesi kitle olarak sınıflandırılmış YP dokudur. RTF ile 60 tane kitleden 53 tanesi doğru tespit


edilmiş kitle, 7 tanesi doku olarak sınıflandırılmış YN kitledir. 174 doku bölgesinden ise 165 tanesi doğru tespit edilmiş doku, 9 tanesi kitle olarak sınıflandırılmış YP dokudur.

Sınıflandırma yapılmadan önce İTF veritabanı için Denklem 4.5 kullanılarak bulunan ve 3.2 olan YP_{kitle} değeri kitle-doku sınıflandırmasında sonra Tablo 4.3 den de görüldüğü gibi doğrusal fonksiyon ile 0.05'e, karesel fonksiyon ile 0.12'ye, RTF ile 0.15'e düşmüştür. MIAS veritabanı içinse 2.9 olan YP_{kitle} değeri kitle-doku sınıflandırmasında sonra doğrusal fonksiyon ile 0.12'ye, karesel fonksiyon ile 0.13'e, RTF ile 0.15'e düşmüştür.


Tablo 4.3: Kitle-doku sınıflandırmada GP, GN, YP, YN sayıları

Mamogram veritabanı	Çekirdek fonksiyon tipi	Gerçek durum	Kestirilen durum	
			Pozitif (Kitle)	Negatif (Doku)
İTF	Doğrusal	Pozitif (Kitle)	69	9
		Negatif (Doku)	3	188
	Karesel	Pozitif (Kitle)	63	15
		Negatif (Doku)	7	184
	RTF	Pozitif (Kitle)	66	12
		Negatif (Doku)	9	182
MIAS	Doğrusal	Pozitif (Kitle)	55	5
		Negatif (Doku)	7	167
	Karesel	Pozitif (Kitle)	46	14
		Negatif (Doku)	8	166
	RTF	Pozitif (Kitle)	53	7
		Negatif (Doku)	9	165

Performans incelemesi için ayrıca alıcı işletim karakteristiği (Receiver Operating Characteristics - ROC) eğrilerinden faydalanılmıştır. Tanı testine ilişkin duyarlılık ve seçicilik değerleri arasındaki ilişkiyi grafiksel olarak gösteren ROC eğrisi testlerin güvenilirliği ve genel sınıflandırma doğruluğu açısından standart yöntem haline gelmiştir. ROC eğrisinin x ekseninde seçicilik, y ekseninde ise duyarlılık vardır. Eğri altında kalan alan ne kadar büyükse yapılan sınıflandırma o kadar başarılıdır. Şekil 4.39 ve 4.40 sırasıyla doğrusal, karesel çekirdek fonksiyonları ve RTF ile İTF veritabanında ve MIAS veritabanında elde edilen DVM sınıflandırma sonuçlarının ROC eğrilerini göstermektedir.



Şekil 4.39: ROC performans eğrisi



Şekil 4.40: ROC performans eğrisi

4.3.2. Malign-Benign Sınıflandırması ve Elde Edilen Sonuçların Değerlendirilmesi

DVM malign-benign sınıflandırmada, GP kitlelerin malign mi (kötü huylu) benign mi (iyi huylu) olduğuna karar verir. BDT'ye olanak sağlayan esas sınıflandırma işlemi malign-benign ayırımıdır. KDD ile elde edilen 6 farklı katsayı matrisinin

$(w_1, w_2, w_3, w_4, w_5, c_5)$ tümünün özellikleri sisteme giriş olarak sunulmuştur. Bunun yanısıra bu katsayı matrisleri niteliklerine göre farklı gruplar halinde kısmi olarak sisteme verilmişlerdir. Burada amaç çok yönlü karşılaştırmayı gerçeklemek ve farklı seviyedeki (ölçekteki) katsayıların sınıflandırma başarısına olan etkisini ölçmektir. Öznitelikleri çıkarılmış katsayı matrisi grupları performans testi için 5 alt gruba ayrılmışlardır. Bunlar; son ölçek katsayıları (Sk) (w_5, c_5) , en yüksek iki ölçek katsayıları (EYİK) (w_4, w_5, c_5) , yaklaşıklık katsayıları (Yk) (c_5) , ayrıntı katsayıları (Ak) $(w_1, w_2, w_3, w_4, w_5)$ ve tüm katsayılarıdır (Tk) $(w_1, w_2, w_3, w_4, w_5, c_5)$. Önerilen BDT sisteminin performansı tüm bu alt gruplar için ayrı ayrı incelenmiştir.

Tespit edilen ilgili bölgelere (ROIs) KDD yöntemine ek olarak HDD yöntemi de uygulanmıştır. Uygulanan HDD iki seviye olup toplam 8 farklı katsayı matrisi elde edilmiştir. Bunlar 1. seviye yaklaşıklık, 1. seviye yatay, 1. seviye dikey, 1. seviye diyagonal, 2. seviye yaklaşıklık, 2. seviye yatay, 2. seviye dikey ve 2. seviye diyagonal $(a_1, y_1, d_1, dy_1, a_2, y_2, d_2, dy_2)$ katsayılarıdır. KDD ile elde edilen toplam katsayı sayısı 6 olduğundan bu sayıya uyumlu olması için 1. seviye ayrıntı katsayılarının sadece ortalaması $(ort(a_1, y_1, d_1))$ kullanılmıştır. Böylece toplam katsayı matrisi sayısı 6'ya düşürülmüştür. HDD uygulamasında da çok yönlü karşılaştırmayı gerçeklemek ve farklı seviyedeki (ölçekteki) katsayıların sınıflandırma başarısına olan etkisini ölçmek için öznitelikleri çıkarılmış katsayı matrisi grupları performans testinde 4 alt gruba ayrılmışlardır. Bunlar; yaklaşıklık ile ortalama ayrıntı katsayıları (Yk&OAK) $(a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2))$, yaklaşıklık katsayıları (Yk) (a_1, a_2) , ayrıntı katsayıları (Ak) $(ort(y_1, d_1, dy_1), y_2, d_2, dy_2)$ ve tüm katsayılarıdır (Tk) $(a_1, a_2, ort(y_1, d_1, dy_1), y_2, d_2, dy_2)$. Önerilen BDT sisteminin performansı tüm bu alt gruplar için ayrı ayrı incelenmiştir.

Tablo 4.4: Doğrusal çekirdek fonksiyonu ile İTF veritabanında elde edilen sonuçlar

Yöntem	Katsayı grubu	DVM k değeri	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
KDD	Sk	8	100	88	94	90.2
KDD	EYİk	8	97	90	94	90.2
KDD	Tk	9	92	90	91	87.4
KDD	Yk	4	89	86	87	83.5
KDD	Ak	7	83	76	79	75.8
-	Kitle matrisi	9	68	81	75	72
HDD	Yk&OAK	9	83	86	85	81.6
HDD	Tk	8	83	81	82	78.7
HDD	Yk	3	78	83	81	77.8
HDD	Ak	9	78	76	78	74.9


Tablo 4.4, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, hazırlanan İTF veritabanında ve doğrusal çekirdek fonksiyonu kullanılarak verdiği sonuçları göstermektedir. Buna göre; KDD uygulanarak katsayıları elde edilmiş kitle matrisinin öz niteliklerinden Denklem 4.7 ile bulunan en yüksek malign-benign sınıflandırma doğruluğunu %94 başarı ile son ölçek katsayıları (Sk) (w_5, c_5) ve en yüksek iki ölçek katsayıları (EYİk) (w_4, w_5, c_5) vermiştir. Sistemin en yüksek performansı olan bu parametreler için ROC puanı 0.997'dir. En düşük malign-benign sınıflandırma doğruluğunu ise %79 başarı ile ayrıştırma katsayıları (Ak) (w_1, w_2, w_3, w_4, w_5) vermiştir.

HDD uygulanarak katsayıları elde edilmiş kitle matrisinin öz niteliklerinden en yüksek malign-benign sınıflandırma doğruluğunu %85 başarı ile son yaklaşıklık ile ortalama ayrıştırma katsayıları (Yk&OAK) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %78 başarı ile ayrıştırma katsayıları (Ak) ($ort(y_1, d_1, dy_1), y_2, d_2, dy_2$) vermiştir.


Denklem 4.8 kullanılarak bulunan en yüksek duyarlılık (%100) KDD katsayılarından son ölçek katsayıları (Sk) ile, Denklem 4.9 kullanılarak bulunan en yüksek seçicilik (%90) ise KDD katsayılarından en yüksek iki ölçek katsayıları (EYİk) ve tüm katsayılar (Tk) ile sağlanmıştır.

Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisi kullanıldığında ise %75 gibi daha düşük bir performans gözlenmiştir. Tablo 4.4 deki son sütun, Denklem 4.10 kullanılarak bulunan tüm BDT sisteminin tanı doğruluğunu göstermektedir. İTF veritabanı için Denklem 4.10 deki 1. sınıflandırma doğruluk değeri, Tablo 4.2 den de görüldüğü gibi en yüksek değer olan %96 olarak alınmıştır. Her katsayı grubu için Denklem 4.10 kullanılarak ayrı bir BDT sistemi tanı doğruluğuna ulaşılmıştır. Buna göre; en yüksek BDT sistemi tanı doğruluğu %90.2 başarı ile KDD uygulamasıyla Sk ve EYİk katsayıları kullanılarak, %81.6 başarı ile de HDD uygulaması ve Yk&OAc katsayıları kullanılarak elde edilmiştir.


Tablo 4.4 ile ilgili 3 adet ROC eğrisi çizilmiştir. Şekil 4.41 de, Tablo 4.4 deki KDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.42 de, Tablo 4.4 deki HDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.43 de, Tablo 4.4 deki en yüksek performansı veren iki KDD katsayı grubu özniteliği, iki HDD katsayı grubu özniteliği ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.



Şekil 4.41: ROC performans eğrisi



Şekil 4.42: ROC performans eğrisi



Şekil 4.43: ROC performans eğrisi

Tablo 4.5: Karesel çekirdek fonksiyonu ile İTF veritabanında elde edilen sonuçlar

Yöntem	Katsayı grubu	DVM k değeri	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
KDD	Sk	4	97	86	91	87.4
KDD	EYİk	8	100	83	91	87.4
KDD	Tk	9	92	81	86	82.6
KDD	Yk	4	92	83	87	83.5
KDD	Ak	6	81	74	77	73.9
-	Kitle matrisi	9	74	77	75	72
HDD	Yk&OAK	9	83	81	82	78.7
HDD	Tk	9	89	71	80	76.8
HDD	Yk	2	81	76	78	74.9
HDD	Ak	3	81	71	76	73

Tablo 4.5 önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, hazırlanan İTF veritabanında ve karesel çekirdek fonksiyonu kullanılarak verdiği sonuçları göstermektedir. Buna göre; KDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden Denklem 4.7 ile bulunan en yüksek malign-benign sınıflandırma doğruluğunu %91 başarı ile son ölçek katsayıları (Sk) (w_5, c_5) ve en yüksek iki ölçek katsayıları (EYİk) (w_4, w_5, c_5) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %77 başarı ile ayrıştırma katsayıları (Ak) (w_1, w_2, w_3, w_4, w_5) vermiştir.

HDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden en yüksek malign-benign sınıflandırma doğruluğunu %82 başarı ile son yaklaşıklık ile ortalama ayrıştırma katsayıları (Yk&OAK) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %76 başarı ile ayrıştırma katsayıları (Ak) ($ort(y_1, d_1, dy_1), y_2, d_2, dy_2$) vermiştir.


Denklem 4.8 kullanılarak bulunan en yüksek duyarlılık (%100) KDD katsayılarından en yüksek iki ölçek katsayıları (EYİk) ile, Denklem 4.9 kullanılarak bulunan en yüksek seçicilik (%86) ise KDD katsayılarından son ölçek katsayıları (Sk) ile sağlanmıştır.

Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisi kullanıldığında ise %75 gibi daha düşük bir performans gözlenmiştir. Tablo 4.5 deki son sütun, Denklem 4.10 kullanılarak bulunan tüm BDT sisteminin tanı doğruluğunu


göstermektedir. İTF veritabanı için Denklem 4.10 deki 1. sınıflandırma doğruluk değeri, Tablo 4.2 den de görüldüğü gibi en yüksek değer olan %96 olarak alınmıştır. Her katsayı grubu için Denklem 4.10 kullanılarak ayrı bir BDT sistemi tanı doğruluğuna ulaşılmıştır. Buna göre; en yüksek BDT sistemi tanı doğruluğu %87.4 başarı ile KDD uygulaması ve Sk ve EYİK katsayıları kullanılarak, %78.7 başarı ile de HDD uygulaması ve Yk&OAK katsayıları kullanılarak elde edilmiştir.

Tablo 4.5 ile ilgili 3 adet ROC eğrisi çizilmiştir. Şekil 4.44 de, Tablo 4.5 deki KDD katsayı gruplarının öznelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznelilik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.45 de, Tablo 4.5 deki HDD katsayı gruplarının öznelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznelilik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.


Şekil 4.46 da, Tablo 4.5 deki en yüksek performansı veren iki KDD katsayı grubu özneliği, iki HDD katsayı grubu özneliği ile KDD veya HDD uygulamadan kitlenin kendi öznelilik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.



Şekil 4.44: ROC performans eğrisi



Şekil 4.45: ROC performans eğrisi



Şekil 4.46: ROC performans eğrisi

Tablo 4.6: RTF çekirdek fonksiyonu ile İTF veritabanında elde edilen sonuçlar

Yöntem	Katsayı grubu	DVM k değeri	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
KDD	Sk	8	89	93	91	87.4
KDD	EYİk	5	92	95	94	90.2
KDD	Tk	9	81	93	87	83.5
KDD	Yk	4	89	83	86	82.6
KDD	Ak	8	78	79	78	74.9
-	Kitle matrisi	9	71	79	75	72
HDD	Yk&OAK	6	78	86	82	78.7
HDD	Tk	5	83	79	81	77.8
HDD	Yk	3	78	86	82	78.7
HDD	Ak	5	78	76	77	73.9

Tablo 4.6, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, hazırlanan İTF veritabanında ve RTF çekirdek fonksiyonu kullanılarak verdiği sonuçları göstermektedir. Buna göre; KDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden Denklem 4.7 ile bulunan en yüksek malign-benign sınıflandırma doğruluğunu %94 başarı ile en yüksek iki ölçek katsayıları (EYİk) (w_4, w_5, c_5) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %78 başarı ile ayrıntı katsayıları (Ak) (w_1, w_2, w_3, w_4, w_5) vermiştir.


HDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden en yüksek malign-benign sınıflandırma doğruluğunu %82 başarı ile son yaklaşıklık ile ortalama ayrıntı katsayıları (Yk&OAK) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) ve yaklaşıklık katsayıları (Yk) (a_1, a_2) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %77 başarı ile ayrıntı katsayıları (Ak) ($ort(y_1, d_1, dy_1), y_2, d_2, dy_2$) vermiştir.

Denklem 4.8 kullanılarak bulunan en yüksek duyarlılık (%92) KDD katsayılarından en yüksek iki ölçek katsayıları (EYİk) ile, Denklem 4.9 kullanılarak bulunan en yüksek seçicilik de (%95) KDD katsayılarından en yüksek iki ölçek katsayıları (EYİk) ile sağlanmıştır.


Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisi kullanıldığında ise %75 gibi daha düşük bir performans gözlenmiştir. Tablo 4.6 daki

son sütun, Denklem 4.10 kullanılarak bulunan tüm BDT sisteminin tanı doğruluğunu göstermektedir. İTF veritabanı için Denklem 4.10 deki 1. sınıflandırma doğruluk değeri, Tablo 4.2 den de görüldüğü gibi en yüksek değer olan %96 olarak alınmıştır. Her katsayı grubu için Denklem 4.10 kullanılarak ayrı bir BDT sistemi tanı doğruluğuna ulaşılmıştır. Buna göre; en yüksek BDT sistemi tanı doğruluğu %90.2 başarı ile KDD uygulaması ve EYİK katsayıları kullanılarak, %78.7 başarı ile de HDD uygulaması ve Yk&OAK ve Yk katsayıları kullanılarak elde edilmiştir.


Tablo 4.6 ile ilgili 3 adet ROC eğrisi çizilmiştir. Şekil 4.47 da, Tablo 4.6 daki KDD katsayı gruplarının öznelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.48 de, Tablo 4.6 daki HDD katsayı gruplarının öznelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.49 de, Tablo 4.6 daki en yüksek performansı veren iki KDD katsayı grubu özneliği, iki HDD katsayı grubu özneliği ile KDD veya HDD uygulamadan kitlenin kendi öznelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.



Şekil 4.47: ROC performans eğrisi



Şekil 4.48: ROC performans eğrisi




Şekil 4.49: ROC performans eğrisi

Tablo 4.7: Doğrusal, karesel ve RTF den İTF veritabanındaki en yüksek ikişer performans

DVM çekirdek fonksiyonu	Yöntem	Katsayı grubu	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
Doğrusal	KDD	Sk	100	88	94	90.2
	KDD	EYİk	97	90	94	90.2
	HDD	Yk&OAk	83	86	85	81.6
	HDD	Tk	83	81	82	78.7
	-	Kitle matrisi	68	81	75	72
Karesel	KDD	Sk	97	86	91	87.4
	KDD	EYİk	100	83	91	87.4
	HDD	Yk&OAk	83	81	82	78.7
	HDD	Tk	89	71	80	76.8
	-	Kitle matrisi	74	77	75	72
RTF	KDD	EYİk	92	95	94	90.2
	KDD	Sk	89	93	91	87.4
	HDD	Yk&OAk	78	86	82	78.7
	HDD	Yk	78	86	82	78.7
	-	Kitle matrisi	71	79	75	72

Tablo 4.7, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, hazırlanan İTF veritabanında, en yüksek ikişer doğrusal fonksiyon sonucunu, en yüksek ikişer karesel fonksiyon sonucunu ve en yüksek ikişer RTF çekirdek fonksiyonu sonuçlarını göstermektedir. Buna göre; doğrusal fonksiyon ile en yüksek BDT sistemi tanı performansı (%90.2) KDD-Sk ve KDD-EYİk katsayı grubu kullanılarak, karesel fonksiyon ile en yüksek sınıflandırma performansı (%87.4) KDD-Sk ve KDD-EYİk katsayı grubu kullanılarak, RTF fonksiyon ile de en yüksek sınıflandırma performansı (%90.2) KDD-EYİk katsayı grubu kullanılarak elde edilmiştir. Şekil 4.50 de en yüksek ikişer performansı karşılaştıran ROC eğrisi çizilmiştir.



Şekil 4.50: ROC performans eğrisi

Tablo 4.8: Doğrusal çekirdek fonksiyonu ile MIAS veritabanında elde edilen sonuçlar

Yöntem	Katsayı grubu	DVM k değeri	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
KDD	Sk	5	91	88	90	85.5
KDD	EYİK	3	100	80	92	87.4
KDD	Tk	5	94	84	90	85.5
KDD	Yk	9	91	88	90	85.5
KDD	Ak	8	86	68	78	74.1
-	Kitle matrisi	7	83	60	73	69.4
HDD	Yk&OAK	5	86	84	85	80.8
HDD	Tk	5	83	88	85	80.8
HDD	Yk	4	86	84	83	78.9
HDD	Ak	2	91	56	77	73.2

Tablo 4.8, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, MIAS veritabanında ve doğrusal çekirdek fonksiyonu kullanılarak verdiği sonuçları göstermektedir. Buna göre; KDD uygulanarak katsayıları elde edilmiş kitle matrisinin özneliliklerinden Denklem 4.7 ile bulunan en yüksek malign-benign sınıflandırma doğruluğunu %92 başarı ile en yüksek iki ölçek katsayıları (EYİK) (w_4, w_5, c_5)

vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %78 başarı ile ayrıntı katsayıları (Ak) (w_1, w_2, w_3, w_4, w_5) vermiştir.


HDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden en yüksek malign-benign sınıflandırma doğruluğunu %85 başarı ile son yaklaşıklık ile ortalama ayrıntı katsayıları (Yk&OAK) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) ve tüm katsayılar (Tk) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %77 başarı ile ayrıntı katsayıları (Ak) ($ort(y_1, d_1, dy_1), y_2, d_2, dy_2$) vermiştir.

Denklem 4.8 kullanılarak bulunan en yüksek duyarlılık (%100) KDD katsayılarından en yüksek iki ölçek katsayıları (EYİK) ile, Denklem 4.9 kullanılarak bulunan en yüksek seçicilik (%88) ise KDD katsayılarından son ölçek katsayıları (Sk), yaklaşıklık katsayıları (Yk) ve HDD katsayılarından tüm katsayılar (Tk) ile sağlanmıştır.


Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisi kullanıldığında ise %73 gibi daha düşük bir performans gözlenmiştir. Tablo 4.8 deki son sütun, Denklem 4.10 kullanılarak bulunan tüm BDT sisteminin tanı doğruluğunu göstermektedir. MIAS veritabanı için Denklem 4.10 deki 1. sınıflandırma doğruluk değeri, Tablo 4.2 den de görüldüğü gibi en yüksek değer olan %95 olarak alınmıştır. Her katsayı grubu için Denklem 4.10 kullanılarak ayrı bir BDT sistemi tanı doğruluğuna ulaşılmıştır. Buna göre; en yüksek BDT sistemi tanı doğruluğu %87.4 başarı ile KDD uygulaması ve EYİK katsayıları kullanılarak, %80.8 başarı ile de HDD uygulaması ve Yk&OAK ile Tk katsayıları kullanılarak elde edilmiştir.

Tablo 4.8 ile ilgili 3 adet ROC eğrisi çizilmiştir. Şekil 4.51 de, Tablo 4.8 deki KDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.52 de, Tablo 4.8 deki HDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.53 de, Tablo 4.8 deki en yüksek performansı veren iki KDD katsayı grubu özneliği, iki HDD katsayı grubu


özniteliği ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.



Şekil 4.51: ROC performans eğrisi



Şekil 4.52: ROC performans eğrisi



Şekil 4.53: ROC performans eğrisi

Tablo 4.9: Karesel çekirdek fonksiyonu ile MIAS veritabanında elde edilen sonuçlar

Yöntem	Katsayı grubu	DVM k değeri	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
KDD	Sk	6	91	88	90	85.5
KDD	EYİk	5	97	88	93	88.4
KDD	Tk	6	86	88	87	82.7
KDD	Yk	3	97	80	90	85.5
KDD	Ak	5	77	80	78	74.1
-	Kitle matrisi	7	80	52	68	64.6
HDD	Yk&OAc	8	97	72	87	82.7
HDD	Tk	6	86	84	85	80.8
HDD	Yk	8	91	72	83	78.9
HDD	Ak	8	83	68	77	73.2


Tablo 4.9, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, MIAS veritabanında ve karesel çekirdek fonksiyonu kullanılarak verdiği sonuçları göstermektedir. Buna göre; KDD uygulanarak katsayıları elde edilmiş kitle matrisinin özneliliklerinden Denklem 4.7 ile bulunan en yüksek malign-benign sınıflandırma doğruluğunu %93 başarı ile en yüksek iki ölçek katsayıları (EYİk) (w_4, w_5, c_5) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %78 başarı ile ayrıştırma katsayıları (Ak) (w_1, w_2, w_3, w_4, w_5) vermiştir.

HDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden en yüksek malign-benign sınıflandırma doğruluğunu %87 başarı ile son yaklaşıklık ile ortalama ayrıntı katsayıları (Yk&OAK) $(a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2))$ vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %77 başarı ile ayrıntı katsayıları (Ak) $(ort(y_1, d_1, dy_1), y_2, d_2, dy_2)$ vermiştir.


Denklem 4.8 kullanılarak bulunan en yüksek duyarlılık (%97) KDD katsayılarından en yüksek iki ölçek katsayıları (EYİK), yaklaşıklık katsayıları (Yk) ve HDD katsayılarından yaklaşıklık ile ortalama ayrıntı katsayıları (Yk&OAK) ile, Denklem 4.9 kullanılarak bulunan en yüksek seçicilik (%88) ise KDD katsayılarından son ölçek katsayıları (Sk), en yüksek iki ölçek katsayıları (EYİK) ve tüm katsayılar (Tk) ile sağlanmıştır.

Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisi kullanıldığında ise %68 gibi daha düşük bir performans gözlenmiştir. Tablo 4.9 daki son sütun, Denklem 4.10 kullanılarak bulunan tüm BDT sisteminin tanı doğruluğunu göstermektedir. MIAS veritabanı için Denklem 4.10 daki 1. sınıflandırma doğruluk değeri, Tablo 4.2 den de görüldüğü gibi en yüksek değer olan %95 olarak alınmıştır. Her katsayı grubu için Denklem 4.10 kullanılarak ayrı bir BDT sistemi tanı doğruluğuna ulaşılmıştır. Buna göre; en yüksek BDT sistemi tanı doğruluğu %88.4 başarı ile KDD uygulaması ve EYİK katsayıları kullanılarak, %82.7 başarı ile de HDD uygulaması ve Yk&OAK kullanılarak elde edilmiştir.


Tablo 4.9 ile ilgili 3 adet ROC eğrisi çizilmiştir. Şekil 4.54 da, Tablo 4.9 daki KDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.55 de, Tablo 4.9 daki HDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.56 de, Tablo 4.9 daki en yüksek performansı veren iki KDD katsayı grubu özneliği, iki HDD katsayı grubu özneliği ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.



Şekil 4.54: ROC performans eğrisi



Şekil 4.55: ROC performans eğrisi



Şekil 4.56: ROC performans eğrisi

Tablo 4.10: RTF çekirdek fonksiyonu ile MIAS veritabanında elde edilen sonuçlar

Yöntem	Katsayı grubu	DVM k değeri	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
KDD	Sk	9	89	85	87	82.7
KDD	EYİK	9	89	84	87	82.7
KDD	Tk	8	86	84	85	80.8
KDD	Yk	2	77	92	83	78.9
KDD	Ak	4	83	68	77	73.2
-	Kitle matrisi	7	86	56	73	69.4
HDD	Yk&OAK	8	86	76	82	77.9
HDD	Tk	2	80	76	78	74.1
HDD	Yk	2	89	68	80	76
HDD	Ak	9	83	64	75	71.3


Tablo 4.10, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, MIAS veritabanında ve RTF çekirdek fonksiyonu kullanılarak verdiği sonuçları göstermektedir. Buna göre; KDD uygulanarak katsayıları elde edilmiş kitle matrisinin özneliliklerinden Denklem 4.7 ile bulunan en yüksek malign-benign sınıflandırma doğruluğunu %87 başarı ile son ölçek katsayıları (Sk) (w_5, c_5) ve en yüksek iki ölçek katsayıları (EYİK) (w_4, w_5, c_5) vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %77 başarı ile ayrıştırma katsayıları (Ak) (w_1, w_2, w_3, w_4, w_5) vermiştir.

HDD uygulanarak katsayıları elde edilmiş kitle matrisinin özniteliklerinden en yüksek malign-benign sınıflandırma doğruluğunu %82 başarı ile son yaklaşıklık ile ortalama ayrıntı katsayıları (Yk&OAK) $(a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2))$ vermiştir. En düşük malign-benign sınıflandırma doğruluğunu ise %75 başarı ile ayrıntı katsayıları (Ak) $(ort(y_1, d_1, dy_1), y_2, d_2, dy_2)$ vermiştir.


Denklem 4.8 kullanılarak bulunan en yüksek duyarlılık (%89) KDD katsayılarından en yüksek iki ölçek katsayıları (EYİK), son ölçek katsayıları (Sk) ve HDD katsayılarından yaklaşıklık (Yk) katsayıları ile, Denklem 4.9 kullanılarak bulunan en yüksek seçicilik (%92) ise KDD katsayılarından yaklaşıklık katsayıları (Yk) ile sağlanmıştır.

Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisi kullanıldığında ise %73 gibi daha düşük bir performans gözlenmiştir. Tablo 4.10 daki son sütun, Denklem 4.10 kullanılarak bulunan tüm BDT sisteminin tanı doğruluğunu göstermektedir. MIAS veritabanı için Denklem 4.10 deki 1. sınıflandırma doğruluk değeri, Tablo 4.2 den de görüldüğü gibi en yüksek değer olan %95 olarak alınmıştır. Her katsayı grubu için Denklem 4.10 kullanılarak ayrı bir BDT sistemi tanı doğruluğuna ulaşılmıştır. Buna göre; en yüksek BDT sistemi tanı doğruluğu %82.7 başarı ile KDD uygulamasıyla Sk ve EYİK katsayıları kullanılarak, %77.9 başarı ile de HDD uygulaması ve Yk&OAK kullanılarak elde edilmiştir.


Tablo 4.10 ile ilgili 3 adet ROC eğrisi çizilmiştir. Şekil 4.57 de, Tablo 4.10 daki KDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.58 de, Tablo 4.10 daki HDD katsayı gruplarının öznitelikleri ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir. Şekil 4.59 da, Tablo 4.10 daki en yüksek performansı veren iki KDD katsayı grubu özneliği, iki HDD katsayı grubu özneliği ile KDD veya HDD uygulamadan kitlenin kendi öznitelik matrisinin sınıflandırma doğruluklarını karşılaştıran ROC eğrisi görülmektedir.



Şekil 4.57: ROC performans eğrisi



Şekil 4.58: ROC performans eğrisi




Şekil 4.59: ROC performans eğrisi

Tablo 4.11: Doğrusal, karesel ve RTF den MIAS veritabanındaki en yüksek ikişer performans

DVM çekirdek fonksiyonu	Yöntem	Katsayı grubu	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
Doğrusal	KDD	EYİK	100	80	92	87.4
	KDD	Sk	91	88	90	85.5
	HDD	Yk&OAK	86	84	85	80.8
	HDD	Tk	83	88	85	80.8
	-	Kitle matrisi	83	60	73	69.4
Karesel	KDD	EYİK	97	88	93	88.4
	KDD	Sk	91	88	90	85.5
	HDD	Yk&OAK	97	72	87	82.7
	HDD	Tk	86	84	85	80.8
	-	Kitle matrisi	80	52	68	64.6
RTF	KDD	Sk	89	85	87	82.7
	KDD	EYİK	89	84	87	82.7
	HDD	Yk&OAK	86	76	82	77.9
	HDD	Yk	89	68	80	76
	-	Kitle matrisi	86	56	73	69.4

Tablo 4.11, önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, MIAS veritabanında, en yüksek ikişer doğrusal fonksiyon sonucunu, en yüksek ikişer karesel fonksiyon sonucunu ve en yüksek ikişer RTF çekirdek fonksiyonu sonuçlarını göstermektedir. Buna göre; doğrusal fonksiyon ile en yüksek BDT sistemi tanı

performansı (%87.4) KDD-EYİK katsayı grubu kullanılarak, karesel fonksiyon ile en yüksek sınıflandırma performansı (%88.4) KDD-EYİK katsayı grubu kullanılarak, RTF fonksiyon ile de en yüksek sınıflandırma performansı (%82.7) KDD-EYİK ve KDD-Sk katsayı grubu kullanılarak elde edilmiştir. Şekil 4.60 da en yüksek ikişer performansı karşılaştıran ROC eğrisi çizilmiştir.




Şekil 4.60: ROC performans eğrisi

Tablo 4.12: Tablo 4.7 ile Tablo 4.11 birleşimi

Mamogram veritabanı	DVM çekirdek fonksiyonu	Yöntem	Katsayı grubu	Duyarlılık (%)	Seçicilik (%)	Malign-benign sınıflandırma doğruluğu (%)	Tüm BDT sisteminin tanı doğruluğu (%)
İTF	Doğrusal	KDD	Sk	100	88	94	90.2
		KDD	EYİK	97	90	94	90.2
		HDD	Yk&OAK	83	86	85	81.6
		HDD	Tk	83	81	82	78.7
		-	Kitle matrisi	68	81	75	72
	Karesel	KDD	Sk	97	86	91	87.4
		KDD	EYİK	100	83	91	87.4
		HDD	Yk&OAK	83	81	82	78.7
		HDD	Tk	89	71	80	76.8
		-	Kitle matrisi	74	77	75	72
	RTF	KDD	EYİK	92	95	94	90.2
		KDD	Sk	89	93	91	87.4
		HDD	Yk&OAK	78	86	82	78.7
		HDD	Yk	78	86	82	78.7
		-	Kitle matrisi	71	79	75	72
MIAS	Doğrusal	KDD	Sk	100	80	92	87.4
		KDD	EYİK	91	88	90	85.5
		HDD	Yk&OAK	86	84	85	80.8
		HDD	Tk	83	88	85	80.8
		-	Kitle matrisi	83	60	73	69.4
	Karesel	KDD	Sk	97	88	93	88.4
		KDD	EYİK	91	88	90	85.5
		HDD	Yk&OAK	97	72	87	82.7
		HDD	Tk	86	84	85	80.8
		-	Kitle matrisi	80	52	68	64.6
	RTF	KDD	EYİK	89	85	87	82.7
		KDD	Sk	89	84	87	82.7
		HDD	Yk&OAK	86	76	82	77.9
		HDD	Yk	89	68	80	76
		-	Kitle matrisi	86	56	73	69.4

Tablo 4.12, Tablo 4.7 ve 4.11 in birleşimidir. Tablo 4.12 de önerilen bilgisayar tabanlı meme kanseri tanısı sisteminin, MIAS ve İTF veritabanına uygulanmasında tüm çekirdek fonksiyonları ve katsayılardan en yüksek ikişer sınıflandırma doğruluğunu sağlayanlar listelenmiştir. Buna göre; İTF veritabanında en yüksek BDT sistemi tanı doğruluğu (%90.2) doğrusal çekirdek fonksiyonu ile KDD uygulamasıyla Sk ve EYİK katsayıları kullanılarak, RTF çekirdek fonksiyonu ile de KDD uygulamasıyla EYİK katsayıları kullanılarak elde edilmiştir. MIAS veritabanında en yüksek BDT sistemi tanı doğruluğu (%88.4) karesel çekirdek fonksiyonu ile KDD uygulamasıyla Sk katsayıları kullanılarak elde edilmiştir. Şekil 4.61 de MIAS ve İTF veritabanlarında en yüksek üçer performansı sağlayan katsayı gruplarına ait ROC eğrisi verilmiştir.



Şekil 4.61: ROC performans eğrisi

5. TARTIŞMA VE SONUÇ

Biyomedikal görüntü işleme alanında yapılan Bilgisayar Destekli Tanı (BDT) çalışmalarının amacı, çeşitli görüntüleme ve tarama (screening) teknolojileri aracılığıyla uzmanlar tarafından yapılan tanıya yardımcı olabilecek şekilde yeni bilgisayar yazılımları geliştirmektir. Bu yazılımlar meme kanseri teşhisinde, uzman radyologlara adeta ikinci bir göz gibi yarar sağlarlar. Şüpheli bir bölgede olası kanser oluşumunu erkenden tanıyabilmek ve teşhis koyabilmek hasta açısından hayati önem arz etmektedir. Bilindiği gibi, yayılmış olan bir kanser vakasında hastayı kurtarmak çoğunlukla mümkün olmamaktadır. BDT ile gözden kaçabilecek kanserli kitle sayısını minimuma indirmek amaçlanır. Son yıllarda meme kanseri ile ilgili yapılan BDT çalışmaları; mamogramlarda gürültü azaltma ve kontrast geliştirme, meme kitlelerini tespit etme, kitleleri kanserli olup olmamasına göre birbirinden ayırt etme, sınıflandırma ve tanı koymayı içermektedir.

Bu tez, görüntü işleme tekniklerine dayalı bilgisayar destekli meme kanseri tanısı koyma çalışması önermektedir. Tez üç aşamada gerçekleştirilmiş olup, birinci aşama mamogramlarda görüntü iyileştirme, ikinci aşama kitleleri tespit etme ve son aşama bulunan bu kitlelerin gerçekte kitle mi yoksa normal meme dokusu mu olduğunun ayrımını yapacak 1. sınıflandırma işlemi ve gerçek kitlelerin malign mi yoksa benign mi olduğunun ayrımını yapacak 2. sınıflandırma işlemidir.

Görüntü iyileştirmede Hızlı Dalgacık Dönüşümü, Homomorfik Filtreleme, Gauss-Laplace modelleme ve adaptif eşikleme yöntemi kullanılmıştır. Şekil 4.6-4.14 arasında gösterilen örneklerde hastaların orjinal ham mamogramları işlenerek iyileştirme yapılmıştır. Bu örneklerden de anlaşıldığı gibi, görüntü iyileştirme ile mamogramlarda genel olarak kontrast artımı olduğu kadar şüpheli bölgelerde de lokal kontrast artımı başarılı bir şekilde gerçekleştirilmiştir. Gürültülü bölgeler bulanıklaştırılarak gürültü azaltılırken, kitleye ait kenar kontürü gibi sınıflandırmada büyük önem taşıyan önemli

kısımlar vurgulanmış ve parlaklığı artırılmıştır. Böylece yoğun (dens) görünüm veren mamogramlarda kitlelerin arka plandan farkı gözle görülür şekilde artmıştır.

Kitleleri tespit etme görüntü bölütleme ile gerçekleştirilmiştir. Bunun için, Merkezden Bölge Büyütme (Seed Region Growing) algoritması temel alınarak Lokal Merkezden Bölge Büyütme (LMBB) algoritması geliştirilmiştir. Bu algoritma ile İTF ve MIAS veritabanındaki tüm mamogramlardaki kitleler tespit edilebilmiş olup tespit başarısı %100'dür. Ancak bu performans tek başına yeterli değildir. Çünkü tespit aşamasında YP kitleler de bulunduğundan bu durum tanıyı yanlış yönlendirmektedir. LMBB sonuçlarına göre, İTF veritabanındaki toplam 78 ve MIAS veritabanındaki toplam 60 GP kitlenin hepsi tespit edilebilmiştir. Ancak İTF veritabanında 191, MIAS veritabanında ise 174 tane YP kitle tespit edilmiştir. Görüntü başına düşen YP kitle sayısı (YP_{kitle}) İTF veritabanında 3.2 iken, MIAS veritabanında 2.9'dur. Bir sonraki sınıflandırma işleminin amacı YP_{kitle} sayısını olabildiğince düşürmektir.

Sınıflandırmanın ilk aşaması kitle-doku sınıflandırmasıdır. LMBB ile bulunan ilgili alanlar (Region of Interests- ROIs) öncelikle Küresel Dalgacık Dönüşümü'nden (KDD) geçirelerek elde edilen katsayılardan öznitelikler çıkarılmıştır. Seçilen öznitelikler, kitlelerin tipik özelliklerini belirleyici rol oynayan boyut, geometrik şekil ve kontür, piksel değeri öznitelikleridir. Öznitelik matrisleri Destek Vektör Makineleri (DVM) kullanılarak sınıflandırılmışlardır. İTF veritabanında kitle-doku sınıflandırması sonuçlarına ulaşmak için LMBB ile elde edilen 191'i YP, 78'i ise GP olan 269 kitlenin katsayı öznitelikleri DVM sistemine giriş olarak verilmiştir. En yüksek başarı yüzdesini %96 ile doğrusal fonksiyon sağlamıştır ve YP_{kitle} değeri 0.05'e düşmüştür. En yüksek duyarlılık (%88) ve en yüksek seçicilik (%98) doğrusal çekirdek fonksiyonu ile sağlanmıştır.

MIAS veritabanında ise kitle-doku sınıflandırması sonuçlarına ulaşmak için LMBB ile elde edilen 174'ü YP, 60'ı ise GP olan 234 kitlenin katsayı öznitelikleri DVM sistemine giriş olarak verilmiştir. En yüksek başarı yüzdesini %95 ile doğrusal fonksiyon sağlamıştır ve YP_{kitle} değeri 0.12'ye düşmüştür. En yüksek duyarlılık (%92) ve en yüksek seçicilik (%96) doğrusal çekirdek fonksiyonu ile sağlanmıştır.

Sınıflandırmanın ikinci aşaması malign-benign kitle sınıflandırmasıdır. Bu aşamada da öznitelik matrisleri Destek Vektör Makineleri (DVM) kullanılarak sınıflandırılmışlardır. Ek olarak; KDD yönteminin üstünlüğünü göstermek için tespit edilen kitlelere Hızlı Dalgacık Dönüşümü (HDD) uygulanmıştır. Sınıflandırma sonuçlarına göre İTF veritabanı için en yüksek malign-benign sınıflandırma doğruluğu %94 olup doğrusal çekirdek fonksiyonu ile KDD katsayılarından son ölçek katsayıları (Sk) (w_5, c_5), doğrusal çekirdek fonksiyonu ile KDD katsayılarından en yüksek iki ölçek katsayıları (EYİk) (w_4, w_5, c_5) ve RTF ile KDD katsayılarından EYİk katsayıları kullanılarak sağlanmıştır.

HDD katsayıları kullanıldığında ise, en yüksek malign-benign sınıflandırma doğruluğu (%85) doğrusal çekirdek fonksiyonu ve son yaklaşıklık ile ortalama ayrıştırma katsayıları (Yk&OAK) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) kullanılarak sağlanmıştır.

MIAS veritabanındaki sınıflandırma sonuçlarına göre, en yüksek malign-benign sınıflandırma doğruluğu (%93) karesel çekirdek fonksiyonu ile KDD katsayılarından son ölçek katsayıları (Sk) (w_5, c_5) kullanılarak sağlanmıştır. HDD katsayıları kullanıldığında ise en yüksek malign-benign sınıflandırma doğruluğu (%87) karesel çekirdek fonksiyonu ve son yaklaşıklık ile ortalama ayrıştırma katsayıları (Yk&OAK) ($a_1, a_2, ort(y_1, d_1, dy_1), ort(y_2, d_2, dy_2)$) kullanılarak elde edilmiştir.

İTF veritabanında en yüksek duyarlılık (%100) doğrusal çekirdek fonksiyonu ve KDD-Sk katsayıları; karesel çekirdek fonksiyonu ve KDD-EYİk katsayılarıyla sağlanırken, en yüksek seçicilik (%95) RTF çekirdek fonksiyonu ve KDD-EYİk katsayılarıyla elde edilmiştir. MIAS veritabanı kullanılarak en yüksek duyarlılık (%100) doğrusal çekirdek fonksiyonu ve KDD-Sk katsayılarıyla sağlanırken, en yüksek seçicilik (%88) doğrusal çekirdek fonksiyonu ile KDD-EYİk ve HDD-Tk (tüm katsayılar), karesel çekirdek fonksiyonu ile KDD-Sk ve KDD-EYİk katsayılarıyla sağlanmıştır.

Tamamı MATLAB paket programı 7.6.0 versiyonunda hazırlanan tez çalışmasında önerilen BDT yönteminin genel performansına bakıldığında; İTF veritabanı kullanarak elde edilen en yüksek tespit ve tanı doğruluğunun KDD yönteminde %90.2, HDD

yönteminde ise %81.6 olduğu, MIAS veritabanı ile sağlanan en yüksek tespit ve tanı doğruluğunun KDD yönteminde %88.4, HDD yönteminde ise %82.7 olduğu görülmektedir. Herhangi bir KDD veya HDD uygulamadan kitlenin kendi öznelik matrisi kullanıldığında ise, İTF veritabanı ile %72, MIAS veritabanı ile %69.4 gibi tespit ve tanı doğruluğu açısından daha düşük bir performans gözlenmiştir.

Bulgular bölümünde ayrıntılı olarak verilen sonuçlara göre; kitlelere KDD veya HDD uygulanması doğru tanı koyma performansını farkedilir derecede artırmıştır. KDD yöntemi ile, HDD yönteminden daha üstün sınıflandırma doğruluğuna ulaşılmıştır. Bunun sebebi meme kitlelerinin geometrik olarak küresel olmasıdır. Ölçekleme fonksiyonunun küresel harmoniklerle oluşturulması da bu üstünlüğü artırmaktadır. Dönüşümlerden elde edilen ayrıntı katsayıları kitleleri tespit etmekte yetersiz kalırken, katsayıların tümünün kullanılması optimum sonucu vermemektedir. En yüksek sınıflandırma performansı her iki veritabanı için de son seviye katsayılarına ağırlık verildikçe artmaktadır. Bunun açıklaması ölçek arttıkça elde edilen katsayıların daha anlamlı hale gelmesidir. Her iki veritabanında elde edilen sonuçların birbirine yakın olması, yapılan çalışmanın tutarlı olduğunu gösterirken, İTF veritabanı sonuçlarının üstünlüğü bu veritabanındaki mamogramların daha kaliteli ve nitelikli görüntü özelliklerine sahip olduğunu göstermektedir.

Bu tez çalışmasında İTF veritabanındaki en yüksek performanslara göre kitleleri tespit etme başarısı %100, kitle-doku sınıflandırma doğruluğu %96, malign-benign sınıflandırma doğruluğu %94, tüm BDT sisteminin tanı doğruluğu %90.2, duyarlılık %100 ve seçicilik %90'dır. Elde edilen bu sonuçlar Genel Kısımlar Bölümü'nde ayrıntılı olarak verilen literatür çalışmaları sonuçları ile karşılaştırıldığında (Tablo 5.1), bu tez çalışmasında geliştirilen BDT sisteminin yüksek performans gösterdiği ve doğru tanıyı koymada radyoloğa yardımcı ve yön verici olabileceği görülmektedir. Böylelikle en yaygın kadın hastalıklarından biri olan meme kanserinde erken tanı şansı artarken, gereksiz biyopsi istenmesi engellenebilir [81].

Tablo 5.1 de, önerilen tez çalışmasında elde edilen sonuçlar ile önceki literatür çalışmalarından [36-39] birkaçının sonuçları karşılaştırılmıştır. Bu çalışmalarla ilgili

ayrıntılar Bölüm 2.4 de verilmiştir. Önerilen tez çalışmasına ait ROC puanı 1. ve 2. sınıflandırma sonuçlarından en yüksek olanların ortalaması alınarak bulunmuştur.

Tablo 5.1: Önerilen yöntem ile diğer yöntemlerin karşılaştırılması

Çalışma	Yıl	Duyarlılık (%)	Seçicilik (%)	ROC puanı	YP_{kitle}
Yu ve ark. [37]	2006	-	-	0.87	0.65
Kom ve ark. [36]	2007	95.91	93.87	0.946	-
Fraschini [39]	2011	94.4	84.6	0.91	-
Hu ve ark. [38]	2011	91.3	-	-	0.71
Önerilen yöntem	2011	100	95	0.984	0.05

İleriye yönelik çalışma olarak, YP_{kitle} değeri daha düşük meme kitlelerini tespit etme algoritması geliştirilebilir. Bunun yanısıra kitlelerin sınıflandırılması için farklı öznelilik çıkarma ve sınıflandırıcılar uygulanarak daha etkin sınıflandırma sonuçları elde edilebilir. Ayrıca veri sayısı artırılarak veya daha üstün görüntüleme teknolojileriyle hazırlanmış veritabanları kullanılarak sınıflandırma doğruluğu daha yüksek değerlere çıkarılabilir.

KAYNAKLAR

- [1] <http://www.kanser.gov.tr/index.php?cat=11> [Ziyaret Tarihi, 10 Ocak 2009].
- [2] 2006, *2004-2006 Yılları Türkiye kanser insidansı* [online], T.C. Sağlık Bakanlığı, <http://www.kanser.gov.tr/folders/file/8iL-2006-SON.pdf> [Ziyaret Tarihi: 11 Ocak 2009].
- [3] 2006, *Türkiye’de primer koruma’da yapılması gerekenler: Kanser erken tanı ve tarama grubu raporu*, <http://www.kanser.gov.tr/folders/file/erken.pdf> [Ziyaret Tarihi: 11 Ocak 2009].
- [4] ÜLGEN, A., 2008, *Dijital mamografi görüntülerinin iyileştirilmesi*, Yüksek Lisans Tezi, İstanbul Üniversitesi Biyomedikal Mühendisliği Anabilim Dalı Fen Bilimleri Enstitüsü.
- [5] LLADO, X., OLIVER, A., FREIXENET, J., MARTI, R., MARTI, J., 2009, A textural approach for mass false positive reduction in mammography, *Computerized Medical Imaging and Graphics*, 33, 415–422.
- [6] PATRICK, J. L., 2007, *Wikimedia commons*, http://commons.wikimedia.org/wiki/File:Breast_anatomy_normal_scheme.png [Ziyaret Tarihi: 01 Mart 2009].
- [7] Dr. ÇAM, F., H., *Meme anatomisi*, <http://annesutu.saglikdanisma.net/memeanatomisi.htm> [Ziyaret Tarihi: 20 Mart 2009].
- [8] ÜSTÜN, E., E., 2000, *Mamografi atlası*, Nobel tıp kitapçevleri, İzmir.
- [9] USTAOĞLU C., 2000, *Meme hastalıklarında görüntüleme yöntemleri ve Isparta yöresi meme kanseri tarama sonuçlarımız*, Yüksek Lisans Tezi, T.C Süleyman Demirel Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim Dalı.
- [10] CANBULAT, N., 2006, *Sağlık çalışanlarının meme kanseri, kendikendine meme muayenesi ve mamografiye ilişkin sağlık inançlarının incelenmesi*, Yüksek Lisans Tezi, Atatürk Üniversitesi Sağlık Bilimleri Enstitüsü Cerrahi Hastalıkları Hemşireliği Anabilim Dalı.
- [11] BERKARDA, B., 2000, *Meme kanseri*, İ.Ü.Basımevi, İstanbul.
- [12] İRGİL, E., 2001, *Meme kanseri epidemiyolojisi*, Nobel tıp kitapçevleri, İstanbul.

- [13] TOPAL, U., 2005, *Meme Kanseri Taraması*, Nobel Tıp Kitapevleri, Bursa.
- [14] ÜSKENT, N., 2003, *Meme kanserinin doğal seyri, gelişimi, risk faktörleri, dünyadaki dağılımı ve epidemiyolojisi, Olgular ışığında meme kanseri*.
- [15] MEREY, S., 2002, *Kadınlarda meme kanseri tarama davranışları*, Yüksek Lisans Tezi, İstanbul Üniversitesi Sağlık Bilimleri Enstitüsü Halk Sağlığı Hemşireliği Anabilim Dalı.
- [16] TEMİZKAN, A., K., 2006, *Yoğun meme yapısı gösteren (Birads 3-4) olgularda dijital mamografi ve film-screen mamografi incelemelerinde lezyon saptama güçlerinin karşılaştırılması*, Tıpta Uzmanlık Tezi, Dokuz Eylül Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim Dalı.
- [17] VOYVODA, Ş., N., Y., 2006, *Türkiye'de mamografi aygıt özellikleri, kullanımı ve mamografi eğitiminin niteliksel ve niceliksel çözümlemesi*, Tıpta Uzmanlık Tezi, Gazi Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı.
- [18] SAMPLE, J., T., 2003, *Computer assisted screening of digital mammogram images*, PhD Thesis, Louisiana State University, USA.
- [19] TUNCEL, E., 2006, *Radyolojiye giriş*, Uludağ Üniversitesi Radyoloji Anabilim Dalı Ders Notları.
- [20] TOPUZ, E., AYDINER, A., 2000, *Meme kanseri. Biyoloji, tanı, evreleme tedavi*, Nobel Tıp Kitapevleri.
- [21] SUTTON, D., 1998, *Textbook of radiology and imaging: In the breast*, Michell MJ., London.
- [22] CARDENOSA, G., 1997, *Breast imaging companion*, Philadelphia, Lippincott-Raven.
- [23] THOMPSON, W., BOWEN, R., DORMAN, B., PRICOLO V., SHAHINIAN T., SODERBERG C., 1991, Mammographic localization and biopsy of nonpalpable breast lesions, *Arch Surg*, 126, 730- 734.
- [24] LOGAN W., W., JANUS, J., 1987, Use of special mammographic views to maximize radiographic information. *Radiol Clin North Am.*, 25, 953- 959.
- [25] SMITH C., BASSET, L., W., FOLD, R., H., et al, 1990, New mammography screen- film combinations: Imaging characteristics and radiation dose, *Am J Roentgenol*, 154, 713- 719.
- [26] ALTUG, A., 1998, Dijital mamografi, *Türk Radyoloji Dergisi*, 33(1), 88- 89.
- [27] ODUKO, J., M., YOUNG, K., C., ALSAGER, A., GUNDOGDU, O., 2008, *Technical evaluation of the IMS GIOTTO FULL FIELD digital mammography system with a tungsten tube*,

<http://www.cancerscreening.nhs.uk/breastscreen/publications/nhsbsp-equipment-report-0804.html> [Ziyaret Tarihi, 10 Mayıs 2009].

- [28] SHTERN, F., 1992, Dijital mammography and related technologies: a perspective from the National Cancer Institute, *Radiology*, 183, 629- 630.
- [29] 2008, *MRI design guide*,
http://www.mednovus.com/downloads/VA_MRI_Design_Guide-08.pdf [Ziyaret Tarihi, 10 Mayıs 2009].
- [30] ALKAN, U., H., 2008, *Meme kanserinde neoadjuvan kemoterapiye yanıtın değerlendirilmesinde mamografi ultrasonografi ve magnetik rezonans görüntüleme bulgularının karşılaştırılması*, Tıpta Uzmanlık Tezi, İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Radyodiagnostik Anabilim Dalı.
- [31] SANKARA, R., ZHANGA, L., QIANB W., 2002, Advances in micro-calcification clusters detection in mammography, *Computers in Biology and Medicine*, 32, 515-528.
- [32] KARAHALIOU N. A., BONIATIS I. S., et. al, 2008, Breast cancer diagnosis: analyzing texture of tissue surrounding microcalcifications, *IEEE Transactions on Information Technology in Biomedicine*, 12, 731-738.
- [33] HWANG H., CHOI H., et al., 2005, Classification of breast tissue images based on wavelet transform using discriminant analysis, neural network and SVM, *IEEE*, 345-349.
- [34] ALI, F., E., ELDOKANY, I., M., SAAD, A., A., et al., 2008, Curvelet fusion of MR and CT images, *Progress in Electromagnetics Research*, 215–224.
- [35] BINH, N., T., THANH, N., C., 2007, Object detection of speckle image base on curvelet transform, *ARPJ Journal of Engineering and Applied Sciences*, 2, 14-16.
- [36] KOM, G., TIEDEU A., KOM, M., 2007, Automated detection of masses in mammograms by local adaptive thresholding, *Computers in Biology and Medicine*, 37, 37-48.
- [37] YU, S., N., LI, K., Y., HUANG, Y., K., 2006, Detection of microcalcifications in digital mammograms using wavelet filter and Markov random field model, *Computerized Medical Imaging and Graphics*, 30, 163-173.
- [38] HU, K., GAO, X., LI, F., 2011, Detection of suspicious lesions by adaptive thresholding based on multiresolution analysis in mammograms, *IEEE Transactions on Instrumentation and Measurement*, 60 (2), 462-472.
- [39] FRASCHINI, M., 2011, Mammographic masses classification: novel and simple signal analysis method, *Electronics Letters*, 47 (1).

- [40] HEATH, M., BOWYER, K., KOPANS, D., et al., 1998, Current status of the digital database for screening mammography, *Proc. 4th Int. Workshop on Digital Mammography*, 457-460.
- [41] GREENSHIELDS, I. R., 2001, 3D Shape approximants via spherical wavelet decompositions, *IEEE*, 31-36.
- [42] NAIN, D., STYNER, M., et al., 2007, Statistical shape analysis of brain structures using spherical wavelets, *IEEE*, 209-212.
- [43] YU, P., GRANT, P., E., YUAN, Q., HAN, X., et al., 2007, Cortical surface shape analysis based on spherical wavelets, *IEEE Transactions on Medical Imaging*, 26(4), 582-597.
- [44] SEGHOUANE, A., K., ONG, J., L., 2009, Multiresolution colonic polyp detection in CT colonography using spherical wavelets, *2009 IEEE/SP 15th Workshop on Statistical Signal Processing*, 125-128.
- [45] KEZELE, I., DESCOTEAUX, M., POUPON, C., et al., 2010, Spherical wavelet transform for ODF sharpening, *Medical Image Analysis*, 14, 332-342.
- [46] STARCK, J., CANDÈS E., DONOHO, D. L., 2003, Astronomical image representation by the curvelet transform , *Astronomy and Astrophysics*, 785-800.
- [47] GÖRGEL, P., SERTBAS, A., UCAN, O., N., 2010, A Wavelet-based mammographic image denoising and enhancement with homomorphic filtering, *Journal of Medical Systems*, 34 (6), 993-1002.
- [48] MALLAT, S., 1989, A theory for multiresolution signal decomposition: The wavelet representation, *IEEE Trans. Pattern Anal. Mach. Intell.*, 11, 674-693.
- [49] ELTOUKHY, M., M., FAYE, I., SAMIR, B., B., 2010, A comparison of wavelet and curvelet for breast cancer diagnosis in digital mammogram, *Computers in Biology and Medicine*, 40, 384-391.
- [50] GONZALEZ, R., WOODS, R., 2004, *Digital image processing*, Prentice Hall, New Jersey.
- [51] KILIC, N., GÖRGEL, P., UCAN, O., N., SERTBAS, A., 2010, Mammographic mass detection using wavelets as input to Neural Networks, *Journal of Medical Systems*, 34 (6), 1083-1088.
- [52] ABRIAL, P., MOUDDEN, Y., et al., 2007, Morphological component analysis and inpainting on the sphere: application in physics and astrophysics , *Journal of Fourier Analysis and Applications (JFAA), Special Issue on ``Analysis on the Sphere''*, 13, 729-748.

- [53] DONOHO, D., DUNCAN M., 2000, Digital curvelet transform: Strategy, implementation and experiments, *Proc. Aerosense Wavelet Applications VII*, 4056, 12–29.
- [54] JAROSZ, W., NATHAN, A., C., JENSEN, H., W., 2009, Importance sampling spherical harmonics, *Eurographics*, 28 (2).
- [55] WADE, W., R., 1995, A Walsh System for polar coordinates, *Computers Math. Applic.*, 30, 221-227.
- [56] MEHRA, M., KEVLAHAN, N., K., R., 2008, An adaptive wavelet collocation method for the solution of partial differential equations on the sphere, *Journal of Computational Physics*, 227, 5610-5632.
- [57] ZHANG, X., LI, D., 2001, A trous wavelet decomposition applied to image edge detection, *Geographic Information Sciences*, 7 (2), 119-123.
- [58] *Feature extraction*, http://en.wikipedia.org/wiki/Feature_extraction [Ziyaret Tarihi, 01 Mart 2010].
- [59] VERMA, B., MCLEOD, P., KLEVANSKY, A., 2010, Classification of benign and malignant patterns in digital mammograms for the diagnosis of breast cancer, *Expert Systems with Applications*, 37, 3344-3351.
- [60] ZHANG, S., W., HUANG, D., S., WANG, S., L., 2010, A method of tumor classification based on wavelet packet transforms and neighborhood rough set, *Computers in Biology and Medicine*, 40, 430-437.
- [61] MATLAB R2008a Product Help, Image processing toolbox.
- [62] DELOGU, P., FANTACCI, M., E., et al., 2007, Characterization of mammographic masses using a gradient-based segmentation algorithm and a neural classifier, *Computers in Biology and Medicine*, 37, 1479-1491.
- [63] AYDIN, I., KARAKÖSE, M., AKIN, E., 2007, Artificial immune based Support Vector Machine algorithm for fault diagnosis of induction motors, *IEEE*.
- [64] CRISTIANINI, N., SHAW-TAYLOR, J., 2000, *An introduction to Support Vector Machines and other kernel-based learning methods*, Cambridge University Press.
- [65] CORTES, C., VAPNIK, V.N., 1995, Support-vector networks, *Machine Learning*, 20, 273-297.
- [66] VAPNIK, V.N., 1995, *The nature of statistical learning theory*, Springer-Verlag, New York, 0-387-94559-8.
- [67] KERHET, A., RAFFETTO, M., BONI, A., MASSA, A., 2006, A SVM-based approach to microwave breast cancer detection, *Engineering Applications of Artificial Intelligence*, 19, 807-818.

- [68] VAPNIK, V., N., 1999, *The nature of statistical learning, theory statistics for engineering and information science*, Springer, Berlin.
- [69] SCHOLKOPF, B., SMOLA, A., J., 2002, *Learning with Kernels*, MIT Press, Cambridge, MA.
- [70] KILIÇ, N., 2008, *Bilgisayarlı tomografi görüntülerinde üç boyutlu şablonlar kullanılarak kolonik polip tespiti*, Doktora tezi, İstanbul Üniversitesi Biyomedikal Mühendisliği Anabilim Dalı.
- [71] GEORGE, J., RAJEEV, K., 2008, Sinc-cauchy hybrid wavelet kernel for Support Vector Machines, *IEEE*, 356-361.
- [72] SCHÖLKOPF, B., 1998, Support vector machine, *IEEE Intelligent System*, 13(4), 18-21.
- [73] SHI, X., CHENG, H., D., HUA, L., et al., 2010, Detection and classification of masses in breast ultrasound images, *Digital Signal Processing*, 20, 824-836.
- [74] KILIÇ, N., GÖRGEL, P., UCAN, O., N., KALA, A., 2008, Multifont ottoman character recognition using support vector machine. *ISCCSP 2008, 12-14 March 2008 Malta*, 328-333.
- [75] SCHNEIDER, J., 1997, *Cross validation*, <http://www.cs.cmu.edu/~schneide/tut5/node42.html> [Ziyaret Tarihi, 01 Mart 2010].
- [76] PAPADOPOULOS, A., FOTIADIS, D., I., COSTARIDOU, L., 2008, Improvement of microcalcification cluster detection in mammography utilizing image enhancement techniques, *Computers in Biology and Medicine*, 38, 1045-1055.
- [77] CLARK, A., F., 2003, *The mini-MIAS database of mammograms*, <http://peipa.essex.ac.uk/info/mias.html> [Ziyaret Tarihi, 01 Ocak 2010].
- [78] GONZALEZ, R., WOODS, R., EDDINS, S., 2004, *Digital image processing using MATLAB*, Prentice Hall, New Jersey, 0-13-008519-7.
- [79] CHENG, H., D., SHI, X., 2006, Approaches for automated detection and classification of masses in mammograms, *Pattern Recognition Science Direct*, 39, 646-668.
- [80] DONOHO, D., L., JOHNSTONE, I., M., et al., 1996, Density estimation by wavelet thesholding, *Annals of Stat.*, 24, 508-539.

- [81] LEE, H., W., LIU, B., HUNG, K., C., et al., 2009, Breast tumor classification of ultrasound images using wavelet-based channel energy and imageJ, *IEEE Journal Of Selected Topics In Signal Processing*, 3(1), 81-93.

ÖZGEÇMİŞ

Pelin GÖRGEL, 1981 yılında İstanbul’da doğdu. İlkokulu Yeşilköy Halil Vedat Fıratlı ilkokulunda tamamladıktan sonra ortaokul ve liseye Büyükşehir Anadolu Lisesi’nde devam etti. 1999 yılında liseden mezun oldu ve İstanbul Üniversitesi Bilgisayar Mühendisliği bölümünü kazandı. 2003 yılında lisans öğrenimini tamamlayarak aynı bölümde Yüksek Lisans eğitime başladı. 2006 yılında MSc. ünvanını aldı ve yine aynı bölümde doktora öğrenimine başladı. Çalışma konuları; görüntü işleme, biyomedikal mühendisliği ve çeşitli yapay zeka uygulamalarıdır. Pelin GÖRGEL, 2004 yılında İ.Ü. Bilgisayar Mühendisliği bölümünde Araştırma Görevlisi olarak başladığı görevini halen sürdürmekte olup, evli ve bir çocuk annesidir.