

**SAYISAL MAMOGRAFİ
GÖRÜNTÜLERİNE YAPAY ZEKA
YÖNTEMLERİNİN UYGULANMASI**

CANAN ORAL

DOKTORA TEZİ

**ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ ANABİLİM DALI**

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SAYISAL MAMOGRAFİ GÖRÜNTÜLERİNE YAPAY ZEKA
YÖNTEMLERİNİN UYGULANMASI

CANAN ORAL

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

AKADEMİK DANIŞMAN
Yrd. Doç. Dr. HATİCE SEZGİN

SAMSUN-2011

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bu çalışma jürimiz tarafından 22 / 06 / 2011 tarihinde yapılan sınav ile Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda DOKTORA tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Ferit Acar SAVACI

Üye : Prof. Dr. Güven ÖNBİLGİN

Üye : Yrd. Doç. Dr. Ayten ATASOY

Üye : Yrd. Doç. Dr. İlyas EMİNOĞLU

Üye : Yrd. Doç. Dr. Hatice SEZGİN

ONAY :

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu Onaylım.

/ /2011

Prof. Dr. Hasan GÜMÜŞ
Fen Bilimleri Enstitüsü Müdürü

SAYISAL MAMOGRAFİ GÖRÜNTÜLERİNE YAPAY ZEKA YÖNTEMLERİNİN UYGULANMASI

ÖZ

Meme kanseri tüm dünyada kadınlarda en sık karşılaşılan ve kadınların ölümüne neden olan kanser türüdür. Meme kanserini henüz kesin önleyen bir yöntem yoktur. Günümüzde bilinen tek yöntem, erken tanıdır. Mamografi, memenin çeşitli açılardan röntgeninin alınmasıdır ve meme kanserinin erken teşhisinde en iyi görüntüleme tekniğidir. Yaklaşık olarak meme kanserlerinin %85-90'ı mamografi görüntülerinin incelenmesi ile elde edilirken, görüntülenen tümörlerin %10-15'i görüntüleme sürecindeki teknik problemler nedeniyle radyologlar tarafından gözden kaçırılmaktadır.

Bilgisayar destekli teşhis (BDT), memedeki anormallikleri tespit etmek için bilgisayarlaştırılmış algoritmaları kullanmaktadır ve meme kanserinin tanısında radyoloji uzmanlarına ikinci bir görüş olarak yardımcı olmaktadır.

Bu çalışmada mamogramlardaki anormallikleri (mikrokalsifikasyonları) tespit etmek ve sınıflandırmak için BDT sistemi tasarlanmıştır. Geliştirilen BDT sistemi; ön işleme, bölümleme, özellik çıkarımı, özellik seçimi ve sınıflandırma olarak beş bölümden oluşmaktadır.

Ön işleme bölümünde görüntüyü iyileştirmek ve gürültüyü atmak için çoklu ölçekli morfolojik iyileştirme tekniği kullanılmıştır. İyileştirilmiş mamogram görüntülerini bölümlemek için yerel eşikleme yöntemi kullanılmıştır.

Özellik çıkarımı aşamasında iyileştirilmiş mamogram görüntülerinden uzaysal özellikler, dokusal özellikler, bölümlenmiş mamogram görüntülerinden şekil tabanlı özellikler çıkarılmıştır.

Özellik seçimi aşamasında, Temel bileşenler analizi (TBA) yöntemi kullanılarak boyut azaltımı gerçekleştirilmiştir.

Sınıflandırma aşamasında, çok katmanlı yapay sinir ağı (ÇKYSA) ve destek vektör makinesi (DVM) kullanılmıştır. Mamogram görüntüleri, normal ve anormal olarak sınıflandırılmıştır. Mamogramları normal ve anormal olarak sınıflandırmada, TBA ile boyut azaltımı gerçekleştirildiğinde elde edilen özellikler kullanıldığında, ÇKYSA sınıflandırıcı için %91,1, DVM sınıflandırıcı için %94,1 başarımlı doğruluğu elde edilmiştir. Mikrokalsifikasyon içeren mamogramları, iyi huylu ve kötü huylu

olarak sınıflandırmada, TBA ile boyut azaltımı gerçekleştirildiğinde elde edilen özellikler kullanıldığında, ÇKYSA sınıflandırıcı için %91,7, DVM sınıflandırıcı için %83,3 başarımla doğruluğu elde edilmiştir.

Anahtar Sözcükler: Meme Kanseri, Mamografi, Bilgisayar Destekli Teşhis, Ön işleme, Bölümleme, Özellik Çıkarımı, Özellik seçimi, Sınıflandırma.

THE APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS ON DIGITAL MAMMOGRAPHY IMAGES

ABSTRACT

Breast cancer is the most common cancer among women and the leading cancer type causing deaths in women. The early detection of breast cancer can be the key to survival. Mammography is x-ray imaging technique of different views of breast, and plays a major role in the early detection of breast cancer. Mammography can find about 85 to 90 percent of breast cancer in women, but 15 to 10 percent of breast lesions are missed during routine screening. A computer aided diagnosis (CAD) system uses computerized algorithms in order to detect breast abnormalities. CAD system works like a second opinion in helping radiologists during diagnostic process.

In this study CAD system is designed to detect mammographic abnormalities. Designed CAD system includes preprocessing, segmentation, feature extraction, feature selection and classification stages. In preprocessing step, multiscale morphology technique is used to enhance mammograms and to remove noise. Local thresholding technique is used to segment enhanced mammograms. In feature extraction step spatial features, textural features are extracted from enhanced mammograms, morphologic features are extracted from segmented mammograms. In feature selection step, principal component analysis is used for dimension reduction.

In classification step, multi layer neural networks (MLP) and support vector machines (SVM) are used. Mammograms are classified as normal or abnormal. In classification mamograms as normal or abnormal, the results using features selected by TBA method has best performance. It achieves 91,1% for MLP, 94,1% for SVM. Mammograms with microcalcification are classified as benign or malignant. In classification mammograms with microcalcification as benign or malign, the results using features selected by TBA method has best performance. It achieves 91,7% for MLP, 83,3% for SVM.

Key Words: Breast Cancer, Mammography, Computer Aided Diagnosis, Preprocessing, Segmentation, Feature Extraction, Feature Selection, Classification

TEŞEKKÜR

Lisans öğrenimimin başında tanıştığım ve bana bu tez boyunca olduğu gibi yüksek lisans tezimde ve akademik hayatımın ilerlemesinde büyük katkıları olan; tüm yoğunluğuna rağmen yardımını ve hoşgörüsünü benden esirgemeyen; bana olan güvenini ve desteğini her zaman yanımda hissettiğim tez danışmanım ve değerli hocam Yrd. Doç. Dr. Hatice SEZGİN'e sonsuz teşekkürlerimi sunarım.

Doktora tez izleme komitesinde yer alan; ilgi ve yönlendirmeleriyle tezime katkıda bulunan değerli hocalarım Yrd.Doç.Dr. İlyas EMİNOĞLU'na, ayrıca büyük bir özveriyle her seferinde uzun bir mesafe kat ederek tüm yoğunluğuna rağmen fedakarlıkta bulunan Yrd.Doç.Dr. Ayten ATASOY'a teşekkür ederim.

Tez çalışmam sürecinde örüntü tanıma ve sınıflandırma konusunda kendilerinden çok şey öğrendiğim, ilgiyle her soruma cevap bulabildiğim, Samsun'a her gidişimde iyi niyetleri ve sıcak karşılamalarıyla odalarının kapılarını bana açan değerli arkadaşlarım Arş.Gör. Gökhan KAYHAN'a ve Öğr.Gör. Ali Ekber ÖZDEMİR'e sonsuz teşekkür ederim.

Bu çalışmanın gerçekleşmesinde sağladıkları çalışma ortamı ve desteklerinden dolayı Amasya Üniversitesi Meslek Yüksekokulu'na ve mesai arkadaşlarıma çok teşekkür ederim.

Tüm bunların yanında doktora sürecim boyunca en zor zamanlarımda yanımda olan, bana inanan, güvenen, beni her konuda destekleyen çok değerli iki dostum Ayfer SU BERGİL'e ve Erhan BERGİL'e sonsuz teşekkür ederim.

Ayrıca beni her konuda destekleyen, tüm eğitim yaşamım boyunca maddi ve manevi olarak her zaman yanımda olan ve bugünlere gelmemi sağlayan aileme sonsuz teşekkür ederim.

İÇİNDEKİLER

1. GİRİŞ	1
2. GENEL BİLGİLER	4
2.1. Meme Kanseri	4
2.2. Mamografi	5
2.2.1. Mamografideki Gelişmeler ve Diğer Görüntüleme Teknikleri	8
2.3. Mamografide Karşılaşılan Anormallikler	10
2.4. Bilgisayar Destekli Tespit ve Teşhis (BDT)	14
2.5. Literatür Özeti	15
3. MATERYAL VE YÖNTEMLER	22
3.1. Ön-İşleme	22
3.1.1. Çoklu Ölçekli Morfolojik Görüntü İyileştirme Yöntemi	25
3.2. Bölümleme	36
3.2.1. Yerel Eşikleme Yöntemi	38
3.3. Özellik Çıkarımı	39
3.3.1. Uzaysal Düzlem Özellikleri	39
3.3.2. Dokusal Özellikler	42
3.3.2.1. Birinci Derece Doku Hesaplamaları	42
3.3.2.2. İkinci Derece Doku Hesaplamaları	45
3.4. Özellik seçimi ve Boyut Azaltımı	51
3.4.1. Temel Bileşenler Analizi (TBA).....	52
3.5. Sınıflandırma..	59
3.5.1. Yapay Sinir Ağı (YSA).....	59
3.5.1.1. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)	61
3.5.2. Destek Vektör Makineleri (DVM)	71
3.5.2.1. Doğrusal Destek Vektör Makineleri	71

3.5.2.2. Doğrusal Olmayan Destek Vektör Makineleri	78
3.5.3. Sınıflandırma Başarımının Ölçülmesi.....	82
4. BULGULAR	84
4.1. Mamografi Veritabanı	84
4.2. Ön İşleme	84
4.3. Bölümleme	90
4.4. Özellik Çıkarımı	91
4.5. Özellik Seçimi ve Boyut Azaltımı	94
4.6. Sınıflandırma	96
5. SONUÇ VE ÖNERİLER.....	108
6. KAYNAKLAR.....	112
7. ÖZGEÇMİŞ	118

SİMGELER VE KISALTMALAR LİSTESİ

SİMGELER

f	Gri seviye görüntüsü
B	Yapı elemanı
$f \oplus B$	Morfolojik genişletme işlemi
$f \ominus B$	Morfolojik aşındırma işlemi
$f \circ B$	Morfolojik açma işlemi
$f \bullet B$	Morfolojik kapama işlemi
T	Eşik değeri
w	Pencere boyutu
k	Eşik katsayısı
$m_w(x,y)$	w penceresindeki piksellerin ortalaması
$\sigma_w(x,y)$	w penceresindeki piksellerin standart sapması
$ortf$	Gri seviye görüntünün ortalama değeri
$ortef$	Gri seviye görüntünün ortalama enerjisi
var	Gri seviye görüntünün piksel yoğunluk varyansı
$evar$	Gri seviye görüntünün enerji varyansı
P	Çevre
A	Alan
C	Yoğunluk
m_{pq}	$(p+q)$ dereceden moment
μ_{pq}	Merkez momenti
ε	Dışmerkezlilik
S	Yayılma
μ_n	n . moment
σ	Standart sapma

U	Homojenlik
d	Mesafe ölçütü
θ	Yönelme açısı
X	Veri kümesi matrisi
X'	Sıfıra ortalananmış veri matrisi
K	Kovaryans matris
V	Kovaryans matrisin özvektör matrisi
λ	Kovaryans matrisin özdeğer matrisi
t_z	Varyansın birikimli yüzdesi
Z	Dönüştürülmüş özellik kümesi
x_i	Yapay sinir ağının i. girişi
w_i	i. yapay sinir hücresinin ağırlık katsayısı
I_j	i. yapay sinir hücresinin ağırlıklı toplamı
O_j	j. yapay sinir hücresinin çıkışı
e_j	j. çıkış sinirindeki hata değeri
E	Toplam karesel hata
δ_j	j. sinir hücresinin eğimi
$\psi(.)$	Yapay sinir ağı için etkinleştirme fonksiyonu
Δw_{ji}	Yapay sinir ağında ij. ağırlığın değişim miktarı
θ_i	i. sinir hücresi için eşik değeri
$\Delta \theta_{ji}$	Yapay sinir ağında ji. eşik miktarındaki değişim
x_i	DVM’de eğitim kümesi
y_i	DVM çıkışı
w	DVM’de ağırlık katsayısı
b	DVM’de eşik değeri
α_i	Lagrange çarpanları

ξ_i	Gevşek değişkenler
C	Düzenleyici parametre
$\phi(x_i)$	Doğrusal olmayan haritalama fonksiyonu
$K(x_i, x)$	Çekirdek fonksiyonu

KISALTMALAR

ACR	American College of Radiology
BDT	Bilgisayar Destekli Teşhis
BIRADS	Breast Imaging Reporting and Data System
CC	Cranial-Caudal görünüm
ÇKGYSA	Çok Katmanlı Yapay Sinir Ağı
DVM	Destek Vektör Makineleri
GN	Gerçek Negatif
GP	Gerçek Pozitif
GSEOM	Gri Seviye Eş Oluşum Matrisi
KKT	Karush-Kuhn-Tucker koşullar
LM	Lateromedial görünüm
MIAS	Mammographic Image Analysis Society
ML	Mediolateral görünüm
MLO	Mediolateral-oblique görünüm
TBA	Temel Bileşenler Analizi
YE	Yapı elemanı
YN	Yanlış Pozitif
YP	Yanlış Negatif
YSA	Yapay Sinir Ağı

ŞEKİLLER LİSTESİ

		Sayfa
Şekil 2.1.	Film mamografi öbek çizgesi	5
Şekil 2.2.	Tarama mamografisinde alınan görüntüler	7
Şekil 2.3.	Mediolateral oblique (MLO) görünüm mamogram göğüse ait kas, meme ucu ve meme kanallarını göstermektedir	7
Şekil 2.4.	Tanısal mamografide alınan ek görünüm. Latero medial (LM) mamografik görünüm, Medio lateral (ML) mamografik görünüm	8
Şekil 2.5.	Sayısal mamografi öbek çizgesi	9
Şekil 2.6.	(a) Sınırlandırılmış kütle, (b) spikül biçimli kütle	10
Şekil 2.7.	Kütle şekilleri (sol) ve sınırları (sağ) için BIRADS tanımlayıcıları	11
Şekil 2.8.	Kalsifikasyon kümesi	12
Şekil 3.1.	Tasarlanan BDT sistemi öbek çizgesi	22
Şekil 3.2.	a) Yapı elemanı, b) Giriş görüntü matrisi, c) Genişletilmiş görüntü matrisi	27
Şekil 3.3.	a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile genişletilmiş görüntü	27
Şekil 3.4.	a) Yapı elemanı. b) Giriş görüntü matrisi. c) Aşındırılmış görüntü matrisi	28
Şekil 3.5.	a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile aşındırılmış görüntü	29
Şekil 3.6.	a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile açılmış görüntü	30
Şekil 3.7.	a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile kapanmış görüntü	31
Şekil 3.8.	a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile beyaz top-hat dönüşümü uygulanmış görüntü	32
Şekil 3.9.	a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile siyah top-hat dönüşümü uygulanmış görüntü	32

Şekil 3.10.	g(t) işlevinin çoklu ölçekli morfoloji ile yerel kontrast iyileştirmesi; (a), (e), (i), (l) ve (m) asıl fonksiyon, (b) ve (f) YE tarafından açılmış işlev. (j), (n) YE tarafından kapanmış işlev, (c) ve (g) her bir ölçekteki beyaz top-hat işlevleri, (k) ve (o) her bir ölçekteki siyah top-hat işlevleri, (d) her bir ölçekte alınan beyaz top-hat işlevlerinin toplamı, (h) her bir ölçekte alınan siyah top-hat işlevlerinin toplamı, (p) yerel iyileştirmeden sonra alınan çıkış işlevi	35
Şekil 3.11.	Seçilen piksel etrafında çeşitli açılar için yönlerin gösterilimi	47
Şekil 3.12.	Veri kümesinin grafiksel gösterimi	57
Şekil 3.13.	Dönüşüm sonucunda elde edilen veri kümesinin grafiksel gösterimi	58
Şekil 3.14.	Yapay sinir hücresi modeli	60
Şekil 3.15.	Çok katmanlı yapay sinir ağı ağ mimarisi	61
Şekil 3.16.	Etkinleştirme fonksiyonları	71
Şekil 3.17.	İki sınıflı veri kümesini ayırabilen birden fazla hiper-düzlem	72
Şekil 3.18.	İki boyutlu uzayda iki sınıflı veri kümesi için en uygun hiper-düzlem	72
Şekil 3.19.	Eğitim verilerinin doğrusal olarak ayıramadığı durum örneği	76
Şekil 3.20.	Verilerin giriş uzayından özellik uzayına aktarımı	78
Şekil 3.21.	DVM Ağ yapısı	82
Şekil 4.1.	1024x1024 piksel boyutlu mamogram görüntüleri	85
Şekil 4.2.	300x300 piksel boyutlu ilgilenilen parçaları içeren kırılmış mamogram görüntüleri	85
Şekil 4.3.	(a) mdb209 mamogram görüntüsü, (b) $k=4$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü	86

Şekil 4.4.	a) mdb219 mamogram görüntüsü, (b) $k=4$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü	87
Şekil 4.5.	(a) mdb209 mamogram görüntüsü, (b) $k=4$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü	88
Şekil 4.6.	(a) mdb219 mamogram görüntüsü, (b) $k=4$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü	89
Şekil 4.7.	(a) İyileştirilmiş mamogram görüntüsü (mdb209), (b) Bölümlenmiş mamogram görüntüsü	90
Şekil 4.8.	İyileştirilmiş mamogram görüntüsü (mdb219), b) Bölümlenmiş mamogram görüntüsü	91
Şekil 4.9.	İyileştirilmiş mamogram görüntüsü (mdb233), b) Bölümlenmiş mamogram görüntüsü	91
Şekil 4.10.	Sınıflandırma sürecinin öbek çizgesi	96
Şekil 4.11.	1. uygulamaya ait ÇKYSA'nın öğrenme hata grafiği	97
Şekil 4.12.	2. uygulamaya ait ÇKYSA'nın öğrenme hata grafiği	100
Şekil 4.13.	3. uygulamaya ait ÇKYSA'nın öğrenme hata grafiği	103
Şekil 4.14.	4. uygulamaya ait ÇKYSA'nın öğrenme hata grafiği	105

ÇİZELGELER LİSTESİ

	Sayfa
Çizelge 2.1. Tüm hayatta kalma oranı	5
Çizelge 2.2. Mikrokalsifikasyonların biçimleri (şekil, morfoloji, dağılım)	13
Çizelge 2.3. Klinik literatürde listelenen kalsifikasyonların yoğunluk ve grup tanımlayıcıları	13
Çizelge 2.4. Kalsifikasyonlar için BIRADS tanımlayıcıları (Olası oluş biçimi; B=muhtemel iyi huylu, M= açık olarak kötü huylu, U= belirsiz)	14
Çizelge 3.1. Örnek matris	51
Çizelge 3.2. Örnek matrise göre gri seviye eş-oluşum matrisi	51
Çizelge 3.3. (a) örnek veri kümesi, (b) sifıra ortalananmış veri kümesi	57
Çizelge 3.4. Dönüşüm sonucunda elde edilen veri kümesi	58
Çizelge 3.5. Karşılaştırma matrisi	82
Çizelge 4.1. Normal mamogram görüntülerine ait uzaysal düzlem özellikleri	92
Çizelge 4.2. Mikrokalsifikasyon içeren mamogram görüntülerine ait uzaysal düzlem özellikleri	92
Çizelge 4.3. Normal mamogram görüntülerine ait $d=1$, $\theta=0^\circ$ için GSEOM özellikleri	92
Çizelge 4.4. Mikrokalsifikasyon içeren mamogram görüntülerine ait $d=1$, $\theta=0^\circ$ için GSEOM özellikleri	92
Çizelge 4.5. İyi huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin ortalaması	93
Çizelge 4.6. İyi huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin standart sapması	93
Çizelge 4.7. Kötü huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin ortalaması	93
Çizelge 4.8. Kötü huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin standart sapması	94
Çizelge 4.9. 1. uygulama için ÇKYSA'nın ağ yapısı bilgileri	97

Çizelge 4.10.	1. uygulama için ÇKYSA'nın karşılaştırma matrisi	98
Çizelge 4.11	1. uygulama için DVM'nin karşılaştırma matrisi	98
Çizelge 4.12.	1. uygulamada ÇKYSA ve DVM için sınıflandırma başarımları sonuçları	99
Çizelge 4.13.	2. uygulama için ÇKYSA'nın ağ yapısı bilgileri	100
Çizelge 4.14.	2. uygulama için ÇKYSA'nın karşılaştırma matrisi	100
Çizelge 4.15.	2. uygulama için DVM'nin karşılaştırma matrisi	101
Çizelge 4.16.	2. uygulamada ÇKYSA ve DVM için sınıflandırma başarımları sonuçları	101
Çizelge 4.17.	3. uygulama için ÇKYSA'nın ağ yapısı bilgileri	102
Çizelge 4.18.	3. uygulama için ÇKYSA'nın karşılaştırma matrisi	103
Çizelge 4.19.	3. uygulama için DVM'nin karşılaştırma matrisi	104
Çizelge 4.20.	3. uygulamada ÇKYSA ve DVM için sınıflandırma başarımları sonuçları	104
Çizelge 4.21.	4. uygulama için ÇKYSA'nın ağ yapısı bilgileri	105
Çizelge 4.22.	4. uygulama için ÇKYSA'nın karşılaştırma matrisi	106
Çizelge 4.23.	4. uygulama için DVM'nin karşılaştırma matrisi	106
Çizelge 4.24.	4. uygulamada ÇKYSA ve DVM için sınıflandırma başarımları sonuçları	107

1. GİRİŞ

Meme kanseri tüm dünyada kadınlarda en sık karşılaşılan (%28) ve kadınların ölümüne neden olan kanser türüdür (Zorukoş, 2008; Ozmen, 2009; American Cancer Society, 2010; Türk Kanser Araştırma ve Savaş Kurumu Derneği, 2010).

Dünyada her üç dakikada bir kadına meme kanseri tanısı konulduğu ifade edilmektedir. Amerika’da yaşamı boyunca her dokuz kadından birinin meme kanserine yakalandığına, üçte ikisinin de bu hastalığa bağlı olarak hayatını kaybetme tehlikesi ile karşı karşıya kaldığına dikkat çekildiği görülmektedir. Avrupa ülkelerinde de, her on kadından birine yaşamı boyunca meme kanseri tanısı konulmaktadır. Türkiye açısından bakıldığında ise meme kanseri kadınlarda görülen en yaygın kanser türü olarak ifade edilmektedir (Somunoğlu, 2009; Gölbaşı, 2010). Türkiye’de meme kanseri, kadınlar arasında görülen kanserler içinde %26.58 ile ilk sırada yer almaktadır (Zorukoş, 2008). Türkiye’de son yıllarda meme kanserinin oluş sıklığının arttığı bilinmekte ve 2012 yılında 51 binden fazla meme kanseri vakası olacağı tahmin edilmektedir (Gölbaşı, 2010).

Meme kanserinin oluş sıklığı ve ölüm oranı farklı coğrafik bölgelerde değişim göstermektedir. Gelişmiş ülkelerde meme kanserinin oluş sıklığının ve ölüm oranının daha yüksek oranlarda bildirilmesine rağmen, meme kanserinin oluş sıklığındaki değişimler Türkiye de dahil düşük ve orta gelirli ülkelerde daha çarpıcıdır. Türkiye’nin farklı bölgelerinde meme kanserinin oluş sıklığının dağılımı coğrafik, ekonomik, sosyal ve kültürel etkenlerden dolayı önemli ölçüde değişiklik göstermektedir. Türkiye’nin batısında meme kanserinin oluş sıklığı doğusundan iki kat daha fazladır. Meme kanseri sıklığı 40 yaşın altındaki kadınlarda %20 olarak saptanmıştır, oysa batı Avrupa’da ve Amerika’da %5 civarında tespit edilmiştir (Ozmen ve ark., 2009).

Meme kanserinde hayatta kalmanın anahtarı erken tespit ve tedavidir. Amerikan Kanser Birliği’ne göre meme kanseri memede sınırlandığında, beş yıl hayatta kalma oranı %100’e yakın olarak ifade edilmektedir (American Cancer Society. Breast Cancer Facts & Figures, 2010).

Meme kanserini henüz kesin olarak önleyen bir yöntem bulunmamaktadır. Günümüzde bilinen tek yöntem, erken tanıdır. Erken tanı sayesinde, meme kanserinin getirdiği sorunlar büyük oranda çözülebilmektedir. Bu sayede hastalığın toplumda

oluşturduğu hasar en aza indirilebilmekte, yaşam süresi ve kalitesi önemli ölçüde artırılabilir (American Cancer Society, 2010).

Mamografi, erken aşamada meme kanserini tespit etmeye yardımcı olmaktadır. Mamografi, memenin çeşitli açılardan röntgeninin alınmasıdır ve meme kanserinin erken teşhisinde en iyi görüntüleme tekniğidir. Yaklaşık olarak meme kanserlerinin %85-90'ı mamografi görüntülerinin incelenmesi ile elde edilirken, görüntülenen tümörlerin %10-15'i görüntüleme sürecindeki teknik problemler nedeniyle radyologlar tarafından gözden kaçırılmaktadır. Bu durumda anormallikler görülmeyebilir ve yanlış yorumlanabilmektedir. Kanserlerin belirlenemeyen bu grubu genellikle gözden kaçırılmış olarak ifade edilmektedir (Shinde, 2003; American Cancer Society. Breast Cancer Facts & Figures, 2010). Mamografiyle yapılan incelemeler sonucunda erken yapılan teşhisin, meme kanserinin ölüm riskini %35 oranında azalttığı bilinmektedir (Özmen, 2009).

Bilgisayar destekli teşhis (BDT) teknolojisi meme görüntüleme alanında son zamanlardaki önemli bir gelişmedir. BDT memedeki anormallikleri tespit etmek için bilgisayarlaştırılmış algoritmaları kullanmaktadır. BDT sistemi herhangi meme anormalliğini tespit ederse, bölgeyi işaretlemektedir. Radyoloji uzmanı ise işaretlenmiş şüpheli bölgeyi tekrar incelemektedir. BDT teknolojisiyle birlikte mamogramın son yorumu radyoloji uzmanına aittir (Nass ve ark., 2001; Bozek ve ark., 2008; Baert ve ark., 2010; American Cancer Society, 2010).

Mamografide karşılaşılan anormallikler, kümelenmiş mikrokalsifikasyonlar, yapısal bozulmalar, asimetrik yoğunluklar ve kütlelerdir. Bunların en çok karşılaşılanları kümelenmiş mikrokalsifikasyonlar ve kütlelerdir. Özellikle mikrokalsifikasyonlar meme kanserinin erken belirtisidir. Boyutları çok küçük olduğu için radyoloji uzmanları tarafından belirlenmeleri zordur.

Bu çalışmada meme kanserinin gözden kaçırılan durumları için mamogramdaki anormallikleri (mikrokalsifikasyonları) belirlemek ve sınıflandırmak amacıyla bir bilgisayar destekli teşhis sistemi tasarlanmıştır. Tasarlanan BDT sistemi, ön işleme, bölümlendirme, özellik çıkarımı, özellik seçimi (boyut azaltımı), sınıflandırma olmak üzere beş bölümden oluşmaktadır. Ön işleme adımında son yıllarda geliştirilen ve x ışını görüntülere uygulanan, çoklu ölçekli morfoloji tekniği kullanılarak mamogramlar yerel olarak iyileştirilmiştir. Bölümlendirme adımında, Niblack yerel eşikleme yöntemiyle mamogramlardan ilgili alanlar çıkarılmıştır. İyileştirilmiş mamogramlardan uzaysal

düzlem özellikleri ve gri seviye eş-oluşum matrisi özellikleri hesaplanmıştır. Bölümlenmiş mamogram görüntülerinden ise şekil tabanlı özellikler çıkarılmıştır. Temel bileşenler analizi yöntemi kullanılarak özellik kümesinde boyut azaltımı gerçekleştirilmiştir. Son olarak çok katmanlı yapay sinir ağı ve destek vektör makineleri kullanılarak sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonuçları karşılaştırılmıştır.

Çalışmanın ikinci bölümünde, meme kanseri ile ilgili genel kavramlara değinilmiş ve sayısal mamografide ortaya çıkan anormalliklerin (mikrokalsifikasyonların) bilgisayar destekli teşhis yöntemleriyle ilgili daha önce yapılan çalışmalar hakkında bilgiler verilmiştir.

Çalışmanın üçüncü bölümünde, tasarlanan BDT sisteminin bölümleri açıklanmış ve her bölümde kullanılan yöntemler hakkında bilgiler verilmiştir.

Çalışmanın dördüncü bölümünde, tasarlanan BDT sisteminin uygulama sonuçları verilmiş ve elde edilen sonuçlar yorumlanmıştır.

Çalışmanın son bölümünde tasarlanan sistemin sonuçları irdelenmiştir.

2. GENEL BİLGİLER

Bu bölümde meme kanseri ile ilgili genel kavramlara değinilmekte ve sayısal mamografide ortaya çıkan anormalliklerin (mikrokalsifikasyonların) bilgisayar destekli tespit ve teşhis yöntemleriyle ilgili daha önce yapılan çalışmalar hakkında bilgiler verilmektedir.

2.1. Meme Kanseri

Meme, süt bezleri ve burada üretilen sütü meme başına taşıyan kanallardan oluşmaktadır. Bu süt bezleri ve kanalları döşeyen hücrelerin, kontrol dışı olarak çoğalmaları ve vücudun çeşitli yerlerine giderek çoğalmaya devam etmelerine meme kanseri denir (American Cancer Society Breast Cancer Facts&Figures 2009-2010, 06.07.2010).

Bazı özellikleri taşıyan kadınlarda, meme kanseri daha sık görülmektedir. Bu özelliklere risk faktörleri denir. Bu risk faktörlerini taşıyan kişilerin, taşımayan kişilere göre meme kanserine yakalanma olasılıkları daha fazla olduğu ifade edilmektedir. Meme kanserine yakalanma riskini artıran faktörler yaş, ailede meme kanseri olması, daha önce meme biyopsisi yapılmış olması, fertil çağ süresi, östrojen hormonu tedavisi görenler, alkol kullanılması, sigara, şişmanlık ve yağlı beslenme olarak sıralanmaktadır (Zorukoş, 2008; American Cancer Society. Breast Cancer Facts & Figures, 2010).


Meme kanserinde hayatta kalma beş yıldan sonra azalmaya devam etmektedir. On yıldan sonra hayatta kalma evreye bağlıdır, erken evre meme kanseri, daha geç evre kanserlerinden daha yüksek hayatta kalma oranına sahiptir (American Cancer Society. Breast Cancer Facts & Figures, 2010). Meme kanserli hastalarda tüm evrelere göre 5 yıllık sağkalım oranları, gelişmiş ülkelerde %83 iken, gelişmekte olan ülkelerde %53 olarak bildirilmektedir. Meme kanseri ölüm oranı gelişmiş ülkelerde %30, az gelişmiş ülkelerde %43 olarak bildirilmektedir (Özmen, 2008). Tüm hayatta kalma oranı Çizelge 2.1’de verilmektedir.

Çizelge 2.1. Tüm hayatta kalma oranı (American Cancer Society. Breast Cancer Facts & Figures, 2010)

5 yıldan sonra	%88
10 yıldan sonra	%80
15 yıldan sonra	%71
20 yıldan sonra	%63

2.2. Mamografi

Meme kanserinin başarılı tedavisi erken teşhise bağlıdır. Mamografi, meme kanserinin erken teşhisinde önemli rol oynamaktadır. Mamografi, memenin ayrıntılı görüntülerini oluşturmak için kullanılan x-ışını görüntülemenin özel bir tipidir. Mamografi, düşük doz x-ışını, yüksek kontrast, yüksek-çözünürlüklü film ve memeyi görüntüleme için özel olarak tasarlanmış x-ışını sistemi kullanmaktadır. Mamografinin 50 yaş üzeri kadınlarda, meme kanserinin %85-90'ının tespit edebildiği ve hissedilmeden iki yıl öncesine kadar yumruyu keşfedebildiği Birleşik Devletler Besin ve İlaç Yönetimi tarafından bildirilmektedir (Shinde, 2003; Tembey, 2003; American Cancer Society. Breast Cancer Facts & Figures, 2010). Film mamografinin öbek çizgesi Şekil 2.1'de verilmektedir.




Şekil 2.1. Film mamografi öbek çizgesi (Berg ve ark., 2006).

Mamografi çekilirken teknolog hastayı konumlandırmakta ve her bir meme ayrı ayrı görüntülenmektedir. Her bir meme dikkatli bir şekilde özel bir film kaseti üzerine yerleştirilerek nazikçe denetim koluyla sıkıştırılmaktadır. Bu sıkıştırma, dokunun maksimum miktarını görüntülemek ve muayene edebilmek için memeyi yassılaştırmaktadır. Mamografi çekmek için, x-ışını kaynağı açılır, x-ışınları sıkıştırılmış meme arasından geçer ve meme altına yerleştirilmiş film kaset üstüne yayılır. X-ışınları memeden geçtiğinde farklı doku yoğunlukları tarafından zayıflatılır. Yağ çok yoğundur ve x-ışınlarının büyük bir kısmını zayıflatır veya soğurur. Meme kanalları ve yağ etrafındaki bağlı doku daha az yoğundur, x-ışınlarını daha az zayıflatır veya soğurur. Bu durumda oluşturulan görüntüler yağ, fibrogulandular doku, meme kanalları ve meme ucu gibi normal yapıları açık bir şekilde gösterir. Memede bulunan anormallikler de x-ışınlarına farklı tepkiler vermektedirler. X-ışınları kasetin içinde bulunan özel fosfor tabakaya çarpar. Bu fosfor x-ışınlarının yoğunluğuna bağlı oransal olarak parlar, bu nedenle memenin içyapısının görüntüsünü içeren film ortaya çıkar. Yüksek duyarlıklı film ve özel x-ışınları, en düşük pozda, en yüksek nitelikli görüntüleri oluşturmak amacıyla mamografi için kullanılmaktadır. Oluşturulan mamografi radyoloji uzmanı tarafından yorumlanmaktadır. Radyoloji uzmanı yeni görüntüleri önceki mamogramlarla karşılaştırır. Bir mamogram parmak izi gibidir, mamogramda memenin ortaya çıkışı kadından kadına çok farklılık göstermektedir. Benzer iki mamogram yoktur. Bu, radyoloji uzmanlarının mamogramları yorumlamasına yardımcı olmaktadır. Meme yağdan, lifli dokudan ve bezelerden oluşmuştur. Meme kütleleri (iyi huylu ve kötü huylu olanları içerenler) mamogramda beyaz bölgeler olarak ortaya çıkarlar. Yağ, mamogram filminde siyah bölgeler olarak ortaya çıkar. Diğer her şey mamogramda beyazın seviyeleri olarak ortaya çıkar (Shinde, 2003; Tembey, 2003; American Cancer Society, 2010).


Mamografi muayenesinin tarama mamografi ve tanı mamografi olmak üzere iki türü vardır:

Tarama mamografi; meme kanseri belirtisi olmayan kadınlarda memelerin x-ışını muayenesidir. Tarama mamografisinin amacı kadın veya doktor tarafından hissedilemeyecek durumlarda kanseri tespit etmektir. Tarama mamografi ile meme kanseri erken evrede tespit edilip tedavi edilmesi sağlanarak hastaların hayatta kalma oranı arttırılmaktadır. Tarama mamografinin, 40 yaşına ulaşan kadınlarda her iki yılda

bir, 50 yaşına ulaşan kadınlarda her yıl bir kez çekilmesi önerilmektedir. Bazı örneklerde doktorlar 40 yaşından önce tarama mamografisine başlamayı önermektedirler (eğer aile geçmişinde meme kanseri varsa). Tarama mamografisi her bir memeden iki görünüm almayı içermektedir. Bunlar tipik olarak yukarıdan görünüm (cranial-caudal görünüm, CC) ve eğik veya açılı görünümüdür (mediolateral-oblique, MLO)'dir (Shinde, 2003; Tembey, 2003; Somunoğlu, 2009; American Cancer Society, 2010). Tarama mamografisinde alınan görüntüler Şekil 2.2'de ve Şekil 2.3'de verilmektedir.



Şekil 2.2. Tarama mamografisinde alınan görüntüler (Shinde, 2003; Tembey, 2003)




Şekil 2.3. Mediolateral oblique (MLO) görünüm mamogram göğüse ait kas, meme ucu ve meme kanallarını göstermektedir (Berg ve ark., 2006)

Tanı mamografi; kadının bir şikayeti olduğunda veya tarama mamografisinde bir anormallik bulunduğunda memenin x-ışını muayenesidir. Tanı mamografisi tarama mamografisinden daha kapsamlıdır ve daha fazla zaman almaktadır. Tanı mamografisi meme anormalliklerinin tam yeri ve boyutunu belirlemek için kullanılmaktadır. Tipik olarak tanı mamografisi boyunca memenin çeşitli ek görüntüleri alınmakta ve

yorumlanmaktadır. Bu nedenle tanı mamografisi tarama mamografisinden daha pahalı olmaktadır. Tanı amaçlı mamografide de her bir meme ayrı ayrı görüntülenmekte ve dört farklı görüntü alınmaktadır.

Bunlar:

- Üsten alınan (cranial-caudal görünüm, CC)
- Eğik veya açılı alınan (mediolateral-oblique, MLO)
- Özel bir problem için uygun hale getirilmiş tamamlayıcı görüntüler. Bunlar her bir kenardan alınan görüntüleri içermektedir (lateromedial, LM: merkeze doğru dışarıdan alınan, ve mediolateral görünüm, ML: meme dışından merkeze alınan görünüm) (Shinde, 2003; Tembey, 2003; Somunoğlu, 2009; American Cancer Society, 2010). Tanı mamografisinde alınan ek görüntüler aşağıda Şekil 2.4'te verilmektedir.




Şekil 2.4. Tanısal mamografide alınan ek görüntüler. Latero medial (LM) mamografik görünüm, Medio lateral (ML) mamografik görünüm (Shinde, 2003; Tembey, 2003)

2.2.1. Mamografideki Gelişmeler ve Diğer Görüntüleme Teknikleri

Memenin x-ışınları ile görüntülenmesi 70 yıldan daha fazla süredir gerçekleştirilmektedir. Geçen sürede teknolojiye büyük ilerlemeler kaydedilmiştir. Öyle ki günümüzün muayenesi 1980'lerden öncesinden önemli ölçüde farklılık göstermektedir (Berg ve ark., 2006).

X-ışını mamografide son zamanlardaki gelişmelerden birisi sayısal mamografidir. Sayısal (bilgisayarlaştırılmış) mamografi memenin ayrıntılı görüntülerini elde etmek için x-ışınlarını kullanan standart mamografiye benzer bir yapıya sahiptir. Sayısal mamografi geleneksel mamografi ile aynı sistemi kullanır, ancak sistem film kaseti yerine bir bilgisayar ve sayısal alıcı içermektedir. Birçok çalışma sayısal mamografinin neredeyse standart mamografi kadar doğruluğa sahip olduğunu

göstermektedir. Sayısal mamografide meme görüntüsü özel elektronik x-ışını dedektör kullanarak alınır ve bilgisayar monitöründe incelenmek için sayısal resme dönüştürülür. Sayısal mamogram bilgisayarda depolanır. Sayısal mamografiyle; büyültme, döndürme, parlaklaştırma gerçekleştirilebilmekte ve görüntünün kontrastı değiştirilebilmektedir (Berg ve ark.,2006; American Cancer Society, 2010). Sayısal mamografinin öbek çizgesi Şekil 2.5’te verilmektedir.



Şekil 2.5. Sayısal mamografi öbek çizgesi (Berg ve ark., 2006).


Ultrason görüntüleme, magnetik rezonans görüntüleme (MRI), t-tarama ve nükleer tıp görüntüleme memeyi görüntülemek için son zamanlarda geliştirilmiş diğer tekniklerdir. MRI görüntüleme, ultrason ve nükleer tıp, geleneksel x-ışını mamografiyle mevcut uzaysal çözünürlük (küçük ayrıntı) sağlamamaktadır. MRI meme kanserlerini ayırt etmek ve tanı koymak için radyoloji uzmanlarına yardımcı olabilen mükemmel kontrast çözünürlüklü görüntüler sağlamaktadır. Ultrason meme biyopsisinde rehberlik etmek ve kistleri görüntülemek için kullanılmaktadır. Nükleer tıp, kanserin yayılımını değerlendirmek için kullanılan bir yöntemdir (Tembey, 2003; American Cancer Society, 2010).

2.3. Mamografide Karşılaşılan Anormallikler

Mamografide karşılaşılan anormallikler; kalsifikasyonlar, kütle lezyonları, asimetrik yoğunluk, yerel yapısal bozulma, ciltte kalınlaşma olarak ifade edilmektedir. Bunların en çok karşılaşılanları kütleler ve kalsifikasyonlardır.

Kütle;


Bir kütle, çevre dokudan daha yoğun birlikte kümelenmiş hücre grubudur. Kütlenin yeri, şekli, sınırı, boyutu ve yoğunluğu radyoloji uzmanlarına meme kanseri olasılığını değerlendirmede önemli tanısal bilgi vermektedir. İyi huylu kütleler düzgün sınırlı, yoğun ve kaba, çember veya eliptik biçimdedirler. Kötü huylu lezyonlar genellikle bulanık sınıra, düzensiz görünüşe sahiptirler. BIRADS (Meme Görüntüleme Raporu ve Veri Sistemi) kütleleri şekillerine ve sınırlarına göre sınıflandırmıştır (Shinde, 2003; Tembey, 2003; American Cancer Society, 2010). Sınırlandırılmış ve spikül biçimli kütle örneği aşağıda Şekil 2.6'da, kütle şekilleri ve sınırları için BIRADS tanımlayıcıları Şekil 2.7'de verilmektedir.



(a)

(b)

Şekil 2.6. (a) Sınırlandırılmış kütle, (b) spikül biçimli kütle (Bozek ve ark., 2008)



Şekil 2.7. Kütle şekilleri (sol) ve sınırları (sağ) için BIRADS tanımlayıcıları (Shinde, 2003)

Kalsifikasyonlar;


Kalsifikasyonlar meme dokusunda bulunan küçük kalsiyum birikintileridir. Bunlar mamogram filmlerinde küçük beyaz bölgeler olarak ortaya çıkarlar. İki tür kalsifikasyon vardır: mikrokalsifikasyon ve makrokalsifikasyon. (Baert ve ark., 2010; Tembey, 2003).

Makrokalsifikasyonlar büyük, dağılmış kalsiyum birikintileridir. Bu birikintiler genellikle iyi huylu koşullarla ilişkilidirler ve nadiren biyopsi gerektirirler. Makrokalsifikasyonlar 50 yaşın üzerindeki kadınların %50'sinde bulunabilmektedir (Tembey, 2003; Bozek ve ark., 2008).

Mikrokalsifikasyonlar memedeki küçük kalsiyum noktalarıdır (mm'nin 1/50'sinden daha küçük). Mikrokalsifikasyonların boyutları 0.1 mm ile 1 mm arasında değişmektedir ve ortalama çapları 0.3 mm'dir (Bozek ve ark., 2008). Birçok mikrokalsifikasyon bir bölgede görüldüğünde, bunlar küme olarak ifade edilmekte ve meme kanserinin göstergesi olarak kabul edilmektedirler. Mamografi tarafından tespit edilen kanserlerin yaklaşık yarısı mikrokalsifikasyon kümesi olarak ortaya çıkmaktadır. Mikrokalsifikasyonlar, meme kanallarında sınırlı meme kanserinin erken işaretidir. Asıl yerinde kanal kanseri vakalarının %90'ı mikrokalsifikasyonlarla ilişkilendirilmektedir. Mamogramda görülen mikrokalsifikasyonların alanı daima kanseri göstermez. Mikrokalsifikasyonların şekli ve düzeni kanser olasılığını değerlendirmede radyoloji uzmanına yardımcı olmaktadır. Mikrokalsifikasyonlar boyutlarına, dağılımlarına,

morfolojilerine ve sayılarına göre değerlendirilmektedir. Kötü huylu olma açısından şüpheli kalsifikasyonlar grup oluşturan mikrokalsifikasyonlardır (Baert ve ark., 2010).

Mikrokalsifikasyonlar büyük, az sayıda, dağılmış ve yuvarlak ise iyi huylu özelliğe sahiptirler. Kümedeki kalsifikasyon sayısı iyi huylu ya da kötü huylu olmayı belirleyen etkenlerden biridir. Bir kümedeki kalsifikasyon sayısı en az dört veya beş olarak tanımlanmaktadır. Kalsifikasyonların şekli yuvarlak veya oval ise bunlar iyi huyludurlar. Daha küçük, düzensiz, polimorfik, dallanmış ve farklı boyutlu kalsifikasyonlar kötü huylu yapıya sahiptirler (Baert ve ark., 2010; Tembey, 2003; Bozek ve ark., 2008). Bir mikrokalsifikasyon kümesi aşağıda Şekil 2.8’de verilmektedir.



Şekil 2.8. Kalsifikasyon kümesi (Bozek ve ark., 2008)

Radyoloji uzmanları iyi huylu ve kötü huylu kalsifikasyonları karakteristiklerine göre sınıflandırmışlardır bunlar Çizelge 2.2 ve Çizelge 2.3’de verilmektedir (Tembey, 2003).

Çizelge 2.2. Mikrokalsifikasyonların biçimleri (şekil, morfoloji, dağılım) (Tembey, 2003)

Biçim tanımlayıcı	Olası oluş biçimi B= olası iyi huylu M= açık olarak kötü huylu U= belirsiz
Doğrusal	M
Dallanma veya V,W,X,Y,Z şekilleri	M
Küçük çok fazla düzensizlik	U
Şekli değişmeyen(monomorfik) bir grupta beneksi biçim	B
Çok biçimli grupta(poliformik) beneksi biçim veya değişen boyut	M
Açısal, köşeli(angular)	U
Düz yoğun	B
Oyuk, halka veya radiolucent veya yumurta kabuğu biçimli	B
Halka şeklinde(annular)	B
Büyük değişimlerle açık, çok açık, zorlukla görülen	M/U
Vida gibi	M
Fasulye biçimli	M
Değişik uzunluklarda Dalgalı çizgi	M
Biçimsiz	U
Yuvarlak veya faceted	B
Çay fincanı biçimli	B
Yuvarlak kenarlarla grup	B
Yumurta biçimli	B

Çizelge 2.3. Klinik literatürde listelenen kalsifikasyonların yoğunluk ve grup tanımlayıcıları (Tembey, 2003)

Yoğunluk ve grup tanımlayıcıları	Olası oluş biçimi B=muhtemel iyi huylu M= açık olarak kötü huylu U= belirsiz
Bulanık çevreler	B
Soluk(pale)	B
Polimorfik grup	M
Monomorfik grup	B
Küçük kümeli	M
Paralel izde(vascular) doğrusal boru biçimli	B

Amerikan Radyoloji Akademisi (ACR) BIRADS kalsifikasyonların şekillerini, morfolojilerini, dağılımlarını ve bulgularını üç kategoride sınıflandırmışlardır (Tembey, 2003). Bunlar aşağıda Çizelge 2.4’te verilmektedir.

Çizelge 2.4. Kalsifikasyonlar için BIRADS tanımlayıcıları (Olası oluş biçimi; B=muhtemel iyi huylu, M= açık olarak kötü huylu, U= belirsiz) (Tembey, 2003)

Morfoloji veya karakter	Deri(kabuk)(parlak merkezli)	B
	Damarlı (vascular) (paralel izli doğrusal boru)	B
	Kaba veya popcorn biçimli	B
	Geniş çubuk biçimli	B
	Yuvarlak(0.5 mm den daha büyük)	B
	Yumurta kabuğu veya teker gibi(rim)(kistik)	B
	Kalsiyum sütü	B
	Distrofi (düzensiz biçimli, 0.5 mm üzerinde, parlak merkezli)	B
	Benekli(0.5 mm den daha küçük yuvarlak)	B
	Sutur(doğrusal veya boru biçimli, yumrulu)	B
	Küresel veya parlak merkezli (düz ve yuvarlak veya oval)	B
	Biçimsiz veya belirsiz	U
	Çok biçimli veya heterojen pürüzler	M
	Açık doğrusal	M
	Açık doğrusal dallanma	M
Dağılım	Kümelenmiş	U
	Kesitli (segmental)	U/M
	Bölgesel(reigonal)	U
	Dağılmış/yayvan(diffuse/scattered)	B
	Doğrusal	M
Sayı	1-5	U
	5-10	U
	>10	U

2.4. Bilgisayar Destekli Tespit ve Teşhis (BDT)

Bilgisayar destekli tespit ve teşhis (BDT) teknolojisi meme görüntüleme alanında son zamanlardaki gelişmelerden biridir. BDT teknolojisi temel olarak, radyoloji uzmanının yorumundan sonra hastanın mamogram filmini gözden geçirmek için ikinci bir göz gibi çalışmaktadır. Eğer bilgisayar yazılımı herhangi meme anormalliğini tespit ederse, bölgeyi işaretler. Radyoloji uzmanı işaretlenmiş şüpheli

bölgeyi tekrar inceler. BDT teknolojisiyle birlikte mamogramın son yorumu yine de radyoloji uzmanına aittir (Nass ve ark., 2001; Baert ve ark., 2010; American Cancer Society, 2010).

İki temel BDT sistemi vardır. Biri bilgisayar destekli tespit (BDTe), diğeri bilgisayar destekli teşhistir (BDTx). BDTe şeması görüntüde şüpheli bölgeleri işaretler ve belirler. Mamografide BDTe'nin amacı kanserin gözden kaçmasını önleyerek radyoloji uzmanına yardımcı olmaktır. BDTx şeması biyopsi gerekip gerekmediği konusunda radyoloji uzmanının karar vermesine yardımcı olmaktadır. BDTx şeması lezyonların kötü huylu olma olasılığını da bildirir. BDTe şeması tarama mamografide, BDTx şeması ise tanı amaçlı mamografide kullanılmaktadır (Nass ve ark., 2001; Baert ve ark., 2010).

2.5. Literatür Özeti

1979 yılında Spiesberger, meme kanserinin erken teşhisi için mamografik görüntüleri sayısallaştırarak mikrokalsifikasyonları tespit etmek amacıyla üç aşamalı karar ağacı kullanmıştır. Çalışmasında çok fazla bellek gerektiren sayısallaştırılmış görüntü verisinin tamamını kaydetmek yerine sadece gerekli olan veri parçasını kaydetmek için bütün görüntüyü sıra sıra tarayan yerel bir işlemci kullanmıştır. İlk karar aşamasında, yerel maksimum dedektörü, pikselleri birbirleriyle karşılaştırarak komşuluğundaki bölgeye göre daha parlak alanları mikrokalsifikasyon adayı olarak işaretlemiş ve kaydetmiştir. İkinci karar aşamasında 3x3 piksel boyutlu alanın ortalaması ile işlemci sınırı arasındaki parlaklık farkını eşik değeri ile karşılaştırmıştır. Parlaklık farkı, eşik değeri aşarsa daha önce işaretlenmiş bölgeyi aday olarak kabul etmiştir. Eşik değeri, bölgenin sınır piksellerini standart sapmasının iki katı olarak hesaplamıştır. Üçüncü karar aşamasında arkaplan-nesne geçişlerinin sayısı ile nesne piksellerinin sayısını karşılaştırarak işlemci alanının dağılmış ya da yoğun olup olmadığına karar vermiştir. Yoğun bölgeler mikrokalsifikasyon olarak kaydedilmiştir. Üç aşamalı karar ağacı algoritmasını 512x512 piksel boyutlu 132 mamogram alt görüntüsüne uygulamıştır. Uygulama sonucunda %68 doğru pozitif, %31 yanlış negatif ve %1 yanlış pozitif oranlarını elde etmiştir (Spiesberger, 1979).

Mikrokalsifikasyonların tespiti ve sınıflandırılmalarıyla ilgili çalışmalar 2000 yılından sonra hız kazanmıştır. Bu nedenle bu çalışmada, 2000 yılından sonra mikrokalsifikasyonların tespiti ve sınıflandırmasıyla ilgili çalışmalar hakkında bilgi verilmektedir.

2000 yılında Yu ve Guan, sayısallaştırılmış mamogramlarda kümelenmiş mikrokalsifikasyonları otomatik olarak tespit etmek için bilgisayar destekli teşhis sistemi tasarlamışlardır. Tasarladıkları sistemin ilk adımında mikrokalsifikasyon piksellerini, gri seviye istatistikleri ve dalgacık özelliklerini kullanarak bölümlenmişlerdir ve olası mikrokalsifikasyonları etiketlemişlerdir. Dalgacık özelliklerini dört seviyeli dalgacık ayrıştırma ve yeniden yapılandırma algoritması tarafından oluşturmuşlardır. Gri seviye istatistiksel özellikleri olarak ortanca kontrast ve normalize gri seviye değeri kullanmışlardır. Bu dalgacık özellikleri ve gri seviye istatistiksel özelliklerini çok katmanlı ileri beslemeli sinir ağı sınıflandırıcısına uygulayarak olası mikrokalsifikasyon piksellerin olasılık haritasını oluşturmuşlardır. İlk adımın sonucunda bölümlenen olası mikrokalsifikasyonların arasından doğru mikrokalsifikasyonları tespit etmek için ikinci bir ayırt edici adım kullanmışlardır. Bu adımda etiketlenen olası mikrokalsifikasyondan 31 özellik çıkarmışlardır. Sıralı ileriye seçim (SİS) yöntemi ve sıralı geriye seçim (SGS) yöntemi kullanarak 31 özellik içinden en ayırt edici özellikleri belirlemişlerdir. Özellik seçim yöntemlerinin sonuçlarını karşılaştırmak için iki ayrı çok katmanlı sinir ağı oluşturarak özellik seçim algoritmaları sonucunda elde edilen en ayırt edici özellikleri sınıflandırıcılara giriş olarak uygulayarak sınıflandırma işlemini gerçekleştirmişlerdir. Son olarak özellik seçim işlemini gerçekleştirmeden 31 özelliği çok katmanlı sinir ağına uygulayarak sınıflandırma gerçekleştirmişlerdir. Bu üç sınıflandırıcının başarımlarını karşılaştırmışlardır. Tasarlanan sistemi 150 mikrokalsifikasyon içeren 40 mamograma uygulamışlardır. Sistemin başarımlarını serbest tepkeli işlem karakteristikleri (STİK) eğrisi kullanarak değerlendirmişlerdir. En iyi sınıflandırma başarımlarını %90 ortalama doğru pozitif tespit oranı ile SGS yöntemiyle seçilen özellikler kullanıldığında elde etmişlerdir (Yu ve Guan, 2000).

2001 yılında Verma ve Zakos, sayısal mamogramlarda mikrokalsifikasyonların görüntülerini tespit ve teşhis etmek için bulanık-sinirsel ve özellik çıkarımına dayalı bir bilgisayar destekli sistem önermişlerdir. Önerilen yöntemde öncelikle radyoloji uzmanları tarafından belirlenen koordinatları kullanarak ya da bulanık tespit algoritmasını kullanarak mamogram görüntülerinden şüpheli mikrokalsifikasyon

alanlarını çıkarmışlardır. Daha sonra mamogram görüntülerinden, ortalama histogram, ortalama gri seviye, enerji, değiştirilmiş enerji, entropi, değiştirilmiş entropi, piksellerin sayısı, standart sapma, değiştirilmiş standart sapma, yamukluk, değiştirilmiş yamukluk, ortalama sınır gri seviyesi, fark ve kontrast olmak üzere 14 özellik hesaplamışlardır. Bir sonraki adımda her bir özellik sınıflandırıcıya tek tek uygulanarak en iyiden en kötüye özelliklerin önceliğini belirlemişlerdir. Daha sonra bu özellikleri karıştırarak farklı özellik birleşimleri elde etmişlerdir. Elde edilen bu karışık özellikleri ileri beslemeli sinir ağına uygulayarak sınıflandırma başarımlarını karşılaştırmışlardır. Tasarlanan sistemi 58 mikrokalsifikasyon içeren alana uygulamışlardır. Sonuç olarak %88.9 sınıflandırma başarımları elde etmişlerdir (Verma ve Zakos, 2001).

2002 yılında El-Naqa ve ark., sayısal mamogramlarda mikrokalsifikasyonları tespit etmek için destek vektör makinelerine (DVM) dayalı bir yaklaşım önermişlerdir. Yöntemde mikrokalsifikasyon tespitini denetlenen öğrenme problemi olarak formüllemiş ve DVM'ye uygulamışlardır. Öncelikle görüntüde arka planı bastırmak için her bir mamograma keskin yüksek geçiren süzgeç uygulamışlardır. Daha sonra sınıflandırıcının giriş vektörünü oluşturmak için süzgeçlenmiş her bir görüntüden "MC var" sınıfı için $M \times M$ boyutlu MC'ye merkezlenmiş görüntüleri ve benzer şekilde "MC yok" sınıfı için $M \times M$ boyutlu görüntüleri mamogramlardan çıkarmışlardır. DVM sınıflandırıcı için çok terimli çekirdek ve Gauss biçimli radyal tabanlı çekirdek işlevleri kullanmışlardır. DVM sınıflandırıcıyı mamogramda her yerde MC olup olmadığını test etmek için denetlenen öğrenme yardımıyla eğitmişlerdir. Önerilen yöntemi 1120 mikrokalsifikasyon (MC) içeren 76 mamogram görüntüsüne uygulamışlardır. Başarımları değerlendirmek için serbest tepkeli alıcı işlem karakteristik eğrisini kullanmışlardır. Görüntü başına bir yanlış pozitif küme hata oranıyla %94 sınıflandırma başarımları elde etmişlerdir (El-Naqa ve ark., 2002).

2002 yılında Zhang ve ark., mamogramlarda mikrokalsifikasyon kümelerini tespit etmek için bir yeni karışık özellikli iki aşamalı yanlış pozitif azaltım yöntemi geliştirmişlerdir. Mamogram görüntülerini iyileştirmek ve bölümlenmek için ağaç yapılı doğrusal olmayan süzgeç mimarisi kullanmışlardır. İyileştirilmiş görüntüden uzaysal düzlem özelliklerini çıkarmışlardır. Bölümlenmiş görüntüden morfolojik düzlem özelliklerini ve küme tanımlama özelliklerini çıkarmışlardır. İlk aşamada uzaysal düzlem ve morfolojik düzlem özelliklerini geriye yayılım sinir ağı sınıflandırıcısına uygulayarak mamogramda açık bir şekilde görülen yanlış pozitif mikrokalsifikasyonları

elemişlerdir. İkinci aşamada ise mamogramlardan çıkarılan bütün özellikleri geriye yayılım sinir ağı sınıflandırıcısına uygulayarak ilk aşama sonucunda elde edilen mikrokalsifikasyon kümelerinden doğru pozitif mikrokalsifikasyonları sınıflandırmışlardır. Geliştirilen yöntemi 67 mamogram görüntüsüne uygulayarak %97 doğru pozitif oranı ile görüntü başına 3.15 yanlış-pozitif azaltımı sağlamışlardır (Zhang ve ark., 2002).

2003 yılında De Santo ve ark., mikrokalsifikasyon kümelerini sınıflandırmak için çoklu uzman siteme dayalı bir yaklaşım önermişlerdir. Bu uzman sistemlerden bazılarını mikrokalsifikasyonları sınıflandırmak için, bazılarını da mikrokalsifikasyon kümelerini sınıflandırmak için kullanmışlardır. Sınıflandırıcı olarak çok katmanlı geriye yayılım ağı kullanmışlardır. Her bir mikrokalsifikasyondan dört şekil tabanlı özellik ve sekiz dokusal düzlem özelliği çıkarmışlardır. Önerilen yöntemi 2123 mikrokalsifikasyon ve 102 küme içeren 40 mamograma uygulamışlardır. Kötü huylu kümeler için %75,7 başarımlı oranı, iyi huylu kümeler için %73,5 başarımlı oranı elde etmişlerdir (De Santo ve ark., 2003).

2004 yılında Soltanian-Zadeh ve ark., mamogramlarda mikrokalsifikasyonları iyi huylu ve kötü huylu olarak sınıflandırmak için dört farklı doku ve şekil özellik çıkarım yönteminin başarımlı sonuçlarını karşılaştırarak değerlendirmişlerdir. Mikrokalsifikasyon kümesi içeren 103 bölge için dört farklı yaklaşım kullanarak doku ve şekil özellikleri çıkarmışlardır. Bu yaklaşımlar, geleneksel şekil niteleyicileri, Haralick'in eş oluşum tabanlı yöntemi, dalgacık dönüşümleri ve çoklu-dalgacık dönüşümleridir. Mamogramlarda mikrokalsifikasyonları, uyarlamalı süzgeç bankası ve morfolojik işlemciler kullanarak bölümlenmişlerdir. Mikrokalsifikasyonları ve kümelerini tanımlamak için yoğunluk, momentler ve küme ilişkili şekil tabanlı özellikler çıkarmışlardır. Haralick özelliklerini çıkarmak için mamogramların eş oluşum matrisini oluşturmuşlardır. Daha sonra bu eş oluşum matrislerinden dokusal özellikleri hesaplamışlardır. Dalgacık özellikleri için iki seviyeli dalgacık paket ayrıştırması kullanarak her bir görüntüden alt görüntüler oluşturmuşlardır. Her bir alt görüntünün enerjisini ve entropisini hesaplamışlardır. Çoklu-dalgacık özellikleri için çeşitli ölçek işlevleri ve çeşitli ana dalgacık kullanarak mamogram görüntülerini 16 alt görüntüye ayırtmışlardır. Her bir alt görüntünün enerjisini ve entropisini hesaplamışlardır Her bir özellik kümesi için en ayırt edici özellikleri ve bu özelliklerin ağırlıklarını gerçel-değerli ve ikili genetik algoritma (GA) özellik seçim yöntemi kullanarak

belirlemişlerdir ve sonuçları k- en yakın sınıflandırıcıya uygulamışlardır. Alıcı işletim karakteristik eğrisini kullanarak sonuçları karşılaştırmışlardır. Çoklu-dalgacık yönteminin başarımının diğer üç yöntemden daha iyi olduğunu tespit etmişlerdir (Soltanian-Zadeh ve ark., 2004).

2005 yılında Fu ve ark., mamogramlarda mikrokalsifikasyonları sınıflandırmak için iki aşamalı bir model önermişlerdir. Modelin ilk aşamasında şüpheli mikrokalsifikasyonların yerini ve şeklini hesaplamak için matematiksel model kullanmışlardır. Öncelikle görüntüyü iyileştirmek için top-hat dönüşümü, daha sonra iyileştirilmiş görüntüde nesnelerin sınırlarını belirlemek ve nesneleri bölümlmek için Sobel ve Canny kenar tanıma yöntemleri kullanmışlardır. İkinci aşamada ise her bir şüpheli mikrokalsifikasyondan 44 dokusal düzlem özelliği, 15 uzaysal düzlem özelliği ve 2 spektral düzlem özelliği olmak üzere 61 özellik çıkarmışlardır. Çıkarılan bu özelliklerden sıralı ileri seçim (SİS) algoritması kullanarak en ayırt edici özellikleri seçmişlerdir. Özellik seçim algortması sonucunda elde edilen en ayırt edici özellikleri genel regresyon sinir ağı (GRSA) ve destek vektör makinesi (DVM) sınıflandırıcılarına uygulamışlardır. 61 özelliğin hepsi kullanıldığında DVM için %97.01, GRSA için %96 sınıflandırma başarımı elde etmişlerdir. SİS özellik seçim yöntemiyle seçilen özellikler kullanıldığında DVM için %98 ve GRSA için %97.8 sınıflandırma başarımı elde etmişlerdir (Fu ve ark., 2005).

2005 yılında Wei ve ark., sayısal mamogramlarda mikrokalsifikasyonların tespiti için ilgi vektör makinesi (İVM) tabanlı bir yöntem önermişlerdir. Öncelikle arkaplanı bastırmak ve sınıflar arasındaki değişimleri sınırlamak için mamogramlara yüksek geçiren süzgeç uygulamışlardır. Daha sonra MC (mikrokalsifikasyon) tespitini denetlenen öğrenme problemi olarak formülleştirerek, mamogramda her bir yerde MC olup olmadığını belirlemek için ilgi vektör makinesine uygulamışlardır. Hesaplama hızını artırmak için iki aşamalı sınıflandırma ağı geliştirmişlerdir. Sınıflandırma sürecinin ilk aşamasında doğrusal İVM sınıflandırıcı kullanarak MC olmayan piksellerin büyük bir kısmını hızlı bir şekilde elemişlerdir. İkinci aşamada, ilk aşamadan kalan pikselleri elemek için daha gelişmiş doğrusal olmayan İVM sınıflandırıcı kullanmışlardır. Önerilen yöntemi 141 mamogramdan oluşan veritabanına uygulayarak sonuçları destek vektör makinesi sınıflandırıcısı ile karşılaştırılmıştır. Uygulama sonucunda İVM sınıflandırıcı için 65 ilgi vektörü (İV), DVM için 521 destek vektör bulmuşlardır. İVM sınıflandırıcı için iki sınıfın ilgi vektörlerinin belirgin bir şekilde

farklılık gösterdiğini gözlemlemişlerdir. İVM sınıflandırıcısının neredeyse DVM sınıflandırıcısının tespit doğruluyla aynı olduğunu ve 35 kat daha hızlı olduğunu tespit etmişlerdir. İVM sınıflandırıcıda yanlış pozitif oranı görüntü başına bir yanlış pozitif kümesi olduğunda yaklaşık %90 duyarlık elde etmişlerdir (Wei ve ark., 2005).

2006 yılında Yu ve ark., sayısal mamogramlarda mikrokalsifikasyonları tespit etmek için bir bilgisayar destekli teşhis sistemi önermişlerdir. Önerilen yaklaşım iki adım içermektedir. İlk adımda şüpheli mikrokalsifikasyonları (MC) tespit etmek için dalgacık süzgeci kullanmışlardır. Mamogram görüntülerini iki seviyeli dalgacık ayrıştırmasıyla ayrıştırmışlardır. Daha sonra alçak frekans alt bantlarını eleyerek mamogramları yeniden oluşturmuşlardır. Uygulamalar sonucunda elde edilen eşik değerleri kullanarak yeniden yapılandırılan mamogram görüntülerini eşikleyerek şüpheli mikrokalsifikasyonları tespit etmişlerdir. İkinci adımda her bir şüpheli MC'nin komşuluğundan birincil özellikler olarak Derin-Elliot modeline dayalı Markov rastgele alan parametrelerini çıkarmışlardır. Sınıflandırmanın başarımını artırmak için ortalama piksel değeri, merkez ikinci moment, kenar yoğunluğu olmak üzere yardımcı doku özellikleri çıkarmışlardır. Sınıflandırıcı olarak Bayes sınıflandırıcısı ve geriye yayılım sinir ağı sınıflandırıcısı kullanmışlardır. Önerilen yöntemi MC kümesi içeren 20 mamograma uygulamışlardır. Sınıflandırma başarımı olarak görüntü başına 0.75 yanlış pozitif ile %92 duyarlık elde etmişlerdir (Yu ve ark., 2006).


2009 yılında Dong ve Wang, Gabor süzgeçleri kullanarak mamogramları otomatik olarak sınıflandırmak için çoklu çözünürlüklü bir yaklaşım önermişlerdir. Öncelikle mamogram görüntülerini iyileştirmek için mamogram görüntülerine histogram eşitleme uygulamışlardır. Mamogramların dokusal örüntülerini çıkarmak için farklı frekans ve yönelmelere sahip Gabor süzgeçleri kullanmışlardır. Görüntü özellikleri olarak her bir süzgeçlenmiş çıkış için genlik katsayısının ortalamasını ve standart sapmasını hesaplamışlardır. Özellik uzayını azaltmak ve sınıflandırma doğruluğunu artırmak için, özellik seçimi ve ağırlıklandırma için istatistiksel t testini ve onun p değerlerini kullanmışlardır. İstatistiksel t testini bütün özelliklere uygulayarak p değerlerini hesaplamışlardır. p değeri 0.05'ten küçük olan özellikleri koruyarak diğer özellikleri çıkarmışlardır. Seçilen özellikleri p değerlerine göre ağırlıklandırarak K-en yakın komşuları sınıflandırıcısına uygulamışlardır (Dong ve Wang, 2009).

2009 yılında Zhang ve ark., mamogramlarda mikrokalsifikasyonları tespit etmek için son zamanlarda geliştirilen makine öğrenme tekniği olan ikiz destek vektör

makinesi (İDVM) temelli bir yaklaşım önermişlerdir. Öncelikle basit artifakt atıcı süzgeç ve yüksek geçiren süzgeç kullanarak ön işleme gerçekleştirmişlerdir. Daha sonra birleştirilmiş görüntü özellik çıkarıcısını 164 görüntü özelliği çıkarmak için uygulamışlardır. Birleşik özellik düzleminde, mikrokalsifikasyon tespit yöntemini gözlenen öğrenme ve sınıflandırma problemi olarak formüle etmişlerdir. Daha sonra mikrokalsifikasyonların var olup olmadığını sınıflandırmak için eğitilmiş İDVM kullanmışlardır. % 97.06 sınıflandırma başarımı elde etmişlerdir (Zhang ve ark., 2009).

3. MATERYAL VE YÖNTEMLER

Bu bölümde meme kanserinin erken belirtisi olan mikrokalsifikasyonları, tespit etmek ve sınıflandırmak amacıyla tasarlanan bilgisayar destekli teşhis sisteminin adımları ve her adımda kullanılan yöntemler verilmektedir. Tasarlanan bilgisayar destekli teşhis (BDT) sisteminin öbek çizgesi Şekil 3.1’de verilmektedir. BDT sistemi ön işleme, bölümleme, özellik çıkarımı, özellik seçimi(boyut azaltımı) ve sınıflandırma olmak üzere beş bölümden oluşmaktadır.



Şekil 3.1. Tasarlanan BDT sistemi öbek çizgesi

3.1. Ön-İşleme

Sayısal görüntülerde ön-işleme gürültüyü bastırmak ve görüntünün kontrastını iyileştirmek için gerçekleştirilmektedir. Görüntü iyileştirmenin amacı, belirli bir uygulama için görüntüyü asıl durumundan daha iyi bir duruma getirmektir. Aynı zamanda görüntü iyileştirme teknikleri verilen görüntünün niteliğini artırmayı amaçlayan matematiksel yöntemlerdir (Gonzalez ve Woods, 2002). Kontrast iyileştirme yöntemleri doğrudan ve dolaylı olarak sınıflandırılabilir. Dolaylı iyileştirme yöntemleri, kontrastı tanımlamaksızın histogramları değiştirmektedir. Doğrudan

yaklaşımlar ise öncelikle kontrastı tanımlayarak tanımlanmış ölçümlere göre kontrastı iyileştirmektedirler. Görüntü iyileştirme, yoğunluk ve kontrast değiştirmeyi, gürültü azaltımını, arka plan çıkarmayı, kenar keskinleştirmeyi ve süzgeçlemeyi içermektedir (Cheng ve ark., 2003).

Geleneksel iyileştirme yöntemleri, genel ve sabit komşuluk teknikleridir ve görüntüde yerel bilgiye uyarlanamazlar. Kontrast yayma, histogram eşitleme, keskinleştiren maskeleme, uzaysal süzgeçleme en bilinen görüntü iyileştirme yöntemleridir (Gonzalez ve Woods, 2002; Cheng ve ark., 2003).

Medikal görüntüler sıklıkla çeşitli parazit kaynaklarından dolayı oluşan gürültü tarafından kötüleşmektedir. Görüntüleme kullanılan yöntemler ve inceleme altındaki fizyolojik sistemin doğası, kontrastı ve ayrıntıların görünüş netliğini azaltmaktadır. Mamogramlar (göğüsün x-ışını görüntüleri) gürültüden çok etkilenmemelerine rağmen görüntüleme sürecinde sıkıştırılan memenin yumuşak dokularının eklenmesinden ve doğasından dolayı kontrastlıkları sınırlanmaktadır. Bu nedenle normal ve anormal dokular arasındaki küçük farklılıklar gürültüyle karıştırılmaktadır. Görüntüleme cihazının ve görüntüleme sürecinin kendine özgü karakteristiklerinden dolayı gürültü, BDT sisteminin duyarlılığını önemli ölçüde etkilemektedir (Qian ve ark., 1994).

Mamogramlarda özellikle yoğun memelerde kontrastın artırılması önemlidir. Çünkü normal doku ile anormal doku arasındaki kontrast farkı mamogramda mevcuttur ancak bu farkın insan gözüyle ayırt edilmesi zordur (Wang ve Karayiannis, 1998). Bu nedenle mamografik özelliklerin iyileştirilmesi gerekmektedir. Bu da şüpheli bölgelerin kontrastını artırarak ve arka plan gürültüsünü azaltarak gerçekleştirilebilmektedir.

Mikrokalsifikasyonlar genellikle çevre dokudan parlak olmalarına rağmen yoğun dokuya sahip memelerde kontrastları oldukça düşük olmaktadır. Aynı zamanda mikrokalsifikasyonların boyutlarının, şekillerinin ve biçimlerinin çeşitliliğinden dolayı mamogramlar bütünsel iyileştirme yöntemleriyle iyileştirilemezler. Bir çok geleneksel iyileştirme yöntemi görüntüde ilgilenilen parçayı iyileştirirken arka plan gürültüsünü de iyileştirmektedir. Mamogramları iyileştirmenin amacı ilgilenilen bölgenin sınırlarını veya kenarlarını keskinleştirmek veya ilgilenilen bölge ile arka plan arasındaki kontrastı artırmaktır (Cheng ve ark., 2003).

Mamogramlarda tanısal özelliklerin (mikrokalsifikasyonlar, kütleler, asimetrik bozukluklar vb.) boyutları ve şekilleri çok fazla çeşitlilik göstermektedir. Bu nedenle

geleneksel yöntemler mamografik özellikleri iyileştirmede, arka plan ve gürültüyü atmada tek başlarına yeterli değildirler (Cheng ve ark., 2003).

Bazı mamogramlar homojen olmayan arka plana sahiptirler. Bu nedenle yerel tabanlı iyileştirme yöntemleri daha etkili olmaktadır. Gordon ve Rangayyan mamogramları iyileştirmek için sabit komşuluklu iyileştirme yöntemi kullanmışlardır. Bu yöntemde mamografik özelliklerin yanında gürültü ve diğer arka plan değişimleri de iyileştirilmiştir. Bu da mikrokalsifikasyonların iyileştirilmiş arka plandan ve gürültüden ayırt edilmesini zorlaştırmaktadır (Cheng ve ark., 2003). Bu olumsuzluğu azaltmak için Dhawan ve ark., en uygun uyarlamalı iyileştirme yöntemi kullanmışlardır. Gürültüyü iyileştirmeden yalnızca mamografik özellikleri iyileştirmek için çeşitli kontrast iyileştirme işlevlerini inceleyerek en uygun kontrast iyileştirme işlevini belirlemişlerdir (Dhawan ve ark., 1986; Cheng ve ark., 2003).

Mamogramları iyileştirmek için bölge tabanlı yöntemlerde kullanılmaktadır. (Cheng ve ark., 2003).

Lai ve ark., mamogram görüntülerini iyileştirmek için değiştirilmiş ortanca süzgeçleme kullanmışlardır. Bu süzgeç ayrıntıları bozmadan gürültüyü atma özelliğine sahiptir (Lai ve ark., 1989).

Qian ve ark., ayrıntıları koruma ve gürültü bastırma için ağaç yapılı doğrusal olmayan süzgeçleme kullanmışlardır. Merkezi ağırlıklı ortanca süzgeç kullanarak görüntüyü iyileştirerek gürültüyü bastırmışlardır (Qian ve ark., 1994).

Kim ve ark., mamogram görüntülerini iyileştirmek için birinci türev ve yerel istatistiklere dayalı görüntü iyileştirme tekniği kullanmışlardır. Kullanılan uyarlamalı iyileştirme yöntemi üç adım içermektedir: a) mikrokalsifikasyon olarak yanlış okunan film artefaktlarını atmak, b) birinci dereceden türev işlemcisi kullanarak gradyan görüntüleri hesaplamak ve c) uyarlamalı olarak ağırlıklandırılmış gradyan görüntülerini toplayarak önemli mamografik özellikleri iyileştirmektedir (Kim ve ark., 1997).

Veldkamp ve Karssemeijer mamogramlarda kontrastı iyileştirmek için uyarlamalı gürültü eşitleme yöntemi önermişlerdir. Yüksek frekanslı gürültüyü gri seviye işlevi olarak elde etmişlerdir. Daha sonra bu bilgiyi kullanarak mamogramlarda yerel kontrast özelliklerinin normalizasyonunu gerçekleştirmişlerdir (Veldkamp ve Karssemeijer, 2000).

Laine ve ark., çoklu çözünürlüklü analiz yöntemi ile mamografik özellikleri iyileştirmişlerdir (Laine ve ark., 1994). Çoklu çözünürlük analizinde en çok kullanılan

yöntem dalgacık dönüşümüdür. Dalgacık dönüşümünde görüntü önce alt bantlara ayrıştırılmaktadır. Daha sonra dalgacık katsayılarının ağırlıkları değiştirilerek eşikleme uygulanmaktadır. Son olarak ters dalgacık dönüşümü uygulanarak görüntü yeniden oluşturulmaktadır. Böylece arka plan dokusu ve gürültü bastırılarak mamogram görüntüsü iyileştirilmektedir.

Bir diğer görüntü iyileştirme tekniği arka planın ön plandan çıkarılmasıdır. Bu yöntemde iyileştirilmiş görüntü asıl görüntüden alçak geçiren süzgeçten geçirilmiş görüntünün çıkarılması ile elde edilmektedir (Cheng ve ark., 2003).

3.1.1. Çoklu Ölçekli Morfolojik Görüntü İyileştirme Yöntemi

Bu çalışmada mamogram görüntüsünü iyileştirmek için son yıllarda geliştirilen ve x ışını görüntülere uygulanan, yerel kontrast iyileştirme yöntemi olan çoklu ölçekli morfoloji (şekil bilgisi) tekniği kullanılmıştır.

Matematiksel morfoloji işaret işleme alanının doğrusal olmayan bir dalıdır. Morfoloji, genel bilimsel bir öngöründen şekillerin ve yapıların çalışması ile ilgili bir kavramdır. Morfolojik işlemler görüntülerin geometrik özelliklerini değiştiren doğrusal olmayan dönüşümlerdir (Parvati ve ark., 2008).

Morfolojik işlemler görüntüde kusurları atmak ve görüntünün yapısıyla ve biçimiyle ilgili bilgi elde etmek için kullanılmaktadır. Morfolojik işlemler kenar belirleme, gürültü atma, görüntü iyileştirme ve görüntü bölümlendirme alanlarında kullanılmaktadır (Gonzalez and Woods, 2002).

Morfolojik işlemlerin iki elemanı vardır. Bunlar giriş görüntüsü ve yapı elemanıdır. Yapı elemanı (YE) farklı boyutlarda ve farklı biçimlerde olabilmektedir. Morfolojik görüntü işleme, uzaysal süzgeçlemeye benzer şekilde gerçekleşmektedir. Yapı elemanı asıl görüntünün bütün piksellerini tarayarak her piksele yeni bir değer atamaktadır. Pikselin yeni değeri morfolojik işleme bağlıdır. Yapı elemanı görüntüden nesneleri ve özellikleri çıkarmada önemli bir rol oynamaktadır. Morfolojik görüntü işlemede temel olarak kullanılan iki işlem vardır. Genişletme (dilation) ve aşındırma (erosion). Diğer işlemler bu iki işlem kullanılarak elde edilmektedir (Mukhopadhyay ve Chanda, 2000; Gonzalez ve Woods, 2002; Wei ve ark., 2007).

Gri seviyeli $f(s,t)$ görüntüsünün $B(x,y)$ yapı elemanı ile genişletme işlemi $f \oplus B$ ile gösterilmektedir ve;

$$(f \oplus B)(s,t) = \max \left\{ f(s-x, t-y) + B(x,y) \mid (s-x), (t-y) \in D_f; (x,y) \in D_B \right\} \quad (3.1)$$

olarak ifade edilmektedir. Yukarıda verilen eşitliklerde D_f ve D_B , f ve B 'nin düzlemlerini ifade etmektedir. Gri seviyeli görüntülerde yapı elemanı değerleri pozitif ise çıkış görüntüsü daha parlak olur. Gri seviyeli görüntülerde genişletme işlemi koyu ayrıntıları atarak görüntüyü daha parlak yapmaktadır.

Genişletme, ikili görüntüde bulunan nesneyi yapı elemanına uygun olarak büyötmeye ve kalınlaştırmaya yarayan bir morfolojik işlemidir. Sayısal bir görüntüyü genişletmek görüntüyü yapı elemanı ile kesiştiği bölümler kadar büyötmek anlamına gelmektedir. Aynı zamanda genişletme görüntüde boşluklar arasında köprü kurar, aralıkları genişletir. Yapı elemanı birçok morfolojik işlemin gerçekleştirilmesinde en önemli öğedir (Gonzalez and Woods, 2002).

Gri seviyeli görüntülerde genişletme işlemi uygulanırken, yapı elemanı giriş görüntüsü üzerinde bütün pikselleri tarar. Yapı elemanının sıfırdan farklı piksellerinin geldiği bölgedeki görüntü piksellerine bakılır bu piksel değerlerinin içinde en büyük değere sahip olan piksel değeri o pikselin yeni değeridir. Örneğin Şekil 3.2'de verilen gri seviye görüntüye ait olan matriste matrisin $f(2,2)$ koordinatının genişletme işlemi sonucunda yeni değeri şu adımlarla belirlenmektedir.

- Genişletme işlemi uygulanmadan önce görüntü matrisinde önce pikselin değeri $f(2,2) = 19$ olarak verilmiştir.
- Yapı elemanının merkezi $(2,2)$ koordinatına gelecek şekilde yerleştirilir.
- Yapı elemanının kapladığı bölümdeki (yapı elemanının sıfırdan farklı olan değerleri) piksellerin değerleri $(23,42,19,255,11)$ olarak yazılır.
- Bunların içinde en büyük piksel değeri (255) o pikselin yeni değeri olur.
- $f(2,2) = 255$ olarak çıkış görüntüsünde yazılır.

Bu işlem görüntüdeki bütün pikseller için tekrarlanır.

0	1	0
1	1	1
0	1	0

(a)

10	23	16	19	111
42	19	255	198	111
76	11	32	56	16
16	54	123	78	61
169	49	23	19	139


(b)

10	23	16	19	111
42	255	255	255	111
76	76	255	198	16
16	123	123	123	61
169	49	23	19	139

(c)

Şekil 3.2. a) Yapı elemanı. b) Giriş görüntü matrisi. c) Genişletilmiş görüntü matrisi

Şekil 3.3’de genişletme işlemi uygulanmış mamogram görüntüleri verilmektedir.



Şekil 3.3. a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile genişletilmiş görüntü

Gri seviyeli $f(s,t)$ görüntüsünün $B(x,y)$ yapı elemanı ile aşındırma işlemi $f \ominus B$ ile gösterilmektedir ve;

$$(f \ominus B)(s,t) = \min \left\{ f(s+x, t+y) - B(x,y) \mid (s+x), (t+y) \in D_f ; (x,y) \in D_B \right\} \quad (3.2)$$

olarak ifade edilmektedir. Yukarıda verilen eşitliklerde D_f ve D_B , f ve B ’nin düzlemlerini ifade etmektedir.

Aşındırma, ikili görüntüde nesneyi küçültür, ve görüntüden ilgisiz parçaları atar. Gri seviye görüntülerde ise yapı elemanının değerleri pozitif ise çıkış görüntüsü daha koyu olur. Aşındırma görüntüde parlak ayrıntıların etkisini azaltır. Ancak burada yapı elemanının biçimi ve boyutu önemlidir.

Gri seviyeli görüntülerde aşındırma işlemi yapılırken yapı elemanı bütün görüntüyü tarar. Yapı elemanının sıfırdan farklı piksellerinin kapladığı giriş görüntüsünün piksellerine bakılır. En küçük gri değere sahip olan piksel değeri yapı elemanının merkezinin yerleştiği yerdeki görüntü pikselinin yeni değeri olur. Örneğin Şekil 3.4’de verilen gri seviye görüntüye ait olan matriste matrisin $f(2,2)$ koordinatının aşındırma işlemi sonucunda yeni değeri şu adımlarla belirlenmektedir.

- Aşındırma işlemi uygulanmadan önce görüntü matrisinde pikselin değeri $f(2,2)=19$ olarak verilmiştir.
- Yapı elemanının merkezi $(2,2)$ koordinatına gelecek şekilde yerleştirilir.
- Yapı elemanının kapladığı bölümdeki (yapı elemanının sıfırdan farklı olan değerleri) piksellerin değerleri $(23,42,19,255,11)$ olarak yazılır.
- Bunların içinde en küçük piksel değeri (11) o pikselin yeni değeri olur.
- $f(2,2) = 11$ olarak çıkış görüntüsünde yazılır

0	1	0
1	1	1
0	1	0

(a)

10	23	16	19	111
42	19	255	198	111
76	11	32	56	16
16	54	123	78	61
169	49	23	19	139


(b)

10	23	16	19	111
42	11	16	19	111
76	11	11	16	16
16	11	23	19	61
169	49	23	19	139

(c)

Şekil 3.4. a) Yapı elemanı. b) Giriş görüntü matrisi. c) Aşındırılmış görüntü matrisi

Şekil 3.5’te aşındırma işlemi uygulanmış mamogram görüntüleri verilmektedir.



(a)

(b)

Şekil 3.5. a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile aşındırılmış görüntü

Genişletme ve aşındırma işlemini kullanılarak elde edilen diğer morfolojik işlemler açma ve kapamadır.


Açma işlemi, aşındırma ve genişletme işlemlerinin ardışıl uygulanmasıyla elde edilir. Aşındırma işlemiyle görüntüde küçük ayrıntılar atılır, görüntü daha karanlık olur. Ardından uygulanan genişletme işlemiyle görüntünün yoğunluğunu artırır (Gonzalez ve Woods, 2002).

f görüntüsünün B yapı elemanı tarafından açma işlemi $f \circ B$ ile gösterilmektedir;

$$f \circ B = (f \ominus B) \oplus B \quad (3.3)$$

olarak ifade edilmektedir.

Açma işlemi genellikle bir nesnenin çevresini yumuşatır ve taşmaları atar. Ayrıca açma işleminde birbirine yakın iki nesne görüntüde fazla değişime neden olmadan ayrılmış olur. Görüntüde küçük parlak noktalar atılır. Görüntüdeki küçük ayrıntıların seçilmesi için açma işleminde boyutu küçük yapı elemanı kullanılmalıdır (Gonzalez ve Woods, 2002). Şekil 3.6'da açma işlemi uygulanmış mamogram görüntüleri verilmektedir.



(a)

(b)

Şekil 3.6. a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile açılmış görüntü


Kapama işlemi, genişletme ve aşındırma işlemlerinin ardışıl uygulanmasıyla elde edilir. Öncelikle genişletme işlemiyle görüntüde koyu ayrıntılar atılır. Ardından uygulanan aşındırma işlemi görüntüyü koyulaştırır.

f görüntüsünün B yapı elemanı tarafından kapama işlemi $f \bullet B$ ile gösterilmektedir;

$$f \bullet B = (f \oplus B) \ominus B \quad (3.4)$$

olarak ifade edilmektedir.

Kapama işlemi ise çevreleri yumuşatma eğilimindedir; ancak açma işleminin tersidir. Ayrıca kapama işleminde birbirine yakın iki nesne görüntüde fazla değişiklik yapılmadan birbirine bağlanmış olur. Kapama işleminde görüntüde koyu ayrıntılar atılır. (Gonzalez ve Woods, 2002). Şekil 3.7’de kapama işlemi uygulanmış mamogram görüntüleri verilmektedir.



(a)

(b)

Şekil 3.7. a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile kapanmış görüntü


Diğer bir morfolojik işlem top-hat dönüşümüdür. Top-hat dönüşümü görüntüde parlak ve karanlık bölgeleri tespit etmek için kullanılan bir yöntemdir. Top-hat dönüşümü beyaz top-hat ve siyah top-hat olmak üzere ikiye ayrılmaktadır. Beyaz top-hat dönüşümü görüntüde yapı elemanından daha küçük parlak noktaları, siyah top-hat dönüşümü ise görüntüde yapı elemanından daha küçük koyu noktaları çıkarmaktadır (Mukhopadhyay ve Chanda, 2000; Gonzalez ve Woods, 2002; Wei ve ark., 2007).

Beyaz top-hat dönüşümü asıl görüntüden açılmış görüntünün çıkarılmasıyla elde edilmektedir. Görüntüde tepe bölgeleri belirginleştirme özelliğine sahiptir (Mukhopadhyay ve Chanda, 2000; Wei ve ark., 2007).

Beyaz top-hat dönüşümü;

$$top(f) = f - (f \circ B) \quad (3.5)$$

olarak ifade edilmektedir. (3.5) eşitliğinde f giriş görüntüsünü, B yapı elemanını göstermektedir. Beyaz top-hat dönüşümü uygulanmış mamogram görüntüsü Şekil 3.8’de verilmektedir.



(a)

(b)


Şekil 3.8. a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile beyaz top-hat dönüşümü uygulanmış görüntü

Siyah top-hat dönüşümü ise kapanmış görüntüden asıl görüntünün çıkarılmasıyla elde edilmektedir (Mukhopadhyay ve Chanda, 2000; Wei ve ark., 2007).

Siyah top-hat dönüşümü;

$$bot(f) = (f \bullet B) - f \quad (3.6)$$

olarak ifade edilmektedir. (3.6) eşitliğinde f asıl görüntüyü, B yapı elemanını göstermektedir (Mukhopadhyay ve Chanda, 2000; Wei ve ark., 2007). Siyah top-hat dönüşümü uygulanmış mamogram görüntüsü Şekil 3.9’da verilmektedir.



(a)

(b)

Şekil 3.9. a) Asıl görüntü. b) Yarıçapı 5 olan disk biçimli yapı elemanı ile siyah top-hat dönüşümü uygulanmış görüntü

Farklı ölçeklerde yapı elemanının kullanıldığı morfolojik işlemler çoklu ölçekli morfoloji olarak adlandırılmaktadır. Çoklu ölçekli açma ve kapama işlemleri aşağıdaki biçimde ifade edilmektedir.

Çoklu ölçekli açma;

$$(f \circ nB)(s,t) = ((f \ominus nB) \oplus nB)(s,t) \quad (3.7)$$

Çoklu ölçekli kapama;

$$(f \bullet nB)(s,t) = ((f \oplus nB) \ominus nB)(s,t) \quad (3.8)$$

olarak ifade edilmektedir.

nB işlemi B yapı elemanının $n-1$ kere tekrarlamalı olarak genişletilmesini ifade etmektedir (Mukhopadhyay ve Chanda, 2000; Wei ve ark., 2007).

$$nB = B \oplus \underbrace{B \oplus B \oplus \dots \oplus B}_{n-1 \text{ ker } e} \quad (3.9)$$

Çoklu ölçekli morfolojik yöntemde, çoklu ölçekli top-hat dönüşümü (beyaz ve siyah) kullanılarak görüntüden çeşitli ölçeklerde parlak ve koyu özellikler çıkarılır. Bu çoklu ölçekli özellikler iyileştirilmiş görüntüyü oluşturmak için birleştirilir. Çoklu ölçekli morfolojik teknik kullanılarak yerel olarak iyileştirilmiş görüntü ifadesi aşağıda verilmiştir. Yöntem uygulanırken aşağıdaki adımlar gerçekleştirilir.

1. Birinci adımda her bir ölçek için beyaz top-hat dönüşümü gerçekleştirilmektedir. Dönüşüm sonucunda görüntüde, verilen yapı elemanından daha küçük genişlikte tepeler (parlak bölgeler) elde edilmektedir. Her bir seviyede gerçekleştirilen beyaz top-hat dönüşümü ifadesi (3.10) eşitliğinde verilmektedir.

$$top_k(r, c) = f(r, c) - f(r, c) \circ kB \quad (3.10)$$

2. İkinci adımda her bir ölçekte siyah top-hat dönüşümü gerçekleştirilmektedir. Dönüşüm sonucunda yapı elemanından daha küçük genişlikte çukurlar (koyu bölgeler) elde edilmektedir. Her bir seviyede gerçekleştirilen siyah top-hat dönüşümü ifadesi aşağıda verilmektedir.

$$bot_k(r, c) = f(r, c) \bullet kB - f(r, c) \quad (3.11)$$

3. Üçüncü adımda ilk iki adımda hesaplanan her bir seviyedeki dönüşüm sonuçları toplanmaktadır.


$$S_{op}(r, c) = 0.5 \sum top_k(r, c) \quad (3.12)$$

$$S_{cl}(r, c) = 0.5 \sum bot_k(r, c) \quad (3.13)$$

4. Son adımda aşağıda verilen (3.14) eşitliği ile yerel olarak iyileştirilmiş görüntü hesaplanmaktadır.

$$f_{iyil}(r, c) = f(r, c) + S_{op}(r, c) - S_{cl}(r, c) \quad (3.14)$$

Yukarıda verilen ifadeler için $f(r, c)$ asıl görüntüyü, k ölçek seviyesini, $top_k(r, c)$ k . seviyedeki parlak noktaları belirleyen çoklu ölçekli beyaz top-hat dönüşümünü, $bot_k(r, c)$ k . seviyedeki çoklu ölçekli siyah top-hat dönüşümünü temsil etmektedir. (Mukhopadhyay ve Chanda, 2000; Wei ve ark., 2007). Bir boyutlu bir işlev için çoklu ölçekli morfoloji tekniğinin uygulaması aşağıda Şekil 3.10'da verilmektedir.



Şekil 3.10. $g(t)$ işlevinin çoklu ölçekli morfoloji ile yerel kontrast iyileştirmesi; (a), (e), (i), (l) ve (m) asıl fonksiyon, (b) ve (f) YE tarafından açılmış işlev, (j), (n) YE tarafından kapanmış işlev, (c) ve (g) her bir ölçekteki beyaz top-hat işlevleri, (k) ve (o) her bir ölçekteki siyah top-hat işlevleri, (d) her bir ölçekte alınan beyaz top-hat işlevlerinin toplamı, (h) her bir ölçekte alınan siyah top-hat işlevlerinin toplamı, (p) yerel iyileştirmeden sonra alınan çıkış işlevi (Mukhopadhyay ve Chanda, 2000)

3.2. Bölümleme

Bölümleme iyileştirilmiş bütün görüntüden sadece ilgilenilen şüpheli parçanın alınması işlemidir. Bu adım bütün tanı sisteminin duyarlılığını tanımlayan önemli bir adımdır. Görüntü bölümleme, görüntüyü birbiriyle çakışmayan fakat görüntünün tümünü içeren alt gruplara ayırma işlemidir. Bu gruplandırma işlemi, görüntünün belirli, bir veya birden fazla özelliği dikkate alınarak gerçekleştirilebilmektedir (Gonzalez ve Woods, 2002; Cheng ve ark., 2003).

Görüntü bölümleme algoritmaları, yoğunluk değerlerinin iki temel özelliği olan süreksizliğe ve benzerliğe dayanmaktadır. İlk grupta, görüntüde kenarlar gibi yoğunluğun ani değişimlerine dayalı olarak görüntü bölümlere ayrılmaktadır. İkinci grupta ise, görüntü önceden tanımlanmış kriterlere göre benzer olan bölgelere bölünmektedir (Gonzalez ve Woods, 2002).

Görüntü bölümleme teknikleri dört gruba ayrılabilir:

- Eşikleme yöntemleri
- Sınır-tabanlı yöntemler
- Bölge-tabanlı yöntemler
- Sınır ve bölge ölçütlerinin birleşimi melez yöntemler (Rangayyan, 2005)

Eşikleme yöntemleri aynı sınıfa ait belli aralıkta bulunan bütün pikselleri tahmin etmeye dayalıdır. Sınır tabanlı yöntemler bölgeler arasındaki sınırlardaki hızlı piksel değişimlerini kullanırlar. Bu yöntemler nesneler ve arkaplanları arasındaki sınırlarda bulunan yoğunluk süreksizliklerini tespit ederek başlarlar. Bölge tabanlı yöntemler, bir bölgedeki komşu piksellerin benzer değerlere sahip olmasına dayalıdır (Rangayyan, 2005).

En temel bölümleme yöntemlerinden bir tanesi sadece parlaklık bilgisinin dikkate alındığı eşikleme işlemidir. Eşikleme işlemi aracılığıyla görüntü iki ya da daha fazla gri seviyeye bölünebilmektedir. Bütünsel eşikleme, yerel eşikleme ve uyarlamalı eşikleme, eşikleme yöntemlerinden bazılarıdır. Bütünsel eşikleme işlemi, görüntünün histogram gibi genel bilgisine dayanmaktadır. Bütünsel eşiklemede bütün görüntü için tek bir eşik değeri kullanılarak görüntü, nesne ve arka plan olarak iki parçaya

ayrılmaktadır. Özellikle biyomedikal görüntülerde bütünsel eşikleme işlemi bölümlleme için yeteri kadar iyi değildir. Bunun için piksellerin gri seviye değerlerinin tüm görüntüdeki dağılımlarının yanı sıra yerel özelliklerini de göz önüne alan yerel eşikleme yöntemleri kullanılmaktadır (Sezgin, 2002).

Belirlenen eşik değeri (T) için eşikleme işlemi;

$$f(x, y) = \begin{cases} 1 & g(x, y) > T \\ 0 & g(x, y) \leq T \end{cases} \quad (3.15)$$

olarak ifade edilir. Yukarıda verilen eşikleme bütün görüntü için tek bir eşik değeri kullandığından bütünsel eşikleme olarak adlandırılmaktadır. Eşikleme işleminin başarımı daha sonraki görüntü işleme yöntemlerinin başarımını doğrudan etkilediği için eşik değerlerinin otomatik olarak ve önemli bilgileri mümkün olduğunca ortaya çıkaracak şekilde belirlenmesi büyük öneme sahiptir. Bir diğer eşikleme yöntemi, görüntünün belirli bir bölgesini göz önüne alarak eşik değerini belirleyen yerel veya uyarlamalı eşikleme yöntemleridir (Sezgin, 2002; Cheng ve ark., 2003).

Yerel eşikleme, görüntünün alt görüntüleri için ayrı ayrı eşik değeri tespitine dayanmaktadır. Bunun için pencere boyutu ve eşik parametreleri seçilmelidir (Cheng ve ark., 2003; Thangavel ve ark., 2005).

Kenar tanıma da bölümlleme için kullanılmaktadır. Roberts gradyanı, Sobel gradyanı, Prewitt gradyanı ve Laplas işlemcisi gibi kenar tanıma işlemcileri kullanılarak bölümlleme gerçekleştirilebilmektedir. Aynı zamanda morfolojik işlemler, bölge büyütme yaklaşımı ve çoklu çözünürlüklü (Dalgacık dönüşümü gibi) analizi de bölümlleme için kullanılmaktadır (Gonzalez and Woods, 2002; Thangavel ve ark., 2005).

Mamogramları bölümllemenin iki amacı bulunmaktadır. Biri radyologlara tanı koymada yardımcı olmak için şüpheli alanların yerini tespit etmek, diğeri ise anormallikleri iyi huylu ve kötü huylu olarak sınıflandırmaktır (Cheng ve ark., 2003; Thangavel ve ark., 2005).

3.2.1. Yerel Eşikleme Yöntemi

Bu çalışmada mamogramlarda mikrokalsifikasyonları bölümlemek için yerel eşikleme yöntemi kullanılmıştır. Yerel eşikleme yöntemlerinde görüntüde her bir piksel için yerel bilgilere bağlı olarak ayrı bir eşik değeri hesaplanmaktadır. Her bir piksel için eşik değeri piksel etrafındaki bölgenin ortalamasına, standart sapmasına, bölgedeki maksimum ve minimum piksel değerine bağlı olarak hesaplanabilmektedir (Sezgin, 2002).

Niblack yönteminde, görüntüde $w = b \times b$ boyutlarındaki pencerede bölgesel olarak ortalama ve standart sapma hesaplanmaktadır. Bu hesaplanan değerler kullanılarak o piksele ait eşik değeri belirlenmektedir (Niblack, 1986; Sezgin, 2002; Leedham ve ark., 2003).

Buna göre Niblack yerel eşikleme yöntemine göre görüntüde her bir piksele ait eşik değeri;

$$T(x, y) = m_w(x, y) + k \cdot \sigma_w(x, y) \quad (3.16)$$

ile hesaplanmaktadır. $T(x, y)$ görüntüde (x, y) noktasına ait eşik değerini, k eşik katsayısını, $m_w(x, y)$ ve $\sigma_w(x, y)$ ise pencere içinde kalan piksellerin ortalamasını ve standart sapmasını temsil etmektedir. Görüntünün her bir pikseli için hesaplanan eşik değerleri kullanılarak görüntüye ikili eşikleme uygulanmaktadır.

$$g(x, y) = \begin{cases} 1 & f(x, y) > T(x, y) \\ 0 & f(x, y) \leq T(x, y) \end{cases} \quad (3.17)$$

$f(x, y)$ giriş görüntüsünü, $g(x, y)$ eşiklenmiş görüntüyü ifade etmektedir.

3.3. Özellik Çıkarımı

Özellik çıkarımı örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynamaktadır. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekmektedir (Şengür, 2006).

Özellik çıkarmanın ana sebepleri:

1. Ölçüm veya örüntü uzayından daha küçük boyuta dönüşmeyi sağlamaktır. Bu sınıflandırıcının küçük hatalar ile eğitimi ve karar aşamasının daha kısa sürede gerçekleşmesi demektir.

2. Boyut olarak daha düşük olan özellik uzayını sınıflandırıcının daha az parametre ile öğrenmesini mümkün hale getirecektir. Bunun yararı örüntü uzayı ile karar uzayı arasındaki dönüşüm aşamasının daha kısa sürede gerçekleşmesidir.

3. Durağan olmayan zaman serilerinde olduğu gibi karmaşık örüntülerin tanımlayıcı karakteristiklerini bulabilmek için özellik çıkarımı şarttır. Böylece karar aşamasının güvenilirliği artacaktır (Şengür, 2006).

Örüntü özelliklerini belirlemede ana problem verilen esas örüntüden en iyi özellikleri seçmektir. Mamogramlardaki şüpheli durumları (mikrokalsifikasyon) belirlemek için iyileştirilmiş mamograma ait onu karakterize eden özelliklerin çıkarılması gerekmektedir. Bu özellikler dokusal olarak, uzaysal düzlemde ve spektral düzlemde ifade edilmektedir.

3.3.1. Uzaysal Düzlem Özellikleri

Uzaysal düzlem özellikleri şekil ilişkili özellikler ve pencere tabanlı özelliklerin her ikisini içermektedir. Aynı zamanda uzaysal düzlem özellikleri doğrudan görüntüden elde edilmektedirler. Bu özellikler ortalama, standart sapma, enerji, piksel yoğunluk varyansı, enerji varyansı gibi ifade edilmektedir (Zheng ve ark, 1996).

Bir $f(x,y)$ gri seviye görüntüsünün;
Ortalaması;

$$ortf = \frac{1}{M \times N} \sum_{x=1}^M \sum_{y=1}^N f(x, y) \quad (3.18)$$

Ortalama enerjisi;

$$ortef = \frac{1}{M \times N} \sum_{x=1}^M \sum_{y=1}^N f^2(x, y) \quad (3.19)$$

Piksel yoğunluk varyansı;

$$\text{var} = \sum_{x=1}^M \sum_{y=1}^N [f(x, y) - ortf]^2 \quad (3.20)$$

Enerji varyansı;

$$e \text{ var} = \sum_{x=1}^M \sum_{y=1}^N [f(x, y)^2 - ortef]^2 \quad (3.21)$$

olarak ifade edilmektedir

Şekil tabanlı özellikler;

Şekil tabanlı özellikler şekil tanıma üzerine odaklanmaktadır. Bu özellikler bölümlenmiş görüntüden elde edilmektedir. Şekil tabanlı özellikler aşağıda verilmiştir (Gonzalez ve Woods, 2002; Tembey, 2003; Soltanian-Zadeh ve ark., 2004).

- **Yoğunluk;** boyutsuz bir niceliktir. Yoğunluk aynı zamanda kapalı alana karşılık çevrenin karmaşıklığını ölçmektedir. Küçük değerler simetrik nesneyi temsil ederken, büyük değerler düzensiz, pütürlü nesneyi temsil etmektedir. Örneğin daire biçiminde bir şekil için yoğunluk minimumdur.

Yoğunluk;

$$C = \frac{\text{Çevreuzunluğu}^2}{\text{Alan}} = \frac{P^2}{A} \quad (3.22)$$

olarak ifade edilmektedir. Yukarıda verilen ifadede P bölümlenmiş nesnenin sınırını tanımlayan piksel sayısı, A bölümlenmiş nesnenin toplam piksel sayısını temsil etmektedir.

- **Momentler;** birçok uygulamada örüntü özellikleri olarak kullanılmaktadır. Moment bir çevrenin pürüzlülüğünü temsil etmektedir. Şekil pürüzlülüğü sayılan bilgiyi vererek ve mikrokalsifikasyonların farklı şekil sınıflarını ayırmak için kullanılmaktadır. İki boyutlu bir $f(x,y)$ sayısal görüntüsünün $(p+q)$ dereceden momenti;

$$m_{pq} = \sum_x \sum_y x^p y^q f(x,y) \quad p,q = 0, 1, 2, \dots \quad (3.23)$$

olarak ifade edilmektedir.

Merkez moment;

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x,y) \quad \bar{x} = \frac{m_{10}}{m_{00}} \text{ ve } \bar{y} = \frac{m_{01}}{m_{00}} \quad (3.24)$$

olarak ifade edilmektedir (Gonzalez ve Woods, 2002; Tembey, 2003).

- **Dışmerkezlilik;** özel bir eksen boyunca ilgilenilen nesnenin kütesinin derecesini ölçmektedir. Değeri $[0-1]$ aralığındadır, 0 değeri dairesel nesneyi ve 1 değeri doğrusal nesneyi tanımlamaktadır.

Dışmerkezlilik;

$$\varepsilon = \frac{(m_{2,0} - m_{0,2})^2 + 4m_{1,1}^2}{(m_{2,0} + m_{0,2})^2} \quad (3.25)$$

olarak ifade edilmektedir. $m_{p,q}$, $(p+q)$ dereceden momenti ifade etmektedir.

- **Yayılma;** sınır piksellerinin merkez momentlerine bağlıdır. Bu parametre eşit olmayan biçimde nesnenin kütesinin onun kitle merkezi boyunca nasıl dağıldığını ölçmektedir ve $[0-1]$ aralığında değerler almaktadır. Düşük değer dairesel nesneyi, büyük değer doğrusal ve birörnek olmayan nesneyi temsil etmektedir. Yayılma;

$$S = \mu_{0,2} + \mu_{2,0} \quad (3.26)$$

olarak ifade edilmektedir. $\mu_{p,q}$ merkez momenti temsil etmektedir.

3.3.2. Dokusal Özellikler

Bir görüntünün doku hesaplamaları görüntüyü oluşturan piksel değerleri üzerinden gerçekleştirilmektedir. Bir pikseli tanımlayan rengin ve parlaklığın aksine, doku bağlanmış piksel grubundan hesaplanmaktadır. Doku hesaplamaları işleme giren piksel ve piksel komşuluk sayısına göre derecelendirilmektedir. Birinci derece doku hesaplamaları asıl görüntü üzerinden yapılan istatistiksel hesaplamalardır. İkinci derece doku hesaplamaları ise görüntü piksellerinin ikili komşuluk grupları halinde incelenmesi sonucunda gerçekleştirilmektedir (Gonzalez ve Woods, 2002).

3.3.2.1. Birinci Derece Doku Hesaplamaları

Birinci derece doku hesaplamaları görüntünün gri seviye histogramının istatistiksel özelliklerine dayalıdır. Bunların en yaygın olanı istatistiksel momentlerdir (Gonzalez ve Woods, 2002).

Gri seviye histogramı $\{h_i, i=0,1,\dots,L-1\}$, eğer N piksellerin toplam sayısı ve L görüntüdeki gri seviyelerin sayısı ise, o zaman görüntünün normalize edilmiş histogramı $\{p_i, i=0,1,2,\dots,L-1\}$ kümesi olur. $p_i=h_i/N$ dir. İlk dört merkezi moment, ortalama, varyans, çarpıklık ve basıklık parametrelerini temsil etmektedir (Gonzalez ve Woods, 2002).

n . moment ifadesi;

$$\mu_n = \sum_{i=0}^{L-1} (i - m)^n p_i \quad (3.27)$$

olarak ifade edilmektedir.

Ortalama gri seviye;

$$m = \sum_{i=0}^{L-1} i p_i \quad (3.28)$$

İkinci moment, doku hesaplamalarında önemli olan varyansı vermektedir. Varyans kullanılarak standart sapma hesaplanmaktadır (Gonzalez ve Woods, 2002).

Varyans;

$$\mu_2 = \sum_{i=0}^{L-1} (i - m)^2 p_i \quad (3.29)$$

Standart sapma;

$$\sigma = \sqrt{\mu_2} \quad (3.30)$$

olarak ifade edilmektedir. Standart sapma kullanılarak bölgenin yumuşaklığı hesaplanabilir. Yoğunluğun sabit olduğu bölgelerde yumuşaklık sıfırdır (Gonzalez ve Woods, 2002).

Yumuşaklık;

$$R = 1 - \frac{1}{(1 + \sigma^2)} \quad (3.31)$$

Üçüncü moment histogramın yamukluğunu (çarpıklığını) ölçmektedir. Bu ölçüm simetrik histogramlar için sıfırdır. Sağa eğri histogramlarda pozitif, sola eğri histogramlarda negatiftir. Yamukluk görüntü ortalaması çevresinde piksel değerlerinin asimetrisinin ölçümünü göstermektedir (Gonzalez ve Woods, 2002; Halkiotis ve ark., 2007).

Yamukluk;

$$\mu_3 = \frac{1}{\sigma^3} \sum_{i=0}^{L-1} (i - m)^3 p_i \quad (3.32)$$

olarak ifade edilmektedir.

Dördüncü moment basıklığı ölçmektedir. Basıklık, normal dağılımla ilişkili olarak dağılımın düz veya sivri olması ölçmektedir (Gonzalez ve Woods, 2002; Halkiotis ve ark., 2007).

Basıklık;

$$\mu_4 = \frac{1}{\sigma^4} \sum_{i=0}^{L-1} (i - m)^4 p_i \quad (3.33)$$

olarak ifade edilmektedir

Histograma dayalı diğer ölçümlerden biri homojenliktir. Bu değer bütün gri seviyeler eşit (maksimum olarak tek çeşit) olduğunda maksimumdur (Gonzalez ve Woods, 2002).

Homojenlik;

$$U = \sum_{i=1}^{L-1} p_i^2 \quad (3.34)$$

olarak ifade edilmektedir.

Entropi; rastgele olmanın bir ölçümüdür. Aynı zamanda sistemin düzensizliğini tanımlamaktadır. Sabit görüntüler için değeri sıfırdır. Zıtlık değerleri farklı olan görüntülerin entropileri yüksektir (Gonzalez ve Woods, 2002).

Entropi;

$$e = - \sum_{i=0}^{L-1} p_i \log_2 p_i \quad (3.35)$$

olarak ifade edilmektedir.

3.3.2.2. İkinci Derece Doku Hesaplamaları

İkinci derece doku hesaplamaları asıl görüntüden oluşturulan yardımcı matrisler üzerinden gerçekleştirilir. En sık kullanılan yardımcı matris gri seviye eş-oluşum matrisidir. Gri seviye eş-oluşum matrisi (GSEOM) görüntüyü oluşturan piksellerin ikili komşuluğa göre gri seviyelerinin kombinasyonlarının hangi sıklıkta olduğunun tablolandığı iki boyutlu matristir. Bu matrisi oluşturan değerler üzerinden dokuya özgü hesaplamalar yapılmaktadır (Haralick ve ark., 1973; Cheng ve Cui, 2004).

İki boyutlu bir görüntüden yatay ve düşey yönlerde N_x ve N_y adet pikselden oluşan bir alt pencere varsayılın ve alt pencere içindeki piksellerin G adet gri-seviye ile nicemlendiği varsayılın. $L_x = \{1, 2, \dots, N_x\}$ yatay uzaysal düzlemi, $L_y = \{1, 2, \dots, N_y\}$ düşey uzaysal düzlemi, $\{0, 1, 2, \dots, G-1\}$ G adet nicemlenmiş gri-tonu temsil etsin. $L_y \times L_x$ kümesi, görüntüde satır-sütun düzeninde sıralanmış alt pencereye ait piksellerin kümesini ifade etmektedir. Bir f gri seviye görüntüsünün doku-içerik bilgisi, P_{ij} bağlı frekanslar matrisi tarafından belirlenmektedir. Bu matriste aralarında d mesafesi

bulunan iki pikselden biri i , öteki de j gri tonuna sahiptir. Açı ve sıklık bilgisi taşıyan matrisle literatürde eş-oluşum matrisi (co-occurrence matrix) ismi verilmektedir. Bu matris, alt pencere içindeki pikseller arasındaki açısal ilişkinin ve mesafenin fonksiyonunu temsil etmektedir. 45° lik aralıklarla nicemlenmiş açılar için normalize edilmemiş sıklık değerleri aşağıdaki şekilde tanımlanmaktadır (Haralick ve ark., 1973; Cheng ve Cui, 2004; Şengür, 2006).


$$P(i, j, d, 0^\circ) = \# \{((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid k - m = 0, |l - n| = d, f(k, l) = i, f(m, n) = j\} \quad (3.36)$$

$$P(i, j, d, 45^\circ) = \# \{((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid (k - m = d, l - n = -d) \text{ veya } (k - m = -d, l - n = d), f(k, l) = i, f(m, n) = j\} \quad (3.37)$$

$$P(i, j, d, 90^\circ) = \# \{((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid |k - m| = d, l - n = 0, f(k, l) = i, f(m, n) = j\} \quad (3.38)$$

$$P(i, j, d, 135^\circ) = \# \{((k, l), (m, n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid (k - m = d, l - n = d) \text{ veya } (k - m = -d, l - n = -d), f(k, l) = i, f(m, n) = j\} \quad (3.39)$$

Burada $\#$ küme içindeki eleman sayısını göstermektedir. Her bir d ve θ değeri için ayrı bir $G \times G$ kare matris oluşturulmaktadır. Aşırı hesap yükü olması nedeniyle, genellikle $d=1$ ve 2 piksel, $\theta = 0^\circ, 45^\circ, 90^\circ$, ve 135° açı değerleri için matrisler oluşturulmaktadır. Görüntüyü daha az sayıda gri-tona nicemleyerek (gri-ton adedini azaltarak) hesap yükünü hafifletmek mümkündür. Ancak, bu durumda bir miktar dokusal bilgi kaybının meydana gelmektedir (Haralick ve ark., 1973; Cheng ve Cui, 2004; Şengür, 2006).



Şekil. 3.11. Seçilen piksel etrafında çeşitli açılar için yönlerin gösterilimi (Haralick ve ark., 1973)

Eş-oluşum matrisi oluşturulduktan sonra bu matris kullanılarak doku ile ilgili özellikler hesaplanmaktadır (Haralick ve ark., 1973).

$p(i,j)$, normalize gri seviye eş oluşum matrisinde (i,j) . girişi temsil etmektedir.

$$p(i, j) = \frac{P(i, j)}{R} \quad (3.40)$$

R , eş oluşum matrisindeki toplam piksel sayısını göstermektedir.

$p_x(i)$: marjinal olasılık matrisinde i . giriştir. $p(i,j)$ 'nin satırları toplanarak elde edilmektedir.

$$p_x(i) = \sum_{j=0}^{G-1} p(i, j) \quad (3.41)$$

G : Nicemlenmiş (kuantalanmış) görüntüde farklı gri-ton seviyesidir.

$p_y(j)$: marjinal olasılık matrisinde j . giriştir. $p(i,j)$ 'nin sütunları toplanarak elde edilmektedir.

$$p_y(j) = \sum_{i=0}^{G-1} p(i, j) \quad (3.42)$$

$$p_{x+y}(k) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i, j) \quad i + j = k; \quad k = 0, 1, \dots, 2(G-1) \quad (3.43)$$

$$p_{x-y}(k) = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i, j) \quad |i - j| = k; \quad k = 0, 1, \dots, 2(G-1) \quad (3.44)$$

Dokusal özellikler;

1) Açısal İkinci Moment:

$$f_1 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{p(i, j)\}^2 \quad (3.45)$$

Görüntüde yerel homojenliğin ölçümünü tanımlamaktadır.

2) Kontrast:

$$f_2 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i - j)^2 p(i, j) \quad (3.46)$$

Görüntüde yerel gri seviye değişimlerin ölçümünü tanımlamaktadır.

3) Korelasyon:

$$f_3 = \frac{\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.47)$$

Yukarıda verilen eşitlikte, μ_x , μ_y ve σ_x , σ_y , p_x ve p_y matrislerinin ortalama ve standart sapmalarını temsil etmektedir. Korelasyon, görüntüde gri seviye doğrusal bağımlılıkların ölçümünü tanımlamaktadır.

4) Kareler Toplamı (Varyans):

$$f_4 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i - \mu)^2 p(i, j) \quad (3.48)$$

5) Ters Fark Momenti:

$$f_5 = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{1}{1+(i-j)^2} p(i, j) \quad (3.49)$$

6) Toplam Ortalama:

$$f_6 = \sum_{i=0}^{2(G-1)} i \cdot p_{x+y}(i) \quad (3.50)$$

7) Toplam Varyans:

$$f_7 = \sum_{i=0}^{2(G-1)} (i - f_6)^2 p_{x+y}(i) \quad (3.51)$$

8) Toplam Entropi:

$$f_8 = - \sum_{i=0}^{2(G-1)} p_{x+y}(i) \log\{p_{x+y}(i)\} \quad (3.52)$$

9) Entropi:

$$f_9 = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i, j) \log(p(i, j)) \quad (3.53)$$

10) Fark Varyansı:

$$f_{10} = p_{x-y} \text{ 'nin var yansı}$$

11) Fark Entropi:

$$f_{11} = -\sum_{i=0}^{G-1} p_{x-y}(i) \log\{p_{x-y}(i)\} \quad (3.54)$$

12), 13) Korelasyon Bilgisinin Ölçümü:

$$f_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (3.55)$$

$$f_{13} = (1 - \exp[-2.0(HXY2 - HXY)])^{1/2} \quad (3.56)$$

$$HXY = -\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i, j) \log(p(i, j)) \quad (3.57)$$

$$HXY1 = -\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i, j) \log\{p_x(i)p_y(i)\} \quad (3.58)$$

$$HXY2 = -\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p_x(i)p_y(i) \log\{p_x(i)p_y(i)\} \quad (3.59)$$

HX ve HY , p_x ve p_y 'nin entropilerini temsil etmektedir.

14) Maksimum Korelasyon katsayısı:

$$f_{14} = (Q' \text{ nun ikinci en büyük öz değeri})^{1/2} \quad (3.60)$$

$$Q(i, j) = \sum_{k=0}^{2(G-1)} \frac{p(i, k)p(j, k)}{p_x(i)p_y(k)} \quad (3.61)$$

Çizelge 3.1. Örnek matris

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

Yukarıda Çizelge 3.1’de verilen örnek matris için $\theta = 0$, $d=1$ için oluşturulan eş-oluşum matrisi Çizelge 3.2’de verilmektedir.

Çizelge 3.2. Örnek matrise göre gri seviye eş-oluşum matrisi

	0	1	2	3
0	2	2	1	0
1	0	2	0	0
2	0	0	3	1
3	0	0	0	1

Oluşturulan eş-oluşum matrisi incelendiğinde;

$(0,0)$, $(0,1)$, $(1,1)$ ikili kombinasyonlarının $(0, 1)$ yönünde 2 kez,

$(0,2)$, $(2,3)$, $(3,3)$ ikili kombinasyonlarının $(0, 1)$ yönünde 1 kez,

$(2,2)$ ikili kombinasyonunun $(0, 1)$ yönünde 3 kez,

$(0,3)$, $(1,0)$, $(1,2)$, $(1,3)$, $(2,0)$, $(2,1)$, $(3,0)$, $(3,1)$, $(3,2)$ kombinasyonlarının ise oluşmadığı görülmektedir.

3.4. Özellik Seçimi ve Boyut Azaltımı

Özellik seçimi ve boyut azaltımı örüntü tanıma sisteminin parçalarından biridir. Özellik vektörünün boyutunun fazla olması (özellik sayısının fazla olması) hesaplama karmaşıklığını artırmakta ve sınıflandırma başarımını etkilemektedir. Özellik seçme ve boyut azaltımı, veri kümesinde bulunan ilgisiz veya gereksiz özellikleri atmayı amaçlamaktadır. İlgisiz özellikler öğrenme başarımını etkilemeksizin atılabilmektedir (Liu ve Motoda, 2008).

Özellik seçimi ile örüntü sınıflarını en iyi şekilde ayırt eden etkili özelliklerin alt kümesi tanımlanmaktadır. Böylece ayırt edici gücü yüksek özellikler seçilerek özellik

veri kümesinin boyutu azaltılmaktadır (Bow, 2002; Costariduo, 2005). Özellik seçimi, sınıflandırma başarımı, sınıflandırma zamanı, öğrenme için gereken örneklerin sayısı ve sınıflandırma başarım maliyeti üzerinde önemli etkiye sahiptir (Meyer-Baese, 2004). Bu nedenle özellik seçimi veya boyut azaltımı gerçekleştirilerek, verinin gösterilimi ve anlaşılması kolaylaşmakta, örüntü tanıma uygulamasının çalıştıracağı sistem belleğinden kazanç sağlanmakta, öğrenme zamanı azalmakta ve sınıflandırma başarımı artmaktadır (Tembey, 2003; Meyer-Baese, 2004; Costariduo, 2005).

Özellik seçimi ve boyut azaltımı için literatürde çok fazla yöntem bulunmaktadır. Bunlardan bazıları, dal-ve-sınır yöntemi, sıralı ileriye seçim, sıralı geriye seçim, genetik algoritma, temel bileşenler analizi (TBA), bağımsız bileşenler analizi (BBA) ve doğrusal diskriminant analizi (DDA) olarak ifade edilmektedir (Jain ve Zongker, 1997; Meyer-Baese, 2004; Liu ve Motoda, 2008). Sıralı ileriye veya geriye seçim, özellik uzayında bulunan özellikleri ayırt edici güçlerine göre sıralamaktadır. Daha sonra ayırt edici gücü yüksek olan özellikler seçilmektedir. TBA, BBA ve DDA bütün özelliklerin doğrusal birleşimi ile özellikler, ayırt edici gücü yüksek olan daha düşük boyuta dönüştürülmektedir (Yu ve Guan, 2000).

Bu çalışmada özellik seçimi ve boyut azaltımı için temel bileşenler analizi kullanılmıştır.

3.4.1. Temel Bileşenler Analizi (TBA)

Temel bileşenler analizi (TBA), örüntü tanımda boyut azaltımı için kullanılmaktadır. Aynı zamanda temel bileşenler analizi, Karhunen-Loeve dönüşümü veya Hotelling dönüşümü olarak bilinmektedir. TBA, ilişkili değişkenleri, temel bileşenler olarak adlandırılan ilişkili olmayan değişkenlere dönüştürmektedir. TBA, yüksek boyutlu bir veri kümesini doğrusal olarak ayrıştırarak, bu kümeyi aynı boyut (özellik) sayısında ancak farklı koordinat sistemine sahip bir uzayda tanımlamayı amaçlamaktadır. Bir başka deyişle temel bileşenler analizinin temel amacı, çok fazla sayıda ilişkili değişkenleri içeren veri kümesinin boyutunu bilgi kaybı olmaksızın azaltmaktır. Bu, temel bileşenler olarak adlandırılan yeni değişkenler kümesine dönüştürülerek gerçekleştirilmektedir TBA ile giriş vektörünün özelliklerinin sayısı (boyutu) yüksek varyanslı değerler korunarak düşük varyanslı değerler atılarak azaltılmaktadır (Duda ve ark., 2001; Smith, 2002; Jolliffe, 2002; Meyer-Baese, 2004).

Temel bileşenler analizi, veri kümesinde bilgi kaybı olmaksızın değişkenlerin sayısını azaltmak ve daha anlamlı yeni değişkenleri tanımlamak için kullanılan bir yöntemdir. Yeni temel bileşen uzayı tamamen bağımsızdır ve ilişkisizdir (Bow, 2002; Semmlow, 2004).

TBA uygulanırken aşağıdaki adımlar gerçekleştirilmektedir.

1. İlk adımda özellikleri içeren yüksek boyutlu veri kümesi alınmaktadır. n adet özellik(boyut) ve m adet örnek içeren veri kümesi $m \times n$ boyutlu bir matris ile ifade edilmektedir. Buna göre veri kümesinin oluşturduğu matris (3.62) eşitliğinde verilmektedir (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008).

$$X = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \dots & x_{1n} \\ x_{21} & x_{22} & x_{23} & \dots & x_{2n} \\ x_{31} & x_{32} & x_{33} & \dots & x_{3n} \\ \dots & \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & x_{m3} & \dots & x_{mn} \end{bmatrix} \quad (3.62)$$

Yukarıda verilen eşitlikte her bir sütun özelliği, her bir satır ise örneği temsil etmektedir.

2. Veri matrisinde her bir özellik(sütun) için o özelliğin ortalaması hesaplanmaktadır. Her bir özelliğin ortalama değeri aşağıda verilen (3.63) eşitliği ile hesaplanmaktadır.

$$\overline{X_i} = \frac{\sum_{j=1}^m X_{ji}}{m} \quad (3.63)$$

Daha sonra veri kümesinde, her özellikten o özelliğin ortalaması çıkarılarak veri kümesi sıfıra ortalananmış biçime getirilmektedir. Sıfıra ortalananmış veri kümesi aşağıda (3.64) eşitliğinde verilmektedir (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008).

$$X' = \begin{bmatrix} x_{11} - \overline{x_1} & x_{12} - \overline{x_2} & x_{13} - \overline{x_3} & \dots & x_{1n} - \overline{x_n} \\ x_{21} - \overline{x_1} & x_{22} - \overline{x_2} & x_{23} - \overline{x_3} & \dots & x_{2n} - \overline{x_n} \\ x_{31} - \overline{x_1} & x_{32} - \overline{x_2} & x_{33} - \overline{x_3} & \dots & x_{3n} - \overline{x_n} \\ \dots & \dots & \dots & \dots & \dots \\ x_{m1} - \overline{x_1} & x_{m2} - \overline{x_2} & x_{m3} - \overline{x_3} & \dots & x_{mn} - \overline{x_n} \end{bmatrix} \quad (3.64)$$

3. Sıfıra ortalanmış matris (X'), kendi devriği ile çarpılarak kovaryans matrisi hesaplanmaktadır. Kovaryans hesaplanarak, veri kümesinde boyutlar (özellikler) arasındaki ilişki belirlenmektedir. Giriş veri kümesi n özellik içerdiği için kovaryans matrisi $n \times n$ boyutlu bir kare matristir. Kovaryans matrisi;

$$K = \frac{1}{m-1} (X'^T \cdot X') \quad (3.65)$$

olarak ifade edilmektedir. Yukarıda verilen eşitlikte X' sıfıra ortalanmış veri matrisini, X'^T ise devriğini temsil etmektedir (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008).

4. Kovaryans matrisinin aşağıda verilen (3.66) eşitliğini sağlayan özdeğerleri ve özvektörleri hesaplanmaktadır (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008;).

$$V \cdot K = \lambda \cdot K \quad (3.66)$$

(3.66) eşitliğinde V , özvektörler matrisini, λ ise özdeğerler matrisini temsil etmektedir. Yukarıda verilen eşitliğe göre her bir özdeğer için özvektör matrisinde bir özvektör bulunmaktadır. λ matrisi, K matrisinin n tane özdeğerini içerirken V matrisi de her sütunda bir öz vektör olmak üzere öz vektörleri içermektedir. Kovaryans matrisin özvektörleri birbirlerine diktir (ortogonal). Buna göre özvektörler matrisi;

$$V = \begin{bmatrix} a_{11} & a_{21} & a_{31} & \dots & a_{n1} \\ a_{12} & a_{22} & a_{32} & \dots & a_{n2} \\ a_{13} & a_{23} & a_{33} & \dots & a_{n3} \\ \dots & \dots & \dots & \dots & \dots \\ a_{1n} & a_{2n} & a_{3n} & \dots & a_{nn} \end{bmatrix} \quad (3.67)$$

olarak ifade edilmektedir. Özvektörler matrisinde her bir özvektör, temel bileşen olarak adlandırılmaktadır.

5. Son adımda temel bileşenlerin sayısı belirlenmekte ve özellik vektörü oluşturulmaktadır. Bu adımda boyut (özellik) azaltımı gerçekleştirilmektedir. Özdeğerler ve özvektörler hesaplandıktan sonra özdeğerler büyük olandan küçük olana doğru sıralanmaktadır. Toplamı belli bir eşik değerini sağlayan özdeğerlere karşılık öz vektörler seçilerek toplamda n adet özellik yerine $z < n$ olmak üzere daha az sayıda özellik kullanılabilir (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008).

Temel bileşen sayısı, varyansın birikimli yüzdesi hesaplanarak belirlenmektedir. Seçilen z temel bileşen için varyansın birikimli yüzdesi;

$$t_z = 100 \frac{\sum_{i=1}^z \lambda_i}{\sum_{j=1}^n \lambda_j} \quad (3.68)$$

olarak ifade edilmektedir. Verilen (3.68) eşitliğinde hesaplanan t_z değeri %70 ve %95 arasında ise bu bileşen sayısı seçilebilir anlamına gelmektedir (Martinez ve ark., 2005). Bileşen sayısı belirlendikten sonra özvektör matrisi yeniden düzenlenmektedir. Seçilen temel bileşenleri (özvektörleri) içeren matris aşağıda (3.69) eşitliğinde verilmektedir (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008).

$$V' = \begin{bmatrix} a_{11} & a_{21} & a_{31} & \dots & a_{z1} \\ a_{12} & a_{22} & a_{32} & \dots & a_{z2} \\ a_{13} & a_{23} & a_{33} & \dots & a_{z3} \\ \dots & \dots & \dots & \dots & \dots \\ a_{1n} & a_{2n} & a_{3n} & \dots & a_{zn} \end{bmatrix} \quad (3.69)$$

z tane seçilen temel bileşeni içeren matris V' , bir dönüşüm matrisi olarak düşünülerek yeni özellik veri kümesi hesaplanmaktadır. Buna göre dönüştürülmüş veri özellik kümesi;

$$Z = X' \cdot V' \quad (3.70)$$

olarak ifade edilmektedir (Smith, 2002; Shlens, 2002; Semmlow, 2004; Nixon ve Aguado, 2008).

Tüm özvektörler yerine sadece belli kısmının alınması dönüşüm esnasında bir miktar veri kaybına yol açsa da amaç veri kaybını mümkün mertebe az tutarak dönüşüm sonrası boyut sayısını olabildiğince azaltmaktır. Böylece dönüşüm sonrasında n sütundan (boyut/özellik) oluşan veri kümesi, z sütundan (boyut/özellik) oluşan veri kümesine dönüştürülmektedir (Smith, 2002; Shlens, 2002; Semmlow, 2004).


Örnek: Aşağıda x ve y 'den oluşan iki boyutlu veri kümesi verilmiş olsun. Bu veri kümesine temel bileşenler analizi yöntemi uygulanmaktadır (Smith, 2002).

Her bir özelliğe ait ortalama değer hesaplanarak, her özellikten o özelliğin ortalaması çıkarılarak veri kümesi sıfıra ortalanmış biçime getirilmektedir. Örnek veri kümesi ve sıfıra ortalanmış veri kümesi aşağıda Çizelge 3.3'de verilmektedir.

Çizelge 3.3. (a) örnek veri kümesi, (b) sıfıra ortalananmış veri kümesi

(a)		(b)	
x	y	x	y
2,50	2,40	0,69	0,49
0,5	0,70	-1,31	-1,21
2,20	2,90	0,39	0,99
1,90	2,20	0,09	0,29
3,10	3,00	1,29	1,09
2,30	2,70	0,49	0,79
2,00	1,60	0,19	-0,31
1,00	1,10	-0,81	-0,81
1,50	1,60	-0,31	-0,31
1,10	0,90	-0,71	-1,01

Giriş veri kümesinin grafiksel gösterimi aşağıda şekil 3.12’de verilmektedir.

**Şekil 3.12.** Veri kümesinin grafiksel gösterimi

Sıfıra ortalananmış veri kümesinin kovaryans matrisi hesaplanır ve aşağıda verilmektedir.

$$K = \begin{bmatrix} 0.616555556 & 0.615444444 \\ 0.61544444 & 0.716555556 \end{bmatrix}$$

Daha sonra kovaryans matrisin özdeğerleri ve özvektörleri (temel bileşenleri) hesaplanmaktadır.


$$\text{Özdeğer matrisi; } \lambda = \begin{bmatrix} 0.0490833989 & 0 \\ 0 & 1.28402771 \end{bmatrix}$$

$$\text{Özvektör matrisi; } V = \begin{bmatrix} -0.735178656 & -0.677873399 \\ 0.677873399 & -0.735178656 \end{bmatrix}$$

Özdeğerler büyük olandan küçük olana doğru sıralanır. En yüksek değerli özdeğer seçilir, diğeri atılır. Atılan özdeğerin değeri çok küçükse bilgi kaybı çok düşük olacaktır. Örnekte verilen özdeğerlerin ikincisi daha yüksek olduğu için ona ait özvektör (temel bileşen) seçilmiştir. Birinci ve ikinci özvektörün varyanslarına bakıldığında 2. özvektör toplam varyansın %96'sını, birinci özvektör ise %4'ü içermektedir. Buna göre 2. özvektör x ve y değişkenlerini göstermek için kullanılabilir. Son olarak ortalaması sıfırlanmış veri ile seçilen özvektör kullanılarak daha düşük boyutlu dönüştürülmüş yeni veri kümesi elde edilir. Boyutu azaltılmış dönüşüm sonucunda elde edilen veri kümesi Çizelge 3.4'te verilmektedir. Dönüşüm sonucunda elde edilen veri kümesinin grafiksel gösterimi Şekil 3.13'de verilmektedir.

Çizelge 3.4. Dönüşüm sonucunda elde edilen veri kümesi

X
-0,827970186
1,77758033
-0,992197494
-0,274210416
-1,67580142
-0,912949103
0,0991094375
1,14457216
0,438046137
1,223820556



Şekil 3.13. Dönüşüm sonucunda elde edilen veri kümesinin grafiksel gösterimi

3.5. Sınıflandırma

Sınıflandırma, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Bir başka deyişle sınıflandırma, temel olarak bilinmeyen bir örüntünün o örüntüye ait özellikler kullanılarak bir karar mekanizması yardımıyla hangi sınıfa ait olduğunun belirlenmesidir (Meyer-Baese, 2004).

Sınıflandırmada kullanılan öğrenme algoritmaları eğitici öğrenme ve eğitici öğrenme olarak iki gruba ayrılmaktadır. Eğitici öğrenmede, girişler ve çıkışlar arasında bir model oluşturulurken eğitme işlemi sırasında giriş verilerinin etiketleri (sınıfları) de sisteme verilmektedir. Böylece hedef çıkış ile hesaplanan çıkış arasındaki hata değeri minimize edilmiş olur. Karar ağaçları, yapay sinir ağları, Bayes sınıflandırıcıları, destek vektör makineleri eğitici öğrenme yöntemlerinden bazılarıdır. Eğitici öğrenmede ise eğitilecek modele eğitim verilerinin sınıf etiketleri verilmez, eğitim verileri arasındaki benzerlik, uzaklık gibi fonksiyonlar kullanılarak model oluşturulmaktadır. Genel olarak eğitici öğrenme yöntemleri kümeleme algoritmaları olarak bilinmektedir (Zurada, 1992; Meyer-Baese, 2004; Zheng ve Xue, 2009).


Bu çalışmada mamogramları sınıflandırmak için çok katmanlı yapay sinir ağı ve destek vektör makineleri kullanılmıştır.

3.5.1. Yapay Sinir Ağı (YSA)

Yapay sinir ağı (YSA), biyolojik sinir sistemi çalışma ilkesinin yapay olarak benzetimi çalışmalarının bir sonucu olarak ortaya çıkmış, basit işlevler içeren bir çok yapay sinir hücresinin, çeşitli ağırlık ve eşik değerleri ile birbirine değişik etki seviyeleri ile bağlanması sonucu oluşan bir sistem olarak tanımlanmaktadır. Yapay sinir ağı genellikle sinir hücresi(nöron) olarak adlandırılan çok fazla basit işleme birimlerini içermektedir (Meyer-Baese, 2004).

YSA'lar, paralel dağılmış yapısı, öğrenilme ve genelleme yapma özellikleri sayesinde karmaşık ve çözümlenmesi güç problemleri çözebilme yeteneğine sahiptir. Örüntü sınıflandırma, işaret işleme, sistem tanımlama ve denetimi gibi birçok mühendislik alanında YSA'lar oldukça başarılı sonuçlar vermektedir (Mitchell, 1997; Haykin, 1999).

Yapay sinir ağı mimarisinin temelini oluşturan yapay sinir hücresi modeli aşağıda Şekil 3.14'te verilmektedir.



Şekil 3.14. Yapay sinir hücresi modeli (Haykin, 1999)

Şekil 3.14'te verilen modelde k . sinir hücresinin ağırlıklı toplamı ve çıkışı aşağıda verilmektedir.

$$I_k = \sum_{j=1}^m x_j w_{kj} + \theta_k \quad (3.71)$$

$$O_k = \psi(I_k) \quad (3.72)$$


Yukarıda verilen (3.71) ve (3.72) eşitliklerinde $x_1, x_2, \dots, x_m$ yapay sinir hücresinin giriş verilerini, $w_{k1}, w_{k2}, \dots, w_{km}$ yapay sinir hücresinin k . ağırlıklarını, I_k giriş verilerinin ağırlıklı toplamını, θ_k eşik değeri, $\psi(.)$ etkinleştirme fonksiyonunu ve O_k yapay sinir hücresinin çıkışını temsil etmektedir (Zurada, 1992; Haykin, 1999; Davies, 2005).

Mimarisi, öğrenme yöntemi, bağlantı stratejisi gibi farklılıklara sahip çok sayıda YSA yapısı bulunmaktadır. Bazı yapay sinir ağları ileri besleme şeklinde yapılandırılırken, bazıları ise geri beslemeli olarak yapılandırılmaktadır. İleri beslemeli ağlarda, işlem elemanları arasındaki bağlantılar bir döngü oluşturmazlar ve bu ağlar giriş verisine genellikle hızlı bir şekilde karşılık üretmektedirler. Geri beslemeli ağlarda ise bağlantılar döngü içerirler ve döngü sebebiyle giriş verisinin karşılığı yavaş bir

şekilde oluşmaktadır. En yaygın olarak kullanılan sinir ağları çok katmanlı ileri beslemeli ağlar ve radyal tabanlı fonksiyon ağlarıdır (Zurada, 1992; Haykin, 1999).

3.5.1.1. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)

Çok katmanlı bir yapay sinir ağı, bir giriş katmanı, en az bir gizli katman ve bir çıkış katmanından oluşmaktadır. Her bir katman en az bir sinir hücresi içermektedir. Çok katmanlı ileri beslemeli sinir ağları, giriş ve çıkış uzayı arasında doğrusal olmayan haritalama uygulamaktadır. Bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilmektedir. Giriş katmanı, dış ortamlardan aldığı bilgileri değişikliğe uğratmadan gizli katmandaki birimlere ileterek, bilgi gizli katmanda ve çıkış katmanında işlenerek ağın çıkışı belirlenmektedir (Haykin, 1999; Meyer-Baese, 2004). Tek bir gizli katmana sahip çok katmanlı sinir ağı mimarisi aşağıda Şekil 3.15'te verilmektedir.



Şekil 3.15. Çok katmanlı yapay sinir ağı ağ mimarisi

ÇKYSA modeli eğitici öğrenme yöntemini kullanmaktadır. Ağa hem girişler hem de bu girişlere karşılık gelen hedef çıkışlar verilmektedir. Ağ kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı

üretmektedir. ÇKYSA modelinde, öğrenme algoritması olarak küçük kareler yöntemine dayanan Delta Kuralının genelleştirilmiş hali olan geriye yayılım öğrenme yöntemi kullanılmaktadır. Geriye yayılım öğrenme yöntemi, sistem hatasını azaltma esasına dayanan bir eniyileme işlemidir. Bu hatayı azaltma işlemini, ağırlıkları değiştirmek suretiyle yaptığı için bir başka deyişle çıkış hatasını geriye yaydığı için “Geriye Yayılım” olarak adlandırılmaktadır. Bu algoritmaya göre ağırlık eğitilebilmesi için eğitim kümesi ve bu kümeye karşılık ağırlık üretmesi gereken hedef çıkış kümesi olmalıdır (Freeman ve Skapura, 1991; Fausett 1994; Haykin, 1999).

Geriye yayılım üç aşamadan oluşmaktadır.

- İleri doğru hesaplama : Giriş eğitim verisinin ileriye doğru yayılması ve ağırlık çıkışının hesaplanması,
- Verilen hedef değerlerine karşılık hatanın hesaplanması,
- Geriye doğru hesaplama: Hatanın geriye doğru yayılarak ağırlıkların değiştirilmesi (Fausett, 1994).

Geriye yayılım öğrenme kullanıldığında, çıkış katmanındaki hatalar kullanılarak gizli katmanın ağırlıkları ayarlanmaktadır. Bu işlem ilk gizli katmana kadar aynı biçimde yinelenmektedir. Bu yolla hatalar katman katman ilgili katmanın ağırlık düzenlemeleri yapılarak, geriye doğru yayılarak ve toplam hata en aza indirilinceye kadar bu işlemler tekrarlanmaktadır (Freeman ve Skapura, 1991; Fausett 1994; Haykin, 1999; Meyer-Baese, 2004).

Eğitime başlamadan önce ÇKYSA modeli için öncelikle eğitim veri kümesi ve bu veri kümesine karşılık hedef çıkış veri kümesi belirlenmelidir. Hedef çıkış veri kümesi, eğitim veri kümesindeki her bir girişin sınıfını (etiketini) içermektedir (Freeman ve Skapura, 1991; Mitchell, 1997; Haykin, 1999). Maksimum yineleme sayısı, katmanlardaki düğüm sayısı, öğrenme oranı ve en küçük hata ölçüt değeri de tanımlanmalıdır.

Geriye yayılım öğrenme işlem adımları;

1. Adım: İleriye doğru yayılma

İleriye doğru yayılma adımı giriş katmanından çıkış katmanına doğru sinir hücrelerinin giriş ve çıkış değerlerinin, hatanın geriye yayılma algoritmasına göre hesaplandığı adımdır.

Bu adımda, öncelikle eğitim veri kümesinin herhangi bir giriş verisi ($x_1, x_2, \dots, x_m$) ve bu girişe karşılık ağda işlenmesinden sonra ağın üretmesi beklenen hedef çıkış verisi ($d_1, d_2, \dots, d_p$) ağa sunulmaktadır. Giriş katmanına uygulanan giriş değerleri, hiçbir işlem uygulanmadan gizli katmana iletilmektedir. Gizli katmanda bulunan bir yapay sinir hücresi, giriş katmanından gelen bilgileri, bağlantı ağırlıklarının etkisi ile kabul temektedir. Gizli katmanda bulunan herhangi bir j . yapay sinir hücresinin ağırlıkları, girişlerinin ağırlıklı toplamı olarak yazılmaktadır (Freeman ve Skapura, 1991; Fausett 1994; Haykin 1999).

$$I_j(u) = \sum_{i=1}^t w_{ji} O_i(u) + \theta_j \quad (3.73)$$

(3.73) eşitliğinde t , bir önceki katmanda bulunan düğüm sayısı, w_{ji} j . yapay sinir hücresinin bir önceki katmanda bulunan i . yapay sinir hücresi arasındaki bağlantı ağırlığının değeri, O_i bir önceki katmanda bulunan yapay sinir hücresi çıkışı ve θ_j eşik elemanın ağırlık değerini göstermektedir. Bir yapay sinir hücresinin ağırlıklı toplamı elde edildikten sonra O_j yapay sinir hücresi çıkışını bulmak için ağırlıklı toplam I_j etkinleştirme fonksiyonuna ($\psi(.)$) uygulanmaktadır (Freeman ve Skapura, 1991; Fausett, 1994; Haykin, 1999).

$$O_j(u) = \psi(I_j(u)) \quad (3.74)$$

Bu şekilde ağ üzerinde önce gizli katmanda ve sonra çıkış katmanında bulunan bütün yapay sinirlerin ağırlıklı giriş değerleri I_j ve yapay sinir hücresi çıkış değerleri O_j hesaplanmaktadır.

2. Adım: Hatanın hesaplanması ve geriye yayılması;

Bu adımda, ağıın ürettiğı çıkış ile olması beklenen çıkış arasındaki fark bütün yapay sinirlerin ağırlıklarına yansıtılmaktadır. Bunun için, ağı sunulan giriş verisi için ağıın ürettiğı çıkış ($O_j(u)$) ile bu veriye karşılık ağıın beklenen hedef çıkış değeri ($d_j(u)$), çıkış katmanındaki yapay sinir hücreleri için karşılaştırılmaktadır. Aradaki fark, $e_j(u)$, u . giriş için j . çıkış yapay sinirindeki hata değeri ifade etmektedir. Toplam hatayı bulmak için eğitim veri kümesinde bulunan bütün girişler için, e_j hatalarının toplanması gerekmektedir. Bazı hata değerlerinin negatif olma ihtimaline karşı ağıın toplam hatasını bulmak için toplam karesel hata hesaplanmaktadır. Eğitimin amacı, ağı parametrelerini ayarlayarak, toplam karesel hata değeri (E) en aza indirmektir (Freeman ve Skapura, 1991; Zurada, 1992; Fausett, 1994; Mittchell, 1997; Haykin, 1999).

$$e_j(u) = d_j(u) - O_j(u) \quad (3.75)$$

$$E = \frac{1}{2} \sum_{j=1}^p e_j(u)^2 \quad (3.76)$$

Çıkış katmanında bulunan bütün yapay sinirler için hata değeri ($e_j(u)$) bulunduktan sonra ağırlıkların güncellenmesi için gerekli eğim değerleri çıkış katmanından gizli katmana doğru hesaplanmaktadır. Çıkış katmanında bulunan j . yapay sinirin eğim değeri δ_j , karesel hatanın sinir girişine göre birinci türevi alınarak bulunmaktadır (Freeman ve Skapura, 1991; Zurada, 1992; Fausett, 1994; Mittchell, 1997; Haykin, 1999).

Çıkış katmanındaki bir sinir hücresi için eğim, δ_j , sinir hücresinin e_j hata değeri ve etkinleştirme fonksiyonunun ($\psi(.)$) türevi aşağıdaki biçimde hesaplanmaktadır.

$$\delta_j = -\frac{\partial E}{\partial I_j} \quad (3.77)$$

$$\frac{\partial E}{\partial I_j} = -\frac{\partial E}{\partial O_j} \frac{\partial O_j}{\partial I_j} \quad (3.78)$$

$$\frac{\partial E}{\partial O_j} = \frac{\partial E}{\partial e_j} \frac{\partial e_j}{\partial O_j} = -e_j \quad (3.79)$$

(3.74) eşitliğine göre;

$$\frac{\partial O_j}{\partial I_j} = \psi'(I_j) \quad (3.80)$$

olarak yazılmaktadır. Buna göre çıkış katmanındaki j . sinir hücresinin eğimi aşağıdaki biçimde ifade edilmektedir (Freeman ve Skapura, 1991; Zurada, 1992; Fausett, 1994; Mitchell, 1997; Haykin, 1999).

$$\delta_j = e_j \psi'(I_j) \quad (3.81)$$

Çıkış katmanındaki bütün sinir hücreleri için eğim hesaplandıktan sonra, gizli katman sinir hücrelerinin eğimleri hesaplanmalıdır. Bunun için çıkış katmanında bulunan sinir hücrelerinde olduğu gibi, (3.77) eşitliğinden faydalanılmaktadır. Gizli katmanda bulunan herhangi bir sinir hücresinin ÇKYSA mimarisine göre çıkış katmanındaki bütün sinirlerle bağlantısı bulunmaktadır. Bu nedenle herhangi bir gizli katman sinir hücresinin eğimi çıkış katmanındaki bütün sinir hücrelerinden etkilenmektedir.

$$\frac{\partial E}{\partial I_j} = -\sum_{i=1}^p \frac{\partial E}{\partial I_i} \frac{\partial I_i}{\partial I_j} \quad (3.82)$$

Burada p çıkış katmanında bulunan sinir hücresi sayısını, I_j , gizli katman sinir hücresinin girişini ve I_i ise çıkış katmanı sinir hücresinin girişini ifade etmektedir.

$$\frac{\partial I_i}{\partial I_j} = \frac{\partial I_i}{\partial O_j} \frac{\partial O_j}{\partial I_j} \quad (3.83)$$

(3.82) ve (3.83) eşitlikleri ile gösterilen kısmi türevler alındığı zaman, gizli katmanda bulunan sinirler için eğim ifadesi aşağıda verilmektedir.

$$\delta_j = \psi'(I_j) \sum_{i=1}^p (\delta_i w_{ij}) \quad (3.84)$$

Burada δ_i çıkış katmanındaki i . düğümün eğimi ve w_{ij} çıkış katmanındaki i . sinir hücresi ile gizli katmandaki j . sinir hücresi arasındaki bağlantı ağırlığını temsil etmektedir. (3.84) eşitliğine göre gizli katmandaki sinir hücrelerinin eğimi için öncelikle çıkış katmanındaki sinir hücrelerinin eğim değeri ile bağlantı ağırlıklarının çarpımlarının toplamı bulunarak, gizli katmandaki sinir hücresi etkinleştirme fonksiyonunun türevi ile çarpılmaktadır.

3. Adım: Ağırlıkların Güncellenmesi

Bu adımda ise gizli katmanda ve çıkış katmanında bulunan sinir hücrelerinin eğim değerlerine bağlı olarak önce giriş katmanı ile gizli katman arasındaki ağırlıklar, daha sonra gizli katman ile çıkış katmanı arasındaki ağırlıklar güncellenmektedir. Yeni ağırlık değerini bulabilmek için önceki değer ile ağırlıktaki değişim miktarına ihtiyaç duyulmaktadır. Ağırlık değerindeki değişimi bulmak amacıyla karesel hata E 'nin ağırlığa (w) göre birinci türevi alınmaktadır (Freeman ve Skapura, 1991; Mitchell, 1997; Haykin, 1999;).

$$w_{ji}^{s+1} = w_{ji}^s + \beta \Delta w_{ji} \quad (3.85)$$

$$\Delta w_{ji} = - \frac{\partial E}{\partial w_{ji}} \quad (3.86)$$

$$\frac{\partial E}{\partial w_{ji}} = - \frac{\partial E}{\partial I_j} \frac{\partial I_j}{\partial w_{ji}} \quad (3.87)$$

Yukarıda verilen eşitliklerde, w_{ji}^{s+1} , bir sonraki çevrim için ağırlığın alacağı yeni değeri, w_{ji}^s ağırlığın önceki değerini, β öğrenme oranını ve Δw_{ji} ağırlık değerlerinde olması gereken değişim miktarını ifade etmektedir.

Ağırlık değişim miktarı;

$$\Delta w_{ji} = \delta_j O_i \quad (3.88)$$

olarak ifade edilmektedir. (3.88) eşitliğinde O_i bir önceki katmanda bulunan i . sinir hücresinin çıkış değerini ve δ_j çalışılan katmandaki j . sinir eğimini ifade etmektedir. Daha sonra (3.85) eşitliği yardımıyla, j . sinir ile bir önceki katmanda bulunan i . sinir arasındaki ağırlık değeri w_{ji}^{s+1} hesaplanmaktadır (Freeman ve Skapura, 1991; Mitchell, 1997; Haykin, 1999).

Sinir hücrelerinin eşik ağırlık değerleri, sinirler arasındaki bağlantı ağırlık değeri ile aynı şekilde hesaplanmaktadır.

$$\theta_{ji}^{s+1} = \theta_{ji}^s + \beta \Delta \theta_{ji} \quad (3.89)$$

$$\Delta \theta_{ji} = - \frac{\partial E}{\partial \theta_{ji}} \quad (3.90)$$

$$\frac{\partial E}{\partial \theta_{ji}} = - \frac{\partial E}{\partial I_j} \frac{\partial I_j}{\partial \theta_{ji}} \quad (3.91)$$

Eşik ağırlıklarındaki değişim miktarı $\Delta \theta_{ji}$ aşağıda verilmektedir.

$$\Delta \theta_{ji} = \delta_j \quad (3.92)$$

Böylece (3.85)-(3.92) arasındaki eşitlikler kullanılarak bağlantı ve eşik ağırlık değerleri değiştirilmektedir. İleriye doğru yayılma fazıyla başlayıp ağırlık ve eşik güncellemesiyle sona eren üç aşamanın tamamına bir “çevrim” adı verilmektedir.

Bir çevrim boyunca, ağırlık girişine uygulanan eğitim verisi ağırlıkların değerlerine ve sinirlerde bulunan etkinleştirme fonksiyonuna göre (3.73) ve (3.74) eşitlikleri kullanılarak ileriye doğru yani giriş katmanından başlayarak çıkış katmanının sinir çıkışları hesaplanıncaya kadar yayılmaktadır. Daha sonra ise çıkış katmanından elde edilen sinir çıkış değerleri, olması gereken çıkış değerleriyle karşılaştırılmaktadır. Buradan elde edilen fark bütün ağırlık geriye yayılma adımıyla çıkış katmanından giriş katmanına doğru yansıtılarak bütün sinir hücreleri için eğitim değerleri hesaplanmaktadır. Hesaplanan bu eğitim değerlerine göre ağırlıkların değerleri güncellenmektedir. Bir sonraki çevrimde, ağırlık girişine eğitim veri kümesinin ve hedef çıkış veri kümesinin sonraki verisi sunularak, ileriye doğru yayılma adımından başlanmaktadır. Bundan sonra eğitim veri kümesinin her girişi için bu işlem tekrarlanmaktadır. Eğitim veri kümesinin tamamı için bilgi işleme aşaması tamamlandığı zaman bir “yineleme” oluşmuş demektir (Haykin, 1999). Eğitimin amacı, herhangi bir veri girişine karşılık ağırlık ürettiği çıkış değerlerinin, hedef çıkış değerleriyle aynı olmasını sağlamaktır. Bunun içinde (3.76) eşitliği ile verilen karesel hata değerinin, eğitime başlamadan önce verilen en küçük hata değerinden daha küçük olmasını sağlamak yani hatayı minimize etmek gerekmektedir (Zurada, 1992; Fausett, 1994; Mitchell, 1997; Haykin, 1999).

Yukarıdaki anlatılan adımlar, ÇKYSA ağırlık eğitimi tamamlandıncaya kadar devam etmektedir. Bir diğer deyişle elde edilen ağırlık çıkışları ile hedeflenen ağırlık çıkışları arasındaki hata kabul edilebilir düzeye ininceye kadar tekrar etmektedir. ÇKYSA modellerinde, maksimum yineleme sayısı ve kabul edilebilir hata değeri (minimum hata kriteri) durdurma ölçütü olarak belirlenmiştir. Eğer ağırlık maksimum yineleme sayısına ulaşmamışsa, her yineleme sonunda hesaplanan karesel hata değeri minimum hata ölçütü ile karşılaştırılarak öğrenmenin gerçekleşip gerçekleşmediğine bakılmaktadır.

Ağırlık eğitiminin tamamlanması, ağırlık girişine uygulanan verilere karşılık gelecek uygun çıkış üretmesini sağlayan ağırlık değerlerinin bulunduğu anlamına gelmektedir. Eğitimi tamamlandıktan sonra ağırlık başarımını ölçmek için test veri kümesi kullanılmaktadır.

ÇKYSA'nın çalışması

Ağın gizli katman düğüm sayısı, maksimum yineleme sayısı, minimum hata ölçütü ve öğrenme oranının değeri de belirtildikten sonra aşağıda kısaca adım adım özetlenen eğitme işlemine başlanır.

Adım 1: Sinirler arasındaki ağırlıklara rastgele değerler atanır.

Adım 2: Eğitim çifti (eğitim verisi ve bu veriye karşılık ağın üretmesi gereken çıkışlar) ağa sunulur.

Adım 3: (3.73) ve (3.74) eşitlikleri kullanılarak sırasıyla gizli katman sinir hücrelerinin önce giriş değeri $I_j(u)$, sonra sinir çıkışları $O_j(u)$ hesaplanır.

$$I_j(u) = \sum_{i=1}^m w_{ji} O_i(u) + \theta_j \quad j = 1, \dots, g \quad (3.93)$$

$$O_j(u) = \psi(I_j(u)) = \frac{1}{1 + e^{-I_j(u)}} \quad j = 1, \dots, g \quad (3.94)$$

Çıkış katmanında bulunan sinir hücrelerinin çıkış değerleri de aynı şekilde gizli katman sinir hücrelerinde elde edilen çıkış değerlerinin ağırlıklı toplamaları alınarak sinir girişleri ve sinir çıkışları elde edilir. O_j değeri, ağa girilen her bir veriye karşılık ağın ürettiği çıkış olarak adlandırılır.

$$I_j(u) = \sum_{i=1}^g w_{ji} O_i(u) + \theta_j \quad j = 1, \dots, p \quad (3.95)$$

$$O_j(u) = \psi(I_j(u)) = \frac{1}{1 + e^{-I_j(u)}} \quad j = 1, \dots, p \quad (3.96)$$

Adım 4: Çıkış katmanındaki bütün sinirler için hata değerleri hesaplanır.

$$e_j(u) = d_j(u) - O_j(u) \quad j = 1, \dots, p \quad (3.97)$$

Adım 5: Çıkış katmanındaki sinir hücrelerinin yerel eğim değerleri hesaplanır.

$$\delta_j = e_j \frac{e^{-I_j}}{(1 + e^{-I_j})^2} \quad j = 1, \dots, p \quad (3.98)$$

Daha sonra gizli katmandaki sinirlerin yerel eğim değerleri, çıkış katmanında bulunan sinirlerin eğimleri ve bu sinirlerle olan bağlantı ağırlıkları hesaplanır.

$$\delta_k = \psi'(I_k) \sum_{i=1}^m (\delta_i w_{ik}) = \frac{e^{-I_k}}{(1 + e^{-I_k})^2} \sum_{i=1}^p (\delta_i w_{ik}) \quad k = 1, \dots, g \quad (3.99)$$

Adım 6: Çıkış katman sinirleri ile gizli katmanı sinirleri arasındaki ağırlıklar ve eşik ağırlıkları bir sonraki çevrim için ayarlanır.

$$w_{ji}^{s+1} = w_{ji}^s + \beta \delta_j O_i \quad j = 1, \dots, p \quad \text{ve} \quad i = 1, \dots, g \quad (3.100)$$


$$\theta_{ji}^{s+1} = \theta_{ji}^s + \beta \delta_j \quad j = 1, \dots, p \quad (3.101)$$

Daha sonra $j=1, \dots, g$ ve $i=1, \dots, m$ 'ye kadar alınarak gizli katman ile giriş katmanı arasındaki ağırlıklar ve eşik ağırlıkları aynı şekilde (3.100) ve (3.101) eşitliklerine göre hesaplanır.

Adım 7: Bütün eğitim verisi için Adım (2-7) tekrar edilir.

Adım 8: Bütün eğitim verisi için Adım 2-7 tamamlandıktan sonra yani yineleme sonunda, (3.76) eşitliğine göre karesel hata (E) hesaplanarak en küçük hata ölçütü ile karşılaştırılır. Eğer ortalama karesel hata, minimum hatadan küçük ise eğitime sonlandırılır ve test verisi kullanılarak test işlemi gerçekleştirilir. Aksi halde bir sonraki yineleme için bütün (2-8) adımları tekrar edilir (Freeman ve Skapura, 1991; Fausett, 1994).

Çok katmanlı yapay sinir ağlarında yaygın olarak kullanılan etkinleştirme fonksiyonları aşağıda Şekil 3.16’da verilmiştir.



Şekil 3.16. Etkinleştirme fonksiyonları (Haykin, 1999; Davies, 2005)

3.5.2. Destek Vektör Makineleri (DVM)

Destek vektör makineleri (DVM), istatistiksel öğrenme temeline dayalı bir eğitici öğrenme yöntemidir. Geleneksel öğrenme yöntemlerine göre oldukça avantajları vardır. 1960’lı yılların sonlarında Vapnik tarafından teorik temelleri atılmıştır. 1995 yılında ise yine Vapnik tarafından ilk defa bir sınıflandırma probleminin çözümünde kullanılmıştır (Vapnik, 1998; Zheng ve Xue, 2009).

DVM, yapısal risk azaltmaya dayalı veri bölme tabanlı bir öğrenme yöntemi olarak bilinmektedir. DVM’lerin genelleme hataları, verileri ayırdığı sınır genişliği ile ilişkilidir. DVM, sınıflandırma işlevi (hiper-düzlem) yardımıyla veri uzayını bölerek bilinmeyen verilerin sınıf etiketlerini tanımlamaktadır. Bu amaçla DVM, veriyi bölmek için en uygun ayırıcı hiper- düzlemi kullanmaktadır. DVM, el yazısını tanıma, görüntü sınıflandırma, ses tanıma ve biyolojik bilgi işleme gibi birçok uygulama alanına sahiptir (El-Naqa ve ark., 2002; Abe, 2005; Zheng ve Xue, 2009).

3.5.2.1 Doğrusal Destek Vektör Makineleri

İkili sınıflandırma probleminde, bir veri kümesini doğrusal olarak ayırabilen sonsuz sayıda hiper-düzlem vardır (Şekil 3.17). Eğitim verilerini hatasız bir şekilde ayırabilen hiper-düzlemler arasından en geniş sınırlı hiper-düzlem bulunmaya çalışılmaktadır. Bu düzlemler arasında maksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır. DVM karar yüzeyini oluştururken iki sınıfa olan uzaklığı maksimum yapmaya

Karar fonksiyonu;

$$f(x) = w^T x + b \quad (3.102)$$

olarak ifade edilmektedir. (3.102) eşitliğinde w , l boyutlu ağırlık vektörü, b ise eşik değerini temsil etmektedir. Her bir eğitim örneği x_i için karar fonksiyonu;

$$\begin{aligned} f(x_i) = w^T x_i + b &\geq 0 \quad y_i = 1 \quad \text{için} \\ f(x_i) = w^T x_i + b &< 0 \quad y_i = -1 \quad \text{için} \end{aligned} \quad (3.103)$$

olarak ifade edilmektedir (Vapnik, 1998; Burges, 1998; El-Naqa ve ark., 2002; Abe, 2005; Zheng ve Xue, 2009).

İki sınıfa ait eğitim örnekleri $f(x) = w^T x + b = 0$ hiper-düzlemi ile ayrılabilir. Buna göre en uygun hiper-düzlem (maksimum sınıra sahip), aşağıda (3.105) denkleminde verilen kısıtlamalar altında $J(w)$ fonksiyonu en küçük yapılarak bulunabilmektedir.

$$J(w) = \frac{1}{2} w^T w = \frac{1}{2} \|w\|^2 \quad (3.104)$$

$$\begin{aligned} w^T x_i + b &\geq +1, \quad y_i = +1 \quad \text{için} \\ w^T x_i + b &\leq -1, \quad y_i = -1 \quad \text{için, } i = 1, \dots, l \end{aligned} \quad (3.105)$$

En uygun hiper-düzlem bu kısıtlamaları sağlamalıdır.

(3.105) eşitliğindeki kısıtlamalar birleştirilmiş olarak

$$y_i [(w^T x_i) + b] \geq 1, \quad i = 1, \dots, l \quad (3.106)$$

yazılabilmektedir.

$J(w)$ fonksiyonunu en küçük yapmak için Lagrange çarpanları yöntemi kullanılmaktadır (Burges,1998; Vapnik, 1998; Abe, 2005; Zheng ve Xue, 2009). Lagrange fonksiyonu;

$$L(w, b, \alpha) = \frac{1}{2}(w^T w) - \sum_{i=1}^l \alpha_i \{[(w^T x_i) + b]y_i - 1\} \quad (3.107)$$

olarak ifade edilmektedir. α_i negatif olmayan Lagrange çarpanlarıdır. (3.107) eşitliğinin en uygun çözümü, $L(w, b, \alpha)$ fonksiyonu, $\alpha_i \geq 0$ değerlerine göre en büyükyapılarak, w ve b değerlerine göre ise en az yapılarak çözülebilmektedir. $L(w, b, \alpha)$ fonksiyonunun w ve b değerlerine göre en küçük noktalarını bulabilmek için $L(w, b, \alpha)$ fonksiyonunun, w ve b değerlerine göre türevleri sıfıra eşitlenir (Burges,1998; Vapnik, 1998; Abe, 2005; Zheng ve Xue, 2009). Türev eşitlikleri aşağıda verilmektedir.

$$\frac{\partial L(w, b, \alpha)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^l \alpha_i y_i x_i \quad (3.108)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = 0 \Rightarrow \sum_{i=1}^l \alpha_i y_i = 0 \quad (3.109)$$

Buna göre Karush-Kuhn-Tucker (KKT) koşulları aşağıda verilmektedir (Burges,1998; Vapnik, 1998; Abe, 2005; Zheng ve Xue, 2009) ;

$$\frac{\partial L(w, b, \alpha)}{\partial b} = 0 \quad (3.110)$$

$$\frac{\partial L(w, b, \alpha)}{\partial w} = 0 \quad (3.111)$$

$$\alpha_i \{[(w^T x_i) + b]y_i - 1\} = 0, \quad i = 1, \dots, l \quad (3.112)$$

$$\alpha_i \geq 0, \quad i = 1, \dots, l \quad (3.113)$$

Eğitim verisindeki her örnek (3.112) eşitliğini sağlamalıdır. Yani $\alpha_i = 0$ veya $(w^T x_i + b)y_i - 1 = 0$ olmalıdır. $\alpha_i \neq 0$ olan her x_i giriş verisi destek vektörü olarak adlandırılmaktadır (Vapnik, 1998; Abe, 2005; Zheng ve Xue, 2009).

Lagrange fonksiyonunda KKT koşulları yerleştirildiğinde;

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.114)$$


olarak düzenlenmektedir. (3.114) eşitliği aşağıda verilen kısıtlamaları sağlamalıdır.

$$\sum_{i=1}^l \alpha_i y_i = 0, \quad \alpha_i \geq 0 \quad i = 1, \dots, l \quad \text{için} \quad (3.115)$$

Sıfırdan farklı α_i 'ler kullanılarak (3.102) eşitliğinde (3.108) eşitliği yerleştirilerek karar fonksiyonu yeniden düzenlenmektedir (Vapnik, 1998; ; Abe, 2005; Zheng ve Xue, 2009).

$$f(x) = \text{sign}\left(\sum_{\text{destek vektörleri}} \alpha_i y_i x_i^T x + b\right) \quad (3.116)$$

Eğitim örnekleri her zaman doğrusal olarak ayıramayabilir. Doğrusal olarak ayıramayan durum Şekil 3.19'da gösterilmektedir. Bunun için kısıtlamaları gevşetmek amacıyla pozitif gevşek değişkenler ($\xi_i \geq 0$) tanımlanmaktadır (Vapnik, 1998; Burges, 1998; Abe, 2005; Zheng ve Xue, 2009).



Şekil 3.19. Eğitim verilerinin doğrusal olarak ayıramadığı durum örneği

Buna göre (3.118) eşitliğinde verilen kısıtlamalar altında $J(w)$ fonksiyonu tekrar yazılabilmektedir.

$$J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (3.117)$$

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad \xi_i \geq 0, \quad i = 1, \dots, l \quad \text{için} \quad (3.118)$$

(3.117) eşitliğinde ikinci terim yanlış sınıflandırma noktasını kontrol etmektedir. C parametresi kullanıcı tarafından tanımlanmaktadır.

Doğrusal olarak ayrılabilir durumda olduğu gibi yukarıda verilen (3.117) eşitliğini en küçük yapmak için Lagrange çarpanları yöntemleri kullanılmaktadır. Lagrange fonksiyonu;

$$L(w, b, \xi, \alpha, \beta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i (y_i (w^T x_i + b) - 1 + \xi_i) - \sum_{i=1}^l \beta_i \xi_i \quad (3.119)$$

olarak yazılmaktadır. (3.119) eşitliğinde α_i ve β_i Lagrange çarpanlarını temsil etmektedir. β_i , ξ_i değerlerinin pozitif olmasını sağlamak için eklenmiştir. $L(w, b, \xi, \alpha, \beta)$ fonksiyonunun, w, b ve ξ değerlerine göre en küçük noktalarını

bulabilmek için $L(w, b, \xi, \alpha, \beta)$ fonksiyonunun, w, b ve ξ değerlerine göre türevleri sıfıra eşitlenir. Türev eşitlikleri aşağıda verilmektedir.

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^l \alpha_i y_i x_i \quad (3.120)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial b} = 0 \Rightarrow \sum_{i=1}^l \alpha_i y_i = 0 \quad (3.121)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial \xi} = 0 \Rightarrow C = \alpha_i + \beta_i \quad (3.122)$$

Buna göre Karush-Kuhn-Tucker (KKT) koşulları aşağıda verilmektedir (Vapnik, 1998; Burges, 1998; Abe, 2005; Zheng ve Xue, 2009) ;

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial w} = 0 \quad (3.123)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial b} = 0 \quad (3.124)$$

$$\frac{\partial L(w, b, \xi, \alpha, \beta)}{\partial \xi} = 0 \quad (3.125)$$

$$\alpha_i (y_i (w^T x_i + b) - 1 + \xi_i) = 0 \quad i = 1, \dots, l \quad \text{için} \quad (3.126)$$

$$\beta_i \xi_i = 0 \quad i = 1, \dots, l \quad \text{için} \quad (3.127)$$

$$\alpha_i \geq 0, \quad \beta_i \geq 0, \quad \xi_i \geq 0 \quad i = 1, \dots, l \quad \text{için} \quad (3.128)$$

Lagrange fonksiyonunda KKT koşulları yerleştirildiğinde;

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.129)$$

olarak düzenlenmektedir. (3.129) eşitliği aşağıda verilen kısıtlamaları sağlamalıdır

$$\sum_{i=1}^l y_i \alpha_i = 0, \quad C \geq \alpha_i \geq 0 \quad i=1, \dots, l \quad \text{için} \quad (3.130)$$


Verilen (3.129) eşitliğine göre $\alpha_i \neq 0$ olan her x_i giriş verisi destek vektörü olarak adlandırılmaktadır. Doğrusal olarak ayrılabilir destek vektör makineleri ile doğrusal olarak ayrılamayan destek vektör makineleri arasındaki tek fark doğrusal olmayan durumda α_i 'nin C 'den büyük olmaması gerektiğidir.

Sıfırdan farklı α_i 'ler kullanılarak (3.102) eşitliğinde (3.120) eşitliği yerleştirilerek karar fonksiyonu yeniden düzenlenmektedir (Vapnik, 1998; Burges, 1998; Abe, 2005; Zheng ve Xue, 2009).

$$f(x) = \text{sign}\left(\sum_{\text{destek vektörleri}} \alpha_i y_i x_i^T x + b\right) \quad (3.131)$$

3.5.2.2. Doğrusal Olmayan Destek Vektör Makineleri

Çoğu gerçek problemde verilerin doğrusal bir ayırım fonksiyonu ile hatasız ayrılabilmesi mümkün değildir. Bu nedenle, doğrusal olmayan haritalama kullanılarak asıl giriş uzayı, özellik uzayı olarak adlandırılan yüksek boyutlu uzaya haritalanmaktadır. Bu durum Şekil 3.20'de gösterilmektedir. Böylece yüksek boyutlu uzayda, doğrusal olarak ayrılamayan veriler ayrılabilir duruma gelmektedir (Vapnik, 1998; Burges, 1998; Abe, 2005; Zheng ve Xue, 2009).



Şekil 3.20. Verilerin giriş uzayından özellik uzayına aktarımı

Şekil 3.20, giriş uzayında doğrusal olmayan eğitim kümesinin yüksek dereceli özellik uzayına dönüştürüldüğünde doğrusal olarak ayırt edilebileceğini göstermektedir. $\phi(x_i) = \phi_1(x_i), \phi_2(x_i), \dots, \phi_l(x_i)$, $i = 1, \dots, l$, doğrusal olmayan haritalama fonksiyonu (dönüşüm fonksiyonu) kullanılarak l boyutlu x giriş vektörü, m boyutlu özellik uzayına haritalanmaktadır. Dönüşüm sonucunda, özellik uzayında doğrusal karar fonksiyonu aşağıdaki biçimde yazılmaktadır (Vapnik, 1998; Burges, 1998; El-Naqa, 2002; Abe, 2005; Zheng ve Xue, 2009).

$$f(x) = w^T \phi(x) + b \quad (3.132)$$

(3.132) eşitliğinde w , l boyutlu ağırlık vektörünü, b eşik değerini temsil etmektedir. Buna göre en uygun hiper-düzlem (maksimum sınıra sahip), aşağıda (3.134)'de verilen kısıtlamalar altında $J(w, \xi)$ fonksiyonu en küçük yapılarak bulunabilmektedir.

$$J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (3.133)$$

$$y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i \quad \xi_i \geq 0, \quad i = 1, \dots, l \quad \text{için} \quad (3.134)$$

Lagrange çarpımları yöntemi kullanılarak KKT koşullarına göre ağırlık vektörü, $\phi(x_i)$ dönüşüm fonksiyonunun doğrusal birleşimi olarak yazılmaktadır.

$$w = \sum_{i=1}^l \alpha_i y_i \phi(x_i) \quad (3.135)$$

En uygun hiper-düzlemi bulmak için yüksek boyutlu özellik uzayında iç çarpımın tanımlanması gerekmektedir. w karar fonksiyonunda yerleştirildiğinde,

$$f(x) = \sum_{i=1}^l \alpha_i y_i \phi^T(x_i) \phi(x) + b = \sum_{i=1}^l \alpha_i y_i K(x_i, x) + b \quad (3.136)$$

Yüksek boyutlu öznitelik uzayındaki $(\phi(x_i)^T \phi(x))$ iç çarpımının hesaplanması çok güç olacağı için bunun yerine düşük boyutlu giriş uzayında, çekirdek fonksiyonunun hesaplanması yeterli olacaktır. $K(x_i, x)$ çekirdek fonksiyonudur ve aşağıdaki biçimde ifade edilmektedir (Vapnik, 1998; Burges, 1998; El-Naqa, 2002; Abe, 2005; Zheng ve Xue, 2009).

$$K(x_i, x) = \phi(x_i)^T \phi(x) \quad (3.137)$$

Çekirdek fonksiyonu kullanılarak aşağıda (3.139) eşitliğinde verilen kısıtlamalar altında Lagrange fonksiyonu çözülerek Lagrange çarpımları hesaplanabilmektedir.

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3.138)$$

$$\sum_{i=1}^l y_i \alpha_i = 0 \quad \text{ve} \quad 0 \leq \alpha_i \leq C \quad i = 1, \dots, l \quad (3.139)$$

(3.138) eşitliğine göre $\alpha_i \neq 0$ olan her x_i giriş verisi destek vektörü olarak adlandırılmaktadır. Buna göre karar fonksiyonu aşağıdaki biçimde yazılmaktadır.

$$f(x) = \text{sign}\left(\sum_{\text{destek vektörleri}} \alpha_i y_i K(x_i, x) + b\right) \quad (3.140)$$

Doğrusal ayırt edilemeyen durumlarda çekirdek fonksiyonlarının seçimi sınıflandırma başarımını oldukça etkilemektedir (Vapnik, 1998; Burges, 1998; El-Naqa, 2002; Abe, 2005; Zheng ve Xue, 2009).

Destek vektör makinelerinde yaygın olarak kullanılan çekirdek fonksiyonları şunlardır (Abe, 2005; Zheng ve Xue, 2009).

- **Doğrusal Çekirdek fonksiyonu;**

$$K(x_i, x) = x_i^T x \quad (3.141)$$

Bu çekirdek işlevi giriş verisinin doğrusal olarak ayrılabilen durumlarında kullanılmaktadır.

- **Çok terimli çekirdek fonksiyonu;**

$$K(x_i, x) = (x_i^T x + 1)^p \quad (3.142)$$


verilen eşitlikte p çekirdek derecesini temsil etmektedir.

- **Radyal tabanlı (RTF) çekirdek fonksiyonu;**

$$K(x_i, x) = \exp(-\gamma \|x_i - x\|^2) \quad (3.143)$$

verilen eşitlikte γ yarıçapı kontrol eden pozitif değerli parametreyi temsil etmektedir.

Doğrusal olmayan bir DVM sınıflandırıcısının ağ yapısı aşağıda Şekil 3.21’de verilmektedir.



Şekil 3.21. DVM Ağ yapısı (Vapnik, 1998)

3.5.3. Sınıflandırma Başarımının Ölçülmesi

Bu çalışmada tanı sisteminin başarımını değerlendirmek için karşılaştırma matrisi kullanılmıştır. Karşılaştırma matrisi aşağıda Çizelge 3.5’te verilmektedir (Fawcett, 2006).

Çizelge 3.5. Karşılaştırma matrisi

		Karşılaştırma matrisi	
		Gerçek Sonuçlar	
		Pozitif	Negatif
Uygulama Sonuçları	Pozitif	a (GP)	b (YP)
	Negatif	c (YN)	d (GN)

a (Gerçek Pozitif): Gerçek hastalara tanı sisteminin de hasta dediği olguları temsil etmektedir.

c (Yanlış Negatif): Gerçekte hasta olup tanı sisteminin hatalı olarak sağlam dediği olguları temsil etmektedir.

b (Yanlış Pozitif): Gerçekte sağlam oldukları halde tanı sistemin hatalı olarak hasta dediği olguları temsil etmektedir.

d (Gerçek Negatif): Gerçekte sağlam olan tanılar için tanı sisteminin de sağlam dediği olguları temsil etmektedir.

Yukarıdaki ölçütler kullanılarak aşağıda hesaplanan değerler tanı sisteminin sonuçlarını değerlendirmede başarımlar olarak kullanılırlar.

- 1) Duyarlılık (Sensitivity): Testin, gerçek hastalar içinden hastaları ayırma yeteneğidir.

$$\text{Duyarlılık} = \frac{a}{a + c} \times 100 = \frac{GP}{GP + YN} \times 100 \quad (3.144)$$

- 2) Kesinlik (Specificity) testin, gerçek sağlamlar içinden sağlamları ayırma yeteneğidir.

$$\text{Kesinlik} = \frac{d}{b + d} \times 100 = \frac{GN}{GN + YP} \times 100 \quad (3.145)$$

- 3) Doğruluk (Accuracy): Gerçekte testin hasta ve sağlam olarak toplam doğru tanı oranına doğruluk denir.

$$\text{Doğruluk} = \frac{(a + d)}{(a + b + c + d)} \times 100 = \frac{(GP + GN)}{(GP + YP + YN + GN)} \times 100 \quad (3.146)$$

4. BULGULAR

Bu bölüm, tez çalışmasının temelini oluşturmaktadır. Tez çalışmasının bu bölümünde mamogramlardaki anormallikleri (mikrokalsifikasyonları) tespit etmek ve sınıflandırmak için tasarlanan bilgisayar destekli teşhis sisteminin sonuçları verilmiştir. İlk olarak çalışmada kullanılan mamogram veri tabanı hakkında bilgi verilmiştir. İkinci bölümde, mamogramları iyileştirmek için kullanılan çoklu ölçekli morfoloji tekniği mamogramlara uygulanmıştır ve sonuçları sunulmuştur. Üçüncü bölümde, iyileştirilmiş mamogram görüntülerine Niblack yerel eşikleme yöntemi uygulanarak mamogramlar bölümlenmiştir. Özellik çıkarımı aşamasında mamogramlardan güvenilir ve belirleyici özellikler elde edilmiştir. Özellik seçimi ve boyut azaltımı aşamasında temel bileşenler analizi yöntemi kullanılarak boyut azaltımı gerçekleştirilmiştir. Sınıflandırma aşamasında çok katmanlı yapay sinir ağı (ÇKYSA) ve destek vektör makineleri (DVM) kullanılmıştır. Sınıflandırıcıların başarımını değerlendirmek için karşılaştırma matrisinden yararlanılmıştır. Ön işleme, bölümleme, özellik çıkarımı ve sınıflandırma (çok katmanlı yapay sinir ağı için) uygulamaları Matlab programı ve DVM uygulamaları matlab için oluşturulan statistical pattern recognition toolbox yardımıyla gerçekleştirilmiştir.


4.1. Mamografi Veritabanı

Mamogram görüntüleri, MIAS (Mammographic Image Analysis Society Mini Mammographic Database) veri tabanından alınmıştır. Veri tabanındaki görüntüler 50µm x 50 µm piksel çözünürlüğüne sahiptir. Her görüntü 1024x1024 piksel boyutunda ve her piksel 8 bit ile temsil edilmektedir. Veri tabanında 161 hastanın sağ ve sol meme görüntülerini içeren 322 görüntü vardır. Bunlardan 208'i normal, 63'ü iyi huylu ve 51'i kötü huylu görüntüdür (<http://peipa.essex.ac.uk/info/mias.html>, 05.07.2010).


4.2. Ön İşleme

Veri tabanından alınan mamogram görüntüleri işlem karmaşıklığını azaltmak için anormallikleri (mikrokalsifikasyonları) kapsayacak şekilde kırılarak, 300x300 piksel boyutlu ilgilenilen parçalar elde edilmiştir. Veri tabanından alınan ham

görüntüler Şekil 4.1’de, ilgilenilen parçaları içeren görüntüler ise Şekil 4.2’de verilmiştir.



Şekil 4.1. 1024x1024 piksel boyutlu mamogram görüntüleri




Şekil 4.2. 300x300 piksel boyutlu ilgilenilen parçaları içeren kırpılmış mamogram görüntüleri


Bölüm 3’te anlatıldığı gibi son yıllarda geliştirilen ve x ışını görüntülere uygulanan, çoklu ölçekli morfoloji tekniği kullanılarak mamogramlar yerel olarak iyileştirilmiştir. Böylece mamogramlarda bulunan anormalliklerin (mikrokalsifikasyonların) kontrastı artırılmıştır. Kullanılan yöntem, farklı ölçek ve farklı yapı elemanlarıyla mamogram görüntülerine uygulanmıştır.

Ölçek seviyesi $k=4, 6$ ve kare biçimli, boyutu 5, 7 piksel olarak seçilen yapı elemanı kullanarak iyileştirilmiş görüntüler Şekil 4.3’te ve Şekil 4.4’te verilmiştir.


Ölçek seviyesi $k=4, 6$ ve disk biçimli, yarıçapı 3, 6 piksel olarak seçilen yapı elemanı kullanarak iyileştirilmiş görüntüler Şekil 4.5'te ve Şekil 4.6'da verilmiştir.




Şekil 4.3. (a) mdb209 mamogram görüntüsü, (b) $k=4$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü




(a)




(b)



(c)




(d)




(e)


Şekil 4.4. (a) mdb219 mamogram görüntüsü, (b) $k=4$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve kare biçimli, boyutu 5 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve kare biçimli, boyutu 7 piksel olan yapı elemanı ile iyileştirilmiş görüntü




(a)




(b)



(c)




(d)




(e)


Şekil 4.5. (a) mdb209 mamogram görüntüsü, (b) $k=4$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü




(a)




(b)



(c)



(d)




(e)

Şekil 4.6. (a) mdb219 mamogram görüntüsü, (b) $k=4$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (c) $k=4$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (d) $k=6$ ve disk biçimli, yarıçapı 3 piksel olan yapı elemanı ile iyileştirilmiş görüntü, (e) $k=6$ ve disk biçimli, yarıçapı 6 piksel olan yapı elemanı ile iyileştirilmiş görüntü

Uygulanan morfolojik yöntemde yapı elemanının boyutu önemlidir. Çünkü yöntem uygulandığında yapı elemanının boyutundan daha küçük boyuttaki özellikler korunur; ancak yapı elemanından daha büyük boyuttaki özellikler atılır. Mamogramlardaki mikrokalsifikasyonların boyutları çok değişken olduğu için yapı elemanının boyutu bütün mikrokalsifikasyonları kapsayacak şekilde seçilmelidir. Gerçekleştirilen uygulamalar sonucunda ölçek sayısı $k=4$, disk biçimli, yarıçapı 6 olan yapı elemanı seçildiğinde ve görüntülere uygulandığında iyileştirme sonuçlarının daha iyi olduğu tespit edilmiştir.

4.3. Bölümleme


Bu bölümde iyileştirilmiş mamogramlarda mikrokalsifikasyonları bölümlemek için Niblack yerel eşikleme yöntemi kullanılmıştır. Kullanılan yöntem, farklı pencere boyutu w ve k eşik katsayısı seçilerek iyileştirilmiş mamogram görüntülerine uygulanmıştır. Gerçekleştirilen uygulamalar sonucunda en iyi şekilde mamogram görüntülerini bölümlemek için pencere boyutu $w = 25$ piksel ve $k=1.5$ olarak seçilmiştir. Yerel eşikleme yöntemi mamogramlara uygulanmıştır. Uygulama sonuçları Şekil 4.7, Şekil 4.8 ve Şekil 4.9’da verilmiştir.




(a)

(b)

Şekil 4.7. (a) İyileştirilmiş mamogram görüntüsü (mdb209), (b) Bölümlenmiş mamogram görüntüsü



Şekil 4.8. İyileştirilmiş mamogram görüntüsü (mdb219), b) Bölümlenmiş mamogram görüntüsü



Şekil 4.9. İyileştirilmiş mamogram görüntüsü (mdb233), b) Bölümlenmiş mamogram görüntüsü

4.4. Özellik Çıkarımı

Bu bölümde mamogram görüntülerini sınıflandırmak için mamogram görüntülerinden çeşitli özellikler çıkarılmıştır. İyileştirilmiş mamogram görüntülerinden entropi, ortalama, standart sapma, homojenlik, yamukluk ve basıklık özellikleri hesaplanmıştır. Daha sonra iyileştirilmiş mamogram görüntülerinden $d=1$ ve $\theta=0^\circ, 45^\circ, 90^\circ, 135^\circ$ yönelme açıları için dört farklı gri seviye eş oluşum matrisi (GSEOM) hesaplanmıştır. Hesaplanan her bir eş oluşum matrisi için kontrast, korelasyon, entropi, homojenlik, fark varyansı, fark entropi, normalize ters fark momenti, enerji, varyans, toplam ortalama, toplam varyans, toplam entropi ve korelasyon bilgisinin ölçümü 1,2

özellikleri hesaplanmıştır. Normal ve mikrokalsifikasyon içeren mamogram görüntüleri için hesaplanan özellikler Çizelge 4.1, Çizelge 4.2, Çizelge 4.3, Çizelge 4.4'te verilmiştir.

Çizelge 4.1. Normal mamogram görüntülerine ait uzaysal düzlem özellikleri

	Entropi	Ortalama	Standart Sapma	Homojenlik	Yamukluk	Basıklık
mdb006	6.18483	145.93129	17.86160	0.01687	0.08134	3.87291
mdb009	6.10355	152.78268	16.78616	0.01701	0.23548	3.50139
mdb011	6.00817	167.23069	15.79099	0.01784	0.32305	3.29681
mdb026	6.69511	128.28883	25.41929	0.01132	0.36788	3.33484

Çizelge 4.2. Mikrokalsifikasyon içeren mamogram görüntülerine ait uzaysal düzlem özellikleri

	Entropi	Ortalama	Standart Sapma	Homojenlik	Yamukluk	Basıklık
mdb209	7.05455	151.62578	34.31380	0.00814	0.24476	2.12730
mdb211	6.53818	154.24480	57.23671	0.01838	-1.74690	5.50284
mdb213	6.84908	135.29261	45.77052	0.01211	-1.42435	5.40594
mdb218	6.79688	167.96008	29.84534	0.01077	-0.95237	6.18157

Çizelge 4.3. Normal mamogram görüntülerine ait $d=1$, $\theta=0^\circ$ için GSEOM özellikleri

	Kontrast	Korelasyon	Entropi	Homojenlik	Fark Varyansı	Fark Entropi	Normalize Ters Fark Momenti
mdb006	116.26294	0.81680	7.64907	0.01687	116.26294	2.89508	0.99668
mdb009	106.61003	0.81027	7.51026	0.01701	106.61003	2.79878	0.99636
mdb011	117.28235	0.76476	7.45045	0.01784	117.28235	2.82385	0.99459
mdb026	145.09162	0.88759	8.24828	0.01132	145.09162	3.09661	0.99652

Çizelge 4.3. (devamı) Normal mamogram görüntülerine ait $d=1$, $\theta=0^\circ$ için GSEOM özellikleri

	Enerji	Varyans	Toplam Ortalama	Toplam Varyans	Toplam Entropi	Korelasyon Bilgisinin Ölçümü 1	Korelasyon Bilgisinin Ölçümü 2
mdb006	0.00095	9928.427	195.98069	37655.775	4.92301	-0.21446	0.91708
mdb009	0.00102	4871.399	135.56239	18097.423	4.87092	-0.22405	0.92183
mdb011	0.00106	3639.439	116.48041	13353.960	4.79275	-0.21088	0.90958
mdb026	0.00042	6478.221	152.65030	24147.660	5.30163	-0.22230	0.93434

Çizelge 4.4. Mikrokalsifikasyon içeren mamogram görüntülerine ait $d=1$, $\theta=0^\circ$ için GSEOM özellikleri

	Kontrast	Korelasyon	Entropi	Homojenlik	Fark Varyansı	Fark Entropi	Normalize Ters Fark Momenti
mdb209	143.66168	0.93900	8.51027	0.21672	143.66168	3.12004	0.99693
mdb211	174.11069	0.97328	7.76640	0.29932	174.11069	2.98473	0.99752
mdb213	199.12527	0.95187	8.13623	0.26478	199.12527	3.06895	0.99723
mdb218	123.29565	0.93029	8.18904	0.23083	123.29565	2.99981	0.99814

Çizelge 4.4. (devamı) Mikrokalsifikasyon içeren mamogram görüntülerine ait $d=1$, $\theta=0^\circ$ için GSEOM özellikleri

	Enerji	Varyans	Toplam Ortalama	Toplam Varyans	Toplam Entropi	Korelasyon Bilgisinin Ölçümü 1	Korelasyon Bilgisinin Ölçümü 2
mdb209	0.00029	13657.295	223.32795	51989.534	5.55836	-0.25965	0.95973
mdb211	0.00972	27468.505	310.88427	106272.44	5.15131	-0.28702	0.96237
mdb213	0.00391	20739.717	273.23098	79800.303	5.39035	-0.28540	0.96628
mdb218	0.00046	29469.705	338.10205	114119.42	5.37392	-0.26090	0.95627

Şekil tabanlı özellikler, bölümlenmiş mamogramlardan elde edilmiştir. Bölümlenmiş mamogramda, her bir olası mikrokalsifikasyonun alanı, büyük eksen uzunluğu, küçük eksen uzunluğu, dışmerkezliliği, yönelmesi, yoğunluğu hesaplanmıştır. Bölümlenmiş mamogramda hesaplanan her bir özelliğin ortalama değeri ve standart sapması hesaplanmıştır. Sonuçta her bir görüntü için 13 tane şekil tabanlı özellik hesaplanmıştır. İyi huylu ve kötü huylu mikrokalsifikasyonlara ait çıkarılan özellikler Çizelge 4.5, Çizelge 4.6, Çizelge 4.7, ve Çizelge 4.8’de verilmiştir.

Çizelge 4.5. İyi huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin ortalaması

	Ortalama Alan	Maksimum Alan	Ortalama Büyük Eksen Uzunluğu	Ortalama Küçük Eksen Uzunluğu	Ortalama Dışmerkezlilik	Ortalama Yönelme	Ortalama Yoğunluk
mdb218	11.10526	43.00000	5.71461	3.07838	0.73046	-20.4928	1.20403
mdb219	15.66667	39.00000	7.13085	3.12367	0.31968	2.28326	1.33551

Çizelge 4.6. İyi huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin standart sapması

	Std Sapma Alan	Std Sapma Büyük Eksen Uzunluğu	Std Sapma Küçük Eksen Uzunluğu	Std Sapma Dışmerkezlilik	Std Sapma Yönelme	Std Sapma Yoğunluk
mdb218	10.82638	3.25582	1.26935	0.22112	52.16250	0.87271
mdb219	20.20726	8.35100	1.41035	0.55370	3.95472	1.03089

Çizelge 4.7. Kötü huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin ortalaması

	Ortalama Alan	Maksimum Alan	Ortalama Büyük Eksen Uzunluğu	Ortalama Küçük Eksen Uzunluğu	Ortalama Dışmerkezlilik	Ortalama Yönelme	Ortalama Yoğunluk
mdb209	10.57692	83.00000	5.19311	2.61669	0.82141	11.55461	0.93840
mdb211	12.66667	51.00000	6.33692	3.06516	0.83712	20.77421	1.30554

Çizelge 4.8. Kötü huylu mikrokalsifikasyon içeren mamogram görüntülerinin şekil özelliklerinin standart sapması

	Std Sapma Alan	Std Sapma Büyük Eksen Uzunluğu	Std Sapma Küçük Eksen Uzunluğu	Std Sapma Dışmerkezlilik	Std Sapma Yönelme	Std Sapma Yoğunluk
mdb209	16.60162	3.86036	1.63822	0.08747	56.68118	0.88007
mdb211	11.55955	3.51638	1.46360	0.09686	37.46458	1.24529

4.5. Özellik Seçimi ve Boyut Azaltımı

Bu çalışmada özellik seçimi ve boyut azaltımı için temel bileşenler analizi (TBA) yöntemi kullanılmıştır. Temel bileşenler analizinde, ilişkili değişkenler içeren veri kümesi doğrusal olarak ayrıştırılarak temel bileşenler olarak adlandırılan yeni değişkenler kümesine dönüştürülmüştür. Veri kümesi matrisi kullanılarak kovaryans matrisi hesaplanmıştır. Daha sonra bu kovaryans matrisin, özdeğerleri ve özvektörleri (temel bileşenler) hesaplanmıştır. Hangi özdeğerlerin seçileceğini belirlemek için özdeğerler büyükten küçüğe sıralanmıştır. Kaç tane özdeğerin seçileceği varyansın birikimli yüzdesi yardımıyla belirlenmiştir.

Bu çalışmada mamogramları sınıflandırmak amacıyla iki farklı özellik kümesi oluşturulmuştur.

1.Özellik kümesi;

Birinci özellik kümesi, iyileştirilmiş mamogram görüntülerinden hesaplanan 6 uzaysal düzlem özelliği ve gri seviye eş oluşum matrisinden hesaplanan 14 dokusal özellik olmak üzere 20 özellikten oluşmaktadır. Birinci özellik kümesinde, boyut azaltımı gerçekleştirmek için temel bileşenler analizi yöntemi uygulanmıştır.

Özellik kümesinin matrisi kullanılarak 20x20 boyutlu kovaryans matris hesaplanmıştır. Daha sonra bu kovaryans matrisin özdeğerleri (20x1 boyutlu) ve özvektörleri (temel bileşenler) (20x20 boyutlu) hesaplanmıştır. Hangi özdeğerlerin seçileceğini belirlemek için özdeğerler büyükten küçüğe sıralanmıştır. Kovaryans matrisin sıralanmış özdeğer matrisi aşağıda verilmiştir.

$$V=[1,825; 0,597; 0,219; 0,211; 0,097; 0,062; 0,038; 0,018; 0,010; 0,009; 0,005; 0,001; 0,0009; 0,0004; 0,0003; 0,0001; 8,79e-06; 1,70e-06; 6,28e-08; 3,24e-18]$$

Kaç tane özdeğerin seçileceği varyansın birikimli yüzdesi yardımıyla hesaplanmıştır. İlk 7 özdeğerin birikimli yüzdesi %98,5 olarak hesaplanmıştır. Bu amaçla özdeğer matrisinde ilk 7 özdeğere ait temel bileşenler (özvektörler) seçilerek özvektör matrisi yeniden düzenlenmiştir. Bu matris dönüşüm matrisi olarak kullanılarak dönüştürülmüş özellik kümesi elde edilmiştir. Böylece 20 özellik içeren 1. özellik kümesi boyut azaltımı ile 7 özellik içeren özellik kümesine dönüştürülmüştür.

2.Özellik kümesi;

İkinci özellik kümesi, iyileştirilmiş mamogram görüntülerinden hesaplanan 6 uzaysal düzlem özelliği ve bölümlenmiş mamogram görüntülerinden hesaplanan 13 şekil tabanlı özellik olmak üzere 19 özellikten oluşmaktadır. İkinci özellik kümesinde, boyut azaltımı gerçekleştirmek için temel bileşenler analizi yöntemi uygulanmıştır.

Özellik kümesinin matrisi kullanılarak 19x19 boyutlu kovaryans matrisi hesaplanmıştır. Daha sonra bu kovaryans matrisin özdeğerleri (19x1 boyutlu) ve özvektörleri (temel bileşenler) (19x19 boyutlu) hesaplanmıştır. Hangi özdeğerlerin seçileceğini belirlemek için özdeğerler büyükten küçüğe sıralanmıştır. Kovaryans matrisin sıralanmış özdeğer matrisi aşağıda verilmiştir.


$$V=[1.6863; 0.9773; 0.5194; 0.4088; 0.3608; 0.2477; 0.2237; 0.1520; 0.1052; 0.0707; 0.0452; 0.0160; 0.0093; 0.0058; 0.0046; 0.0034; 0.0018; 0.0006; 0.0001]$$

Kaç tane özdeğerin seçileceği varyansın birikimli yüzdesi yardımıyla hesaplanmıştır. İlk 9 özdeğerin birikimli yüzdesi %96,74 olarak hesaplanmıştır. Bu amaçla özdeğer matrisinde ilk 9 özdeğere ait temel bileşenler (özvektörler) seçilerek özvektör matrisi yeniden düzenlenmiştir. Bu matris, dönüşüm matrisi olarak kullanılarak dönüştürülmüş özellik kümesi elde edilmiştir. Böylece 19 özellik içeren özellik kümesi boyut azaltımı ile 9 özellik içeren özellik kümesine dönüştürülmüştür.

4.6. Sınıflandırma

Bu çalışmanın sınıflandırma aşamasında, çok katmanlı yapay sinir ağı ve destek vektör makineleri kullanılmıştır.

Mamogramlar, öncelikle normal ve anormal olarak sınıflandırılmışlardır. Daha sonra mikrokalsifikasyon içeren mamogramlar, iyi huylu ve kötü huylu olarak sınıflandırılmışlardır. Sınıflandırmanın, öğrenme ve test aşamaları için 66 normal mamogram görüntüsü 26 mikrokalsifikasyon kümesi içeren görüntü (11'i iyi huylu, 15'i kötü huylu) kullanılmıştır. Sınıflandırma dört uygulama olarak gerçekleştirilmiştir. Sınıflandırma sürecinin genel öbek çizgesi Şekil 4.10'da verilmiştir.



Şekil 4.10. Sınıflandırma sürecinin öbek çizgesi

1. Sınıflandırma uygulaması;

Birinci uygulamada normal mamogram görüntüleri ve mikrokalsifikasyon içeren mamogram görüntüleri normal ve anormal olarak sınıflandırılmıştır. Sınıflandırma için 1. özellik kümesi kullanılmıştır. 1. özellik kümesi, 6 tane uzaysal düzlem özelliği ve gri seviye eş oluşum matrisinden hesaplanan 14 tane özellik olmak üzere 20 özellik içermektedir. Bu uygulamada, eğitim aşamasında 40 normal mamogram görüntüsü ve 12 tane mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır. Test aşamasında ise 26 normal mamogram görüntüsü ve 8 mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır.


a) ÇKYSA uygulaması;

20 özellik içeren özellik kümesi öncelikle çok katmanlı yapay sinir ağına uygulanmıştır ve sınıflandırma gerçekleştirilmiştir. Sınıflandırıcının giriş katmanında özellik vektörünün boyutu ile aynı sayıda sinir hücresi kullanılmıştır. Ara katman olarak bir ara katman tercih edilmiştir ve çeşitli denemelerden sonra en uygun sinir hücresi sayısı belirlenmiştir. Çıkış katmanında ise tek sinir hücresi kullanılmıştır. Normal görüntü için çıkış sıfır (0), anormal görüntü için çıkış (1) olarak atanmıştır. Çok katmanlı yapay sinir ağının ağ yapısı ile ilgili parametreler Çizelge 4.9’da verilmiştir.

Çizelge 4.9. 1. uygulama için ÇKYSA’nın ağ yapısı bilgileri

1. Uygulama için Çok Katmanlı Yapay Sinir Ağının Yapısı	
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş katmanı: 20 Gizli katman : 30 Çıkış katmanı: 1
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Aktivasyon fonksiyonları	Tanjant sigmoid
Ağ parametreleri	
Öğrenme kuralı	Hata geri yayılım
Öğrenme oranı	0.6
Toplam karesel hata	1e-10

ÇKYSA’nın öğrenme sürecinin hata grafiği Şekil 4.11’de verilmiştir.



Şekil 4.11. 1. uygulamaya ait ÇKYSA’nın öğrenme hata grafiği

ÇKYSA'nın başarımını değerlendirmek için oluşturulan karşılaştırma matrisi Çizelge 4.10'da verilmiştir.

Çizelge 4.10. 1. uygulama için ÇKYSA'nın karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (anormal)	Negatif (normal)
Uygulama Sonuçları	Pozitif (anormal)	6	5
	Negatif (normal)	2	21

ÇKYSA sınıflandırıcısı için, başarımlar değerlendirildiğinde sonucunda duyarlılık %75, kesinlik %80,77 ve doğruluk %79,4 olarak elde edilmiştir.

b) DVM uygulaması;

20 özellik içeren özellik kümesi öncelikle destek vektör makinesine uygulanmıştır. Yapılan uygulamalar sonucunda DVM için çekirdek olarak çokterimli çekirdek ve derecesi 9 olarak seçilmiştir. C parametresi ise 10 olarak seçilmiştir.

DVM'nin başarımını değerlendirmek için oluşturulan karşılaştırma matrisi Çizelge 4.11'de verilmiştir.

Çizelge 4.11. 1. uygulama için DVM'nin karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (anormal)	Negatif (normal)
Uygulama Sonuçları	Pozitif (anormal)	6	2
	Negatif (normal)	2	24

Sınıflandırma sisteminin başarımlar değerlendirildiğinde sonucunda duyarlılık %75, kesinlik %92,3 ve doğruluk %88,2 olarak elde edilmiştir.

1. uygulamada kullanılan sınıflandırıcıların başarımlar sonuçları Çizelge 4.12'de verilmiştir.

Çizelge 4.12. 1. uygulamada ÇKYSA ve DVM için sınıflandırma başarımları sonuçları

Sınıflandırıcı	Özellik sayısı	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
ÇKYSA	20	75	80,77	79,4
DVM	20	75	92,3	88,2

Çizelge 4.12'den mamogram görüntülerini boyut azaltımı gerçekleştirmeden normal ve anormal olarak sınıflandırmada, DVM'nin başarımının daha yüksek olduğu görülmektedir.

2. Sınıflandırma uygulaması;

İkinci uygulamada, normal mamogramlar ve mikrokalsifikasyon içeren mamogram görüntüleri normal ve anormal olarak sınıflandırılmıştır. Ancak 1. özellik kümesine TBA uygulanarak boyut azaltımı gerçekleştirilmiştir. TBA sonucunda elde edilen 7 özellik içeren özellik kümesi kullanılarak sınıflandırma gerçekleştirilmiştir. Bu uygulamada, eğitim aşamasında 40 normal mamogram görüntüsü ve 12 tane mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır. Test aşamasında ise 26 normal mamogram görüntüsü ve 8 mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır.


a) ÇKYSA uygulaması;

Boyut azaltımı sonucunda elde edilen 7 özellik içeren özellik kümesi öncelikle çok katmanlı yapay sinir ağına uygulanmıştır ve sınıflandırma gerçekleştirilmiştir. Sınıflandırıcının giriş katmanında özellik vektörünün boyutu ile aynı sayıda sinir hücresi kullanılmıştır. Ara katman olarak bir ara katman tercih edilmiştir ve çeşitli denemelerden sonra en uygun sinir hücresi sayısı belirlenmiştir. Çıkış katmanında ise tek sinir hücresi kullanılmıştır. Normal görüntü için çıkış sıfır (0), anormal görüntü için çıkış (1) olarak atanmıştır. Çok katmanlı yapay sinir ağının ağ yapısı ile ilgili parametreler Çizelge 4.13'de verilmiştir.

Çizelge 4.13. 2. uygulama için ÇKYSA'nın ağ yapısı bilgileri
2. Uygulama için Çok Katmanlı Yapay Sinir Ağının Yapısı

Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş katmanı: 7 Gizli katman : 11 Çıkış katmanı: 1
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Aktivasyon fonksiyonları	Tanjant sigmoid
Ağ parametreleri	
Öğrenme kuralı	Hata geri yayılım
Öğrenme oranı	0.4
Toplam karesel hata	1e-12

Öğrenme sürecinin hata grafiği aşağıda Şekil 4.12'de verilmiştir



Şekil 4.12. 2. uygulamaya ait ÇKYSA'nın öğrenme hata grafiği

ÇKYSA'nın başarımını değerlendirmek için oluşturulan karşılaştırma matrisi Çizelge 4.14'de verilmiştir.

Çizelge 4.14. 2. uygulama için ÇKYSA'nın karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (anormal)	Negatif (normal)
Uygulama Sonuçları	Pozitif (anormal)	7	2
	Negatif (normal)	1	24

Sınıflandırma sisteminin başarımlarını değerlendirmesi sonucunda duyarlılık %87,5, kesinlik %92,3 ve doğruluk %91,1 olarak elde edilmiştir.

b) DVM uygulaması;

Boyut azaltımı sonucunda elde edilen 7 özellik içeren özellik kümesi destek vektör makinesine uygulanmıştır ve sınıflandırma gerçekleştirilmiştir. Yapılan uygulamalar sonucunda DVM için çekirdek olarak, radyal tabanlı çekirdek ve çekirdek genişliği 3,5 olarak seçilmiştir. C parametresi ise 10 olarak seçilmiştir.

DVM'nin başarımlarını değerlendirmek için oluşturulan karşılaştırma matrisi Çizelge 4.15'de verilmiştir.

Çizelge 4.15. 2. uygulama için DVM'nin karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (anormal)	Negatif (normal)
Uygulama Sonuçları	Pozitif (anormal)	7	1
	Negatif (normal)	1	25

Sınıflandırma sisteminin başarımlarını değerlendirmesi sonucunda duyarlılık %87,5, kesinlik %96,1 ve doğruluk %94,1 olarak elde edilmiştir.

2. uygulamada kullanılan sınıflandırıcıların başarımlarını sonuçları aşağıda Çizelge 4.16'da verilmiştir.

Çizelge 4.16. 2. uygulamada ÇKYSA ve DVM için sınıflandırma başarımlarını sonuçları

Sınıflandırıcı	TBA ile azaltılan özellik sayısı	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
ÇKYSA	7	87,5	92,3	91,1
DVM	7	87,5	96,1	94,1

Çizelge 4.16'dan mamogram görüntülerini boyut azaltımı gerçekleştirildiğinde, normal ve anormal olarak sınıflandırmada, DVM'nin başarımlarının daha yüksek olduğu görülmektedir. Aynı zamanda boyut azaltımının her iki sınıflandırıcının başarımlarını artırdığı görülmektedir.

3. Sınıflandırma uygulaması;

Sınıflandırmanın ikinci aşamasında mikrokalsifikasyon içeren mamogramlar, iyi huylu ve kötü huylu olarak sınıflandırılmıştır. Sınıflandırma için 2. özellik kümesi kullanılmıştır. 2. özellik kümesi, 6 tane uzaysal düzlem özelliği ve 13 tane şekil tabanlı özellik olmak üzere 19 özellik içermektedir. Bu uygulamada, eğitim aşamasında, 6 iyi huylu mikrokalsifikasyon içeren mamogram görüntüsü ve 8 kötü huylu mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır. Test aşamasında ise 5 iyi huylu mikrokalsifikasyon içeren mamogram görüntüsü ve 7 kötü huylu mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır.


a) ÇKYSA uygulaması;

19 özellik içeren özellik kümesi öncelikle çok katmanlı yapay sinir ağına uygulanmıştır ve sınıflandırma gerçekleştirilmiştir. Sınıflandırıcının giriş katmanında özellik vektörünün boyutu ile aynı sayıda sinir hücresi kullanılmıştır. Ara katman olarak bir ara katman tercih edilmiştir ve çeşitli denemelerden sonra en uygun sinir hücresi sayısı belirlenmiştir. Çıkış katmanında ise tek sinir hücresi kullanılmıştır. İyi huylu mikrokalsifikasyon içeren mamogram görüntüleri için çıkış sıfır (0), kötü huylu mikrokalsifikasyon içeren mamogram görüntüleri anormal görüntü için çıkış (1) olarak atanmıştır. Çok katmanlı yapay sinir ağının ağ yapısı ile ilgili parametreler Çizelge 4.17’de verilmiştir.

Çizelge 4.17. 3. uygulama için ÇKYSA’nın ağ yapısı bilgileri

3. Uygulama için Çok Katmanlı Yapay Sinir Ağının Yapısı	
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş katmanı: 19 Gizli katman : 11 Çıkış katmanı: 1
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Aktivasyon fonksiyonları	Logaritmik sigmoid
Ağ parametreleri	
Öğrenme kuralı	Hata geri yayılım
Öğrenme oranı	0.4
Toplam karesel hata	1e-10

Öğrenme sürecinin hata grafiği Şekil 4.13’de verilmiştir.



Şekil 4.13. 3. uygulamaya ait ÇKYSA’nın öğrenme hata grafiği

ÇKYSA’nın başarımını değerlendirmek için oluşturulan karşılaştırma matrisi Çizelge 4.18’de verilmiştir.

Çizelge 4.18. 3. uygulama için ÇKYSA’nın karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (kötü huylu)	Negatif (iyi huylu)
Uygulama Sonuçları	Pozitif (kötü huylu)	6	2
	Negatif (iyi huylu)	1	3

Sınıflandırma sisteminin başarımlarını değerlendirmesi sonucunda duyarlılık %85,7 kesinlik %60 ve doğruluk %75 olarak elde edilmiştir.

b) DVM Uygulaması;

19 özellik içeren özellik kümesi öncelikle destek vektör makinesine uygulanmıştır. Yapılan uygulamalar sonucunda DVM için çekirdek olarak çokterimli çekirdek ve derecesi 7 olarak seçilmiştir. C parametresi ise 10 olarak seçilmiştir.

DVM'nin başarımını değerlendirmek için karşılaştırma matrisi Çizelge 4.19'da verilmiştir.

Çizelge 4.19. 3. uygulama için DVM'nin karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (kötü huylu)	Negatif (iyi huylu)
Uygulama Sonuçları	Pozitif (kötü huylu)	6	2
	Negatif (iyi huylu)	1	3

Sınıflandırma sisteminin başarımlarını değerlendirmesi sonucunda duyarlılık %85,7, kesinlik %60 ve doğruluk %75 olarak elde edilmiştir.

3. uygulamada kullanılan sınıflandırıcıların başarımlarını sonuçları aşağıda Çizelge 4.20'de verilmiştir.

Çizelge 4.20. 3. uygulamada ÇKYSA ve DVM için sınıflandırma başarımlarını sonuçları

Sınıflandırıcı	Özellik sayısı	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
ÇKYSA	19	85,7	60	75
DVM	19	85,7	60	75

Çizelge 4.20'den mikrokalsifikasyon içeren mamogram görüntülerini boyut azaltımı gerçekleştirilmeden iyi huylu ve kötü huylu olarak sınıflandırmada, her iki sınıflandırıcının başarımlarının aynı olduğu görülmektedir.

4. Sınıflandırma uygulaması;

Dördüncü uygulamada; mikrokalsifikasyon içeren mamogramlar, iyi huylu ve kötü huylu olarak sınıflandırılmıştır. Ancak 2. özellik kümesine TBA uygulanarak boyut azaltımı gerçekleştirilmiştir. TBA sonucunda elde edilen 9 özellik içeren özellik kümesi kullanılarak sınıflandırma gerçekleştirilmiştir. Bu uygulamada, eğitim aşamasında, 6 iyi huylu mikrokalsifikasyon içeren mamogram görüntüsü ve 8 kötü huylu mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır. Test aşamasında ise 5 iyi huylu mikrokalsifikasyon içeren mamogram görüntüsü ve 7 kötü huylu mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır.


a) ÇKYSA uygulaması;

Boyut azaltımı sonucunda elde edilen 9 özellik içeren özellik kümesi öncelikle çok katmanlı yapay sinir ağına uygulanmıştır ve sınıflandırma gerçekleştirilmiştir. Sınıflandırıcının giriş katmanında özellik vektörünün boyutu ile aynı sayıda sinir hücresi kullanılmıştır. Ara katman olarak bir ara katman tercih edilmiştir ve çeşitli denemelerden sonra en uygun sinir hücresi sayısı belirlenmiştir. Çıkış katmanında ise tek sinir hücresi kullanılmıştır. Normal görüntü için çıkış sıfır (0), anormal görüntü için çıkış (1) olarak atanmıştır. Çok katmanlı yapay sinir ağının ağ yapısı ile ilgili parametreler Çizelge 4.21’de verilmiştir.

Çizelge 4.21. 4. uygulama için ÇKYSA’nın ağ yapısı bilgileri
4. Uygulama için Çok Katmanlı Yapay Sinir Ağının Yapısı

Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş katmanı: 9 Gizli katman : 15 Çıkış katmanı: 1
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Aktivasyon fonksiyonları	Logaritmik sigmoid
Ağ parametreleri	
Öğrenme kuralı	Hata geri yayılım
Öğrenme oranı	0.4
Toplam karesel hata	1e-12

Öğrenme sürecinin hata grafiği Şekil 4.14’de verilmiştir.



Şekil 4.14. 4. uygulamaya ait ÇKYSA’nın öğrenme hata grafiği

ÇKYSA'nın başarımını değerlendirmek için oluşturulan karşılaştırma matrisi Çizelge 4.22'de verilmiştir.

Çizelge 4.22. 4. uygulama için ÇKYSA'nın karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (kötü huylu)	Negatif (iyi huylu)
Uygulama Sonuçları	Pozitif (kötü huylu)	7	1
	Negatif (iyi huylu)	0	4

Sınıflandırma sisteminin başarım değerlendirmesi sonucunda duyarlılık %100, kesinlik %80 ve doğruluk %91,7 olarak elde edilmiştir.

b) DVM Uygulaması;

Boyut azaltımı sonucunda elde edilen 9 özellik içeren özellik kümesi destek vektör makinesine uygulanmıştır ve sınıflandırma gerçekleştirilmiştir. Yapılan uygulamalar sonucunda DVM için çekirdek olarak radyal tabanlı çekirdek ve çekirdek genişliği 2,9 olarak seçilmiştir. C parametresi ise 10 olarak seçilmiştir. DVM'nin başarımını değerlendirmek için karşılaştırma matrisi Çizelge 4.23'de verilmiştir.

Çizelge 4.23. 4. uygulama için DVM'nin karşılaştırma matrisi

		Gerçek Sonuçlar	
		Pozitif (kötü huylu)	Negatif (iyi huylu)
Uygulama Sonuçları	Pozitif (kötü huylu)	6	1
	Negatif (iyi huylu)	1	4

Sınıflandırma sisteminin başarım değerlendirmesi sonucunda duyarlılık %85,7, kesinlik %80 ve doğruluk %83,3 olarak elde edilmiştir.

4. uygulamada kullanılan sınıflandırıcıların başarım sonuçları aşağıda Çizelge 4.24'de verilmiştir.

Çizelge 4.24. 4. uygulamada ÇKYSA ve DVM için sınıflandırma başarımları sonuçları

Sınıflandırıcı	TBA ile azaltılan özellik sayısı	Duyarlılık (%)	Kesinlik (%)	Doğruluk (%)
ÇKYSA	9	100	80	91,7
DVM	9	85,7	80	83,3

Çizelge 4.24'ten mikrokalsifikasyon içeren mamogram görüntülerini boyut azaltımı gerçekleştirildiğinde iyi huylu ve kötü huylu olarak sınıflandırmada, ÇKYSA'nın başarımının daha yüksek olduğu görülmektedir. Aynı zamanda boyut azaltımının her iki sınıflandırıcının başarımını artırdığı görülmektedir.

5. SONUÇ VE ÖNERİLER

Mamografide en çok karşılaşılan anormallikler, kümelenmiş mikrokalsifikasyonlar ve kütlelerdir. Özellikle mikrokalsifikasyonlar meme kanserinin erken belirtisidir. Bu da meme kanserinin erken tespitinde önemli bir rol oynamaktadır. Ancak boyutları çok küçük olduğu için radyoloji uzmanları tarafından belirlenmeleri zordur. Yaklaşık olarak meme kanserlerinin %85-90'ı mamografi görüntülerinin incelenmesi ile elde edilirken, %10-15'i görüntüleme sürecindeki teknik problemler nedeniyle radyologlar tarafından gözden kaçırılmaktadır. Kanserlerin belirlenemeyen bu grubu genellikle gözden kaçırılmış olarak ifade edilirler. Bu tez çalışmasında mamogramlardaki anormallikleri (mikrokalsifikasyonları) tespit etmek ve sınıflandırmak amacıyla ön işleme, bölümleme, özellik çıkarımı, özellik seçimi (boyut azaltımı) ve sınıflandırma adımlarını içeren örüntü tanıma tabanlı bir bilgisayar destekli teşhis sistemi tasarlanmıştır.

- **Ön işleme aşamasında**, mamogramlarda bulunan düşük kontrasta sahip mikrokalsifikasyonların kontrastını artırmak için geleneksel iyileştirme yöntemleri yerine son yıllarda geliştirilen yerel tabanlı iyileştirme yöntemi olan çoklu ölçekli morfoloji tekniği, mamogram görüntülerine uygulanmıştır. Böylece mamogramlarda bulunan mikrokalsifikasyonlar yerel olarak iyileştirilmiştir. Farklı ölçek seviyesi, farklı boyutta ve biçimde yapı elemanları kullanılarak iyileştirme yöntemi mamogramlara uygulanmıştır. Uygulama sonuçlarından, yapı elemanının boyutunun ve biçiminin mamogramlarda olası bütün mikrokalsifikasyonları kapsayacak şekilde tespit edilmesi gerektiği gözlenmiştir.
- **Bölümleme aşamasında**, mamogramlar Niblack yerel eşikleme yöntemi ile bölümlenmiştir. Yerel eşikleme yönteminde, piksellerin gri seviye değerlerinin tüm görüntüdeki dağılımlarının yanı sıra yerel özelliklerini de göz önüne alınmaktadır. Böylece görüntüde her bir piksel için ayrı ayrı eşik değeri hesaplanmıştır. Niblack yerel eşikleme yöntemi kullanılarak olası mikrokalsifikasyonlar bölümlenmiştir.

- **Özellik çıkarımı aşamasında**, mamogram görüntülerini sınıflandırmak için mamogram görüntülerinden çeşitli özellikler çıkarılmıştır. Uzaysal düzlem özellikleri ve gri seviye eş oluşum matrisinden elde edilen özellikler, iyileştirilmiş mamogram görüntülerinden hesaplanmıştır. Şekil tabanlı özellikler ise bölümlenmiş mamogram görüntülerinden hesaplanmıştır. Sınıflandırma için iki farklı özellik kümesi oluşturulmuştur. 1. özellik kümesi, iyileştirilmiş mamogram görüntülerinden hesaplanan 6 uzaysal düzlem özelliği ve gri seviye eş oluşum matrisinden hesaplanan 14 dokusal özellik olmak üzere 20 özellikten oluşmaktadır. 2. özellik kümesi, iyileştirilmiş mamogram görüntülerinden hesaplanan 6 uzaysal düzlem özelliği ve bölümlenmiş mamogram görüntülerinden hesaplanan 13 şekil tabanlı özellik olmak üzere 19 özellikten oluşmaktadır.
- **Özellik seçimi aşamasında**, temel bileşenler analizi yöntemi kullanılarak oluşturulan iki özellik kümesinde, bilgi kaybı olmaksızın boyut azaltımı gerçekleştirilerek örüntü sınıflarını daha iyi temsil eden özellikler oluşturulmuştur. 20 özellik içeren 1. özellik kümesi boyut azaltımı ile 7 özellik içeren özellik kümesine dönüştürülmüştür. 19 özellik içeren 2. özellik kümesi boyut azaltımı ile 9 özellik içeren özellik kümesine dönüştürülmüştür.
- **Sınıflandırma aşamasında**, çok katmanlı yapay sinir ağı ve destek vektör makineleri kullanılmıştır. Sınıflandırıcı başarımları karşılaştırma matrisleri ile değerlendirilmiştir. İki sınıflandırıcının başarımları karşılaştırılmıştır. Öncelikle mamogramlar normal ve anormal olarak sınıflandırılmışlardır. Eğitim aşamasında 40 normal mamogram görüntüsü ve 12 tane mikrokalsifikasyon içeren mamogram görüntüsü, test aşamasında ise 26 normal mamogram görüntüsü ve 8 mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır.
 - a) 20 özellik içeren 1. özellik kümesi çok katmanlı yapay sinir ağına ve destek vektör makinesine uygulanarak sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonucunda, ÇKYSA için %79,4 ve DVM için %88,2 olarak sınıflandırma doğruluğu elde edilmiştir.
 - b) 1. özellik kümesi için boyut azaltımı sonucunda elde edilen 7 özellik içeren özellik kümesi çok katmanlı sinir ağına ve destek vektör makinesine

uygulanarak sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonucunda, ÇKYSA için %91,1 ve DVM için %94,1 olarak sınıflandırma doğruluğu elde edilmiştir.

Uygulamalar sonucunda mamogramları normal ve anormal olarak sınıflandırmada boyut azaltımı gerçekleştirmenin sınıflandırma başarımını artırdığı gözlenmiştir. Aynı zamanda mamogramları normal ve anormal olarak sınıflandırmada, DVM sınıflandırıcısının başarımının ÇKYSA sınıflandırıcıya göre daha yüksek olduğu tespit edilmiştir.

Daha sonra mikrokalsifikasyon içeren mamogramlar, iyi huylu ve kötü huylu olarak sınıflandırılmıştır. Eğitim aşamasında, 6 iyi huylu mikrokalsifikasyon içeren mamogram görüntüsü ve 8 kötü huylu mikrokalsifikasyon içeren mamogram görüntüsü, test aşamasında ise 5 iyi huylu mikrokalsifikasyon içeren mamogram görüntüsü ve 7 kötü huylu mikrokalsifikasyon içeren mamogram görüntüsü kullanılmıştır.

c) 19 özellik içeren 2. özellik kümesi çok katmanlı yapay sinir ağına ve destek vektör makinesine uygulanarak sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonucunda, ÇKYSA için %75 ve DVM için %75 olarak sınıflandırma doğruluğu elde edilmiştir.

d) 2. özellik kümesi için boyut azaltımı sonucunda elde edilen 9 özellik içeren özellik kümesi çok katmanlı sinir ağına ve destek vektör makinesine uygulanarak sınıflandırma gerçekleştirilmiştir. Sınıflandırma sonucunda, ÇKYSA için %91,7 ve DVM için %83,3 olarak sınıflandırma doğruluğu elde edilmiştir.

Uygulamalar sonucunda mikrokalsifikasyon içeren mamogramları, iyi huylu ve kötü huylu olarak sınıflandırmada boyut azaltımı gerçekleştirmenin sınıflandırma başarımını artırdığı gözlenmiştir. Aynı zamanda mikrokalsifikasyon içeren mamogramları, iyi huylu ve kötü huylu olarak sınıflandırmada, ÇKYSA sınıflandırıcısının başarımının, DVM sınıflandırıcıya göre daha yüksek olduğu tespit edilmiştir.

Literatürde bulunan diğer BDT yöntemleri incelendiğinde, Yu ve Guan %90; Verma ve Zakos %88,9; El-Naqa ve ark., %94; Zhang ve ark., %97; Fu ve ark., %98; Wei ve ark., %90; Yu ve ark., %92 olarak sınıflandırma başarımı elde etmişlerdir.

Bu tez çalışmasında tasarlanan BDT sistemi için elde edilen başarımlar sonuçları, yukarıda belirtilen literatür sonuçları ile karşılaştırıldığında %94,1 ve %91,7 sınıflandırma doğruluğu açısından başarılı olduğu görülmektedir.

Mamogramlarda mikrokalsifikasyonları tespit etmek ve sınıflandırmak için ön işleme, bölümlendirme, özellik çıkarımı, özellik seçimi ve sınıflandırma aşamalarında farklı yöntemler kullanılarak bu yöntemlerin bilgisayar destekli teşhis sistemine olan etkileri incelenebilir. Hibrit yöntemler oluşturularak sistemin sınıflandırma başarımı artırılabilir. Farklı veri tabanları kullanılarak sistemin başarımı değerlendirilebilir. Sistem tasarlanırken kullanılan yöntemler farklı medikal görüntülerin sınıflandırılması için kullanılabilir.

6. KAYNAKLAR

- American Cancer Society. Breast Cancer Facts&Figures 2009-2010 (06.07.2010).
- American Cancer Society. Cancer Facts&Figures 2010 (06.07.2010).
- American Cancer Society, 2010. Mammograms and Other Breast Imaging Procedures.
- Abe, S., 2005. *Support Vector Machines for Pattern Classification*. Springer, 486s, New York.
- Baert, A.L., Reiser, M.F., Hricak, H., Knauth, M., 2010. *Digital Mammography*. Springer-Verlag Berlin Heidelberg, 222s.
- Berg, W.A., Birdwell, R.L., Gombos, E., Wang, S.C., Parkinson, B., Raza, S., Gren, G., Kennedy, A., Ketler, M.D., 2006. *Diagnostic Imaging Breast*. Amirsys, 830s, Canada.
- Bozek, J., Delac, K., Grgic, M., 2008. Computer-Aided Detection of Breast Abnormalities in Digital Mammography. 50th International Symposium ELMAR-2008, 45-52.
- Bow, S.T., 2002. *Pattern Recognition and Image Preprocessing*. Marcel Dekker, 698 s, New York.
- Burges, C.J.C., 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*. (Editör: Usama Fayyad), s: 121-167, Kluwer Academic Publishers, Boston.
- Cheng, H.D., Cai, X., Chen, X., Hu, L., Lou, X., 2003. Computer-Aided Detection and Classification of Microcalcifications in Mammograms: A Survey. *Pattern Recognition*, 36, 2967-2991.
- Cheng, H.D., Cui, M., 2004. Mass Lesion Detection with a Fuzzy Neural Network. *Pattern Recognition*, 37, 1189-1200.
- Costaridou, L., 2005. *Medical Image Analysis Methods*. CRC Pres, 552s, USA.
- Davies, E.R., 2005. *Machine Vision: Theory Algorithms Practicalities*. Morgan Kaufmann Publishers Inc., 934s, Sac Francisco.
- De Santo, M., Molinara, M., Tortorella, F., Vento, M., 2003. Automatic Classification of Clustered Microcalcifications by a Multiple Expert System. *Pattern recognition*, 36, 1467-1477.

- Dhawan, A.P., Buelloni, G., and Gordon, R., 1986. Enhancement of Mammographic Features by Optimal Adaptive Neighborhood Image Processing. *IEEE Transactions on Medical Imaging*, Vol. MI-5, No. 1, 8-15.
- Dong, A., Wang, B., 2009. Feature Selection and Analysis on Mammogram Classification. *Communications, Computers and Signal Processing*, IEEE Pacific Rim Conference on, PACRIM'09, 731-735.
- Duda, R.O., Hart, P.E., Stork, D.G., 2001. *Pattern Classification*. Wiley-Interscience, 654s, New York.
- El-Naqa, I., Yang, Y., Wernick, M.N., Galatsanos, N.P., Nishikawa, R.M., 2002. A Support Vector Machine Approach for Detection of Microcalcifications. *IEEE Transaction on Medical Imaging*, vol. 21, no. 12, 1552-1563.
- Fausett, L., 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice Hall, 461s, New Jersey.
- Fawcett, T., 2006. An Introduction to ROC Analysis. *Pattern recognition Letters*, 27, 861-874.
- Freeman, J.A., Skapura, D.M., 1991. *Neural Networks Algorithms, Applications, and Programming Techniques*. Addison-Wesley Publishing Company, 414s, USA.
- Fu, J.C., Lee, S.K., Wong, S.T.C., Yeh, J.Y., Wang, A.H., Wu, H.K., 2005. Image Segmentation Feature Selection and Pattern Classification for Mammographic Microcalcifications. *Computerized medical Imaging and Graphics*, 29, 419-429.
- Gonzalez R. C., Woods R.E., 2002. *Digital Image Processing*, 2nd Edition, Prentice Hall, 792s, USA.
- Gölbaşı, Z., Çetin, R., Kalkan, S., Durmuş, T., 2010. Üniversite öğrencisi kızların meme kanseri ve kendi kendine meme muayenesi ile ilgili bilgi ve davranışları. *Meme Sağlığı Dergisi*, vol 6(2), 69-73.
- Halkiotis, S., Botsis, T., Rangoussi, M., 2007. Automatic Detection of Clustered Microcalcifications in Digital Mammograms Using Mathematical Morphology and Neural Networks. *Signal Processing*, 87, 1559-1568.
- Haralick, R.M., Shanmugam, K., Dinstein, I., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, 610-621.
- Haykin, S., 1999. *Neural Networks: A Comprehensive Foundation*. Prentice Hall, 842s, New Jersey.

- Jain, A., Zongker, D., 1997. Feature Selection: Evaluation, Application, and Small Sample Performance. *IEEE Transaction Pattern Analysis and Machine Intelligence*, Vol 19(2), 18s.
- Jolliffe, I.T., 2002. *Principal Component Analysis*. Springer, 519s, New York.
- Kim, J.K., Park, J.M., Song, K.S., Park, H.W., 1997. Adaptive Mamographic Image Enhancement Using First Derivative and Local Statistics. *IEEE Transactions on Medical Imaging*, vol. 16, no. 5, 495-502.
- Lai, S.M., Li, X., Bischof, W.F., 1989. On Techniques for Detecting Circumscribed Masses in Mammograms. *IEEE Transactions on Medical Imaging*, vol. 8, no. 4, 377- 386.
- Laine, A.F., Schuler, S., Fan, J., and Huda, W., 1994. Mamographic Feature Enhancement by Multiscale Analysis. *IEEE Transactions on Medical Imaging*, vol. 13, no. 4, 725-740.
- Leedham, G., Yan, C., Takru, K., Tan, J.H.N., Mian, L., 2003. Comparison of Some Thresholding Algorithms for Text/Background Segmentation in Difficult Document Images. *Proceedings of the Seventh International Conference on Document Analysis and Recognition (ICDAR 2003)*, 859-864.
- Liu, H., Motoda, H., 2008. *Computational Methods of Feature Selection*. Chapman & Hall/CRC, 411s, USA.
- Martinez, W.L., Martinez, A., Solka, J., 2005. *Exploratory Data Analysis with Matlab*. Chapman & Hall , 424s, USA.
- Meyer-Baese, A., 2004. *Pattern Recognition for Medical Imaging*. Elsevier Academic Pres, 404s, California.
- Mitchell, T.M., 1997. *Machine Learning*. McGraw-Hill Science/Engineering/Math, 412s, USA.
- Mukhopadhyay, S. Chanda, B., 2000. Local Contrast Enhancement of Grayscale Images Using Multiscale Morphology. *Proc. ICVGIP-2000*, 17-24.
- Nass, S.J., Henderson, I.C., Lashof, J.C., 2001. *Mammography and Beyond: Developing Technologies for Early Detection of Breast Cancer*. National Academy Pres, 288s, Washington, DC.
- Niblack, W., 1986. *An introduction to digital image processing*. Prentice Hall, 215s, New Jersey.

- Nixon, M.S., Aguado, A.S., 2008. *Feature Extraction and Image Processing*. Academic Pres, 423s, London.
- Özmen, V., 2008. Dünya’da ve Türkiye’de Meme Kanseri. *Meme Sağlığı Dergisi*, 4,2, VII-IX.
- Ozmen, V., 2009. Meme hastalıklarının cerrahi tedavi kalitesi nasıl yükseltilebilir?. *The Journal of Breast Health*, vol 5(2), 119-121.
- Ozmen V., Ozcinar B., Karanlik H., Cabioglu N., Tukenmez M., Disci R., Ozmen T., Igci A., Muslumanoglu M. , Mustafa Kecer M. and Soran A., 2009. Breast cancer risk factors in Turkish women – a University Hospital based nested case control study. *World Journal of Surgical Oncology*, Vol 7, 8 s.
- Parvati, K., Prasaka Rao, B.S., Mariya Das, M., 2008. Image Segmentation Using Gray-Scale Morphology and Marker-Controlled Watershed Transformation. *Discrete Dynamics in Nature and Society*, Volume 2008, Article ID 384346.
- Qian, W., Clarke, L.P., Kallergi, M., Clark, R.A., 1994. Tree-structured Nonlinear Filters in Digital Mammography. *IEEE Transactions on Medical Imaging*, vol. 13, no. 1, 25-36.
- Rangayyan, R.M., 2005. *Biomedical Image Analysis*. CRC Pres, Amerika, 1311s.
- Semmlow, J.L., 2004. *Biosignal and Biomedical Image Processing*. Marcel Dekker Inc., 424s, USA.
- Sezgin, M., 2002. *İmge Eşikleme Yöntemlerinin Başarım Değerlendirmesi ve Tahribatsız Muayenede Kullanımı*. Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 172s.
- Shinde, M., 2003. *Computer Aided Diagnosis In Digital Mammography: Classification Of Mass And Normal Tissue*. Master Thesis, University of South Florida, South Florida, 53p.
- Shlens, J., 2002. A Tutorial on Principal Component Analysis. <http://www.sn1.salk.edu/~shlens/pca.pdf>, (26.04.2011).
- Smith, L.I., 2002. A tutorial on Principal Component Analysis. http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf, (26.04.2011).
- Soltanian-Zadeh, H., Rafiee-Rad, F., Pourabdollah-Nejad D.S., 2004. Comparison of Multiewavelet, Wavelet, Haralick, and Shape Features for Microcalcification Classification in Mammograms. *Pattern Recognition*, 37, 1973-1986.

- Somunoğlu, S., 2009. Meme Kanseri: Belirtileri ve Erken Tanıda Kullanılan Tarama Yöntemleri . Fırat Sağlık Hizmetleri Dergisi, Cilt 4, Sayı:10, 103-122.
- Spiesberger, W. 1979. Mammogram Inspection by Computer. IEEE Transactions on Biomedical Engineering, vol. bme-26, no. 4, 213-219.
- Şengür, A., 2006. Endoskopik Görüntülerin Değerlendirmesinde Görüntü İşleme Temelli Akıllı Karar Destek Sistemi. Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 153s.
- Thangavel, K., Karnan, M., Sivakumar, R., Mohideen, A.K., 2005. Automatic Detection of Microcalcification in Mammograms – A Review. ICGST-GVIP Journal, 5(5), 31-61.
- Tembey, M., 2003. Computer-Aided Diagnosis for Mammographic Microcalcification Clusters. Yüksek Lisans Tezi, Computer Science Department of Computer Science and Engineering College of Engineering, University of South Florida, 112s.
- Vapnik, V.N., 1998. *Statistical Learning Theory*. Wiley-Interscience, 736s, New York.
- Veldkamp, W.J.H., Karssemeijer, N., 2000. Normalization of Local Contrast in Mammograms. IEEE Transactions on Medical Imaging, vol. 19, no. 7, 731-738.
- Verma, B., Zakos, J., 2001. A Computer-Aided Diagnosis System for Digital Mammograms Based on Fuzzy-Neural and Feature Extraction Techniques. IEEE Transactions on Information Technology in Biomedicine, vol. 5, no. 1, 46-54.
- Vojtech F.,
- Wang, T.C., Karayiannis, N.B., 1998. Detection of Microcalcifications in Digital Mammograms Using Wavelets. IEEE Transactions on Medical Imaging, vol. 17, no. 4, 498-509.
- Wei, L., Yang, Y., Nishikawa, R.M., Wernick, M.N., Edwards, A., 2005. Relevance Vector Machine for Automatic Detection Clustered microcalcifications. IEEE Transactions on Medical Imaging, vol. 24, no. 10, 1278-1285.
- Wei, Z., Hua, Y., Hui-sheng, S., Hong-qi, F., 2007. X-ray Image Enhancement Based on Multiscale Morphology. Bioinformatics and Biomedical Engineering, ICBBE 2007, The 1st International Conference on. 702-705.
- Yu, S., Guan, L., 2000. A CAD System for the Automatic Detection of Clustered Microcalcifications in Digitized Mammogram Films. IEEE Transactions on Medical Imaging, vol. 19, no. 2, 115-126.

- Yu, S.N., Li, K.Y., Huang, Y.K., 2006. Detection of Microcalcifications in Digital Mammograms Using Wavelet Filter and Markow Random Field Model. *Computerized Medical Imaging and Graphics*, 30, 163-173.
- Zhang, L., Sankar, R., Qian, W., 2002. Advances in Micro-calcification Clusters Detection in Mammography. *Computers in Biology and Medicine*, 32, 515-528.
- Zhang, X., Gao, X., Wang, Y., 2009. MCs Detection with Combined Image Features and Twin Support Vector Machines. *Journal of Computers*, vol. 4, no. 3, 215-221.
- Zheng, N., Xue, J., 2009. *Statistical Learning and Pattern Analysis for Image and Video Processing*. Springer-Verlag London Limited, 365 s, London.
- Zheng, B., Qian, W., Clarke, L.P., 1996. Digital Mammography: Mixed Feature Neural Network with Spectral Entropy Decision for Detection of Microcalcifications. *IEEE Transactions on Medical Imaging*, vol. 15, no. 5, 589-597.
- Zorukoş, S., 2008. Birinci Derece Yakınlarında Meme Kanseri Olan Kadınlar İçin Bilgi ve Destek Gereksinimleri Ölçeği'nin Türkçe'ye Uyarlanması. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sağlık Bilimleri Enstitüsü, İzmir, 82s.
- Zurada, J.M., 1992. *Introduction to Artificial Neural Systems*. West Publishing Company, 764s, St Paul.
- Türk Kanser Araştırma ve Savaş Kurumu Derneği. Türkiyede kanser istatistikleri., http://www.turkcancer.org/newsfiles/60turkiye_kanser_istatistikleri-2.pdf, (06.07.2010)

7. ÖZGEÇMİŞ

Adı Soyadı : Canan ORAL

Doğum Yeri : Kırıkhan / Hatay

Doğum Tarihi : 05.01.1980

Medeni Hali : Bekar

Bildiği Yabancı Diller: İngilizce

Eğitim Durumu

Lise : Samsun Cumhuriyet Lisesi - 1996

Lisans : Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü - 2001

Yüksek Lisans : Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı - 2004

Çalıştığı Kurumlar ve Yıl:

- Ondokuz Mayıs Üniversitesi Amasya Meslek Yüksekokulu (2001 – 2006)
- Amasya Üniversitesi Meslek Yüksekokulu (2006 -

İletişim Bilgileri: Amasya Üniversitesi Meslek Yüksekokulu Amasya

Telefon : 0535 553 13 63

Mail adresi : oralcanan@yahoo.com

Yayımları:

- 1- **Oral, C.**, Sezgin, H., 2010. Çok Katmanlı Sinir Ağı Kullanarak Mamogramların Sınıflandırılması. ELECO 2010 Elektrik-Elektronik Ve Bilgisayar Mühendisliği Sempozyumu, 2-5 Aralık, Bursa, Türkiye.
- 2- **Oral, C.**, Kayhan, G., Sezgin, H., 2006. Using Discrete Hilbert Transform For Minimum Phasing In Dispersive Band Limited Detector And Inverse Filter Applications. 3rd International Symposium and Exhibition on Electrical, Electronic and Computer Engineering, 23-25 November 2006, Cyprus.
- 3- **Oral, C.**, Sezgin, H., 2005. Using Root Moments For Minimum Phasing In Dispersive Band Limited Detector And Inverse Filter Applications. Fourth International Conference on Electrical and Electronics, 7-11 December 2005, Bursa- Turkey.