

**T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TIBBİ GÖRÜNTÜLEMEDE
BİLGİSAYAR DESTEKLİ TESPİT**

**Serhat ÖZEKES
(Bilgisayar ve Kontrol Öğretmeni)**

**DOKTORA TEZİ
ELEKTRONİK BİLGİSAYAR EĞİTİMİ ANABİLİM DALI
BİLGİSAYAR KONTROL EĞİTİMİ PROGRAMI**

**DANIŞMAN
Prof. Dr. Yılmaz ÇAMURCU**

İSTANBUL 2006

**T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TIBBİ GÖRÜNTÜLEMEDE
BİLGİSAYAR DESTEKLİ TESPİT**

Serhat ÖZEKES
(Bilgisayar ve Kontrol Öğretmeni)
(141200420020036)

DOKTORA TEZİ
ELEKTRONİK BİLGİSAYAR EĞİTİMİ ANABİLİM DALI
BİLGİSAYAR KONTROL EĞİTİMİ PROGRAMI

DANIŞMAN
Prof. Dr. Yılmaz ÇAMURCU

İSTANBUL 2006

ÖNSÖZ

Lisans öğrenimimin henüz başında tanıştığım ve bana bu tez boyunca olduğu gibi tüm akademik hayatımın ilerlemesinde de büyük katkıları olmuş değerli hocam Prof. Dr. Yılmaz ÇAMURCU'ya sonsuz teşekkürlerimi sunarım.

Tez çalışmam boyunca bana her zaman yardımcı olan Prof. Dr. Sezgin ALSAN'a ve Doç. Dr. Fevzi BABA'ya teşekkür ederim. Ayrıca medikal görüntüler ve görüntü anormallikleri ile tanışmam sırasında, bana ayırdığı vakit ve verdiği destek için Dr. İsmail ÇEREZCİ'ye teşekkür ederim.

Son olarak bana tez süresince her zaman destek veren, çalışmalarım sırasında sabır gösteren nişanlım Özge BÜKEY'e ve sevgilerini her zaman kalbimde hissettiğim, bugüne gelmemi sağlayan sevgili annem ve babama şükranlarımı sunarım.

Aralık, 2006

Serhat ÖZEKES

İÇİNDEKİLER

	SAYFA
ÖNSÖZ.....	I
İÇİNDEKİLER.....	II
ÖZET.....	VI
ABSTRACT	VIII
YENİLİK BEYANI.....	X
SEMBOL LİSTESİ.....	XII
KISALTMALAR LİSTESİ.....	XIV
ŞEKİL LİSTESİ.....	XVI
TABLO LİSTESİ.....	XXII
BÖLÜM I. GİRİŞ VE AMAÇ.....	1
I.1. GİRİŞ.....	1
I.2. AMAÇ.....	2
I.3. TEZ BÖLÜMLERİNİN ÖZETİ.....	2
BÖLÜM II. TIBBİ GÖRÜNTÜLEME VE BİLGİSAYAR	
DESTEKLİ TESPİT YÖNTEMLERİ.....	4
II.1. GİRİŞ.....	4

II.2. GÖRÜNTÜLEME YÖNTEMLERİ VE ÖZELLİKLERİ.....	4
II.2.1. Röntgen.....	7
II.2.1.1. Radyografi.....	10
II.2.1.2. Mamografi.....	10
II.2.1.3. Göğüs Röntgenogramı.....	13
II.2.1.4. Fluoroskopi.....	14
II.2.2 Bilgisayarlı Tomografi (BT)	15
II.2.3. Manyetik Rezonans Görüntüleme (MRG)	21
II.2.4. Ultrasonografi (US)	21
II.2.5. Nükleer Tıp Görüntüleme.....	22
II.3. TIBBİ GÖRÜNTÜ DEĞERLENDİRMELERİNDE	
KULLANILAN PERFORMANS ÖLÇÜMLERİ.....	22
II.4. BDT ÇALIŞMALARINA İLİŞKİN LİTERATÜR	
ARAŞTIRMASI.....	24

BÖLÜM III. TIBBİ GÖRÜNTÜLERDE BİLGİSAYAR

DESTEKLİ TESPİT YAZILIMLARININ

TASARIMI İÇİN KULLANILAN VERİ

SETLERİ VE YÖNTEMLER 35

III.1. GİRİŞ.....	35
III.2. KULLANILAN VERİ SETLERİ.....	35
III.3. İLGİ ALANLARININ BELİRLENMESİ.....	38
III.4. BAĞLANTILI BİLEŞEN ETİKETLEME (BBE).....	43
III.5. ŞABLON EŞLEME VE KONVOLÜSYON.....	46
III.6. GENETİK ALGORİTMALAR ve UYGULAMA ALANLARI. 48	
III.7. HÜCRESEL YAPAY SİNİR AĞLARI.....	54
III.7.1. Hücresel Yapay Sinir Ağlarında Komşuluk İlişkisi.....	55
III.7.2. Hücre Yapıları.....	58
III.7.3. Ayrık Zamanlı Hücresel Yapay Sinir Ağı.....	59
III.7.4. Hücresel Yapay Sinir Ağları ve Konvolüsyon İlişkisi.....	60

BÖLÜM IV. MAMOGRAFİ GÖRÜNTÜLERİNDEKİ

KİTLELERİ TESPİT EDEN BDT

YAZILIMLARININ TASARIMI.....61

IV.1. GİRİŞ.....	61
IV.2. MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN	
TESPİT EDİLMESİ.....	61
IV.2.1. Mamografi Görüntülerindeki Kitlelerin Kural Tabanlı	
Tespiti.....	62
IV.2.2. Şablon Eşleme Yöntemiyle Kitlelerin Tespiti.....	69

IV.2.3. Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemleriyle Meme Bölgesinin Bölütlendirilmesi ve Kitlelerin Tespit Edilmesi.....	75
BÖLÜM V. AKCİĞER BT GÖRÜNTÜLERİNDEKİ	
NODÜLLERİ TESPİT EDEN BDT	
YAZILIMLARININ TASARIMI.....	86
V.1. GİRİŞ.....	86
V.2. AKCİĞER BİLGİSAYARLI TOMOGRAFİ (BT)	
GÖRÜNTÜLERİNDEKİ NODÜLLERİN TESPİT EDİLMESİ	86
V.2.1. Akciğer BT Görüntülerindeki Nodüllerin Kural Tabanlı Tespiti.....	87
V.2.2. Şablon Eşleme Yöntemiyle Nodüllerin Tespiti.....	90
V.2.3. Akciğer Bölgesinin Bölütlendirilmesi ve Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemiyle Nodüllerin Tespit Edilmesi.....	98
V.2.3.1. Akciğer Bölgesinin Kural Tabanlı Bölütlendirilmesi.....	98
V.2.3.2. Akciğer Bölgesinin Hücrel Yapay Sinir Ağı Şablonları Kullanılarak Bölütlendirilmesi.....	102
V.2.3.3. Bölütlendirilmiş Akciğer Bölgesindeki Nodüllerin Genetik Algoritma Kullanılarak Eğitilmiş Şablon İle Tespit Edilmesi.....	105
BÖLÜM VI. SONUÇLAR	109
VI.1. GİRİŞ.....	109
VI.2. MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN TESPİT EDİLMESİ ÇALIŞMALARININ SONUÇLARI.....	109
VI.2.1. Mamografi Görüntülerindeki Kitlelerin Kural Tabanlı Tespiti Çalışmasının Sonuçları.....	110
VI.2.2. Şablon Eşleme Yöntemiyle Kitlelerin Tespiti Çalışmasının Sonuçları.....	110
VI.2.3. Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemleriyle Meme Bölgesinin Bölütlendirilmesi ve Kitlelerin Tespit Edilmesi Çalışmasının Sonuçları.....	116
VI.3. AKCİĞER BİLGİSAYARLI TOMOGRAFİ (BT)	
GÖRÜNTÜLERİNDEKİ NODÜLLERİN TESPİT EDİLMESİ ÇALIŞMALARININ SONUÇLARI.....	120
VI.3.1. Akciğer BT Görüntülerindeki Nodüllerin Kural Tabanlı Tespiti Çalışmasının Sonuçları.....	120
VI.3.2. Şablon Eşleme Yöntemiyle Nodüllerin Tespiti Çalışmasının Sonuçları.....	122
VI.3.3. Bölütlendirilmiş Akciğer Bölgesindeki Nodüllerin Genetik Algoritma Kullanılarak Eğitilmiş Şablon İle Tespit Edilmesi Çalışmasının Sonuçları.....	126
VI.3.3.1. Akciğer Bölgesinin Kural Tabanlı Bölütlendirilmesi ile Elde Edilen Sonuçlar.....	127

VI.3.3.2. Akciğer Bölgesinin HYSA Şablonları Kullanılarak Bölütlendirilmesi ile Elde Edilen Sonuçlar.....	130
BÖLÜM VII. DEĞERLENDİRME VE ÖNERİLER.....	132
VII.1. DEĞERLENDİRME.....	132
VII.2. ÖNERİLER.....	138
KAYNAKLAR.....	139
ÖZGEÇMİŞ.....	139

ÖZET

TIBBİ GÖRÜNTÜLEMEDE BİLGİSAYAR DESTEKLİ TESPİT

Bilgisayar Destekli Tespit (BDT) yazılımları, ileri örüntü tanıma ve görüntü işleme yöntemlerini kullanarak radyoloji uzmanlarına medikal görüntülerdeki anormalliklerin tespitinde yardımcı olan yazılımlardır. BDT yazılımları anormalliklerin erken tespitinde radyoloji uzmanına ikinci bir gözden geçirme imkanı tanır. Bu tez, mamografi görüntülerindeki kitlelerin ve akciğer BT görüntülerindeki nodüllerin tespit edilmesini amaçlayan verimli teknikler ortaya konmuştur. Tez çalışmasının ana başlıkları şu şekildedir: (1) Bölütlendirme; (2) ilgi alanlarının belirlenmesi; (3) anormalliklerin tespit edilmesi amacıyla ilgi alanlarının sınıflandırılması.

Meme ve akciğer bölgesini bölütlendirmek amacıyla literatürdeki bölütleme yöntemlerine alternatif bir yöntem olarak genetik algoritma ile eğitilmiş hücresel yapay sinir ağları kullanılmıştır. Ayrıca akciğer bölgesini bölütlendirmek amacıyla ikinci bir yöntem olarak kural tabanlı bölütleme gerçekleştirilmiştir. İlgi alanlarının belirlenmesi amacıyla yoğunluk tabanlı bir yöntem kullanılmıştır. Bu yöntem, bölütlendirilmiş alanı yoğunluk eşik değerleriyle 8 yönlü tarayarak ilgi alanlarını belirlemiştir. Seri akciğer BT görüntülerindeki ilgi alanlarının sayısının azaltılması amacıyla bir ön-sınıflandırma gerçekleştirilmiştir. Bu yöntem ile mevcut kesitteki ilgi alanlarının üst ve alt kesitlerdeki konum değişimleri incelenmiştir. Konum değişim miktarının beklenenden fazla olması durumunda gözlem altındaki ilgi alanı normal bir yapı olarak değerlendirilmiştir. İlgi alanlarının sınıflandırılması amacıyla üç yöntem kullanılmıştır. İlkinde kural tabanlı algoritma ile ilgi alanlarının morfolojik özellikleri incelenirken, ikinci yöntemde benzerlik ölçümü olarak hata tabanlı iki adet kuralın kullanıldığı bir şablon eşleme tekniği kullanılmıştır. Üçüncü yöntem olarak şablonun genetik algoritma ile eğitildiği başka bir şablon eşleme yöntemi kullanılmıştır. Bu yöntemde eğitilmiş şablon ile her bir ilgi alanı arasındaki benzerlik konvolüsyon kullanılarak ölçülmüştür. Böylece anormallikler başarılı bir şekilde tespit edilmiştir.

Sonular kullanılan yöntemlerin anormallik tespit performanslarının tatmin edici olduėunu, akciėer nodüllerinin ve mamogram kitlelerinin bilgisayar destekli tespitinde de verimliliėi arttırabileceėini göstermiştir.

ABSTRACT

COMPUTER AIDED DETECTION IN MEDICAL IMAGING

Computer Aided Detection (CAD) is a system that incorporates advanced pattern recognition and image analysis capabilities to aid radiologists in the detection of abnormalities on medical images. CAD systems provide a targeted second review for busy radiologists in order to improve the early detection of abnormality. This dissertation provides efficient techniques on detecting masses in mammograms and detecting nodules in lung CT slices. The main topics of the study are as follows: (1) Segmentation; (2) extraction of the regions of interest (ROIs); (3) classification of ROIs in order to detect abnormalities.

To segment the breast and lung region, genetic algorithm trained cellular neural networks was used as an alternative to the known segmentation algorithms in literature. Also a rule based algorithm was used as a second method to extract the lung region. A density threshold based algorithm was used to extract the ROIs. This algorithm searched the segmented region with density thresholds in 8 directions. A pre-classification was performed to reduce the numbers of ROIs in serial CT lung images. This algorithm examined the location changes of ROIs in current slice with upper and lower slices. If the location change value was greater than expected than the ROI under observation was pre-classified as normal. To classify the ROIs three algorithms were developed. While the first one analyzed the morphological features of the ROIs using a rule based subsystem, the second one used a template matching algorithm with two error based rules as the similarity measure. As the third algorithm another template matching algorithm was used where the template was trained using genetic algorithm. In this algorithm the similarity between the trained template and each ROI was measured by the convolution operation. Finally the abnormalities were detected successfully.

The results indicate that the detection performance of the developed algorithms were satisfactory, and may improve the efficiency of computer-aided detection of lung nodules and mammogram masses.

YENİLİK BEYANI

TIBBİ GÖRÜNTÜLEMEDE BİLGİSAYAR DESTEKLİ TESPİT

Medikal görüntüleme tekniklerindeki gelişmelere paralel olarak, medikal görüntülerin analizi konusu güncel bir araştırma alanı haline gelmiştir. Bu konuda uluslararası alanda bilimsel geçerliliği olan çalışmalar Bilimsel Atıf Dizini (Science Citation Index, SCI) tarafından taranan dergilerde yayımlanmaktadır. Tez çalışmasının bir kısmı Bilimsel Atıf Dizini tarafından taranan iki farklı dergide yayımlanmıştır. Bu tezde akciğer bilgisayarlı tomografi (BT) görüntülerindeki ve mamogram görüntülerindeki anormalliklerin bilgisayar destekli tespiti amaçlanmıştır. Çalışma kapsamında mevcut yöntemler eklemeler yapılarak kullanılmıştır. Yapılan çalışmalarda ortaya konan katkılar üç bölümde özetlenebilir.

Medikal görüntülerin analizinde bölütleme çok önemli bir kavramdır. Bölütleme işlemi sonucu arama yapılacak alan daraltılmış olur. Bu tez çalışmasında akciğer BT'lerinde ve mamogramlarda akciğer ve meme bölgelerinin bölütlendirilmesi için hücresel sinir ağı şablonları kullanılmıştır. Genetik algoritma aracılığıyla eğitilmiş hücresel yapay sinir ağı şablonlarının kullanıldığı konvolüsyon tabanlı şablon eşleme yöntemi ile akciğer ve meme bölgeleri bölütlendirilmiştir.

Bölütlenmiş görüntüde anormal yapı özelliği gösteren ilgi alanlarının belirlenmesi önemli diğer bir konudur. Bu tez çalışmasında akciğer BT'lerindeki ve mamogramlardaki ilgi alanlarının tespiti için yoğunluk değerlerinin incelendiği gri seviyeli eşikleme yönteminin kullanıldığı bir filtreleme yöntemi kullanılmıştır. Bu yöntem kapsamında, analiz edilen akciğer BT ve mamogram görüntülerindeki her piksel için yoğunluk değerlerinin sorgulandığı 8 yönlü tarama yapılarak ilgi alanlarının tespit edilmesi gerçekleştirilmiştir. Ayrıca seri kesitlerden oluşan akciğer görüntülerindeki ilgi alanlarının konum değişimlerinin analiz edilmesi yöntemi ile, ilgi alanlarının ön sınıflandırılması gerçekleştirilerek de akciğer nodül tespit işleminin hızlandırılması sağlanmıştır.

Bu tez çalışmasında anormallik tespiti için gerçekleştirilen ilgi alanlarının sınıflandırılmasında kullanılan şablon eşleme tekniğinde, benzerlik ölçümü olarak eşikleme tabanlı bir yöntem kullanılmıştır. Bu yöntemde benzerliği ölçmek için 2 farklı hata kuralı kullanılmıştır. Sınıflama yöntemi sırasında şablona olan benzerliği ölçmek için kullanılan yöntemle ilgi alanının morfolojik özelliklerine de karar verilebilmektedir. Yine bu tez çalışması kapsamında gerçekleştirilen diğer bir şablon eşleme tekniğinde, şablon değerlerinin hesaplanması için genetik algoritma yöntemi kullanılmıştır. Benzerlik ölçümü olarak konvolüsyon yönteminin kullanıldığı bu çalışmada şablon değerlerinin optimizasyonu sağlanmıştır.

SEMBOL LİSTESİ

H^+	: Hasta
H	: Hasta Değil
T^+	: Pozitif
T	: Negatif
D	: Duyarlılık
S	: Seçicilik
Ptd	: Pozitif tahmin değeri
Ntd	: Negatif tahmin değeri
Dk	: Doğruluk
Cov_{xy}	: Ortak Değişinti (Covariance)
$R(i,j)$	: Korelasyon katsayısı
$G(i,j)$	: Yoğunlaşma miktarı
$d(i,y)$	: Yoğunluk bileşeni
a_i	: a görüntüsündeki i inci piksel
b_i	: b görüntüsündeki i inci piksel
$I(X;Y)$	: X ve Y 'nin karşılıklı bilgi miktarı
$\mathbb{R}^2$	: Öklid düzlemi
$g(t)$	: Süzgeç fonksiyonu
$f(t)$	: Süzgeçleme işleminde giriş verisi
$h(t)$	: Süzgeçleme işleminde çıkış verisi
w	: Açısal frekans
f	: Frekans
C_{ij}	: HYSA'da (i,j) indisli hücre
u_{ij}	: C_{ij} hücresinin girişi
y_{ij}	: C_{ij} hücresinin çıkışı
x_{ij}	: C_{ij} hücresinde durum
A_{ij}	: Geri besleme ağırlık katsayısı

B_{ij}	: Giriş ağırlık katsayısı
I_{ij}	: Eşik seviyesi
E_d	: Öklid uzunluğu
Y	: Yükseklik
G	: Genişlik
x_c, y_c	: Merkez koordinatları
y_{cmin}	: x_c 'ye karşılık minimum y noktası
y_{cmax}	: x_c 'ye karşılık maksimum y noktası
x_{cmin}	: y_c 'ye karşılık minimum x noktası
x_{cmax}	: y_c 'ye karşılık maksimum x noktası
R	: Yapının biçimi
P	: HYSA'da çıkış görüntüsü
T	: HYSA'da hedef görüntüsü
$\oplus$	: XOR işlemi
C	: Konvolüsyon
Ed_{minust}	: Üst kesitteki ilgi alanlarıyla en küçük uzaklık
Ed_{minalt}	: Alt kesitteki ilgi alanlarıyla en küçük uzaklık
T_{lc}	: Konum değişim eşiği
$E_{beyazpiksel}$	: Beyaz piksel hatası
$E_{siyahpiksel}$	: Siyah piksel hatası
$T_{beyazhata}$	: Beyaz hata eşiği
$T_{siyahhata}$	: Siyah hata eşiği
$EBO(k)$	: k . yapının en-boy oranı
$G(k)$	: k . yapının genişliği

KISALTMALAR LİSTESİ

BDT	: Bilgisayar Destekli Tespit
BT	: Bilgisayarlı Tomografi
MR	: Manyetik Rezonans
US	: Ultrasonografi
RF	: Radyofrekans
AgBr	: Gümüş Bromür
CaPO₄	: Kalsiyum Fosfat
CC	: Craniocaudal
ML	: Mediolateral
PA	: Pulmoner Arter
TR	: Trakea (Nefes Borusu)
CL	: Köprücük Kemîği
AA	: Arkus Aorta
SVC	: Superior Vena Kava
RA	: Sağ Kulakçık
CoPhS	: Diyafragmatik Oluk
LV	: Sol Ventrikül
D	: Diyafram
L	: Karaciğer
Sca	: Kürek Kemîği
R	: Kaburga
HU	: Hounsfield Ünitesi
MB-R	: Sağ Ana Bronş
MB-L	: Sol Ana Bronş
Sca	: Kürek Kemîği
PA	: Pulmoner Arter
DesA	: Azalan Aort

AscA	: Artan Aort
SVC	: Superior Vena Kava
MRG	: Manyetik Rezonans Görüntüleme
DP	: Doğru Pozitif
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
DN	: Doğru Negatif
NCCC	: Normalize Edilmiş Çapraz Korelasyon Katsayısı
MIAS	: Mammographic Images Analysis Society
LIDC	: Lung Image Database Consortium
BBE	: Bağlantılı Bileşen Etiketleme
GA	: Genetik Algoritmalar
HYSA	: Hücresel Yapay Sinir Ağları

ŞEKİL LİSTESİ

SAYFA NO

Şekil II.1	Vücudun (a) Aksiyal, (b) Sagital ve (c) Koronal Düzlemleri.....	5
Şekil II.2	Elektromanyetik Spektrum.....	7
Şekil II.3	Röntgen Filmi Üzerinde Görüntü Oluşumu	9
Şekil II.4	Radyografi Görüntüleme Tekniği	10
Şekil II.5	Sol Memenin (a) Craniocaudal ve (b) Mediolateral Görünümler.....	11
Şekil II.6	Meme Yapıları.....	12
Şekil II.7	Göğüs (Arka-Ön) Röntgenogramları (a) Normal, (b) Kanser.....	13
Şekil II.8	Göğüs Röntgenogramındaki Yapılar	14
Şekil II.9	Fluoroskopi Görüntüleme.....	15
Şekil II.10	BT Görüntüleme.....	16
Şekil II.11	(Helikal Spiral) BT Görüntüleme	17
Şekil II.12	Piksel (a x b) ve Voksel (a x b x d), D: Görüntü Alanının Çapı	18
Şekil II.13	Hounsfield Ölçeği	18
Şekil II.14	Akciğer BT Kesiti Yapıları	20
Şekil II.15	Akciğer BT Kesiti Yapıları.....	20
Şekil II.16	Genel BDT Basamakları.....	25
Şekil II.17	Özellikleri Hesaplamak İçin Kullanılan A ve B Maskeleri	28
Şekil III.1	(a) Sınırları Düzgün Kitle İçeren Mamogram, (b) Spiküler Kitle İçeren Mamogram.....	36
Şekil III.2	Örnek Bir Akciğer BT Kesiti.....	37
Şekil III.3	LIDC Veri Setinde Nodül İçeren Bir Akciğer BT Kesit Örneği.....	38
Şekil III.4	(a) Kitleye Sahip Bir Mamografi Görüntüsü, (b) Kitle İle Benzer Yoğunluktaki Yapılar.....	39

Şekil III.5	(a) Nodüle Sahip Bir Akciğer BT Görüntüsü, (b) Nodül İle Benzer Yoğunluktaki Yapılar.....	40
Şekil III.6	8 Yöndeki Eşik Değerleri.....	41
Şekil III.7	8 Yöndeki Eşik Değerlerinin Kullanım Örnekleri: (a) “ <i>minimum uzunluk eşiği</i> ” değerinden daha az sayıda komşu piksele sahip normal yapı pikseli, (b) “ <i>maximum uzunluk eşiği</i> ” değerinden daha fazla sayıda komşu piksele sahip normal yapı pikseli, (c) anormal olmaya aday yapı pikseli.....	42
Şekil III.8	İlgi Alanı Belirleme Yöntemi Akış Diyagramı.....	43
Şekil III.9	BBE Yönteminin Uygulama Örnekleri: (a) 1 yoğunluk değerine sahip pikseller, (b) 1 yoğunluklu piksellerden oluşan bağımsız yapılar.....	44
Şekil III.10	BBE Yönteminin Akış Diyagramı.....	45
Şekil III.11	(a) Aramanın Gerçekleştirileceği Büyük Görüntü, (b) Şablon Görüntüsü.....	46
Şekil III.12	Şablon Eşlemede Kullanılacak Görüntü ve Daha Küçük Olan Şablon.....	48
Şekil III.13	Genetik Algoritma Akış Diyagramı.....	51
Şekil III.14	Rulet Tekerleği Örneği	52
Şekil III.15	Tek Noktalı Çaprazlama	53
Şekil III.16	Tek Bir Mutasyon	54
Şekil III.17	4x4 Boyutunda Bir Hücresel Yapay Sinir Ağı Gösterimi	56
Şekil III.18	Hücresel Yapay Sinir Ağlarında Hücreler Arasındaki Komşuluk İlişkisi.....	57
Şekil III.19	Bir Hücrenin Dinamik Yapısı.....	58
Şekil III.20	C(i,j) Hücresinin Blok Diyagramı.....	58
Şekil IV.1	Kitlelerin Kural Tabanlı Tespitine Genel Bakış.....	62
Şekil IV.2	(a) Spiküler Kitle İçeren Mamografi Görüntüsü, (b) Kural Tabanlı Kitle Tespiti İçin Bulunan İlgi Alanları.....	63
Şekil IV.3	Bir Damarın Öklid Uzunluğunun Hesaplanması.....	64
Şekil IV.4	Bir Kitlenin Öklid Uzunluğunun Hesaplanması.....	65
Şekil IV.5	Bir Damarın Biçim Miktarının Hesaplanması.....	66
Şekil IV.6	Bir Kitlenin Biçim Miktarının Hesaplanması.....	67
Şekil IV.7	Şekil IV.2(b)’de Verilen Görüntüde Tespit Edilen Kitle.....	67

Şekil IV.8	Kural Tabanlı Kitle Tespiti Yazılımının Akış Diyagramı.....	68
Şekil IV.9	Kitlelerin Şablon Eşleme Yöntemiyle Tespiti.....	69
Şekil IV.10	(a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, (b) Şablon Eşleme Yöntemiyle Kitle Tespiti İçin Bulunan İlgi Alanları.....	70
Şekil IV.11	30 X 30 Piksel Boyutlarında Kitle Şablonu.....	71
Şekil IV.12	(a) Gerçek Bir Kitle, (b) Kitlenin Bir Parçasının Şablon İle Tespiti.....	72
Şekil IV.13	(a) Gerçek Bir Damar, (b) Damarın Bir Parçasının Şablon İle Tespiti.....	72
Şekil IV.14	Şekil IV.10(b)'de Verilen Görüntüde Tespit Edilen Kitle.....	73
Şekil IV.15	Kitlelerin Şablon Eşleme Yöntemiyle Tespiti Yazılımının Akış Diyagramı.....	74
Şekil IV.16	GA İle Eğitilen Şablonlar Kullanılarak Bölütlendirme ve Kitle Tespiti Aşamalarının Gösterimi.....	75
Şekil IV.17	Meme Bölgesinin Bölütlendirilmesi Amacıyla HYSA Şablonlarının Eğitimi Çalışmasının Akış Diyagramı.....	78
Şekil IV.18	a) Sınırları Düzgün Kitle İçeren Orijinal Mamografi Görüntüsü, (b) HYSA'nın Girişini Oluşturan Eşikleme Kuralı İle Elde Edilen Görüntü, (c) HYSA Kullanılarak Bölütlendirilmiş Meme Bölgesi, (d) Meme Bölgesinin Orijinal Görüntüsü.....	80
Şekil IV.19	(a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, (b) Bulunan İlgi Alanları.....	81
Şekil IV.20	T kitle şablonunun eğitimi çalışmasının akış diyagramları.....	84
Şekil IV.21	HYSA Şablonları İle Bölütlenmiş Meme Bölgesindeki Kitlelerin GA İle Eğitilmiş Şablon İle Bulunması Çalışmasının Akış Diyagramı.....	85
Şekil V.1	Akciğer BT Görüntü Kesitlerindeki Nodüllerin Kural Tabanlı Tespitine Genel Bakış.....	87
Şekil V.2	7 Adet Nodül İçeren Akciğer BT Kesiti.....	88
Şekil V.3	“Minimum Uzunluk Eşiği” 1 Piksel ve “Maximum Uzunluk Eşiği” 5 Piksel İçin İlgi Alanları.....	88
Şekil V.4	“Minimum Uzunluk Eşiği” 0 Piksel ve “Maximum Uzunluk Eşiği” 5 Piksel İçin İlgi Alanları.....	89

Şekil V.5	Tespit Edilen Akciğer Nodülleri.....	90
Şekil V.6	Akciğer Nodüllerinin Kural Tabanlı Tespiti Çalışmasının Akış Diyagramı.....	91
Şekil V.7	Nodüllerin Şablon Eşleme Yöntemiyle Tespiti.....	92
Şekil V.8	(a), (b), (c) Seri Akciğer BT Kesitleri, (d), (e), (f) Her Kesit İçin Bulunan İlgi Alanları.....	93
Şekil V.9	İlgi Alanlarının Konum Değişimlerinin Analiz Edilmesi.....	95
Şekil V.10	(a) Şekil V.8(b)'deki BT İçin Bulunan İlgi Alanları, (b) İlgi Alanlarının Konum Değişimlerine Göre Sınıflandırılması.....	95
Şekil V.11	(a) Nodül Şablonu, (b) Gerçek Akciğer Nodülü, (C) Şablon Kullanılarak Nodülün Bir Parçasının Tespit Edilmesi.....	96
Şekil V.12	Akciğer Nodüllerinin Şablon Eşleme Yöntemiyle Tespiti Çalışmasının Akış Diyagramı.....	97
Şekil V.13	Bölütlendirilmiş Akciğer Bölgesinde GA İle Eğitilen Şablonlar Kullanılarak Akciğer Nodül Tespiti Aşamalarının Gösterimi.....	98
Şekil V.14	Akciğer Bölgesinin Kural-Tabanlı Bölütlendirme Basamakları, (a) BT Görüntüsü, (b) Eşikleme, (c) Etiketleme ve Akciğer Bölgesindeki Küçük Siyah Yapıların Çıkarılması, (d) Etiketleme ve Akciğer Bölgesinin Elde Edilmesi, (e) Akciğer Bölgesinin BT Görüntüsü.....	100
Şekil V.15	Akciğer Bölgesinin Kural Tabanlı Bölütlendirilmesi Çalışmasının Akış Diyagramı.....	101
Şekil V.16	Akciğer Bölgesinin Bölütlendirilmesi Amacıyla HYSA Şablonlarının Eğitilmesi Çalışmasının Akış Diyagramı.....	104
Şekil V.17	(a) Orijinal akciğer BT Görüntüsü, (b) HYSA'nın Girişini Oluşturan Eşiklenmiş Görüntü, (c) HYSA Kullanılarak Bölütlendirilmiş Akciğer Bölgesi, (d) Akciğer Bölgesinin Orijinal Görüntüsü.....	105
Şekil V.18	T nodül şablonunun eğitimi çalışmasının akış diyagramları.....	107
Şekil V.19	Bölütlenmiş Akciğer Bölgesindeki Nodüllerin GA İle Eğitilmiş Şablon İle Bulunması Çalışmasının Akış Diyagramı.....	108
Şekil VI.1	(a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, (b) Belirlenmiş İlgi Alanları, (c) Kural Tabanlı Yaklaşım İle Kitle	

	Olarak Sınıflandırılmış İlgili Alanı, (d) Mamografi Görüntüsü Üzerinde Tespit Edilen Kitle.....	111
Şekil VI.2	(a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, b) Belirlenmiş İlgili Alanları, c) Şablon Eşleme Yöntemi İle Kitle Olarak Sınıflandırılmış İlgili Alanı, d) Mamografi Görüntüsü Üzerinde Tespit Edilen Kitle.....	112
Şekil VI.3	Şablon Eşleme Yöntemiyle Kitle Tespiti Çalışmasında Şablon Çapı İle Görüntü Başına Düşen Doğru Pozitif Oranı Grafiği.....	114
Şekil VI.4	Şablon Eşleme Yöntemiyle Kitle Tespiti Çalışmasında Şablon Çapı İle Görüntü Başına Düşen Yanlış Pozitif Oranı Grafiği.....	115
Şekil VI.5	Şablon Eşleme Yöntemiyle Kitle Tespitinde Yazılımın Performansını Gösteren FROC (Free-Response Receiver Operating Characteristic) Eğrisi.....	115
Şekil VI.6	(a) Spiküler Kitle İçeren Mamografi Görüntüsü, (b) Bölütlendirilmiş Meme Bölgesi, (d) Meme Bölgesinde Belirlenmiş İlgili Alanları, (d) Şablon Eşleme Yöntemi İle Kitle Olarak Sınıflandırılmış İlgili Alanı, (e) Mamografi Görüntüsü Üzerinde Tespit Edilen Kitle.....	119
Şekil VI.7	Yazılımın Nodül Tespit Performansını Gösteren FROC Eğrisi.....	121
Şekil VI.8	Kural Tabanlı Yöntem ile BT Kesitinde Tespit Edilen Nodüller.....	122
Şekil VI.9	Şablon Eşleme Yöntemiyle Nodül Tespitinde Şablon Çapı İle Görüntü Başına Düşen Doğru Pozitif Oranı Grafiği.....	124
Şekil VI.10	Şablon Eşleme Yöntemiyle Nodül Tespitinde Şablon Çapı İle Görüntü Başına Düşen Yanlış Pozitif Oranı Grafiği.....	125
Şekil VI.11	Şablon Eşleme Yöntemiyle Nodül Tespitinde Yazılımın Performansını Gösteren FROC (Free-Response Receiver Operating Characteristic) Eğrisi.....	125
Şekil VI.12	(a) Nodül İçeren Akciğer BT Görüntüsü, (b) 8 Yönlü Arama ve Konum Değişimi Ölçümü Kullanılarak Belirlenmiş İlgili Alanları, (c) Şablon Eşleme Yöntemi İle Nodül Olarak Sınıflandırılmış İlgili Alanı, (d) BT Görüntüsü Üzerinde Tespit Edilen Nodül.....	126
Şekil VI.13	(a) Orijinal Akciğer BT Görüntüsü, (b) Bölütlendirilmiş Akciğer Bölgesi, (c) Bölütlendirilmiş Akciğer Bölgesinde	

Konum Değişimlerini İnceleyerek Sınıflandırma Sonucu	
Tespit Edilmiş İlgili Alanları, (d) Konvolüsyon Sonucu	
Tespit Edilen Nodül, (e) Nodülün Orijinal Görüntüdeki Yeri.....	129

TABLO LİSTESİ

	<u>SAYFA NO</u>
Tablo II.1 Temel performans ölçütleri.....	23
Tablo VI.1 Kitlelerin Kural Tabanlı Tespiti Çalışmasının Sonuçları.....	110
Tablo VI.2 Kitlelerin 30 Piksel Çapındaki Şablon Kullanılarak Tespiti Çalışmasının Sonuçları.....	113
Tablo VI.3 Kitlelerin 20 Piksel Çapındaki Şablon Kullanılarak Tespiti Çalışmasının Sonuçları.....	113
Tablo VI.4 Kitlelerin 10 Piksel Çapındaki Şablon Kullanılarak Tespiti Çalışmasının Sonuçları.....	114
Tablo VI.5 Meme Bölgesinin Bölütlendirilmesinde Kullanılan HYSA Şablonlarının GA ile Eğitim Parametreleri.....	116
Tablo VI.6 Kitle Şablonu Eğitimi İçin Kullanılan Genetik Algoritma Parametreleri.....	117
Tablo VI.7 Genetik Algoritma İle Hesaplanmış Kitle Şablonu Değerleri.....	117
Tablo VI.8 Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemleriyle Kitlelerin Tespit Edilmesi Çalışmasının Sonuçları.....	118
Tablo VI.9 Akciğer Nodüllerinin Kural Tabanlı Tespiti Çalışmasının Sonuçları.....	121
Tablo VI.10 Akciğer Nodüllerinin 8 Piksel Çapındaki Şablon İle Tespit Sonuçları.....	123
Tablo VI.11 Akciğer Nodüllerinin 14 Piksel Çapındaki Şablon İle Tespit Sonuçları.....	123
Tablo VI.12 Akciğer Nodüllerinin 20 Piksel Çapındaki Şablon İle Tespit Sonuçları.....	124
Tablo VI.13 Nodül Şablonu Eğitimi İçin Kullanılan Genetik Algoritma Parametreleri.....	127

Tablo VI.14	Kural Tabanlı Bölütlendirilmiş Akciğer Bölgesindeki Nodüllerin GA İle Eğitilmiş Şablon ile Tespiti Sonuçları.....	128
Tablo VI.15	Akciğer Bölgesinin Bölütlendirilmesinde Kullanılan HYSA Şablonlarının GA ile Eğitim Parametreleri.....	130
Tablo VI.16	GA İle Eğitilmiş Şablonlar Kullanılarak Akciğer Bölgesinin Bölütlendirilmesi ve Nodüllerin Tespiti Sonuçları.....	131
Tablo VII.1	Tez Kapsamında Gerçekleştirilen Kitle Tespit Çalışmalarının Karşılaştırılması.....	134
Tablo VII.2	Literatürde MIAS Veri Seti Kullanılarak Yapılan Çalışmalar	135
Tablo VII.3	Tez Kapsamında Gerçekleştirilen Akciğer Nodülü Tespit Çalışmalarının Karşılaştırılması.....	137
Tablo VII.4	Literatürde LIDC Veri Seti Kullanılarak Yapılan Çalışmalar.....	137

BÖLÜM I

GİRİŞ VE AMAÇ

I.1. GİRİŞ

Bilgisayar destekli tespit (BDT), ileri görüntü işleme ve örüntü tanıma teknikleri kullanılarak radyoloji uzmanlarına medikal görüntülerdeki anormalliklerin tespit edilmesi çalışmalarında yardımcı olunmasıdır [1]. Bilgisayar sistemlerinin her geçen gün hem ucuzluyor, hem de güçlerinin artıyor olması, bilgisayarlarda daha büyük miktarlarda verinin saklanabilmesine olanak vermektedir. Zaman içerisinde birikmiş verilerden bilgisayar aracılığıyla çıkartılan ilginç bilgiler teşhisleri desteklemekte ve hastalığın seyri ile ilgili doktorlara önemli bilgiler sağlamaktadır.

BDT, teşhis aşamasında radyologlara destek verecek faydalı çıkarımlar sağlaması, karar vermeyi hızlandırması, insan hatasının teşhisteki yerini azaltması ve sağlık sektöründe maliyetleri düşürmesi gibi avantajlarından dolayı tıbbi görüntüye dayalı bilgisayar destekli teşhis teknikleri günümüzde önem kazanmış ve güncel teknolojilerden biri haline gelmiştir.

Elde edilen veri, çok çeşitli tipte veri tabanlarında depolanabilir. Bu veri tabanlarından biri de tıbbi görüntü veri tabanlarıdır. Günümüzde görüntü arşivleme ve iletişim sistemlerinden elde edilen dijital verilerin bilgisayarlar aracılığıyla yönetilip işlenmesiyle elde edilen bilgiler sağlık alanındaki araştırmalara büyük katkıda bulunmaktadır. Bu durum bilgisayar destekli radyoloji alanındaki gelişiminin temelini oluşturmaktadır. Bilgisayar destekli radyoloji alanındaki ileri gelişmeler yeni akıllı yöntemlerin kullanılmasıyla hastalığın teşhis edilmesi için

gerekli bilginin keşfedilmesini sağlamaktadır. Radyoloji bölümleri teknolojiye büyük gelişmenin merkezinde bulunmaktadır. Tıbbi görüntü yönetiminin neredeyse bir asırdır temelini oluşturan radyografik film yerini yeni dijital görüntüleme yöntemlerine bırakmaktadır. Kağıt ve film üzerinde veri toplanan klasik hastane bilgi sistemlerinden farklı olarak dijital cihazlardan elde edilen verilerden yararlanmak çok daha kolay gibi görünse de bu verilerin bireysel çalışmalarla işlenmesi ve yorumlanması gerekmektedir. İşte bu aşamada bilgisayar destekli teşhis teknikleri önem kazanmış ve büyük miktardaki verinin işlenip yorumlanması bu teknikler sayesinde mümkün hale gelebilmektedir.

I.2. AMAÇ

Tıbbi görüntülerin bilgisayar aracılığıyla işlenmesi ve analizi son yılların en popüler bilimsel çalışma alanlarından biri haline gelmiştir. Özellikle akciğer kanseri, göğüs kanseri, beyin hastalıkları ve göz hastalıkları üzerinde pek çok bilimsel çalışma yapılmış ve yapılmaktadır. Bu tezin amacı mamografi ve akciğer bilgisayarlı tomografi (BT) görüntülerine bilgisayar destekli tespit tekniklerini uygulayıp anormal bölgenin yerini en kısa sürede ve doğru olarak tespit edilmesini sağlayacak yöntemleri uygulamalı olarak araştırmaktır.

Tıp alanında kaydedilen teknolojik yeniliklerin temel olarak iki amacı vardır: insanlara sağlanan sağlık hizmetlerinin kalitesinin artırılması ve sağlık sektöründeki maliyetlerin düşürülmesi. Bu tez çalışması sonucunda ortaya çıkan uygulamaların her iki konuda da tıp dünyasına önemli yararlar sağlayacağı düşünülmektedir. Sağlık sektöründeki en önemli sorunlardan biri teşhiste yapılan hatalardır. Yine bu tez çalışmasının amaçlarından birisi de insan hatasının teşhisteki yerinin en aza indirilmesi ve anormal bölge tespitlerinin güvenilirliğinin artırılmasıdır.

I.3. TEZ BÖLÜMLERİNİN ÖZETİ

Bölüm II’de özellikle mamografi ve bilgisayarlı tomografi (BT) olmak üzere medikal görüntülemelerde kullanılan yöntemler ve bu yöntemlerle elde edilmiş görüntülerin özellikleri anlatılmaktadır. Ayrıca medikal görüntü değerlendirmelerinde kullanılan performans ölçümleri ve literatürde gerçekleştirilmiş mamografi ve akciğer BT görüntülerindeki anormalliklerin bilgisayar destekli tespit yöntemleri incelenmektedir.

Bölüm III’de tez çalışmalarında kullanılan veri setleri ve bu veri setlerdeki mamografi ve akciğer BT görüntülerin özellikleri anlatılmaktadır. Yine bölüm III’de tez boyunca kullanılan ilgi alanlarının belirlenmesi, bağlantılı bileşen etiketleme, şablon eşleme, konvolüsyon, genetik algoritmalar ve hücrel yapay sinir ağları gibi yöntemler açıklanmaktadır.

Bölüm IV’de bu yöntemler kullanılarak gerçekleştirilen mamografi görüntülerindeki bölütlendirme, ilgi alanlarının bulunması, şablonun eğitilmesi ve kitle tespiti çalışmaları anlatılmaktadır.

Bölüm V’de bu yöntemler kullanılarak gerçekleştirilen akciğer BT görüntülerindeki bölütlendirme, ilgi alanlarının bulunması, şablonun eğitilmesi ve nodül tespiti çalışmaları anlatılmaktadır.

Bölüm VI’da tespit çalışmalarında elde edilen sonuçlar incelenmekte ve son olarak bölüm VII’de de değerlendirme ve öneriler açıklanmaktadır.

BÖLÜM II

TIBBİ GÖRÜNTÜLEME VE BİLGİSAYAR DESTEKLİ TESPİT YÖNTEMLERİ

II.1. GİRİŞ

Bu bölümde tıp alanında kullanılan görüntüleme yöntemleri olan röntgen, mamografi, fluoroskopi, bilgisayarlı tomografi, manyetik rezonans, ultrasonografi ve nükleer tıp görüntüleme hakkında genel bilgiler verilmektedir. Özellikle tez çalışması kapsamında kullanılan meme ve akciğer kesiti görüntülerinin mamografi ve bilgisayarlı tomografi (BT) yöntemleri kullanılarak nasıl elde edildiği detaylı bir biçimde anlatılmaktadır. Mamografi ve akciğer BT görüntülerindeki normal ve anormal yapılar hakkında detaylı bilgiler verilmektedir. Ardından medikal görüntülerin değerlendirilmesinde kullanılan genel performans ölçümleri hakkında bilgi verilmektedir. Ve son olarak akciğer BT ve mamografi görüntülerinde anormalliklerin tespit edilmesi konusunda literatürde geçen çalışmalar incelenmektedir.

II.2. GÖRÜNTÜLEME YÖNTEMLERİ VE ÖZELLİKLERİ

Tıpta bir uzmanlık dalı olan radyolojide birçok ileri teknoloji ürünü modern makine ve araç-gereç bulunur. Bu makinelerin görevi vücudun organ ve dokularını bir fotoğraf şeklinde görüntülemektir. Bu görüntülerin kullanılmasının iki amacı vardır [1]:


- *Tanısal (Diyagnostik) Radyoloji:* Organ ve dokuların hasta olup olmadığını belirlemek; yani anormallikleri saptamak (tanı koymak, teşhis etmek).

- *Girişimsel Radyoloji*: Görüntülerin kılavuzluğunda hastalıklı bölgeden parça almak ya da tedavi amacıyla o bölgeye müdahale etmek.

Radyolojinin hastalıkların tanısı ile uğraşan bölümü olan tanısal radyolojideki (radyodiagnostik) görüntüleme yöntemleri ana başlıklarıyla şunlardır [2]:

- Röntgen
 - o Radyografi
 - o Fluoroskopi
- Bilgisayarlı Tomografi (BT)
- Manyetik Rezonans (MR)
- Ultrasonografi (US)
- Nükleer Tıp Görüntüleme

Röntgende görüntüler iki boyutludur, ışının geçtiği üçüncü boyuttaki yapılar üst üste düşer (projeksiyon görüntüleri). BT, MR ve US'de ise vücut bir kesit şeklinde görüntülenir, görüntülerde üst üste düşme yoktur (kesit görüntüler). Şekil II.1'de görüldüğü gibi vücudun birbirine dik üç ana düzlemi vardır: Aksiyal, sagittal, koronal. Şekil II.1(a)'da görülen aksiyal düzlem, vücudun uzun aksına dik olarak vücudun dilim dilim kesitleridir. Şekil II.1(b)'de görülen sagittal önden arkaya doğru, Şekil II.1(c)'de görülen koronal bir yandan diğerine doğru uzanan kesit düzlemleridir. Üç düzlem de birbirlerine diktir. MR ve US'de istenilen oblik düzlemlerde de kesitler alınabilir.



Şekil II.1. Vücudun (a) Aksiyal, (b) Sagittal ve (c) Koronal Düzlemleri [3]


Radyolojik görüntüler, ister projeksiyon isterse kesit görüntüler olsun, renkli Doppler dışında, bir ucunda beyaz diğer ucunda siyah rengin bulunduğu gri tonlardan oluşur [1]. X-ışını görüntüleri olan röntgen ve BT'de koyu tonlar x-ışınına görece olarak az tutan (çok geçiren), açık tonlar ise tersine çok tutan (az geçiren)

dokuları temsil eder. MR görüntülerinde ise kullanılan enerji türü farklı olduğu için gri tonların anlamları da değişiktir. Görüntü oluşturulurken kullanılan parametrelerin değiştirilmesiyle aynı dokuların farklı tonlarda görülebilmesi, MR görüntülerinin yorumlanmasını daha karmaşık hale getirir. US görüntülerinde ise açık tonlar sesin çok yankılandığı, koyu tonlar ise az yankılandığı kesimleri temsil eder. İçlerinde hiç yankılanmanın olmadığı sıvıyla dolu yapılar ile sesin hiç geçmediği kesimler siyah görülür [2].

Röntgende ve BT’de kullanılan enerji x-ışını, MR’de kullanılan enerji radyofrekans ve manyetizma, US’de ise yüksek frekanslı sestir. Medikal görüntü çekiminde görüntülenen, röntgende ve BT’de x-ışınlarının vücudu geçerken tutulma farklılıkları, MR’de hidrojen çekirdeklerinin miktarındaki ve radyofrekans enerjisini geri verme süresindeki farklılıklar, US’de ise sesin doku yüzeylerinden yansıma farklılıklarıdır [2].

Röntgende detektör olarak röntgen filmi kullanılır. Röntgen görüntüsü vücudu geçen x-ışınlarının filme doğrudan etkisiyle ortaya çıkar (analog görüntü); ancak bu şekilde görüntü elde etmek için çok fazla x-ışını gerekeceğinden pratikte üzerine x-ışını düştüğünde ışık yayan ekranlar kullanılır. Dijital röntgende ve BT’de ise bu farklılıklar detektörlerle saptanır ve dijitalize edilir [4]. Görüntüler dijitalize edilen bu değerlerden oluşturulur (dijital görüntüler). MR’de de görüntüler dijitaldir. US’de ise yankılanan sesin genlik (amplitüd) farklılıkları doğrudan kaydedilir. Bu US görüntüleri de analogdur, ancak günümüzdeki ileri teknoloji aygıtlarda veriler dijital olarak işlenir [2].

X-ışını ve radyofrekans (RF) elektromanyetik radyasyon spektrumu içerisinde yer alır (Şekil II.2). Transvers dalga formundadırlar; enerjileri frekansları ile doğru, dalga boyları ile ters orantılıdır. Ultrasonografide kullanılan ses ise mekanik bir enerji türüdür, longitudinal dalga formunda sıkışma ve gevşeme periyotları şeklinde yayılır. X-ışınları iyonizan ışınlardır, geçtikleri ortamda iyon çiftleri oluştururlar; dolayısıyla zararlıdır. Radyofrekansın ve yüksek frekanslı sesin, radyolojide kullanıldığı sınırlarda, zararlı etkileri yoktur [1].



Şekil II.2. Elektromanyetik Spektrum [1]

Genelde birbirinin tamamlayıcısı olan radyolojik görüntüleme yöntemleri, çoğu zaman da benzer bilgileri verir. Bu nedenle bir hastalığın tanısında radyolojik yöntemleri, yöntemlerin yapabilecekleri ve yapamayacakları temel alınarak, yararlılık ve zararsızlık ölçütlerine göre belirli bir disiplin içerisinde kullanmak gerekir. Radyolojik görüntüleme yöntemleri hakkında genel bilgiler aşağıda verilmektedir. Bu tez çalışması kapsamında mamografi ve BT görüntüleri üzerinde çalışıldığından bu yöntemler daha detaylı anlatılmıştır.

II.2.1. Röntgen

X-ışınlarının Wilhelm Roentgen tarafından 8 Kasım 1895’de bulunması ile ortaya çıkmış ilk medikal görüntüleme yöntemi olan röntgen bir projeksiyon yöntemidir [5]. Roentgen insan anatomisinin ilk radyografik görüntüsünü elde eden kişidir [6]. Bir projeksiyon makinesi, nasıl üzerine konan bir şekil ya da yazıyı perdeye yansıtırsa, vücudu geçen X-ışınları da vücudun iç yapılarını röntgen filmi üzerine o şekilde yansıtır. X-ışını önüne konan insan vücudu üç boyutludur; sadece eni, boyu değil derinliği de vardır ve bu derinlikteki bütün yapılar röntgen filmi üzerinde üst üste düşer (süperpozisyon). Örneğin, arka-ön bir göğüs röntgenogramında omurga, nefes borusu (trakea), kalp, göğüs kemiği (sternum) üst üste düşer ve bu yapıların her birinin açık bir şekilde görüntülenmesi engellenir [1]. Bu sorun, BT ve MR gibi kesit görüntüleme yöntemlerinin kliniğe girmesi ile çözümlenmiştir.


X-ışınları, röntgen tüpü denilen özel aygıtlarda yüksek gerilimli elektrik enerjisi ile üretilir. Gerilim ne kadar yüksekse elde edilen X-ışınının dalga boyu o kadar kısa, dolayısıyla enerjisi de o kadar yüksek olur. X-ışının dalga boyu kısalıp enerjisi arttıkça dokuyu geçme yani penetrasyon yeteneği de aynı ölçüde artar. Röntgen tüpünden çıkan X-ışınları vücudu geçerken bazı bölgelerde daha çok tutulur. Yani bazı vücut yapıları X-ışınlarını diğer kesimlere göre daha az geçirir. Bir yapının kalınlığı ne kadar fazla ve içerdiği maddelerin yoğunlukları ve atom numaraları ne kadar yüksekse, X-ışınlarını o kadar fazla tutar [4].

Röntgen görüntüsü, X-ışınının dokulardaki tutulum farklılıklarının bir röntgen filminde gösterilmesinden ibarettir. Röntgen filmi şeffaf plastik bir yapraktır. Üzerinde, her tarafa eşit bir şekilde dağıtılmış gümüş bromür (AgBr) molekülleri vardır. Bu film, aynı fotoğraf filmi gibi ışığa ve X-ışınlarına karşı duyarlıdır. Bu nedenle kaset denen ışık geçirmez gereçler içinde taşınır [1].

Röntgen filmi üzerinde görüntünün oluşumunu şu şekilde özetlenebilir (Şekil II.3) [1]:

- Röntgen filmi üzerine farklı oranlarda düşen X-ışınları karşılaştıkları AgBr moleküllerindeki bağları gevşetir, diğer moleküllerde bir değişiklik olmaz.
- X-ışınları ile karşılaşan bu röntgen filmi, bağları gevşemiş moleküllerdeki bromu gümüşten ayırıp alacak bir kimyasal solüsyon içine sokulur. Brom sıvıya geçer, gümüş film üzerinde kalır ve okside olur (I. Röntgen Banyosu)
- X-ışını düşmemiş AgBr moleküllerinin bir işlevi yoktur; başka bir kimyasal solüsyonla film üzerinden alınır (II. Röntgen Banyosu).

Bir röntgenogram üzerindeki görüntüyü oluşturan işte bu tek başına kalan gümüş atomlarıdır. Röntgenogram, röntgen filminin şeffaf plastik tabanı üzerinde okside gümüş atomlarının siyahlığı ile oluşturulur. Röntgenogram üzerindeki siyah yerler X-ışınını göreceli olarak az tutan yani çok geçirgen, beyaz yerler ise tersine çok tutan, az geçirgen bölgelerin karşılığıdır [1].




Şekil II.3. Röntgen Filmi Üzerinde Görüntü Oluşumu [1]

Vücudumuzdaki yumuşak dokuların büyük bölümü sudur. Bu dokular hidrojen ve oksijen, karbon, azot ve bazı nadir elementlerden oluşur ve ortalama atom numarası yüksek değildir. Kemik ise kalsiyum fosfat (CaPO_4) kristallerinden oluşur. Kalsiyumun atom numarası yumuşak dokulara göre oldukça yüksektir. Kaburgalar ince olmalarına rağmen açık tonda olmalarının, yani fazla X-ışını tutmalarının sebebi kalsiyumun atom numarasının yani elektron sayısının yumuşak dokulardakinden yüksek olmasıdır. Buna karşılık akciğerler, içi hava dolu olduğu yani yoğunluğu düşük olduğu için, aynı kalınlıkta olan karaciğere göre koyu gri tondadır [4].

Göğüs röntgenogramlarında bulunabilecek en beyaz yapı, film üstünde hastanın sağ ve sol tarafını işaret eden R (right) ve L (left) harfleri olabilir. İncecik bir kurşun plaktan yapılan harfler karaciğerden de kemiklerden de beyaz görünür. Bunun nedeni, kurşunun atom numarasının, dolayısıyla elektron sayısının çok yüksek olmasıdır. Aynı nedenle radyoloji çalışanlarını X-ışınlarından korumak amacıyla yapılan önlüklerin içine 0.25-0.5 mm kalınlığında kurşun tabakalar yerleştirilir. Röntgen odalarının duvarları ince kurşun levhalarla kaplanır [1].

II.2.1.1. Radyografi


Radyografide hastanın incelenecek bölgesi röntgen filmini taşıyan kaset üzerine konur. Röntgen tüpünden incelenecek bölgeye x-ışını gönderilir (Şekil II.4). X-ışınının enerjisi, miktarı ve süresi dokular arasındaki kontrast farkını ortaya çıkaracak şekilde ayarlanmalıdır. Radyografide gerçekleşen olay vücudu geçen ışının saptanmasıdır. Röntgen filmi geçen ışınları almak için objenin gerisine yerleştirilir [7].




Şekil II.4. Radyografi Görüntüleme Tekniği [1]

II.2.1.2. Mamografi

Memenin röntgenogramını elde etme yöntemidir. Sadece bu iş için üretilmiş özel röntgen cihazları ile çalışılır. Yukarıda da detaylı bir şekilde anlatıldığı gibi röntgen tabanlı olan mamografi cihazları memeyi x-ışınları göndererek incelerler [8]. Genel olarak bu inceleme işlemi her bir meme için craniocaudal (CC) adı verilen yukarıdan aşağıya doğru ve mediolateral (ML) adı verilen yandan içten dışa doğru gerçekleşir [9]. Şekil II.5(a)'da CC görüntü, Şekil II.5(b)'de ise ML görüntü verilmektedir.




(a)



(b)

Şekil II.5. Sol Memenin (a) Craniocaudal ve (b) Mediolateral Görünümler [9]

Bayan memesinin iç yapısı çoğunlukla yağ ve fibröz bağlantı dokularından oluşmaktadır. Şekil II.6'de mediolateral bir meme görüntüsü ve temel yapıları görünmektedir. Memedeki yoğun dokular meme görüntüsünde daha açık renkte görünürler. Kaslar, fibroglandular doku, kötü huylu (malign) ve iyi huylu (benign) kitleler ve damar dokusu açık renkte görünürken, yağ ve cilt daha koyu renkte görünürler [9].




Şekil II.6. Meme Yapıları [9]

Mamografi meme kanseri taramasında temel yöntemdir [8]. Günümüzde meme kanseri tarama merkezleri, mamografi ve ona bağlı gelişmiş biyopsi cihazlarından oluşmaktadır. Meme görüntülerinde rastlanabilen anormalliklerden bazıları kitleler, mikrokalsifikasyonlar ve yapısal distorsiyonlardır. Bu tez çalışması kapsamında kitlelerin yerlerinin bilgisayar aracılığıyla tespit edilmesi amaçlanmıştır. Kitle etrafındaki yapılardan daha yoğun bir yapıya sahiptir. Meme görüntülerinde karşılaşılan kitleler çeşitlilik gösterirler. Kitleler şekil, yoğunluk ve kenar gibi özellikleriyle kategorize edilirler. Şekilleri yuvarlak, oval, yuvarlak çıkıntılı ve düzensiz olabilir. Yoğunlukları yüksek yoğunluklu, düşük yoğunluklu, eşit yoğunluklu ve yağ içerikli olabilir. Kenar özellikleri de düzgün kenarlı (circumscribed) ve tırtıklı (spiküler) kenarlı olabilir [9]. Bu kategoriler radyoloji uzmanlarına kitlelerin benign veya malign oldukları konusunda karar vermelerini kolaylaştırır.

Kanser taramasında amaç kanseri erken fazda yakalamaktır. Bu evredeki kanserin tek bulgusu kötü huylu (malign) özellikler taşıyan kitlelerdir. Böyle bir lezyon saptandığında lezyonun çıkarılabilmesi için yerinin işaretlenmesi gerekir. İşaretleme, kitle alanının dışarıdan sokulan bir iğne ile belirlenmesidir ve mamografi kontrolü ile yapılır. İğnenin ucu ile işaretlenmiş doku, ameliyatla çıkarılır. Günümüzde bu işlem, meme kanseri tarama merkezlerinde stereotaktik biyopsi cihazları ile radyologlar tarafından yapılmaktadır. Mamografinin diğer kullanımı tanısal amaçlıdır. Genellikle ele gelen kitle yakınması ile başvuran hastalarda lezyonun iyi huylu (benign) ya da kötü huylu (malign) olup olmadığına karar verilmeye çalışılır. Bu konuda en önemli ölçüt lezyonun kenarıdır; genellikle düzgün kontur iyi huyluluğu, tırtıklı (spiküler) kenar ise kötü huyluluğu işaret eder [1].

II.2.1.3. Göğüs Röntgenogramı


Hava ile dolu akciğerler göğüs röntgenogramında çok iyi görünürler. Solunum sisteminin ilk radyolojik inceleme yöntemidir ve tanı değeri yüksektir. Şekil II.7(a)'da görülen normal bir göğüs röntgenogramında kalp, soluk ve yemek borusu (mediastinal yapılar) her iki akciğerin ortasındadır. Akciğerler oldukça simetrik yerleşimdedir. Röntgenogramlarda anormal görünümün nedeni anatominin bozulması ve/ya radyolojik yoğunlukların değişmesidir. Şekil II.7(b)'de akciğerdeki kanserli dokular görünmektedir.



Şekil II.7. Göğüs (Arka-Ön) Röntgenogramları (a) Normal, (b) Kanser [1]

Şekil II.8'de göğüs röntgenogramında görülebilecek yapılar belirtilmektedir. Bu yapılar ve açılımları şu şekildedir: PA (pulmoner arter), TR (Trakea , Nefes borusu), CL (köprücük kemiği), AA (arkus aorta), SVC (superior vena kava), RA


(Sağ kulakçık), CoPhS (diyaframatik oluk), LV (sol ventrikül), D (diyafram), L (karaciğer), Sca (kürek kemiği) ve R (kaburga) [10].



Şekil II.8. Göğüs Röntgenogramındaki Yapılar [10]

II.2.1.4. Fluoroskopi

Radyoskopi olarak da bilinen bu yöntemde floresan ekranlar kullanılır. Şekil II.9’da görüldüğü gibi floresan ekranlar, üzerine x-ışını düştüğünde ultraviyole ışık yayan maddelerle kaplanmış levhalardır [11]. Vücudu geçen x-ışınları bu ekran üzerinde ultraviyole ışığı şeklinde izlenebilir. Fluoroskopinin radyografiden temel farkı görüntünün canlı izlenebilmesidir. Röntgenogramlarda görüntü fotoğraf gibi sabit bir kayıt iken, fluoroskopide görüntü, canlı olarak ("real-time") izlenir [11]. Örneğin kalp atışları gözlemlenebildiği gibi, diyafragma hareketleri ya da sindirim borusunun hareketleri de incelenebilir.



Şekil II.9. Fluoroskopi Görüntüleme [1].

Radyografi ve fluoroskopi bilgisayar teknolojisi ile entegre edilerek dijitalize edilebilir. Bunun için hastayı geçen x-ışınları röntgen filmi üzerine değil dijitalize edilebilecek bir düzencek üzerine düşürülür [4]. Bu düzencek, x-ışınlarının miktarını ölçen bir dedektör sistemi olabileceği gibi, lazer ışını ile taranabilecek bir fosfor plağı da olabilir. Dijitalizasyon yöntemi ne olursa olsun, sonuçta yapılan iş hastayı geçen x-ışınlarının sayısal olarak ölçülmesi ve görüntünün bu ölçümlerden güçlü bilgisayarlar aracılığı ile oluşturulmasıdır. Vücudu geçen ve detektörlerin saptadığı x-ışını değerlerinden bilgisayar marifetiyle yapılan hesaplamalarla her piksele bir sayısal değer verilir. Görüntü, bu değerlerin karşılığı olan gri tonlarla piksellerin boyanması sonucu elde edilir [4].

II.2.2 Bilgisayarlı Tomografi (BT)


BT, 1970'li yılların başlarından itibaren kullanılan ve bilgisayar yardımıyla elde edilen ilk medikal görüntüleme yöntemidir [12]. Tomografi terimi bir kesitin (tomo) görüntüsü (grafi) anlamındadır [4]. Bir x-ışını yöntemidir. Vücudu kesitler şeklinde görüntüler (tomografi). Röntgenogramlardaki üst üste düşme ortadan kaldırılmıştır. Görüntüleri röntgenden çok daha ayrıntılıdır. BT, x-ışınının bilgisayar teknolojisi ile birleşmesinin ürünüdür. Bir BT kesiti oluşturabilmek için, kesit düzlemindeki her noktanın x-ışınını zayıflatma değerini bilmek gerekir. Bu değerler, kesit düzleminin çevre her yönünden x-ışını geçirilerek yapılan çok sayıdaki ölçümün güçlü bilgisayarlar ile işlenmesi ile bulunur. Bulunan bu sayısal değerler, karşılığı olan gri tonlarla boyanarak kesit görüntüleri elde edilir [3].

Röntgende x-ışının geçtiği boyuttaki yapılar üst üste düştüğünden, aralarındaki yoğunluk farkı belirgin olmayan yapıların seçilmesi zorlaşır. Bu sakınca ince bir

vücut dilimini görüntüleyen BT’de ortadan kaldırılmıştır. Yöntemin kullandığı enerji x-ışını olduğu için, görüntülerdeki gri tonların anlamı röntgende olduğu gibidir: Koyu gri tonlar, açık tonlara göre x-ışınlarının daha az tutulduğu bölgeleri gösterir [3].

BT aygıtında 3 ana bölüm vardır [1]: (Şekil II.10)

1. **Tarama bölümü:** Bu bölüm gantri ve hasta masasından oluşur. Gantri, içerisinde X-ışını tüpü ve detektörlerin bulunduğu, kare şeklinde, eni dar büyük bir kutudur. Ortasında gantri açıklığı denilen hastanın girdiği yuvarlak bir açıklık vardır. Tüp ve detektör zinciri bu açıklığın çevresindedir. Tüp kesit alma sırasında hastanın çevresinde döner. Hasta masası seçilen kesit kalınlığına ve kesitler arasındaki aralığa göre her kesitten sonra hareket eder. Hastayı geçerek detektörler üzerine düşen X-ışınlarının miktarı ölçülür ve dijitalize edilir.




Şekil II.10. BT Görüntüleme [1]

2. **Bilgisayar sistemi:** Detektörlerden gelen dijitalize verileri işleyen çok gelişmiş bir bilgisayar sistemidir. Bilgisayar sisteminin görevi, esas olarak bu dijital verileri kesiti oluşturacak voksellerin değerlerine dönüştürmektir.
3. **Görüntüleme bölümü:** Sayısal değerlerden oluşan görüntünün ortaya çıktığı ve işlendiği bölümdür. Çözünürlüğü yüksek bir monitör ve kayıt sistemi bulunur. Görüntüler burada işlenir ve içlerinden seçilenler film üzerine geçirilir. Bu bölüm aynı zamanda sistemin komuta ünitesidir.

Günümüzdeki modern aygıtlar vücudu kesit kesit değil bir blok halinde ve çok hızlı bir şekilde taramaktadır [4]. Helikal (spiral) BT ’de tüp inceleme sırasında


devamlı döner, hasta masası ise devamlı kayar. Bir defada 40-80 cm'lik bir alan bir nefes tutma süresinde taranabilir (Şekil II.11). Çok kesitli BT'de ise helikal teknolojiye ek olarak tek detektör halkası yerine yan yana sıralanan detektör halkaları bir detektör bloğu oluşturur [1]. Bu detektör bloklarında halka sayısı 64'e kadar çıkar. Böylece aygıtın aynı anda taradığı hacim artar. BT'de görüntü kalitesi olabileceği en üst sınırlara ulaşmıştır. Kesit kesit tarama yapan konvansiyonel BT'ye göre yeni yöntemler vücudu blok olarak taradıkları için inceleme süresi çok kısalmıştır. Hareketin istenmeyen etkileri ortadan kalkar. Ayrıca blok görüntüleme yaptığından, bu verilerden yapılacak 2 veya 3 boyutlu reformasyon görüntülerinin kalitesi yüksek olur.



Şekil II.11. (Helikal Spiral) BT Görüntüleme [1].


BT görüntüsü bir kesit görüntüsüdür. Kesit görüntü oluşturabilmek için yapılan işlemler sırasıyla şöyle özetlenebilir [1]:

- İlk koşul X-ışını tüpünün, kesit düzlemi çevresinde 360 derece dönerek dar bir X-ışını demeti göndermesidir. X-ışınları vücuda gönderilirken ölçülür, vücudu geçtikten sonra ölçülür, aradaki fark hesaplanarak detektörlerin karşısına gelen dokunun X-ışını ne oranda tuttuğu bulunur ve görüntü bu çok sayıdaki ölçümlerden karmaşık bilgisayar işlemleriyle oluşturulur .
- Bütün dijital görüntülerde olduğu gibi BT'de de görüntü piksellerden oluşur. Buna görüntü matrisi denir. Matris sayısı görüntünün iki kenarındaki piksel sayısının çarpımı şeklinde gösterilir ve günümüzdeki aygıtlarda bu sayı genellikle 512x512'dir.
- BT'de görüntüler aslında iki boyutlu değildir; bizim tarafımızdan belirlenen bir kalınlıkları vardır. BT'de ölçüm yapılan birimler piksel değil, tabanını pikselin, yüksekliğini kesit kalınlığının yaptığı dikdörtgen prizmalardır [4]. Bu prizmalara hacim elementi anlamına gelen voksel adı verilir (Şekil II.12).



Şekil II.12. Piksel ($a \times b$) ve Voksel ($a \times b \times d$), D: Görüntü Alanının Çapı [4]

- Detektörlerin ölçtüğü ve dijitalize ettiği değerler, bilgisayarlar aracılığıyla her vokselin X-ışınlarını tutma değerlerine dönüştürülür. Bu işlem suyun X-ışınını tutma değerini 0 kabul eden, bir ucu -1000 diğer ucu $+1000$ olan bir cetvele göre yapılır [13]. Bu cetvele, yöntemi geliştirenlerden biri olan İngiliz fizikçisi Hounsfield'den dolayı Hounsfield cetveli ve bu cetveldeki sayılara da BT ünitesi veya Hounsfield ünitesi (HU) adı verilir (Şekil II.13).



Şekil II.13. Hounsfield Ölçeği [1]


- Sistemin bilgisayarları bu cetvele göre tüm voksellere bir sayı verir. Bu sayı, yoğunluğu sudan yüksek olan dokularda artı, düşük olanlarda ise eksi değerlerdedir [13].
- Sistemin yapacağı son işlem Hounsfield cetveline göre sayısal değerler almış vokselleri, aldıkları sayılara uyan siyah, beyaz ve aradaki gri tonlarla boyamaktır. Bunun için artı ucu beyaz, eksi ucu siyah olan gri bir cetvel kullanılır.

Vokselin sayısal değeri vokselin içerisine giren tüm yapıların ortalama değeridir. Bir BT kesitinde gördüğümüz piksellerin rengi, aslında ait olduğu vokselin ortalama rengidir. Dijital röntgende ise pikselin rengi, X-ışınının geçtiği tüm kalınlığın X-ışınını tutma değerinin karşılığıdır [4].

BT görüntüleri tümüyle dijitaldir ve sayısal verilerden oluşması nedeniyle, görüntüler işlenebilir ve istenilen bölgelerin yoğunlukları ölçülebilir. Akciğerlerin incelenmesinde göğüs röntgenogramından sonra en sık istenen yöntem göğüs bilgisayarlı tomografisidir [2]. Şekil II.14 ve Şekil II.15’de iki farklı bölgeden alınmış akciğer BT kesitleri görülmektedir. Şekil II.14’deki yapılar şunlardır: MB-R (sağ ana bronş), MB-L (sol ana bronş), Sca (kürek kemiği), PA (pulmoner arter), DesA (azalan aort), AscA (artan aort) ve SVC (superior vena kava). Şekil II.15’de ise kalp, göğüs duvarı, perikard, plevra, aort, özofagus ve anormal bir yapı olarak nodül görülmektedir [10].



Şekil II.14. Akciğer BT Kesiti Yapıları [10].



Şekil II.15. Akciğer BT Kesiti Yapıları.

II.2.3. Manyetik Rezonans Görüntüleme (MRG)

MR, BT gibi bir kesit görüntüleme yöntemidir [14]. Görüntüleri, BT’de olduğu gibi dijitalize edilmiş değerlerden, güçlü bilgisayarlar marifetiyle oluşturulur. Dijital olan bu görüntüler, bilgisayar teknolojisinden yararlanılarak işlenir ve üç boyutlu görüntüler yapılabilir. MR yönteminin önemli bir avantajı hastanın pozisyonunu değiştirmeden her düzlemde görüntü alabilmesidir [14]. MR’nin kullandığı enerji radyo dalgalarıdır. Radyofrekans (RF) olarak isimlendirilen bu enerji, elektromanyetik radyasyon yelpazesi içerisinde yer alır. Bu teknik kanser, kalp ve damar rahatsızlıkları, eklem ve kas-iskelet düzensizlikleri gibi patolojik durumlarda geniş bir kullanım alanına sahiptir. MRG ile kemiklerin yakınındaki ve çevresindeki yumuşak dokuların çok temiz görüntülerini elde etmek mümkün olduğu için özellikle diz, omuz ve bilek gibi eklemlerin etkilendiği spor yaralanmalarında kullanılmaktadır [15]. MRG, diğer görüntüleme yöntemleri ile görülemeyecek bazı vücut yapılarının değerlendirilmelerine imkan sağlar. MRG, göğüs kanserinin erken teşhisinde önemli rol oynayan geleneksel x-ışınli mamografiye alternatif bir yöntem olarak popülaritesini arttırmaktadır [16].

II.2.4. Ultrasonografi (US)

US, vücuda yüksek frekanstaki ses dalgaları (ultrason) gönderip, farklı doku yüzeylerinden yansımalarını (eko) saptama temeline dayanır. Gri skala US adı verilen kesit yönteminde görüntüler ekoların genlikleri (amplitüdüleri) ile oluşturulur. Doppler US’de ise ekoların frekans ve faz değişiklikleri işlenerek kan akımı değerlendirilir [4].

Mekanik enerji halindeki yüksek frekanslı (ultra) ses, hasta anatomisinin görüntülerinin oluşturulmasında kullanılır. Ultrases ifadesi insan işitme sisteminin duyabileceğinden (20 kilohertz) daha fazla frekanslar için kullanılır. Tipik bir sonografi tarayıcısı 2 – 13 megahertz frekans aralığında çalışır. Bir ultrases transdüseri tarafından oluşturulan kısa süreli bir ses, görüntülenmek istenen dokuyla direkt temas ettirilir. Dokuya ulaşan ses vücuttaki yapılardan yansır ve ekolar oluşturur. Yansıyan ses dalgaları transdüsera ulaşır ve transdüserde bulunan elemanları titretir. Bu titreme elektrik darbelerine dönüşür, bu darbeler işlenir ve bir ultrasonik görüntüye dönüştürülür. Elde edilen ekodan görüntünün oluşturulabilmesi için ultrason tarayıcısının sorguladığı üç soru vardır [1]: 1) Hangi transdüser elemanları ekoyu algıladı, 2) ekonun siddeti ne kadardı?, 3) Ses iletildikten sonra

ekonun alınması ne kadar sürede gerçekleşti? Ultrason tarayıcısı bu üç soruya cevap bulduktan sonra görüntüdeki hangi pikselin açık renk, hangisinin de koyu renkte olacağına karar verir. Ultrason genelde hamilelik aşamasında fetüsün gelişiminin kontrol edilmesi amacıyla kullanılır [17].

II.2.5. Nükleer Tıp Görüntüleme

Nükleer tıp, kimyasal veya radyoaktif izotop içeren bileşimin hastaya ağız yoluyla, enjekte edilerek veya solunum yoluyla verildiği radyoloji dalıdır. Hastanın fizyolojik durumuna göre bileşim kendini vücuda yaydıktan sonra, radyoaktif bozulma sırasında yayılan x ve/veya gamma ışınları radyasyon detektörleri ile tutulur ve görüntü elde edilir. Her gamma ışının detektörde bir sintilasyon şeklinde görülmesi nedeniyle bu yönetime sintigrafi adı da verilmiştir.

II.3. TIBBİ GÖRÜNTÜ DEĞERLENDİRMELERİNDE KULLANILAN PERFORMANS ÖLÇÜMLERİ

Tıbbi karar verme son zamanlarda tıp literatürlerinde oldukça önemli bir konu haline gelmiştir. Bu bölümde bir tıbbi görüntünün değerlendirilmesinde, kanser gibi bir fizyolojik bulgu veya anormallik teşhisinde sıkça kullanılan bazı ölçütler tanımlanmıştır. Bir görüntüde “pozitif” gözlem bulgunun varolması, “negatif” gözlem ise bir bulgunun gözlemlenmemiş olması anlamına gelir. Bir “gerçek bulgu” gerçekten varolan bir durumu ifade ederken, bir gözlem bir testin sonucudur. Gerçek bulgudan ve gözlem sonucundan Tablo II.1’de gözüktüğü gibi dört temel ölçüt tanımlanır [2]:

Tablo II.1. Temel performans ölçütleri

		Gerçek Bulgu		
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H)</i>	
BDT Gözlemi	<i>Pozitif (T^+)</i>	Doğru pozitif (DP) a	Yanlış pozitif (YP) b	$T^+ = a + b$
	<i>Negatif (T)</i>	Yanlış negatif (YN) c	Doğru negatif (DN) d	$T^- = c + d$
		$H^+ = a + c$	$H^- = b + d$	

Bu ölçütler kullanılarak hesaplanan aşağıdaki değerler, medikal görüntülerine uygulanan tüm testlerin sonuçlarının değerlendirilmesinde performans kriteri olarak kullanılırlar.

$$D = \frac{a}{(a + c)} \times 100 \quad (\text{II.1})$$

Duyarlılık (Sensitivity): Gerçek bulgu değerlendirmesinde hasta olduğu saptanan vakaların $(a+c)$ içinde BDT için kullanılan yeni testin sonucuna göre de pozitif (hasta) olarak saptanan bireylerin oranına BDT sisteminin hastalığa duyarlılığı denir [2].

$$S = \frac{d}{(b + d)} \times 100 \quad (\text{II.2})$$

Seçicilik (Specificity): Gerçek bulgu değerlendirmesinde hasta olmadığı saptanan bireylerin $(b+d)$ içinde BDT için kullanılan yeni testin sonucuna göre de negatif (hasta olmayan) olarak saptanan bireylerin oranına özgüllük veya BDT sisteminin sağlıklı bireylere karşı seçiciliği denir [2].

$$Ptd = \frac{a}{(a + b)} \times 100 \quad (\text{II.3})$$

Pozitif tahmin değeri (Positive predictive value): BDT testlerinin sonucuna göre pozitif (hasta) olan vakaların içindeki gerçek hastaların oranıdır [2].

$$Ntd = \frac{d}{(c + d)} \times 100 \quad (\text{II.4})$$

Negatif tahmin değeri (Negative predictive value): BDT testlerinin sonucuna göre hasta olmadığına karar verilen bireylerin gerçekten hasta olmayan vakalara oranıdır [2].

$$Dk = \frac{(a + d)}{(a + b + c + d)} \times 100 \quad (\text{II.5})$$


Doğruluk (Accuracy): BDT değerlendirilmesi sonucunda elde edilen tüm doğru kararların toplam verilen karar sayısına oranıdır. Bu değerin yüksek olması sistemin tanı için klinik olarak kullanılabilirliğini gösterir [2,4].

II.4. BDT ÇALIŞMALARINA İLİŞKİN LİTERATÜR ARAŞTIRMASI

BDT'deki güncel konulardan ikisi, akciğer bilgisayarlı tomografi (BT) görüntülerindeki nodüllerin ve mamografi görüntülerindeki anormalliklerin tespit edilmesidir. Bu konularda son yıllarda yapılan akademik çalışmalarda kullanılan yöntemlerden bazıları şunlardır: Gauss filtresi [18-22], eşikleme [23-25], alan büyütme [26-29], morfolojik filtreler [30-34], histogram eşikleme [35,36], bulanık mantık [37-39], dalgacık dönüşümü [40-43] ve yapay sinir ağları [44-46]. Bu bölümde, yapılmış olan bu çalışmalardan bazıları incelenmiştir. Öncelikle genel bir özet verildikten sonra özellikle şablon eşleme yöntemi kullanılarak gerçekleştirilmiş çalışmalar incelenmiştir.

Literatürdeki çalışmalar incelendiğinde BDT basamakları Şekil II.16'da görüldüğü gibidir. Akciğer BT'lerinde akciğer bölgesinin, mamografi görüntülerinde de meme bölgesinin elde edilmesini sağlayan bölütleme aşaması, anormallik arama alanını daraltarak BDT'nin hızını arttırmaktadır. Kural tabanlı eşikleme yöntemi ile bölütleme, yoğunluk değişimini kontrol eden histogram tabanlı bölütleme ve bölge büyütme tabanlı bölütleme literatürde en sık karşılaşılan bölütleme yöntemlerindendir. İkinci bir aşama olarak karşımıza çıkan ilgi alanlarının

belirlenmesi işlemindeki amaç anormal olmaya aday yapıların ortaya çıkarılması ve arama işleminin bu yapılar üzerinde gerçekleştirilerek sonucun en kısa sürede elde edilmesidir. Literatürde ilgi alanları tespiti amacıyla genel olarak kullanılan yöntemler gri seviyeli eşikleme, filtreleme, bulanık mantık ve kümeleme yöntemleridir. Son aşamada ilgi alanlarının sınıflandırılması ve anormalliklerin tespiti gerçekleştirilmektedir. Bu amaçla kural tabanlı yaklaşımlar, şablon eşleme, en yakın komşu kümelemesi, Markov rastgele alanları, yapay sinir ağları ve Bayes sınıflandırıcı kullanılan yöntemlerden birkaçıdır.



Şekil II.16. Genel BDT Basamakları

Giger [47] ve Armato [48] tarafından da kullanılan gri seviyeli eşikleme yöntemlerinde ilgi alanlarının belirlenmesinde sadece her bir pikselin yoğunluk değerleri kullanılmıştır. Lin [49] tarafından kullanılan bulanık sinir ağı modelinde akciğer bölgesinin histogramına göre bir eşik değeri seçilmiş ve ardından bu eşik değerinden yüksek yoğunluktaki yapılar ilgi alanı olarak tespit edilmiştir. Kanazawa [50] tarafından kullanılan bulanık kümeleme yöntemi de direkt olarak gri seviye özelliğine bağlıdır. Filtreleme yöntemlerinde orijinal görüntüye filtre uygulanır ve filtreleme sonucu ilgi alanı olarak belirlenir. Wiemker [51] eşiklenmiş binary

görüntüye bir filtre uygulayarak dairesel tüm yapıları bulmuştur. Penedo [52] tarafından gerçekleştirilen yapay sinir ağı tabanlı yöntemde ilgi alanlarının bulunması amacıyla eğitilmiş bir Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP) kullanılmıştır.


Brzakovic ve Neskovic meme bölgesinin bölütlendirilmesi için bulanık mantık tabanlı bir algoritma kullanmışlardır [53]. Petrick ve arkadaşları mamografik kitlelerin tespiti için iki basamaklı bir yoğunluk ağırlıklı parlaklık artırma algoritması kullanmışlardır [54]. Chan ve arkadaşları uzamsal gri seviye bağımlılık matrislerinden çıkarılan doku özelliklerini kullanarak kitlelerin normal yapılardan ayrılmasını sağlamışlardır [55]. Yin ve arkadaşları kitle lezyonlarının belirlenmesi için mamografik asimetrisi tespit etmişlerdir [56]. Aynı zamanda çeşitli şirketler bazı ticari yazılımlar da geliştirmişlerdir. Bu yazılımların tescilli ürünler olması sebebiyle doğal olarak şirketler görüntü işleme algoritmaları hakkında çok fazla bilgi vermemektedirler. R2 Technology (*Los Altos, CA, ABD*) adlı şirket tarafından çıkarılan ImageChecker yazılımı günümüzde en çok kullanılan BDT yazılımlarından birisidir. Bu yazılım kitle tespiti için yoğun bölgeleri bir merkezden yayılan dairelerle arar. İlgi alanları işaretlendikten sonra bir yapay sinir ağı algoritması ile işlenmektedirler. İkinci bir yazılım da CADx Medical Systems (*Montreal, Quebec, Kanada*) firması tarafından üretilen ve Second Look adı verilen yazılımdır. Şüpheli alanlar yapay zeka algoritmaları kullanılarak belirlendikten sonra radyolojik ve istatistiksel özellikler kullanılarak analiz edilirler.

Ryan ve arkadaşları [57] nodülleri ve damarları modellemek için küreleri ve silindirleri kullanmışlardır. Nodülleri damarlardan ayırma işlemi yumuşak doku ve hava yoğunluklarını karşılaştırarak gerçekleştirilmiştir. Kanazawa ve arkadaşları [58] damarları ve potansiyel nodülleri belirlemek için bir bulanık kümeleme (fuzzy clustering) algoritması geliştirmişlerdir. Nodülleri damarlardan ayırmak için kural tabanlı bir yaklaşım kullanılmıştır. Sonuçta 224 durumlu bir veri setinde 11 yanlış pozitif ile %86 duyarlılık elde edilmiştir. Giger ve arkadaşları [59] nodülleri damarlardan ayırmak için geometrik şekilleri çeşitli gri seviyeli eşik değerleri ile analiz etmişlerdir. 8 durumlu veri setinde her durum için ortalama 1.25 yanlış pozitif ile %94 duyarlılık elde edilmiştir. Ko ve arkadaşları [60] gri seviyeli eşik değer tabanlı bir nodul tespit sistemi geliştirmişlerdir. Belirlenemeyen yanlış pozitif değerine rağmen % 86 duyarlılık elde edilmiştir. Armato ve arkadaşları [61] BT'lerde akciğer nodüllerinin otomatik tespiti için 3 boyutlu bir yaklaşım geliştirmişlerdir.

Akciğer nodül adayları BT görüntülerinden gri seviyeli eşik değerleri kullanılarak elde edilmiştir. McNitt-Gray ve arkadaşları [62] akciğer nodüllerini zararlı ve zararsız olarak nitelemek için örüntü-sınıflama yaklaşımı kullanmışlardır. Kawata ve arkadaşları [63] akciğer nodüllerinin dahili yapılarını histogram özelliklerini kullanarak analiz etmişlerdir. Reeves ve arkadaşları [64] akciğer nodüllerini sınıflamak için şekil metriklerini araştırmışlardır. Penedo ve arkadaşları [65] birincisi ilgi alanlarını, ikincisi de nodülleri tespit edecek iki yapay sinir ağı kullanmışlardır. 90 nodül içeren 60 radyografi görüntüsü kullanarak yöntemlerini deneyen grup, nodül büyüklüklerine bağlı olarak %89 - %96 aralığında duyarlılık ve görüntü başına 5-7 YP elde etmişlerdir. Xu ve arkadaşları [66] karar kuralları kümesi ve ileri beslemeli yapay sinir ağı kullanarak nodül örüntülerini tespit etmişlerdir. 100 normal ve 100 anormal görüntü kullanan Xu ve arkadaşları 1.7 YP oranıyla %70 duyarlılık elde etmişlerdir. Farklı bir yöntem izleyene Lo ve arkadaşları [67] iki aşamalı bir sistem kullanmışlardır. İlki ilgi alanlarını belirlerken, diğeri de konvolüsyon tabanlı sinir ağı kullanarak nodülleri belirlemişlerdir.

Medikal görüntülerin analizini konu alan akademik çalışmalarda kullanılan en önemli tekniklerden biri de şablon eşleme tekniğidir. Hatanaka ve arkadaşları [68] tarafından yapılan çalışmada, mamogramlardaki kitlelerin tespiti için eşikleme tekniğini kullanarak bir algoritma geliştirilmiş ve filmin köşelerindeki kitlelerin tespitinde kısmi bölge kaybı sorunu yaşandığı belirlenmiştir [68]. Bu problemi çözmek için şablon eşleme yöntemini kullanmışlar ve kısmen kaybolan kitleleri sektör formundaki modele benzerlikleri ile tespit etmişlerdir. Bu çalışmada esas amaç göğüs duvarına yakın bölgedeki kitleleri tespit etmek olduğu için arama alanı olarak Şekil II.17'de görüldüğü gibi pectoralis kasının içi (A alanı) ve dışı (B alanı) olmak üzere iki bölge belirlenmiştir [68]. C bölgesi tarama alanının dışında bırakılmıştır. Benzerliği hesaplamak için dört özellik kullanılmıştır: 1) ortalama piksel değeri, 2) piksel değerlerinin standart sapması, 3) sektör-formundaki model ile tanımlanan standart korelasyon katsayısı, 4) değişen yoğunluk ile karşılaştırılan yoğunlaşma özelliği. 1, 2 ve 4 numaralı özellikleri hesaplamak için Şekil II.17'de görüldüğü üzere A ve B maskeleri kullanılmıştır. Şekil II.17'de görülmekte olan A ve B maskeleri için piksel değerlerin ortalaması ve standart sapması hesaplanmıştır. Kitlelerin her zaman düşük yoğunluklu alanlar oldukları, piksel değerlerinin standart sapmasının meme bezleri ve kan damarları gibi yapılarından daha düşük olduğu bilinmektedir [68]. Bu yüzden 3 ve 4 numaralı özellikleri hesaplarken yüksek piksel

değerli veya yüksek standart sapmalı aday bölgelerin göz ardı edilmesi mümkün görülmüştür [68].



Şekil II.17. Özellikleri Hesaplamak İçin Kullanılan A ve B Maskeleri [68].

Bir kitlenin yoğunluğu Gauss dağılımına sahip olduğundan, bu çalışmada gerçek kitleyi temsilen benzer bir dağılım kullanılmıştır. Kitle modeli olarak Gauss dağılımından faydalanarak çapı 41 piksel ve merkez açısı 120° olan bir bölge kullanılmıştır. Şablon eşleme için R ve L görüntüleri referans görüntüler olarak kullanılmıştır. B alanı için benzerlik A ve R, B ve L olmak üzere her iki görüntü çifti ile hesaplanmış, A alanı için ise benzerlik sadece A ve R görüntüleri ile hesaplanmıştır [68]. Benzerlik Şekil II.17’de görülen tüm arama alanları için hesaplanmıştır ve iki arama alanı için özellik hesaplama ve şablon eşleme görüntüleri farklıydı. Şekil II.17’de gösterildiği gibi B alanı için benzerlik A ve R, B ve L ikili görüntüleri kullanılarak hesaplanmıştır. Fakat A alanı için sadece A ve R görüntüleri kullanıldı çünkü B ve L görüntülerinin kullanımı pektoralis kas alanında eksik tespitlere sebep olmuştur. Bir mamogramın sağ üst tarafından (pektoralis kası yönünde) sol alt tarafına (meme ucu) doğru gidilirse piksel değerlerinin arttığı (daha koyu hale geldiği) görülür. Özellikle piksel değerlerindeki değişim pektoralis kası bölgesi ile göğüs bölgesi sınırında çok belirginleşir. Korelasyon sabiti $R(i,j)$ yi hesaplamak için mamogramın 41 X 41 piksellik alanı ve R veya L görüntüsü kullanılmıştır. L görüntüsü Gauss dağılımına bağlı olduğu için, merkezden sol alt köşeye gidildikçe piksel değerleri artar [68]. Bunun gibi pektoralis kası bölgesinde de piksel değerlerinde benzer artışlar görülmektedir. Ek olarak aynı durum kitle aday alanında da ortaya

çıkar [68]. Bu yüzden pektoralis kası bölgesinde L örüntüsü kullanıldığında yanlış tespit sayısı artacaktır. Oysaki R örüntüsünde merkezden sol üst köşeye gidildikçe piksel değerleri artar. Pektoralis kasının hiçbir bölgesinde belirtilen yönde bir artma olmaz. Bu yüzden pektoralis kası bölgesinde R örüntüsünü kullanarak hatalı kitle tespit sayısını azaltmak mümkündür. $S(i,j)$ eşik değeri deneysel olarak 56 olarak belirlenmiştir ve benzerliği bu değerden fazla olan noktalar kötü huylu kitleyi oluşturan şüpheli noktalardan olarak belirlenir. Aday noktalardan elde edilen bilgilerle şüpheli aday bölgeler belirlenmiştir. Komşu aday noktayla uzaklığı 20 pikselden az olan noktalar aynı şüpheli bölgenin bir parçası olarak değerlendirilmiştir. Şüpheli aday bölge dışındaki noktalar YP olarak değerlendirilmiştir.

Bir parçası kısmen belirsiz olan kitlelerin tespiti için geliştirilen bu metodun değerlendirilmesi için 30 adet kısmen belirsiz kitle içeren mamogram ve 305 adet normal mamogram kullanılmıştır. Kısmen belirsiz kitlelerin tespit duyarlılığı yanlış pozitif oranının görüntü başına 0.2 olarak sabitlenmesi durumunda %90 a çıkmıştır [68].

Mamogramları yorumlarken aralık değişiminin analiz edilmesi önemlidir. Hadjiiski ve arkadaşları [69] tarafından gerçekleştirilen çalışmanın amacı aynı görüş alanından en son mamogramdaki kitle ile önceki mamogram arasındaki farkların bilgisayarlı analizini yapan bir teknik geliştirmektir. Bu bilgisayar algoritması radyoloji uzmanlarına aralık değişimini ölçmeyi ve böylece iyi huylu ve kötü huylu kitlelerin ayrımını yapmayı sağlamıştır. Bu teknik tamamen geliştirildiğinde radyoloji uzmanı veya BDT sistemi tarafından belirlenen kitleye uygulanmış ve böylece aralık değişim analizi otomatik BDT sisteminin bir parçası olarak entegre edilebilmiştir. Bu çalışmada en son mamogramdaki kitlenin bilinmesi durumunda önceki mamogramda kitleye karşılık gelen yerin otomatik olarak belirlenmesine önem verilmiştir. Bunun için en son mamogramda radyoloji uzmanı tarafından belirlenen kitle konumu başlangıç noktası olarak kullanılmış ve önceki mamogramdaki kitle pozisyonu göğüs geometrisine göre tahmin edilmiştir [69]. En son mamogramdaki kitlenin konumu meme ucu merkez olmak üzere belirlenmiştir. İlk olarak en son mamogramdaki kitlenin konumuna göre önceki mamogram üzerinde kitle merkezi merkez alınarak yelpaze şeklinde bir başlangıç arama alanı tanımlanmış ve en son mamogramda yelpaze şeklinde bir şablon belirlenmiştir [69]. Önceki mamogram üzerinde en iyi arama alanının bulunması işlemi en son

mamogramdan alınmış yelpaze şeklindeki şablon ve önceki mamogramdaki göğüs yapıları arasındaki maksimum korelasyonun bulunması ile gerçekleştirilmiştir [69]. Bu çalışmada kullanılan benzerlik ölçümü Pearson'ın korelasyon katsayısıdır [69]. Şablon yelpaze şeklindeki başlangıç arama alanında piksel piksel kaydırılmış ve her piksel konumu için korelasyon ölçümü hesaplanmıştır. Maksimum korelasyonu sağlayan piksel en iyi arama alanının merkezi olarak kullanılmıştır. Ayrıca korelasyon miktarını arttırmak için yelpaze şeklindeki şablonunu döndürülmesi gerekmektedir. Bu döndürme işlemi için afin dönüşümü ve tekyönlü eniyileme kullanılmıştır. Afin dönüşümü ölçekleme, dönme ve çeviri işlemlerini birleştiren lineer bir dönüşümdür [69].

Bu aşamada önceki mamogram üzerinde daha küçük ölçülerde yeni bir arama alanı belirlenmiştir. Bu yeni arama alanını büyüklüğü sonucu iyileştirecek şekilde deneysel olarak belirlenmiştir. En son mamogramdan kitle şablonu elde edilmiştir. Ardından önceki mamogramdaki kitlenin yeri arama alanındaki yapılar ve kitle şablonu arasındaki korelasyonun maksimum olduğu noktada tespit edilmiş olur [69]. Bu çalışmanın performansını ölçmek için en son mamogramlardaki kitlelerin yerleri teşhis edilmiş 124 mamogram çifti kullanılmıştır. Bu 124 mamogram çiftinden 73 tanesi kötü huylu ve 51 tanesi de iyi huyludur [69]. Radyoloji uzmanları tarafından her bir mamogramda kitle etrafına kutu çizilmiş ve meme ucu konumu işaretlenmiştir. Aynı zamanda hem en son mamogramlarda hem de önceki mamogramlarda kitlelerin büyüklükleri ölçülmüştür. Üzerinde çalışılan yöntemlerin doğruluğu iki ölçüm ile test edilmiştir. İlk ölçüm önceki mamogramda tahmin edilen ve gerçek lezyon arasındaki örtüşme alanı miktarıdır. Tahmin edilen lezyon konumlarının %87 oranında gerçek lezyon konumlarıyla örtüştüğü tespit edilmiştir. İkinci ölçüm ise tahmin edilen lezyon merkezinin gerçek lezyon merkezinden öklid uzaklık miktarıdır. 124 çift için önceki mamogramlardaki tahmin edilen lezyon merkezinin gerçek lezyon merkezinden ortalama uzaklığı 4.2 ± 5.7 mm ve en büyük uzaklık ise 31.6 mm olarak bulunmuştur [69].

Lee ve arkadaşları [70] tarafından yapılan çalışmanın amacı akciğer bilgisayarlı tomografilerindeki nodüllerin bilgisayar destekli tespiti için bir teknik geliştirmektir. Akciğer nodüllerinin tespiti için, gerçek nodülü temsil eden modeller kullanılarak iki şablon eşleme tekniği kullanılmıştır. Bu teknikte nodülün yeri ve büyüklüğü önemsenmiştir. Küçük nodüller sadece bir kesitte görülürken (2 boyutlu yaklaşım), büyük nodüller birden fazla kesitte ve devam eden biçimde görülebilirler

(3 boyutlu yaklaşım). Ayrıca nodüller akciğer duvarına dayanmış yarı dairesel olarak da görülebilmektedir. Bu çalışmada akciğer bölgesindeki nodüllerin tespiti için genetik algoritma tabanlı yeni bir şablon eşleme tekniği geliştirilmiştir [70]. Bu şablon eşleme tekniğinde küresel ve dairesel olmak üzere 2 farklı tipte şablonlar kullanılmıştır. BT'lerdeki nodüllerin değerlerinin Gauss dağılımına dayanan küresel şablonlar büyük nodüllerin tespitinde, küresel şablonların ortadaki kesitinden oluşan dairesel şablonlar da küçük nodüllerin tespitinde kullanılmıştır [70]. Bu teknikte, incelenen görüntüdeki hedef konumları en iyi şekilde seçmek ve hızlı şablon eşleme için çeşitli şablonlar arasından en uygununu seçmek için genetik algoritma tekniği kullanılmıştır. Kullanılan genetik algoritmadaki her bir bireyin kromozomu hedef konumları seçmek için ve en uygun şablonu seçmek için ikili bitlerden oluşur. Kromozom 25 bitten oluşmaktadır. Bireyin uygunluğunun belirlenmesinde benzerlik ölçümü olarak çapraz korelasyon kullanılmıştır [70].

Çapraz korelasyon katsayısı Cauchy–Schwarz eşitsizliğine göre -1 ile 1 arasında değişmektedir. n değeri görüntüdeki piksel sayısıdır [70]. a ve b değerleri karşılaştırılacak resimleri belirtmektedirler. a_i değeri a görüntüsündeki i inci piksel, b_i değeri b görüntüsündeki i inci pikseldir. Akciğer duvarındaki nodülleri tespit etmek için şablon eşleme tekniğinde yarı dairesel şablonlar kullanılmış ve hedef noktadaki akciğer duvar sınırının açısı

Bu çalışma 557 görüntü üzerinde gerçekleştirilmiştir. Görüntü başına 1.1 yanlış pozitif oranıyla, 98 nodülden 71 tanesi doğru bir şekilde tespit edilmiştir [70].

Tourassi ve arkadaşları [71] mamogramlardaki kitlelerin tespiti için bilgi tabanlı bir sistem geliştirmişlerdir. Bu çalışmadaki bilgisayar destekli tespit sistemi, kesin referansları (ground truth) bilinen mamografik ilgi alanlarından oluşan bir bilgi veri bankasından faydalanmıştır [71]. Bilgi tabanlı BDT sistemleri veri bankası kullanarak kanıt tabanlı karar vermeyi amaçlanmıştır. Bir doktorun o anki durum ile geçmişte karşılaştıkları arasında ilişki kurması gibi, bilgi tabanlı sistem de yeni durum ile bilgi veri bankasındaki benzer durumlar arasında bağıntı kurar. Benzer durumlara göre aradaki eşleme yeteri kadar yakınsa yeni duruma mevcut teşhislerden biri atanır [71]. Veri bankasındaki her bir ilgi alanı şablon görevi görmüştür. Bu sistemdeki şablon eşleme yaklaşımında, sorgulanan ilgi alanının gerçek kitle ile arasındaki benzerlik ölçümü karşılıklı bilgi ilkesi ile kontrol edilmiştir. Karşılıklı bilgi ilkesi bilgi teorisinin en temel ilkelerindendir ve iki nesne arasında birinin diğerini ne kadar açıklayabileceğini ölçer. Başka bir deyişle karşılıklı ilişki, x ve y

gibi iki deęişken arasındaki benzerlięin ölçümüdür. Bilgi içeriklerine göre tüm benzer ilgi alanları sıralı bir şekilde elde edilmiştir. Ardından sorgulamanın en iyi sonuçlarına dayanarak karar indeksi hesaplanmıştır [71]. Karar indeksi, sorgulanan ilgi alanındaki kitlenin varlığını belirleyecek en iyi eşlenmiş şablonların benzerlik ve kesin referans bilgilerini en verimli şekilde birleştirmiştir.

Sistem 1465 ilgi alanından oluşan bir veritabanı kullanılarak geliştirilmiş ve değerlendirilmiştir. Veritabanında 809 adet saptanmış kitle ilgi alanı (455 adet kötü huylu ve 354 adet iyi huylu) ve 656 adet normal ilgi alanı bulunmaktadır. Sonuçlar sistem duyarlılığının %95'e ulaştığını göstermektedir [71].

Farag ve arkadaşları [72] tarafından yapılan çalışmanın amacı, akciğer görüntülerindeki nodüllerin otomatik olarak tespit edilmesidir. Nodüllerin tespit edilmesinin ilk aşaması arama alanını azaltan iki basamaklı bölütlendirme işlemidir. İlk basamakta akciğerler, BT kesitinde görülen ve kendilerini çevreleyen anatomik yapılardan (kaburga, karaciğer ve diğer organlar) ayrılmaktadırlar. İkinci basamakta ise ayrılmış durumdaki akciğerlerdeki atardamarlar, toplardamarlar, bronşlar, bronsiyoller ve akciğer anormallikler çıkartılmaktadır. Bu bölütlendirme işlemi Markov-Gibbs rasgele alanları algoritmaları ile gerçekleştirilmiştir. Bu çalışmada esas olarak nodüllerin 2 ve 3 boyutlu şekli deęişebilen şablonlar kullanılarak geometrik yapıları ve gri seviye dağılımları gibi özelliklerinden faydalanarak tespit edilmesine odaklanılmıştır. Ortası boş ve ortası dolu büyük nodüllerin tespiti için 3 katmanlı şablonlar, küçük nodüllerin tespiti için dairesel şablonlar, akciğer duvarındaki nodüllerin tespiti için de yarı dairesel şablonlar kullanılmıştır [72].

Bu çalışmada benzerlik ölçümü olarak çapraz korelasyon kullanılmıştır. İncelenen 3 boyutlu görüntüdeki korelasyonu maksimum değere ulaştıracak şablonun konumunun, boyutunun ve açısının (akciğer duvarındaki nodüller için) belirlenmesi genetik eniyileme ile gerçekleştirilmiştir. Gerçek akciğer nodülleri tam olarak küresel, dairesel veya yarı dairesel olmadığı için bazı gerçek nodüller tespit edilemedięi gibi yanlış pozitif sayısı da artmaktadır [72]. Bu hata oranını azaltmak için aday nodüller üzerinde sınıflama yapılmaktadır. Bu sınıflama işlemi tespit edilen her nodülün şu üç dokusal ve geometrik özellięi ile gerçekleştirilir: (i) şablonun merkezi ile nesnenin kenarı arasındaki uzaklıkların maksimumu ile minimumu arasındaki fark olan radyal düzensizlik, (ii) 2 veya 3 boyutlu nodül şablonundaki ortalama gri seviye, (iii) 2 veya 3 boyutlu nodül şablonundaki kenarda olan gri seviye dağılımı için %10 yana konmuş gri seviye. Yanlış pozitif nodüller ve doęru

pozitif nodüller arasında ayırım yapmak için yanlış ve doğru nodüllerden oluşan eğitim setinden faydalanılmış ve bu eğitim seti ile eğitilen Bayesian sınıflandırma yöntemi kullanılmıştır. Yanlış pozitif nodüllerin sınıflandırılması için üç özelliğin hepsi kullanılırken, akciğer duvarındaki nodüller için son iki özellik kullanılmıştır [72].

Bu algoritma 200 BT görüntüsü üzerinde test edilmiştir. Bunlardan 21 tanesi anormallikler içerirken, 179 tanesi anormal durum içermiyordu. Birinci aşamada şablon eşleme 130 gerçek nodülden 110 tanesini 49 adet yanlış pozitif nodül ile tespit etmiştir. İkinci aşamadaki sınıflandırma ile yanlış pozitif nodül sayısı 12'ye inmişken doğru pozitif nodül sayısı da 3 tane azalmıştır. Sonuç olarak sistemin doğru tespit oranı %82.3 ve yanlış pozitif oranı da %9.2 olmuştur [72].

Wang ve arkadaşları [73] yüksek risk grubundaki hastaların üç boyutlu göğüs BT görüntülerindeki 6-20 mm çapındaki akciğer tümörlerinin bilgisayarlı tespitini gerçekleştiren tamamen otomatikleşmiş bir yöntem geliştirmişlerdir. Tipik bir 3 boyutlu durumu temsil etmek amacıyla 6 mm çapındaki nodül için küre görünümünde sabit yoğunluklu bir model oluşturulmuştur. Düzlemdeki her piksel 1x1 mm ve her kesit 3mm kalınlığındadır [73]. Bu küresel modeldeki kesim örneklem düzlemlerinin konumlarındaki değişebilirliği dikkate alarak her model boyutu için kaydırmalı üç şablon modeli oluşturulmuştur. Hesaplama hızını arttırmak için otomatik bir akciğer bölütleme prosedürü gerçekleştirilerek akciğer dışındaki önemsiz yapılar çıkarılmıştır. Bu bölütlendirme işleminde histogram tabanlı eşikleme ile akciğer kendisini çevreleyen kaslardan ve kemiksel yapılardan ayrılmıştır. Ardından gelen morfolojik işlemlerle de akciğerdeki damarlar ayrılmıştır. Böylece elde edilen görüntü ile sadece akciğer yapısı üzerine maskeleme yapılarak nodüllerin aranması sağlanmıştır. Bu aşamada denklem 7 kullanılarak 3 boyutlu normalize edilmiş çapraz korelasyon katsayısı (normalized cross correlation coefficient, NCCC) hesaplaması yapılarak akciğer hacmi üzerinde 3 boyutlu modele uygun yapılar aranmıştır. Burada x modeldeki seri kesitleri ve y hasta görüntü kesitlerini temsil etmektedir. 3 boyutlu NCCC her akciğer kesiti için hesaplanmıştır. Normalize edilmiş korelasyonda mükemmel uyum 1 ile gösterilmiştir [73].

Sonuçta elde edilen görüntü serilerinde üç boyutlu nesnelerle üç boyutlu korelasyon ile arama yapılarak tümörler elde edilmiştir. Bu yöntem akciğerinde metastatik hastalığı bilinen 7 hastadan alınan görüntüler üzerinde test edilmiştir. 479 kesitten oluşan bu görüntülerde 40 adet tanımlanabilir lezyon bulunmuştur.

Görüntüler üzerinde 6, 8 ve 10 mm çaplarındaki üç küresel şablon kullanılmıştır ve 40 adet gerçek tümörden tamamı 12 adet yanlış pozitif ile tespit edilebilmiştir [73].

Anormallik tespiti uygulamalarında en hızlı yöntem gri seviye tabanlı yöntemlerdir [74]. Akciğer nodül tespit çalışmalarında bu yöntem, diğer yapılardan izole durumdaki nodüllerin tespitinde çok iyi sonuçlar vermektedir. Akciğer nodülleri üzerinde yapılan ilk BDT çalışmalarında 5-10 mm kalınlığındaki kesitler kullanılmaktaydı. Bu görüntülerde karşılaşılan akciğer duvarı veya damar gibi yapılara yapışık durumdaki nodüllerin tespiti için gri seviye tabanlı yöntemler uygun değildir. Çünkü 5-10 mm kalınlığında kesitlerdeki nodül ile yapışık olduğu yapı benzer yoğunluklar göstermektedir. Bu nedenle bölge büyütme veya bağlantılı bileşen etiketleme (BBE) gibi yöntemler nodülü normal yapının bir parçası gibi algılamaktadır.

Günümüzde kullanılan ve 1 mm'in altında kalınlığa sahip kesitler sunan yüksek çözünürlüklü BT'lerinde (HRCT) bu problem aşılmıştır. Ancak bu durumda da görüntü sayısı arttığı için işlenecek veri miktarı da oldukça artmaktadır. Ayrıca kesitlerdeki bu inceleme ile doğru orantılı olarak her kesitte belirlenen ilgi alanı sayısı da artmaktadır. Bu nedenlerle yüksek çözünürlüklü BT'lerin incelendiği BDT yöntemlerinde sadece uygun yoğunluktaki yapıların aranması yeterli değildir. Bu çalışmalarda ilgi alanlarının şekil analizleri de yapılmalıdır. Bu nedenlerle nodüllerin normal yapılardan ayırt edilmesi için gri seviye tabanlı yöntemler morfolojik işlemler ile birlikte kullanılmaktadır. Örneğin Brown [75] tarafından kullanılan yöntemde ilgi alanları eşikleme ile elde edilmiş ve ardından nodülleri damarlardan ayırmak için morfolojik işlemler kullanılmıştır.

Lee [76] tarafından da kullanılan şablon tabanlı yöntemler nodül tespitinde yüksek tespit oranları sunmaktadır. Ancak bu yöntemlerin en büyük dezavantajı yüksek hesaplama maliyetleridir. Şablona benzer görüntülerin tespit edilmesi amacıyla korelasyon, karşılıklı bilgi, gradyan farkı, rank dönüşümü, Gamma katsayısı ve Jaccard gibi benzerlik ölçüm yöntemleri kullanılmaktadır.

BÖLÜM III


TIBBİ GÖRÜNTÜLERDE BİLGİSAYAR DESTEKLİ TESPİT YAZILIMLARININ TASARIMI İÇİN KULLANILAN VERİ SETLERİ VE YÖNTEMLER

III.1. GİRİŞ


Bu bölümde önce tez çalışması kapsamında kullanılan mamogram ve akciğer BT veri setleri anlatılmaktadır. Ardından bu veri setlerindeki anormalliklerin tespitinde kullanılan ilgi alanlarının 8 yönlü arama yöntemi ile belirlenmesi, bağlantılı bileşen etiketleme, şablon eşleme yöntemi, konvolüsyon, genetik algoritmalar ve hücrel yapay sinir ağları gibi araştırma yöntemleri açıklanmaktadır. Tez kapsamında tıbbi görüntülerdeki anormallikleri tespit çalışmaları Şekil II.16'da görülen BDT basamakları dikkate alınarak gerçekleştirilmiştir.

III.2. KULLANILAN VERİ SETLERİ

Bu tez çalışması kapsamında gerçekleştirilen mamografi görüntülerindeki kitlelerin tespitini gerçekleştiren BDT sisteminin geliştirilmesi ve değerlendirilmesi için MiniMIAS (Mammographic Images Analysis Society) [77] veri seti kullanılmıştır. Bu veri seti yaşları 50 ve 65 arasında değişen 161 hastanın sağ ve sol meme görüntülerini içermektedir. Tüm görüntüler 1024 X 1024 piksel çözünürlüğünde ve 8 bit gri seviyede dijital hale getirilmiştir. Tüm görüntülerdeki anormalliklerin konumları da ayrı bir metin dosyasında mevcuttur. Şekil III.1(a)'da sınırları düzgün iki adet kitle içeren mamogram ve Şekil III.1(b)'de spiküler kitle içeren mamogram örneği görülmektedir.



(a)



(b)

Şekil III.1 (a) Sınırları Düzgün Kitle İçeren Mamogram, (b) Spiküler Kitle İçeren Mamogram

Yine tez çalışması kapsamında gerçekleştirilen ve akciğer BT kesitlerindeki nodülleri tespit eden BDT sisteminin geliştirilmesi ve değerlendirilmesi için iki farklı veri seti kullanılmıştır. Tez kapsamında gerçekleştirilen ilk çalışmalar EMAR İleri Görüntüleme ve Tanı Merkezinden alınan akciğer BT'leri kullanılarak gerçekleştirilmiştir. Şekil III.2'de bir örneği görülen ve 512 X 512 piksel

boyutlarında matris formunda olan bu BT kesitleri 6 mm kalınlığındadır. İki kesit arasında 1 mm boşluk bulunmaktadır.



Şekil III.2. Örnek Bir Akciğer BT Kesiti

Kullanılan bu veri seti ile gerçekleştirilen ilk çalışmalar uluslararası dergi hakemleri tarafından yorumlanmıştır. Hakemlerden gelen görüşler ışığında ve görüntüleme sistemlerindeki ilerlemeler sonucunda daha ince görüntü kesitleri üzerinde çalışmalar yapılmıştır. Bu çalışmalarda uluslararası geçerliliği olan ve yeni geliştirilmekte olan LIDC (Lung Image Database Consortium) [78] veri seti kullanılmıştır. Bu veri setinde BT kesitleri 0.625 mm kalınlığındadır ve her kesit 16 bit gri seviyede 512 X 512 piksel boyutlarında matris formundadır. Şekil III.3’de örnek bir BT görüntüsü görülmektedir. Veri setindeki her BT kesit görüntüsü için akciğer nodülünün yerini belirten bir görüntü de mevcuttur. Halen geliştirilmekte olan bu veri setinde 23 adet hastanın görüntüleri bulunmaktadır. Her hastaya ait ortalama 35 adet BT kesit görüntüsü bulunmaktadır. Her hastada bir adet akciğer nodülü bulunmaktadır. Bu nodüllerin çapları 3.5-7.3 milimetre ve kalınlığı da 5.625-18.75 milimetre aralığındadır.




Şekil III.3. LIDC Veri Setinde Nodül İçeren Bir Akciğer BT Kesit Örneği

III.3. İLGI ALANLARININ BELİRLENMESİ

Medikal görüntülerde bilgi verici işaretler, görüntü arka planı, kemikler, kaslar, damarlar ve ilgisiz doku alanları gibi anormal yumuşak doku yapılarıyla ilgisi bulunmayan yapılar da mevcuttur. Bu yapılar sistemin karmaşıklığını arttırmakta ve sistem duyarlılığını tehdit etmektedirler. Bu bölümde anlatılan yöntem ile karmaşıklık yaratan yapılar çıkartılarak sadece anormal olmaya aday yapılar elde edilmiştir. Bu yapılara ilgi alanları adı verilmektedir. Böylece anormal yapılar sadece bu ilgi alanları içinde aranmakta ve sonuç çok daha kısa sürede elde edilmektedir.


İlgi alanlarının diğer yapılardan ayrılması için ilgi alanlarını oluşturan pikseller kümesinin, birbirine komşu olan ve uygun yoğunluktaki piksellerden oluşması gerektiği düşünülmüştür. Veri setleri incelendiğinde anormal yapıların yoğunluk miktarlarının belirli değerler arasında olduğu görülmüştür. Bu anormal olmaya uygun yoğunluktaki yapıların belirlenmesi için yoğunluk sınırlarını belirten 2 adet eşik değeri kullanılmıştır. Bunlar “*minimum yoğunluk eşiği*” ve “*maksimum yoğunluk eşiği*” değerleridir. Ancak ilgi alanlarının belirlenmesinde sadece bu

yoğunluk eşik değerlerinin kullanılması yeterli değildir. Çünkü bu eşik değerlerin arasında yoğunluğa sahip ve anormal olmayan başka yapıların uzantıları veya kendileri de bulunmaktadır. Bu durum Şekil III.4 ve III.5’de görülmektedir. Bu şekillerde anormal yapılar ve bu anormal yapılar ile benzer yoğunluktaki normal yapılar oklar ile gösterilmiştir.




Şekil III.4. (a) Kitleye Sahip Bir Mamografi Görüntüsü, (b) Kitle İle Benzer Yoğunluktaki Yapılar

Görüldüğü gibi gerek meme kitlesi olsun, gerekse akciğer nodülü olsun anormal yapılar ile benzer yoğunluktaki normal yapılar da bulunmaktadır. Şekil III.4(b) ve Şekil III.5(b)’de görüldüğü gibi eşikleme yapılarak bir ön işlemden geçmiş olan görüntülerde anormal yapıların tespit edilmesi aşamasında normal yapıların da sorgulanması performans kaybına sebep olan gereksiz bir işlemdir. Bu nedenle ön işleme aşamasında normal yapıların da mümkün olduğunca çıkartılması önem taşımaktadır.




(a)



(b)

Şekil III.5. (a) Nodüle Sahip Bir Akciğer BT Görüntüsü, (b) Nodül İle Benzer Yoğunluktaki Yapılar


Eldeki veri setleri incelendiğinde mamografi görüntülerindeki kitleleri ve akciğer BT görüntülerindeki nodüllerin kendi aralarında benzer fakat normal yapıların büyük bir kısmından farklı morfolojik yapıda oldukları anlaşılmıştır. Damarlar ve kemikler gibi normal yapılar ince uzun yapıdayken, anormal yapılar daha dairesel ve belirli bir büyüklüktedir. Yani anormal alanlarının büyüklüklerinin alt ve üst sınırları vardır. Bu nedenle anormal olmaya aday bölgelerinin çapları önemle incelenmelidir. Bu nedenle Şekil III.4(b) ve Şekil III.5(b) gibi eşikleme önışleminden geçirilmiş olan görüntüler piksel piksel taranmış ve bir pikselin anormal aday bölgesinde olup olmadığının anlaşılması için, söz konusu piksel merkez alınıp Şekil III.6’da görüldüğü gibi 8 yönlü inceleme gerçekleştirilmiştir.



Şekil III.6. 8 Yöndeki Eşik Değerleri


Burada “*minimum uzunluk eşiği*” alt sınırı, “*maksimum uzunluk eşiği*” ise üst sınırı temsil etmektedir. Bir piksel 8 yönde, “*minimum uzunluk eşiği*” değerinden daha az veya “*maksimum uzunluk eşiği*” değerinden daha fazla komşuya sahipse, söz konusu piksel anormal aday bölgesinde olamaz. Aksi halde söz konusu piksel ilgi alanı bölgesindedir. Şekil III.7’de 8 yöndeki eşik değerlerinin kullanımına örnekler görülmektedir. Bu görüntülerde gri renkler uygun yoğunluktaki pikselleri temsil etmektedir. Şekil III.7(a)’daki örnekte bazı yönlerde “*minimum uzunluk eşiği*” değerinden daha az sayıda komşu piksel olduğu için inceleme altındaki piksel

anormal aday bölgesinde değildir. Şekil III.7(b)'deki örnekte bazı yönlerde “*maximum uzunluk eşiği*” değerinden daha fazla sayıda komşu piksel olduğu için inceleme altındaki piksel anormal aday bölgesinde değildir. Şekil III.7(c)'deki örnekte her yönde “*minimum uzunluk eşiği*” değerinden daha fazla sayıda ve “*maximum uzunluk eşiği*” değerinden daha az sayıda komşu piksel olduğu için inceleme altındaki piksel anormal aday bölgesindedir. Bu durumda bu piksel bizim ilgi alanımızın bir parçasını oluşturmaktadır.



Şekil III.7. 8 Yöndeki Eşik Değerlerinin Kullanım Örnekleri: (a) “*minimum uzunluk eşiği*” değerinden daha az sayıda komşu piksele sahip normal yapı pikseli, (b) “*maximum uzunluk eşiği*” değerinden daha fazla sayıda komşu piksele sahip normal yapı pikseli, (c) anormal olmaya aday yapı pikseli.

Minimum ve maksimum uzunluk eşik değerleri bilgi verici işaretler ve damarlar gibi çok büyük veya çok küçük yapıların ilgi alanında yer almasını önlemek amacıyla kullanılmaktadır. Şekil III.8 ilgi alanı belirleme yönteminin akış diyagramını göstermektedir.



Şekil III.8. İlgi Alanı Belirleme Yöntemi Akış Diyagramı

III.4. BAĞLANTILI BİLEŞEN ETİKETLEME (BBE)

Bu kısımda tez çalışması kapsamında çeşitli defalar kullanılan ve görüntü işleme teknikleri arasında önemli bir yeri olan Bağlantılı Bileşen Etiketleme (BBE) yöntemi anlatılmaktadır. BBE’de amaç bir görüntüdeki birbirinden bağımsız yapıların etiketlenmesi ve bu şekilleri oluşturan piksellerin koordinatlarının kayıt altına alınmasıdır. Örnek olarak Şekil III.9(a)’da görüldüğü gibi 1 yoğunluk değerine

sahip pikseller birbirlerinden bağımsız yapılar oluşturmaktadır. BBE' nin amacı Şekil III.9(b)'de görüldüğü gibi bu yapıları ve piksel koordinatlarını ayrı ayrı elde etmektir.

0	1	1	0	1	0	0	0
0	1	1	0	1	0	0	1
1	1	1	0	1	0	0	1
0	0	0	0	1	1	1	1
0	1	0	0	0	0	0	0
0	1	1	1	1	1	1	0
0	1	1	1	0	0	0	0

(a)

0	1	1	0	1	0	0	0
0	1	1	0	1	0	0	1
1	1	1	0	1	0	0	1
0	0	0	0	1	1	1	1
0	1	0	0	0	0	0	0
0	1	1	1	1	1	1	0
0	1	1	1	0	0	0	0


(b)

Şekil III.9. BBE Yönteminin Uygulama Örnekleri: (a) 1 yoğunluk değerine sahip pikseller, (b) 1 yoğunluklu piksellerden oluşan bağımsız yapılar.

BBE'de resim piksel piksel (yukarıdan aşağıya ve soldan sağa) taranması esasına dayanır [79]. Tarama sırasında aynı V yoğunluk değerine sahip bağlantılı komşu pikseller belirlenir. Resmin taranması işlemi satır boyunca devam eder ve $V=\{1\}$ yoğunluğuna sahip p noktasına gelince bekletilir. p noktasına gelindiğinde p noktasının tarama işleminden geçmiş 4 komşusu incelenir. Bu komşular: (i) p 'nin sol komşusu, (ii) p 'nin üst komşusu ve (iii ve iv) p 'nin iki üst köşegen komşusudur. Buna göre p noktasının etiketlenmesi şu şekilde oluşur [80,81]:

- eğer 4 komşunun da yoğunluk değeri $V=\{0\}$ ise, p noktasına yeni etiket atanır,
- eğer sadece bir komşunun yoğunluk değeri $V=\{1\}$ ise, p noktasına o komşunun etiket değeri atanır,
- eğer bir veya daha fazla komşunun yoğunluk değeri $V=\{1\}$ ise, etiketlerden biri atanır ve bu eşdeğer durumu kaydedilir.


Tarama işlemi tamamlandığında eşdeğer etiket çiftleri eşdeğerlik sınıflarına göre sıralanır ve her bir sınıfa tek bir etiket atanır. BBE benzer özelliklerdeki komşu yapıların aynı değerle etiketlenmesi esasına dayanır. BBE yönteminin akış diyagramı Şekil III.10'da görülmektedir.



Şekil III.10. BBE Yönteminin Akış Diyagramı

III.5. ŞABLON EŞLEME VE KONVOLÜSYON

Şablon eşleme tekniği, Şekil III.11’da görüldüğü gibi büyük bir görüntüde şablon görüntüsüne benzeyen küçük parçaların bulunması esasına dayanmaktadır [82]. Şablon görüntüsü büyük görüntü üzerinde dolaştırılır ve her pikselde eşleme yapılarak benzerlik ölçülür. Benzer şekillerin piksel koordinatları kaydedilir.



Şekil III.11. (a) Aramanın Gerçekleştirileceği Büyük Görüntü, (b) Şablon Görüntüsü [83].

Şekil III.11(a)’daki görüntüde, Şekil III.11(b)’de görülen şablona benzeyen yapılar aranır. Bu arama işleminde benzerlik ölçümleri kullanılır. Literatürde benzerlik ölçümü olarak kullanılan yöntemler şunlardır [83]: konvolüsyon, korelasyon, karşılıklı bilgi, gradyan farkı, örüntü yoğunluğu, rank transformu, kosinüs katsayısı, gama katsayısı ve Jaccard ölçümü. Bu tez çalışmasında şablon eşleme yönteminde benzerlik ölçümü olarak konvolüsyon yöntemi kullanılmıştır.

Konvolüsyon, matematikte ve özellikle fonksiyon analizlerinde f ve g gibi iki fonksiyonu ele alarak bu iki fonksiyonun örtüşme miktarını temsil eden üçüncü bir fonksiyon oluşturan matematiksel bir operatördür [84]. f ve g ’nin konvolüsyonu $f * g$ şeklinde yazılır. Bu yapı iki fonksiyondan birinin kaydırılarak diğeriyle çarpımı şeklinde tanımlanır. Bu tanım konvolüsyon integrali ile denklem (III.1) ile yazılır [84]:

$$h(x) = \int_{-\infty}^{\infty} f(a)g(x-a)da \quad (III.1)$$

ya da,

$$h(x) = f(x) * g(x) \quad (\text{III.2})$$

şeklinde gösterilir. Bu integral sürekli fonksiyonlar için yapılmasına karşın ayrık fonksiyonlar için süzgeçlenmiş veriler aşağıdaki bağıntı ile verilir.

$$h(x) = \sum_a f(a)g(x-a) \quad (\text{III.3})$$

Konvolüsyon yönteminin mühendislikte de pek çok uygulama alanı bulunmaktadır [85]. Örneğin sinyal işleme çalışmalarında giriş verisinde gürültüden arıtma gibi birçok yerde kullanılan süzgeçler bulunmaktadır. Süzgeçleme işlemi sayısal hale dönüştürülmüş olan veri gurubunu giriş olarak alıp, çıkış olarak sayısal bir fonksiyona çevirme işlemidir.

Konvolüsyonun başka bir uygulama alanı da görüntü işlemedir. Görüntü filtreleme, kenar tespiti ve şablon eşleme gibi uygulamalarda 2 boyutlu konvolüsyon kullanılır. 2 boyutlu görüntüler için giriş görüntüsü f ile g şablonunun konvolüsyonundan elde edilen h için konvolüsyon integrali,

$$h(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x-a, y-b)g(a, b)da db \quad (\text{III.4})$$

şeklindedir [86]. Bu integral denklem (III.5) ile de ifade edilir:

$$h(x, y) = \sum_{a=-\infty}^{\infty} \sum_{b=-\infty}^{\infty} f(x-a, y-b)g(a, b) \quad (\text{III.5})$$

$(N \times N)$ 'lik f görüntüsü ile $(k \times k)$ 'lık g şablonun 2 boyutlu konvolusyonu denklem (III.6) ile yazılır.

$$h(x, y) = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} f(x+i, y+j)g(i, j) \quad (\text{III.6})$$

Bu denklem aynı zamanda şablon eşleme olarak da adlandırılır [87]. Şekil III.12'de örnek bir giriş resmi ve bir şablon görülmektedir. Konvolüsyon, sol üst köşeden başlanarak şablonun görüntü sınırları içerisinde kaydırılmasıyla gerçekleştirilir.

Şablonun her konumu için şablon değerleri ile altta kalan görüntü değerleri çarpılarak toplanır ve böylece çıkış görüntüsü elde edilmiş olur.

I₁₁	I₁₂	I₁₃	I₁₄	I₁₅	I₁₆	I₁₇	I₁₈	I₁₉
I₂₁	I₂₂	I₂₃	I₂₄	I₂₅	I₂₆	I₂₇	I₂₈	I₂₉
I₃₁	I₃₂	I₃₃	I₃₄	I₃₅	I₃₆	I₃₇	I₃₈	I₃₉
I₄₁	I₄₂	I₄₃	I₄₄	I₄₅	I₄₆	I₄₇	I₄₈	I₄₉
I₅₁	I₅₂	I₅₃	I₅₄	I₅₅	I₅₆	I₅₇	I₅₈	I₅₉
I₆₁	I₆₂	I₆₃	I₆₄	I₆₅	I₆₆	I₆₇	I₆₈	I₆₉

K₁₁	K₁₂	K₁₃
K₂₁	K₂₂	K₂₃

Şekil III.12. Şablon Eşlemede Kullanılacak Görüntü ve Daha Küçük Olan Şablon.

Şekil III.12’de görülen örnekte şablonun görüntünün sağ alt köşesine konumlandığı düşünülürse konvolüsyon sonucunda oluşacak çıkış görüntüsünün O57 ile ifade piksel değeri denklem (III.7) ile hesaplanmış olacaktır:

$$O_{57} = I_{57} K_{11} + I_{58} K_{12} + I_{59} K_{13} + I_{67} K_{21} + I_{68} K_{22} + I_{69} K_{23} \quad (III.7)$$

III.6. GENETİK ALGORİTMALAR ve UYGULAMA ALANLARI

Darwin’in “en iyi olan yaşar (survival of the fittest)” prensibine dayalı olarak bir popülasyonu oluşturan bireylerin rekabet etmelerini ve rekabet sonucu elenmelerini sağlayan, evrimsel süreci simüle eden Genetik Algoritmalar (GA), ilk olarak John Holland tarafından ortaya atılmıştır [88]. Bunlar güçlü arama algoritmaları olarak kendilerini ispatlamış ve çeşitli alanlardaki zor problemlerle başa çıkmak için kullanılmışlardır.

GA’lar, birden fazla (popülasyon büyüklüğü kadar) çözüm üzerinde çalışırlar. Çözümler, problemin yapısına uygun bir şekilde kodlanmış kromozomlar tarafından temsil edilirler. Genetik Algoritma, bireylerin bir başlangıç popülasyonunu alarak ve her yeniden üretimde genetik operatörleri kullanarak bu prosesleri simüle eder. Optimizasyon açısından, popülasyondaki her birey, verilen problemde olası çözümü

gösteren bir dizi veya kromozoma kodlanır. Bir bireyin uyumu, verilen amaç fonksiyonuna göre değerlendirilir. Uyum fonksiyonu, kromozomların ifade ettikleri çözümlerin ne derece iyi olduğunu ifade eder. Yüksek uyum gösteren bireyler veya çözümler, çaprazlama prosedüründe diğer yüksek uyumlu bireylerle, genetik bilgilerindeki parçaları değiştirerek yeniden üretilme fırsatını bulurlar. Bu da ebeveynlerin her ikisinden de alınan bazı karakterleri paylaşan yeni çocuk çözümler üretir. Mutasyon çoğu zaman dizilerdeki bazı genleri değiştirerek çaprazlamadan sonra uygulanır. Çocuk bütün popülasyonu değiştirmekle elde edilebileceği gibi, az uyumlu özelliklerin değişmesiyle de oluşabilir. Bu, çevrim-seçim-yeniden üretim döngüsü, istenen sayıda kuşak yaratılana veya başka bir durma kriteri doğrulanana kadar tekrarlanır ve yaratılan en iyi çözüm problemin çözümü olarak alınır.

Temel ilkelerinin ortaya atılmasından sonra, genetik algoritmalar hakkında birçok bilimsel çalışma yayınlanmıştır. Genetik algoritmaların, fonksiyon eniyileme, çizelgeleme, mekanik öğrenme, tasarım, hücresel üretim gibi alanlarda başarılı uygulamaları bulunmaktadır. Geleneksel eniyileme yöntemlerine göre farklılıkları olan genetik algoritmalar, parametre kümesini değil kodlanmış biçimlerini kullanırlar. Olasılık kurallarına göre çalışan genetik algoritmalar, yalnızca amaç fonksiyonuna gereksinim duyar. Çözüm uzayının tamamını değil belirli bir kısmını tararlar. Böylece, etkin arama yaparak çok daha kısa bir sürede çözüme ulaşırlar [89]. Diğer bir önemli üstünlükleri ise çözümlerden oluşan popülasyonu eş zamanlı incelemeleri ve böylelikle yerel en iyi çözümlere takılmamalarıdır.

Genetik algoritmanın temel teoremi ise şöyle açıklanmaktadır [90]:

Popülasyon ortalamasının üstünde uyum gücü gösteren, kısa uzunluğa ve düşük dereceye sahip alt diziler zamanın ilerlemesiyle üstsel olarak çoğalırlar. Bu çoğalma, genetik işlemler aracılığı ile gerçekleşmektedir ve sonucunda ana-babadan daha üstün özellikler taşıyan bireyler ortaya çıkmaktadır. Bu çözüm kalitesinin kuşaktan kuşağa artması iki nedene bağlanmaktadır.

Bu nedenler şöyle açıklanmaktadır [91]:

Başarısız olan bireylerin üreme şansları azaltıldığı için kötüye gidiş zorlaşmaktadır. Genetik algoritmaların yapısı kötüye gidişi engellemekle kalmamakta, genetik algoritmaların temel teoremi uyarınca, zaman içinde hızlı bir iyiye gidiş de sağlayabilmektedir. Genetik algoritmaların işleme adımları incelendiğinde bu nedenler daha iyi anlaşılmaktadır. Genetik algoritmalar yapısı gereği, kötü bireyleri yani uygun olmayan çözümleri, operatörleri sayesinde

elemektedir. Bu işlemler bir döngü içerisinde durdurma kriteri sağlanana kadar devam etmektedir.

Bir çok alanda uygulama imkanı ve uygulamaları olan genetik algoritmaların işleme adımları şöyle açıklanır [92]:


- Arama uzayındaki tüm mümkün çözümler dizi olarak kodlanır.
- Genellikle rastsal bir çözüm kümesi seçilir ve başlangıç popülasyonu olarak kabul edilir.
- Her bir dizi için bir uygunluk değeri hesaplanır, bulunan uygunluk değerleri dizilerin çözüm kalitesini gösterir.
- Bir grup dizi belirli bir olasılık değerine göre rastsal olarak seçilip çoğalma işlemi gerçekleştirilir.
- Yeni bireylerin uygunluk değerleri hesaplanarak, çaprazlama ve mutasyon işlemlerine tabi tutulur.
- Önceden belirlenen kuşak sayısı boyunca yukarıdaki işlemler devam ettirilir.
- İterasyon, belirlenen kuşak sayısına ulaşınca işlem sona erdirilir. Amaç fonksiyonuna göre en uygun olan dizi seçilir.

Genetik algoritmalar bir çözüm uzayındaki her noktayı, kromozom adı verilen ikili bit dizisi ile kodlar. Her noktanın bir uygunluk değeri vardır. Tek bir nokta yerine, genetik algoritmalar bir popülasyon olarak noktalar kümesini muhafaza eder. Her kuşakta, genetik algoritma, çaprazlama ve mutasyon gibi genetik operatörleri kullanarak yeni bir popülasyon oluşturur. Birkaç kuşak sonunda, popülasyon daha iyi uygunluk değerine sahip üyeleri içerir. Bu, Darwin'in rastsal mutasyona ve doğal seçime dayanan evrim modellerine benzemektedir. Genetik algoritmalar, çözümlerin kodlanmasını, uygunlukların hesaplanmasını, çoğalma, çaprazlama ve mutasyon operatörlerinin uygulanmasını içerir [93]. Bu çalışmada kullanılan genetik algoritma yöntemlerinin genel akış diyagramı Şekil III.13'de görülmektedir.

Çözümlerin Kodlanması: Bir problemin çözümü için genetik algoritma geliştirmenin ilk adımı, tüm çözümlerin aynı boyutlara sahip bitler dizisi biçiminde gösterilmesidir. Dizilerden her biri, problemin olası çözümler uzayındaki rastsal bir noktayı simgeler [90]. Parametrelerin kodlanması, probleme özgü bilgilerin genetik algoritmanın kullanacağı şekle çevrilmesine olanak tanır [93].

İlk Popülasyonun Oluşturulması: Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur. Çözüm grubu popülasyon, çözümlerin kodları da kromozom

olarak adlandırılır. İkili alfabenin kullanıldığı kromozomların gösteriminde, ilk popülasyonun oluşturulması için rastsal sayı üreticileri kullanılabilir. Rastsal sayı üreticisi çağrılır ve değer 0,5'den küçükse konum 0'a, değilse 1 değerine ayarlanır [94]. Birey sayısının ve kromozom uzunluğunun az olduğu problemlerde yazı-tura ile de konum değerleri belirlenebilmektedir. Genetik algoritmalarda ikili kodlama yöntemi dışında, çözümü aranan probleme bağlı olarak farklı kodlama yöntemleri de kullanılmaktadır [89].




Şekil III.13. Genetik Algoritma Akış Diyagramı

Uygunluk Değerinin Hesaplanması: Bir kuşak oluşturulduktan sonraki ilk adım, popülasyondaki her üyenin uygunluk değerini hesaplama adımıdır. Örneğin, bir maksimizasyon problemi için i . üyenin uygunluk değeri $f(i)$, genellikle o noktadaki amaç fonksiyonunun değeridir [93]. Çözümü aranan her problem için bir uygunluk fonksiyonu mevcuttur. Verilen belirli bir kromozom için uygunluk


fonksiyonu, o kromozomun temsil ettiği çözümün kullanımıyla veya yeteneğiyle orantılı olan sayısal bir uygunluk değeri verir. Bu bilgi, her kuşakta daha uygun çözümlerin seçiminde yol göstermektedir. Bir çözümün uygunluk değeri ne kadar yüksekse, yaşama ve çoğalma şansı o kadar fazladır ve bir sonraki kuşakta temsil edilme oranı da o kadar yüksektir [90].

Çoğalma İşleminin Uygulanması: Çoğalma operatöründe diziler, amaç fonksiyonuna göre kopyalanır ve iyi kalıtsal özellikleri gelecek kuşağa daha iyi aktaracak bireyler seçilir. Üreme operatörü yapay bir seçimdir. Dizileri uygunluk değerlerine göre kopyalama, daha yüksek uygunluk değerine sahip dizilerin, bir sonraki kuşaktaki bir veya daha fazla yavruya daha yüksek bir olasılıkla katkıda bulunması anlamına gelmektedir. Çoğalma, bireyleri seçme işleminden, seçilmiş bireyleri bir eşleme havuzuna kopyalama işleminden ve havuzda bireyleri çiftler halinde gruplara ayırma işleminden oluşur [95]. Uygunluk değerinin hesaplanması adımından sonra mevcut kuşaktan yeni bir populasyon yaratılmalıdır. Seçim işlemi, bir sonraki kuşak için yavru üretmek amacıyla hangi ailelerin yer alması gerektiğine karar vermektedir. Bu doğal seçimdeki en uygunun yaşaması durumuna benzerdir. Bu yöntemin amacı, ortalama uygunluğun üzerindeki değerlere çoğalma fırsatı tanımaktır. Bir dizinin kopyalanma şansı, uygunluk fonksiyonuyla hesaplanan dizinin uygunluk değerine bağlıdır [93]. Seçim yöntemlerine Şekil III.14’de görülen rulet tekerleği seçimi, turnuva seçimi ve sıralama seçimi gibi seçim yöntemleri örnek verilebilir.




Şekil III.14. Rulet Tekerleği Örneği [93]

Çaprazlama İşleminin Uygulanması: Mevcut gen havuzunun potansiyelini araştırmak üzere, bir önceki kuşaktan daha iyi nitelikler içeren yeni kromozomlar yaratmak amacıyla çaprazlama operatörü kullanılmaktadır. Çaprazlama genellikle, verilen bir çaprazlama oranına eşit bir olasılıkla seçilen aile çeşitlerine uygulanmaktadır [93]. Genetik algoritmanın performansını etkileyen önemli parametrelerden biri olan çaprazlama operatörü doğal populasyonlardaki çaprazlamaya karşılık gelmektedir. Çoğalma işlemi sonucunda elde edilen yeni populasyondan rastsal olarak iki kromozom seçilmekte ve karşılıklı çaprazlama işlemine tabi tutulmaktadır. Çaprazlama işleminde dizi uzunluğu L olmak üzere, $1 < k \leq L-1$ aralığında k tamsayısı seçilmektedir. Bu tamsayı değerine göre dizi çaprazlamaya uğratılır. En basit çaprazlama yöntemi tek noktalı çaprazlama yöntemidir. Tek noktalı çaprazlama yapılabilmesi için her iki kromozomun da aynı gen uzunluğunda olması gerekir. Şekil III.15’de görülen iki noktalı çaprazlamada ise kromozom iki noktadan kesilir ve karşılıklı olarak pozisyonlar yer değiştirilir [95].



Şekil III.15. Tek Noktalı Çaprazlama [95]

Mutasyon İşleminin Uygulanması: Çaprazlama mevcut gen potansiyellerini araştırmak üzere kullanılır. Fakat populasyon gerekli tüm kodlanmış bilgiyi içermez ise, çaprazlama tatmin edici bir çözüm üretmez. Bundan dolayı, mevcut kromozomlardan yeni kromozomlar üretme yeteneğine sahip bir operatör gerekmektedir. Bu görevi mutasyon gerçekleştirir. Yapay genetik sistemlerde mutasyon operatörü, bir daha elde edilemeyebilir iyi bir çözümün kaybına karşı koruma sağlamaktadır [89]. İkili kodlama sisteminin kullanıldığı problemlerde mutasyon, düşük bir olasılık değeri altında bir bit değerini (0 veya 1 olabilir) Şekil III.16’de görüldüğü gibi diğer bit değerine dönüştürür. İkili kodlama sisteminin kullanılmadığı problemlerde ise daha farklı mutasyon yöntemleri kullanılmaktadır. Hangi yöntem kullanılırsa kullanılsın, mutasyonun genel amacı, genetik çeşitliliği sağlamak veya korumaktır [96].



Şekil III.16. Tek Bir Mutasyon [95]

Yeni Kuşağın Oluşması ve Döngünün Durdurulması: Yeni kuşak çoğalma, çaprazlama ve mutasyon işlemlerinden sonra tanımlanmakta ve bir sonraki kuşağın ebeveynleri olmaktadır. Süreç yeni kuşakla çoğalma için belirlenen uygunluk ile devam eder. Bu süreç, önceden belirlenen kuşak sayısı kadar veya bir hedefe ulaşıncaya kadar ya da başka bir durdurma kriteri sağlanana kadar devam eder [94]. İstenen hassasiyet derecesine göre de maksimum iterasyon sayısı belirlenebilmekte ve iterasyon bu sayıya ulaştığında döngü durdurulabilmektedir. Durdurma kriteri iterasyon sayısı olabileceği gibi hedeflenen uygunluk değeri de olabilmektedir [97].

III.7. HÜCRESEL YAPAY SİNİR AĞLARI

Hücrel sinir ağı konusu tarihsel gelişimi ve temel özellikleri bakımından yapay sinir ağı alanındaki gelişim sürecinin bir devamını oluşturmaktadır. İnsan davranışlarının taklit edilmeye çalışılması, teknolojik gelişmelerin en önemli yapı taşlarından birini oluşturmaktadır. Beyindeki her hangi bir mekanizmanın çalışma prensibinin anlaşılması ve daha sonra da mevcut imkanlar dahilinde taklit edilmeye çalışılması fikri, tarih boyunca insanın nörobilyoloji ve psikoloji bilim dallarındaki gözlemleri sonucu ortaya çıkmıştır. İnsan beyninin biyolojik yapısından esinlenerek ortaya konulmuş bir hesaplama yöntemi olan yapay sinir ağı basit bir görevi gerçekleştiren yapının (nöron) kendi aralarında paralel ve çok sayıda bağlantı oluşturmaları sonucu oluşmuş oluşan bir ağ yöntemidir [98].


Yapay sinir ağlarının özel bir çeşidi olan hücrel yapay sinir ağı ilk olarak 1988 yılında Leon Chua ve Lin Yang tarafından ortaya atıldıktan sonra önemli çalışma alanları bulmuştur [98,99]. Birbirine bağlı ve çoğunlukla iki boyutlu hücrelerden meydana gelmiş olan dinamik yapay sinir ağıdır. Bilinen anlamdaki yapay sinir ağlarının bazı temel özelliklerini taşımalarının yanı sıra özellikle iki boyutlu yapılarından dolayı görüntü işleme ve görüntü tanıma konularında oldukça fazla uygulama alanları bulmaktadırlar [100,101]. İki boyutlu bir dizi oluşturacak şekilde

sıralanmış hücrelerden oluşan hücresel yapay sinir ağlarında her hücre bilinen yapay sinir ağlarının aksine yakın komşuluğundaki hücrelerle bağlantı halindedir. Gerek bu durum ve gerekse hücreler arasındaki bağlantı katsayılarının çalışılan düzlemde değişmemesi durumu, hücresel sinir ağlarını özellikle görüntü işleme konularında (kenar belirleme, gürültü temizleme, boşluk doldurma vb.) oldukça geniş kullanım alanlarına sahip olmasını sağlamıştır. Böylece klasik yapay sinir ağlarına kıyasla bir görüntüden istenilen amaca yönelik başka bir görüntünün elde edilmesi işlemi daha az katsayı kullanılarak gerçekleştirilebilmektedir.

Hücresel yapay sinir ağları paralel çalışma ve iki boyutlu özelliklerinden dolayı bu alanda karakterlerin bazı ayırt edici özelliklerinin çıkarılmasını sağlayan bir ön işleme elemanı olarak kullanılmalarına neden olmuştur. Burada üzerinde işlem yapılacak olan görüntüdeki her nokta bir nörona karşılık düşer. Böyle bir yapıda görüntü hücresel yapay sinir ağına doğrudan verilebileceği gibi, özellikle görüntünün bazı ayırt edici özelliklerinin ortaya çıkarılmasını sağlayan bir ön işlemeden geçirildikten sonra da ağa verilebilmektedir. Bunun yanı sıra hücresel yapay sinir ağının kendisi de bir ayırt edici özellik çıkarıcı olarak kullanılabilir [102,103]. Hücresel yapay sinir ağları görüntü işlemenin yanı sıra hareket sezme işlemlerinde de kullanılmaktadır [104,105].

III.7.1. Hücresel Yapay Sinir Ağlarında Komşuluk İlişkisi

İki boyutlu bir dizi oluşturacak şekilde sıralanmış hücrelerden meydana gelmiş olan bu yapılarda, bilinen yapay sinir ağlarının aksine buradaki her hücre yakın komşuluğundaki hücrelerle belli bir komşuluk ilişkisi altında bağlantı halindedir. Şekil III.17 her bir hücrenin sadece çevresindeki hücrelerle bağlantı halinde olduğu 4x4 boyutunda bir hücresel yapay sinir ağını göstermektedir [106].




Şekil III.17. 4x4 Boyutunda Bir Hücresel Yapay Sinir Ağı Gösterimi [106].

M satır ve N sütundan oluşan bir $M \times N$ lik hücresel yapay sinir ağı örneği ele alındığında i . satır ve j . kolona (i,j) hücresi adı verilip $C(i,j)$ olarak ifade edilir. Burada herhangi bir $C(i,j)$ hücresinin r -komşuluğu denklem (III.8) ile tanımlanır [106].

$$N_r(i,j) = \left\{ C(k,l) \mid \max(|i-k|, |j-l|) \leq r, \quad 1 \leq i \leq M; 1 \leq j \leq N \right\} \quad (\text{III.8})$$

Burada komşuluğu gösteren r pozitif bir tamsayıdır ve her bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından doğrudan etkileneceğine işaret eder. Şekil III.18'de de görüldüğü gibi $r=1$ komşuluğunda yapı içerisindeki her bir hücre sadece çevresindeki hücreler tarafından etkilenirken (Buradaki etkilenme doğrudan bir etkilenmeyi vurgulamaktadır, gerçekte bu yapıdaki her bir hücre yapının hücre sayısına bağlı olarak belli bir zaman veya çevrim sonunda birbirlerini yayılım etkisi sonucu etkileyebilmektedirler.) $r=2$ ve $r=3$ komşuluklarında hücreler kendilerinden iki ve üç hücre uzaklıklarındaki hücreler tarafından da etkilenebileceğini göstermektedir [106].



Şekil III.18. Hücresel Yapay Sinir Ağlarında Hücreler Arasındaki Komşuluk İlişkisi [106]


$r=1$, $r=2$ ve $r=3$ Olmak üzere üç farklı komşuluk durumunun bulunduğu bu gösterimlerde genellikle $r=1$, $r=2$ ve $r=3$ komşuluklarına sırasıyla “3x3”, “5x5 ve “7x7” komşulukları da denir. Bir r -komşuluğu içerisinde $(2r+1)(2r+1)$ tane hücre bulunur. Komşuluk aynı zamanda simetri özelliğine de sahiptir. Yani $C(k,l) \in N_r(i,j)$ ise $C(i,j) \in N_r(k,l)$ dir. Hücrelerin bu şekilde karesel olarak sıralandığı bir yapının yanı sıra aynı komşuluk ilişkileri içerisinde ve karesel olmayan formatta da sıralanmaları olasıdır.

Bir hücresel yapay sinir ağının görüntü işlemedeki temel fonksiyonu herhangi bir giriş görüntüsünü istenilen amaca uygun olarak bir çıkış görüntüsüne dönüştürmesidir. Burada çıkış görüntüsü hücresel yapay sinir ağları ilk haliyle ele alındığında her piksel (nokta) değeri -1 ve $+1$ olacak şekilde sınırlandırılır. Ancak buna karşılık giriş görüntüleri uygun gerilim değerleri de sağlandıktan sonra, çoklu gri seviyelerine de sahip olabilirler. Verilen bir giriş görüntüsü ile başlatılan veya sürülen herhangi bir geçici rejim sonrasında, hücresel yapay sinir ağından geçirilmiş görüntü, gerekli koşullar sağlandığı takdirde her zaman bir kararlı durum sabit noktasına yakınsamaktadır.

Görüntü işlemede hücresel yapay sinir ağlarında genel olarak yapılan işlem, verilen bir giriş görüntüsünün doğrusal olmayan ve dinamik bir işlemde geçirilerek çıkış görüntüsünün oluşturulmasıdır. Yapının dinamik olmasından dolayı istenilen kararlı görüntü durumu elde edilene kadar çıkış görüntüsü her zaman aralığında sürekli değişim göstermektedir. Hücresel yapay sinir ağlarının komşuluk düzenindeki bu yapıları özellikle tüm devre gerçeklemelerinde büyük kolaylıklar sağlamıştır.


III.7.2. Hücre Yapıları

Hücresel yapay sinir ağlarındaki bu yapıda her bir hücre ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal dinamik bir ara birim ve n parçalı orijine göre simetrik bir çıkış biriminden oluşan dinamik bir devredir (Şekil III.19).



Şekil III.19. Bir Hücresinin Dinamik Yapısı [106].

Hücresel yapay sinir ağındaki bir hücrenin dinamiklerini çıkış geri beslemesinin etkisini belirleyen $A(i,j;k,l)$ parametresi ile girişin kontrol etkisini belirleyen $B(i,j;k,l)$ parametreleri oluşturur. Bu parametreler ayrıca $A(i,j;k,l)$ geri besleme ağırlık katsayısı ve $B(i,j;k,l)$ giriş ağırlık katsayısı olarak da adlandırılırlar. $(i,j;k,l)$ indis çifti $C(k,l)$ hücresinden $C(i,j)$ hücresine olan sinyal yönünü göstermektedir. Şekil III.20’de görüldüğü gibi HYSA’nın genel yapısı bir şablon seti ile belirtilmektedir. Bu şablon seti A şablonu, B şablonu ve I eşiğinden oluşmaktadır.



Şekil III.20. C(i,j) Hücresinin Blok Diyagramı

Teorik açıdan hücresel yapay sinir ağları çok boyutlu olarak tanımlanabilmelerine rağmen tez boyunca yapılan çalışmalarda özellikle görüntü işleme uygulamaları üzerinde durulduğundan burada ele alınan hücresel yapay sinir ağları iki boyutlu olarak kullanılmıştır.

III.7.3. Ayırık Zamanlı Hücresel Yapay Sinir Ağı

Bir hücresel yapay sinir ağının görüntü işlemedeki temel fonksiyonu herhangi bir giriş görüntüsüne dönüştürmesidir. Ele alınan görüntüler sayısal olduklarından hücresel yapay sinir ağının ayırık denklemleri bilinmelidir. Ayırık zamanlı bir hücresel yapay sinir ağını temsil eden denklemler şu şekilde gösterilir:

$$x_{i,j}(n+1) = \sum_{(k,l) \in N_r(i,j)} A_{i,j;k,l} \cdot y_{k,l}(n) + \sum_{(k,l) \in N_r(i,j)} B_{i,j;k,l} \cdot u_{k,l}(n) + I_{i,j} \quad (\text{III.9})$$

$$y_{i,j}(n) = f[x_{i,j}(n)] = \frac{1}{2}(|x_{i,j}(n) + 1| - |x_{i,j}(n) - 1|) \quad (\text{III.10})$$

Burada $u_{i,j}$ -1 ve +1 arasında değerler alabilen girişi, $y_{i,j}$ çıkışı ve $x_{i,j}$ ise durumu gösterirken; $A_{i,j}$ geri besleme ağırlık katsayılarını, $B_{i,j}$ giriş ağırlık katsayılarını ve $I_{i,j}$ ise her hücre için genellikle aynı olan eşik seviyesini temsil etmektedir. Buna göre denklem (III.9)'da gösterilen bu fark denklemini görüntü işleminde iki boyutlu bir filtre gibi kabul edilir. Bu filtre $x_{i,j}(n)$ değerinden $x_{i,j}(n+1)$ değerine dönüşüm yapan bir filtre olacaktır. Başka bir deyişle bu dönüşüm tek adım olarak düşündüğümüzde $x_{i,j}(0)$, $u_{i,j}$, $A_{i,j}$, $B_{i,j}$ ve $I_{i,j}$ değerlerinin bilinmesi durumunda seçilen komşuluk kuralına ve $x_{i,j}(0)$ değerine bağlı olarak herhangi bir n anında $y_{i,j}(n)$ çıkışının bulunmasına olanak sağlayacaktır. Dikkat edilecek olunursa burada iteratif bir filtreleme yapılmaktadır. Bu iteratif filtreleme sayesinde bir görüntüdeki yerel bilgilerin yanı sıra iterasyon sayısına bağlı olarak global bilgilerin de ortaya çıkması sağlanmaktadır. Tek iterasyonda görüntü üzerinde her nokta etkilenirken, iterasyon sayısı arttıkça birbirinden oldukça uzaktaki noktaların birbirlerini etkilemeleri mümkün olmaktadır.

III.7.4. Hücresel Yapay Sinir Ağları ve Konvolüsyon İlişkisi

Denklem (III.9)'da verilen ve ayrık zamanlı hücresel yapay sinir ağını ifade eden formülde A ile y arasındaki ilişki ile B ve u arasındaki ilişki aynı olup iki boyutlu bir konvolüsyon ilişkisidir. Buna göre denklem (III.9) yeniden düzenlenecek olursa

$$x(n+1) = A * y(n) + B * u + I \quad (\text{III.11})$$

$$x_{i,j}(n+1) = \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} \hat{A}_{i,j} \cdot y_{i-k,j-l}(n) + \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} \hat{B}_{i,j} \cdot u_{i-k,j-l} + I \quad (\text{III.12})$$

elde edilir.

Ancak burada dikkat edilmesi gereken iki önemli nokta vardır ki, bunlardan birincisi bu ifadenin işlenecek olan görüntülerin sınır değerlerinin tamamen sıfır olarak seçildiği kabulü altında bu konvolüsyon toplamının yazılabileceği; ikincisi $\hat{A}$ ve $\hat{B}$ değerlerinin denklem (III.9) ile ilişkisinin $\hat{A}_{i,j} = A_{-i,-j}$ ve $\hat{B}_{i,j} = B_{-i,-j}$ şeklinde olması gerektiğidir. Buna göre denklem (III.12) yeniden yazılacak olursa

$$x_{i,j}(n+1) = \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} A_{-i,-j} \cdot y_{i-k,j-l}(n) + \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} B_{-i,-j} \cdot u_{i-k,j-l} + I \quad (\text{III.13})$$

elde edilir.

BÖLÜM IV

MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİ TESPİT EDEN BDT YAZILIMLARININ TASARIMI

IV.1. GİRİŞ

Bu bölümde tez kapsamında gerçekleştirilen mamografi görüntüleri üzerine yapılan çalışmalar açıklanmaktadır. Bu çalışmalar,

- hücresel yapay sinir ağları şablonları kullanılarak meme bölgesinin bölütlendirilmesi,
- morfolojik özellikler kullanılarak kitlelerin tespit edilmesi,
- şablon eşleme tekniği kullanılarak kitlelerin tespit edilmesi,
- genetik algoritma eğitimi ile en iyi şablon değerlerinin hesaplanması,
- konvolüsyon tabanlı şablon eşleme yöntemi ile kitlelerin tespit edilmesi


başlıkları altında anlatılmaktadır.

IV.2. MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN TESPİT EDİLMESİ

Tez çalışması kapsamında mamografi görüntülerindeki kitlelerin tespit edilmesi amacıyla çeşitli yöntemler kullanılmıştır. Bu bölümde mamografi görüntüleri üzerinde gerçekleştirilen çalışmaların her biri alt bölümler halinde detaylı bir şekilde anlatılmaktadır.

IV.2.1. Mamografi Görüntülerindeki Kitlelerin Kural Tabanlı Tespiti

Şekil IV.1 de görüldüğü gibi bu çalışmanın ilk aşaması bölüm III.3’de anlatılan yöntemle 8 yönlü arama yapılarak ilgi alanlarının bulunmasıdır. Şekil IV.1’deki Blok I’de görülen bu yöntemde “*minimum uzunluk eşiği*” ve “*maksimum uzunluk eşiği*” için uygun değerler atanarak Şekil IV.2 de görüldüğü gibi ilgi alanları bulunmuştur.



Şekil IV.1. Kitlelerin Kural Tabanlı Tespitine Genel Bakış

Şekil IV.2(b)’de de görüldüğü gibi ilgi alanları incelendiğinde kitlelerin daha kalın ve dairesel, diğer yapıların ise daha ince ve uzun olduğu görülmüştür. Buna göre kitleleri normal yapılardan ayırmak amacıyla ilgi alanlarının morfolojileri incelenmiştir. Bu nedenle Şekil IV.1’deki Blok II’de görüldüğü gibi BBE yöntemi ile yapılar etiketlenmiş ve her yapıyı oluşturan piksellerin koordinatları kaydedilmiştir. Benzer özelliklerdeki komşu yapıların aynı değerle etiketlenmesi esasına dayanan BBE sistemi bölüm III.4’de detaylı bir şekilde anlatılmıştır.



(a)



(b)


Şekil IV.2. (a) Spiküler Kitle İçeren Mamografi Görüntüsü, (b) Kural Tabanlı Kitle Tespiti İçin Bulunan İlgi Alanları

İlgi alanlarının morfolojileri incelenmesi iki kural kullanılarak gerçekleştirilmiştir. Birinci kuralda ilgi alanlarının öklid uzunlukları, ikinci kuralda ise öklid uzunluğun kalınlığa oranıyla elde edilen ilgi alanlarının biçim değerleri sorgulanmaktadır. Bu kurallar şu şekildedir:


Kural 1 (Uzunluk): Bir yapının öklid uzunluğu “*öklid uzunluk eşiği*” değerinden büyükse, söz konusu yapı gerçek bir kitle olamaz. Öklid uzunluk denklemi denklem (IV.1) ile verilmiştir.

$$E_d = \sqrt{(x_{\max} - x_{\min})^2 + (y_{\max} - y_{\min})^2} \quad (IV.1)$$

Şekil IV.3’de bir damarın öklid uzunluğunun hesaplanması, Şekil IV.4’de ise bir kitlenin öklid uzunluğunun hesaplanması örnekleri gösterilmektedir.



Şekil IV.3. Bir Damarın Öklid Uzunluğunun Hesaplanması



Şekil IV.4. Bir Kitlenin Öklid Uzunluğunun Hesaplanması

Kural 2 (Kalınlık ve biçim): Bir yapının öklid uzunluğunun kalınlığına oranı “*biçim eşiği*” değerinden büyükse, söz konusu yapı gerçek bir kitle olamaz. Bir yapının kalınlığını bulmak için öncelikle merkez koordinatları bulunmaktadır. Merkez koordinatları (x_c, y_c) denklem (IV.2) ve (IV.3) ile hesaplanır. Bu denklemlerde *fix* fonksiyonu sayının tam kısmını elde etmek amacıyla kullanılmıştır.

$$x_c = \text{fix} \left(x_{\min} + \frac{x_{\max} - x_{\min}}{2} \right) \quad (\text{IV.2})$$

$$y_c = \text{fix} \left(y_{\min} + \frac{y_{\max} - y_{\min}}{2} \right) \quad (\text{IV.3})$$

Ardından $y_{c \min}$ (x_c ’ye karşılık minimum y noktası), $y_{c \max}$ (x_c ’ye karşılık maksimum y noktası), $x_{c \min}$ (y_c ’ye karşılık minimum x noktası) ve $x_{c \max}$ (y_c ’ye karşılık maksimum x noktası) koordinatları bulunur. Bu değerleri kullanarak yükseklik (Y) ve genişlik (G) değerleri denklem (IV.4) ve (IV.5) ile hesaplanır:

$$Y = y_{c \max} - y_{c \min} \quad (\text{IV.4})$$

$$G = x_{c \max} - x_{c \min} \quad (\text{IV.5})$$


S ile belirtilen yapının en küçük kalınlığını bulmak için yüksekliğin ve genişliğin küçük olanı seçilir:

$$S = \min(Y, G) \quad (IV.6)$$

ve son olarak R ile gösterilen incelenen yapının biçimi denklem (IV.7) ile hesaplanır:


$$R = \frac{E_d}{S} \quad (IV.7)$$

Şekil IV.5 ve IV.6’da sırasıyla bir damarın ve bir kitlenin biçim miktarının hesaplanması gösterilmektedir.




Şekil IV.5. Bir Damarın Biçim Miktarının Hesaplanması


Bir ilgi alanı yapısı için her iki kural da geçerli ise yani, öklid uzunluğu “*öklid uzunluk eşiği*” değerinden büyük ve biçim miktarı da “*biçim eşiği*” değerinden büyük ise söz konusu yapı damardır. Bu yapı ilgi alanı görüntüsünde çıkartılır. Bu işlem örneğin Şekil IV.2(b)’deki tüm ilgi alanı yapıları için tekrar edilirse ve sonuçta sadece kitleyi bulunduran Şekil IV.7 deki sonuç görüntüsü elde edilir. Mamografi görüntülerindeki kitlelerin kural tabanlı tespitini gerçekleştiren yazılımın akış diyagramı Şekil IV.8’de görülmektedir.



Şekil IV.6. Bir Kitlenin Biçim Miktarının Hesaplanması




Şekil IV.7. Şekil IV.2(b)'de Verilen Görüntüde Tespit Edilen Kitle.



Şekil IV.8. Kural Tabanlı Kitle Tespiti Yazılımının Akış Diyagramı


IV.2.2. Şablon Eşleme Yöntemiyle Kitlelerin Tespiti

Önceki çalışmadan farklı olarak bu çalışmada şablon eşleme yöntemi kullanılmıştır. Şablon eşleme işleminde benzerlik ölçümü olarak eşleşmede oluşan hatayı ölçen ve karar veren kural tabanlı bir yöntem kullanılmıştır. Bu çalışmada kullanılan yöntem Şekil IV.9 da detaylı bir şekilde verilmiştir. Blok I’de görüldüğü gibi bu çalışmada da ilk aşama ilgi alanlarının bulunmasıdır. İlgi alanları “*minimum uzunluk eşiği*” ve “*maksimum uzunluk eşiği*” için uygun değerler atanarak Şekil IV.10’da görüldüğü gibi bulunduktan sonra sınıflandırma işlemi için kitle şablonları kullanılmıştır.




Şekil IV.9. Kitlelerin Şablon Eşleme Yöntemiyle Tespiti

Şekil IV.9’daki blok II’de görüldüğü gibi bu noktadaki amaç ilgi alanlarının kitle veya normal yapı olarak sınıflandırılmasıdır. Önceki aşamada bulunmuş olan ilgi alanları incelendiğinde farklı morfolojik yapılarda oldukları gözlemlenmiştir. Kitleler daha kalın ve dairesel iken, diğer yapılar daha ince uzundur. Buna göre yapısal özellikleri kullanarak kitleleri normal yapılardan ayırmak için Şekil IV.11’de görülmekte olan şablon kullanılmıştır. Bu şablon siyah ve beyaz piksellerden oluşmaktadır. Beyaz pikseller meme kitlesi adaylarını temsil ederken, siyah pikseller “*minimum yoğunluk eşiği*” ve “*maksimum yoğunluk eşiği*” aralığı dışında yoğunluğa sahip pikselleri temsil etmektedir.




(a)



(b)


Şekil IV.10. (a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, (b) Şablon Eşleme Yöntemiyle Kitle Tespiti İçin Bulunan İlgi Alanları




Şekil IV.11. 30 X 30 Piksel Boyutlarında Kitle Şablonu

İlgi alanlarından oluşan görüntü sol üst köşeden başlayarak piksel piksel taranmıştır. Bu taramada her piksel kitle şablonunun sol üst köşesi ile eşlenmiştir. Bu eşlemede ilgi alanları görüntüsünün şablona olan benzerliği ölçülmüştür. Bu eşlemede 2 hata belirlenmiştir. Bunlardan birincisi şablonda siyah olup ilgi alanları görüntüsünde beyaz olan piksellerin sayısını veren “*siyah piksel hatası*”, diğeri ise şablonda beyaz olup ilgi alanları görüntüsünde siyah olan piksellerin sayısını veren “*beyaz piksel hatası*” değerleridir. Bu hataları kullanarak ilgi alanları görüntüsündeki her bir piksel için şablondaki kitleye benzer şekiller (ilgi alanı parçaları) aranmıştır. Benzerlik “*siyah hata eşiği*” ve “*beyaz hata eşiği*” değerleri ile kontrol edilmiştir. Benzer bir Şekil bulunması durumunda şekli oluşturan beyaz piksellerin koordinatları kaydedilmiştir. Bu koordinatlar gerçek bir kitlenin parçalarını oluşturmaktadır. Aşağıda kitle şablonunun kullanılması örneklerle anlatılmaktadır.

Şekil IV.12 ve IV.13, 30 x 30 piksel boyutlarında bir şablon kullanarak kitlenin ve damar gibi normal bir yapının tespit edilmesini göstermektedir. Şekil IV.12(a) gerçek bir kitleyi, Şekil IV.13(a) ise damarı göstermektedir. Şekil IV.12(b) ve Şekil IV.13(b) X pikseli ile Şekil IV.11’deki şablonun eşlenmesini göstermektedir. Şablon beyaz bir çerçeve içinde gösterilmektedir. Bu eşleme sonucunda beyaz çerçeve içinde iki farklı renkte hata görülmektedir. “*siyah piksel hatası*” olarak adlandırılan gri renkteki pikseller ilgi alanında olan fakat şablondaki kitlenin parçası olmayan piksellerdir. “*beyaz piksel hatası*” olarak adlandırılan koyu gri renkteki pikseller ise şablon kitlesinde olan fakat ilgi alanın parçası olmayan piksellerdir.




(a)




(b)

Şekil IV.12. (a) Gerçek Bir Kitle, (b) Kitlenin Bir Parçasının Şablon İle Tespiti



(a)



(b)

Şekil IV.13. (a) Gerçek Bir Damar, (b) Damarın Bir Parçasının Şablon İle Tespiti

İnceleme altındaki ilgi alanı için bu hata değerleri “siyah hata eşiği” ve “beyaz hata eşiği” değerleri ile karşılaştırılır ve şu sınıflama kuralı kullanılır:

EĞER “*siyah piksel hatası*” > “*siyah hata eşiği*”

VE


“*beyaz piksel hatası*” < “*beyaz hata eşiği*” İSE

Sonuç = gerçek bir kitle parçasıdır


DEĞİLSE

Sonuç = normal bir yapıdır

Bu kural tanımlanırken eşik değerleri ince ve uzun şekilleri önleyecek şekilde seçilir. Eğer “*siyah piksel hatası*” değeri küçük ise ilgi alanı uzundur. Eğer “*beyaz piksel hatası*” değeri büyükse ilgi alanı incedir. Bu işlem örneğin Şekil IV.10(b)’deki tüm ilgi alanları için tekrar edilirse ve sonuçta sadece kitleyi bulunduran Şekil IV.14’deki sonuç görüntüsü elde edilir. Mamografi görüntülerindeki kitleleri şablon eşleme yöntemiyle tespiti çalışmasının akış diyagramı Şekil IV.15’de görülmektedir.




Şekil IV.14. Şekil IV.10(b)’de Verilen Görüntüde Tespit Edilen Kitle



Şekil IV.15. Kitlelerin Şablon Eşleme Yöntemiyle Tespiti Yazılımının Akış Diyagramı

IV.2.3. Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemleriyle Meme Bölgesinin Bölütlendirilmesi ve Kitlelerin Tespit Edilmesi

Yukarıda anlatılan kitle tespit yöntemlerinden farklı olarak bu çalışmada meme bölgesinin bölütlendirilmesi ve ilgi alanlarını arama işleminin bu bölgede yapılması sağlanmıştır. Böylece ilgi alanlarının belirlenmesi işlemi hızlandırılması amaçlanmıştır. Belirlenmiş olan ilgi alanlarının sınıflandırılması amacıyla yine şablon eşleme yöntemi kullanılmıştır. Ancak bu şablon eşleme yönteminin önceki yöntemden iki açıdan farkı bulunmaktadır. Öncelikle kullanılan şablonu oluşturan değerler genetik algoritma kullanılarak hesaplanmış ve amaca uygun en iyi şablon değerleri kullanılmıştır. Ardından hesaplanmış olan bu en iyi şablon ile eşleme yapılırken benzerlik ölçümü olarak konvolüsyon tabanlı filtreleme kullanılmıştır. Bu çalışmada kullanılan yöntem Şekil IV.16’da detaylı bir şekilde verilmiştir.



Şekil IV.16. GA İle Eğitilen Şablonlar Kullanılarak Bölütlendirme ve Kitle Tespiti Aşamalarının Gösterimi

Bu çalışmada ilk olarak meme bölgesini bölütlendirecek HYSA şablonlarının eğitimi gerçekleştirilmiştir. Bu eğitim için kullanılan genetik algoritma işlem basamakları şu şekildedir:

1. *Basamak. İlk popülasyonun oluşturulması:* Başlangıç popülasyon matrisi $m \times n$ boyutlarında rasgele oluşturulmuştur.

2. *Basamak. HYSA şablonlarının oluşturulması:* Kromozomlar HYSA şablonları olan A, B ve I şablonlarının ikili kodlanmasından oluşturulmuştur. Şablon

değerleri ise $[-1,1]$ değer aralığında kromozom kodlarının çözülmesiyle hesaplanmıştır. HYSA şablonları için komşuluk derecesi 1 olarak seçildiğinde A ve B şablonları 3×3 'lük matris oluştururken, I şablonu her bir elemanı aynı olan $m \times n$ 'lik bir matris oluşturur. Bu A ve B şablonları simetrik olarak şu şekilde verilir:

$$A = \begin{bmatrix} a_2 & a_1 & a_2 \\ a_1 & a_0 & a_1 \\ a_2 & a_1 & a_2 \end{bmatrix}, \quad B = \begin{bmatrix} b_2 & b_1 & b_2 \\ b_1 & b_0 & b_1 \\ b_2 & b_1 & b_2 \end{bmatrix}$$

Bu durumda S ile ifade edilen değişkenlerin sayısı 7 olur ve S 'nin her bir elemanı ikili olarak kodlanmıştır:

$$S = [a_0 \ a_1 \ a_2 \ b_0 \ b_1 \ b_2 \ i]$$

burada i ile ifade edilen değişken I matrisinin tüm elemanlarını oluşturan değerdir.

Meme bölgesinin bölütlendirilmesi için A ve B şablonları için komşuluk derecesi olarak 5 değeri kullanılmıştır. Şablonlar simetrik tasarlanmasından dolayı her bir şablon 21 değişkenden oluşmuştur. Böylece S değişken vektörü A şablonu için 21 değişken, B şablonu için 21 değişken ve I şablonu için 1 değişken olmak üzere toplam 43 değişkene sahiptir. 11×11 piksel boyutlarındaki A ve B şablonları aşağıda görülmektedir. Bölütlendirme işleminin hesaplama süresini azaltmak amacıyla mamografi görüntülerinin boyutları 128×128 piksel değerine düşürülmüştür. Meme bölgesinin bölütlendirilme işlemi başarıyla tamamlanmasının ardından mamografi görüntüsünün boyutları tekrar eski değeri olan 1024×1024 piksel değerine büyütülmüştür.

$$A = \begin{bmatrix} A0 & A1 & A2 & A3 & A4 & A5 & A4 & A3 & A2 & A1 & A0 \\ A1 & A6 & A7 & A8 & A9 & A10 & A9 & A8 & A7 & A6 & A1 \\ A2 & A7 & A11 & A12 & A13 & A14 & A13 & A12 & A11 & A7 & A2 \\ A3 & A8 & A12 & A15 & A16 & A17 & A16 & A15 & A12 & A8 & A3 \\ A4 & A9 & A13 & A16 & A18 & A19 & A18 & A16 & A13 & A9 & A4 \\ A5 & A10 & A14 & A17 & A19 & A20 & A19 & A17 & A14 & A10 & A5 \\ A4 & A9 & A13 & A16 & A18 & A19 & A18 & A16 & A13 & A9 & A4 \\ A3 & A8 & A12 & A15 & A16 & A17 & A16 & A15 & A12 & A8 & A3 \\ A2 & A7 & A11 & A12 & A13 & A14 & A13 & A12 & A11 & A7 & A2 \\ A1 & A6 & A7 & A8 & A9 & A10 & A9 & A8 & A7 & A6 & A1 \\ A0 & A1 & A2 & A3 & A4 & A5 & A4 & A3 & A2 & A1 & A0 \end{bmatrix}$$

$$B = \begin{bmatrix} B0 & B1 & B2 & B3 & B4 & B5 & B4 & B3 & B2 & B1 & B0 \\ B1 & B6 & B7 & B8 & B9 & B10 & B9 & B8 & B7 & B6 & B1 \\ B2 & B7 & B11 & B12 & B13 & B14 & B13 & B12 & B11 & B7 & B2 \\ B3 & B8 & B12 & B15 & B16 & B17 & B16 & B15 & B12 & B8 & B3 \\ B4 & B9 & B13 & B16 & B18 & B19 & B18 & B16 & B13 & B9 & B4 \\ B5 & B10 & B14 & B17 & B19 & B20 & B19 & B17 & B14 & B10 & B5 \\ B4 & B9 & B13 & B16 & B18 & B19 & B18 & B16 & B13 & B9 & B4 \\ B3 & B8 & B12 & B15 & B16 & B17 & B16 & B15 & B12 & B8 & B3 \\ B2 & B7 & B11 & B12 & B13 & B14 & B13 & B12 & B11 & B7 & B2 \\ B1 & B6 & B7 & B8 & B9 & B10 & B9 & B8 & B7 & B6 & B1 \\ B0 & B1 & B2 & B3 & B4 & B5 & B4 & B3 & B2 & B1 & B0 \end{bmatrix}$$

3. *Basamak. Amaç ve uygunluk fonksiyonlarının hesaplanması:* Bu aşamada eğitim görüntüsü olarak seçilen görüntü, ilk kromozoma bağlı olarak çalışan HYSA sisteminin girişine uygulanmıştır. HYSA çıkışı kararlı olduğunda elde edilen çıkış görüntüsü ile istenen görüntü arasındaki amaç fonksiyonu hesaplanmıştır. Bu işlem popülasyondaki her bir kromozoma ait olan şablon kümeleri ile tekrar edilmiştir. Bu çalışmada kullanılan amaç fonksiyon denklem (IV.8)'de görülmektedir [101].

$$amaç(A, B, I) = \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} P_{i,j} \oplus T_{i,j} \quad (IV.8)$$


Bu fonksiyonda P ve T ifadeleri sırasıyla HYSA çıkış görüntüsünü ve hedef görüntüyü belirtmektedir. $\oplus$ sembolü P ve T 'nin pikselleri arasındaki XOR işlemi temsil etmektedir. Amaç fonksiyonunun bu şekilde hesaplanmasından sonra, her bir kromozom için uygunluk değeri denklem (IV.9) ile hesaplanmıştır:

$$uygunluk(A, B, I) = m \times n - amaç(A, B, I) \quad (IV.9)$$

Durdurma kriteri olarak denklem (IV.10) kullanılmıştır:

$$durdurmakriteri = 0.99 \times m \times n \quad (IV.10)$$

4. *Basamak. Çaprazlama ve Mutasyon:* Çaprazlama ve mutasyon ile yeni bir kuşağın oluşması sağlanmıştır. Durdurma kriteri sağlandığında ve genetik algoritma sonlandığında, en iyi A, B ve I şablonları elde edilmiştir. HYSA şablonlarının eğitimi çalışmasının akış diyagramı Şekil IV.17'de görülmektedir.




Şekil IV.17. Meme Bölgesinin Bölütlendirilmesi Amacıyla HYSA Şablonlarının Eğitimi Çalışmasının Akış Diyagramı

Bu çalışmada HYSA şablonlarının eniyilemesinde genetik algoritma yöntemi kullanılmıştır. Elde edilen şablonlar ile yeni bir görüntü HYSA girişine uygulandığında, bu görüntü için meme bölgesi elde edilmiştir. Orijinal mamografi görüntüsü HYSA girişine uygulanmadan önce Şekil IV.16’de belirtildiği gibi bir eşikleme işleminden geçirilmelidir. Şekil IV.18(a)’da görüldüğü gibi meme kitlesi, kaslar ve dokular görüntü arka planından daha açık renktedir. Bu daha büyük yoğunluk değerlerine sahip olduklarını göstermektedir. Bu yüzden meme bölgesinin kabaca elde edilmesi için öncelikle eşikleme yöntemi uygulanmıştır. $I(x,y)$ ile ifade edilen Şekil IV.18(a)’daki görüntüye aşağıdaki kural uygulanırsa Şekil IV.18(b)’deki görüntü elde edilir. Bu kuralda 1 beyaz rengi temsil ederken, 0 siyah rengi temsil etmektedir.


$$\begin{aligned} & \text{EĞER } I(x,y) > 30 \text{ İSE} \\ & \quad I(x,y) = 1 \\ & \text{DEĞİLSE} \\ & \quad I(x,y) = 0 \end{aligned}$$

Şekil IV.18(b)’deki görüntü eğitilmiş A, B ve I şablonları ile çalışan HYSA girişine uygulandığında Şekil IV.18(c)’deki görüntü elde edilir. Şekil IV.18(d)’de orijinal mamografi görüntüsündeki meme bölgesini göstermektedir.

Bölütlenmiş meme görüntüsüne bölüm III.3’de anlatılan 8 yönlü ilgi alanı arama yöntemi uygulandığında Şekil IV.19(b)’de görülen ilgi alanları elde edilir. Bu noktadaki amaç ilgi alanlarının kitle veya normal yapı olarak sınıflandırılmasıdır. Önceki aşamada bulunmuş olan ilgi alanları incelendiğinde farklı yapılarda oldukları gözlemlenmiştir. Kitleler daha kalın ve dairesel iken, diğer yapılar daha ince uzundur. Buna göre yapısal özellikleri kullanarak kitleleri normal yapılardan ayırmak için kitle şablonu kullanılmıştır. Bu şablonun değerlerinin hesaplanması da genetik algoritma ile gerçekleştirilmiştir. Şablonun eğitimi için gerçekleştirilen genetik algoritma basamakları şu şekildedir:



Şekil IV.18. a) Sınırları Düzgün Kitle İçeren Orijinal Mamografi Görüntüsü, (b) HYSA'nın Girişini Oluşturan Eşikleme Kuralı İle Elde Edilen Görüntü, (c) HYSA Kullanılarak Bölütlendirilmiş Meme Bölgesi, (d) Meme Bölgesinin Orijinal Görüntüsü.



Şekil IV.19. (a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, (b) Bulunan İlgi Alanları

1. *Basamak. İlk popülasyonun oluşturulması:* Başlangıç popülasyon matrisi $m \times n$ boyutlarında rastsal olarak oluşturulmuştur.

2. *Basamak. Kitle şablonunun oluşturulması:* Kromozomlar kitle şablonu olan T şablonunun ikili kodlanmasından oluşturulmuştur. Şablon değerleri ise $[-5, 5]$ değer aralığında kromozom kodlarının çözülmesiyle hesaplanmıştır. 16×16 piksel boyutlarında olan T kitle şablonu şu şekildedir:

$$T = \begin{bmatrix} t_{28} & t_{29} & t_{30} & t_{31} & t_{32} & t_{33} & t_{34} & t_{35} & t_{35} & t_{34} & t_{33} & t_{32} & t_{31} & t_{30} & t_{29} & t_{28} \\ t_{29} & t_{21} & t_{22} & t_{23} & t_{24} & t_{25} & t_{26} & t_{27} & t_{27} & t_{26} & t_{25} & t_{24} & t_{23} & t_{22} & t_{21} & t_{29} \\ t_{30} & t_{22} & t_{15} & t_{16} & t_{17} & t_{18} & t_{19} & t_{20} & t_{20} & t_{19} & t_{18} & t_{17} & t_{16} & t_{15} & t_{22} & t_{30} \\ t_{31} & t_{23} & t_{16} & t_{10} & t_{11} & t_{12} & t_{13} & t_{14} & t_{14} & t_{13} & t_{12} & t_{11} & t_{10} & t_{16} & t_{23} & t_{31} \\ t_{32} & t_{24} & t_{17} & t_{11} & t_6 & t_7 & t_8 & t_9 & t_9 & t_8 & t_7 & t_6 & t_{11} & t_{17} & t_{24} & t_{32} \\ t_{33} & t_{25} & t_{18} & t_{12} & t_7 & t_3 & t_4 & t_5 & t_5 & t_4 & t_3 & t_7 & t_{12} & t_{18} & t_{25} & t_{33} \\ t_{34} & t_{26} & t_{19} & t_{13} & t_8 & t_4 & t_1 & t_2 & t_2 & t_1 & t_4 & t_8 & t_{13} & t_{19} & t_{26} & t_{34} \\ t_{35} & t_{27} & t_{20} & t_{14} & t_9 & t_5 & t_2 & t_0 & t_0 & t_2 & t_5 & t_9 & t_{14} & t_{20} & t_{27} & t_{35} \\ t_{35} & t_{27} & t_{20} & t_{14} & t_9 & t_5 & t_2 & t_0 & t_0 & t_2 & t_5 & t_9 & t_{14} & t_{20} & t_{27} & t_{35} \\ t_{34} & t_{26} & t_{19} & t_{13} & t_8 & t_4 & t_1 & t_2 & t_2 & t_1 & t_4 & t_8 & t_{13} & t_{19} & t_{26} & t_{34} \\ t_{33} & t_{25} & t_{18} & t_{12} & t_7 & t_3 & t_4 & t_5 & t_5 & t_4 & t_3 & t_7 & t_{12} & t_{18} & t_{25} & t_{33} \\ t_{32} & t_{24} & t_{17} & t_{11} & t_6 & t_7 & t_8 & t_9 & t_9 & t_8 & t_7 & t_6 & t_{11} & t_{17} & t_{24} & t_{32} \\ t_{31} & t_{23} & t_{16} & t_{10} & t_{11} & t_{12} & t_{13} & t_{14} & t_{14} & t_{13} & t_{12} & t_{11} & t_{10} & t_{16} & t_{23} & t_{31} \\ t_{30} & t_{22} & t_{15} & t_{16} & t_{17} & t_{18} & t_{19} & t_{20} & t_{20} & t_{19} & t_{18} & t_{17} & t_{16} & t_{15} & t_{22} & t_{30} \\ t_{29} & t_{21} & t_{22} & t_{23} & t_{24} & t_{25} & t_{26} & t_{27} & t_{27} & t_{26} & t_{25} & t_{24} & t_{23} & t_{22} & t_{21} & t_{29} \\ t_{28} & t_{29} & t_{30} & t_{31} & t_{32} & t_{33} & t_{34} & t_{35} & t_{35} & t_{34} & t_{33} & t_{32} & t_{31} & t_{30} & t_{29} & t_{28} \end{bmatrix}$$

Görüldüğü gibi T şablonunun simetrik olmasından dolayı S ile ifade edilen değişkenlerin sayısı 36 olur ve S 'nin her bir elemanı aşağıda görüldüğü gibi ikili olarak kodlanmıştır:

$$S = [t_0 \quad t_1 \quad t_2 \quad . \quad . \quad . \quad t_{33} \quad t_{34} \quad t_{35}]$$

3. *Basamak. Amaç ve uygunluk fonksiyonlarının hesaplanması:* Bu aşamada eğitim görüntüsü olarak seçilen görüntü, ilk kromozoma bağlı olarak çalışan T şablonu ile konvole edilmiştir. Bu konvolüsyon işleminin amacı giriş görüntüsündeki normal yapılardan kitleyi ayırmaktır. $n \times m$ boyutlarındaki şablonun $T(x, y)$ ile ve $M \times N$ boyutlarındaki giriş görüntüsünün $I(x, y)$ ile temsil edildiği düşünülürse, T 'nin I ile konvolüsyonu denklem (IV.11) ile ifade edilir [106]:

$$C(x, y) = T * I(x, y) = \sum_{i=0}^{n-1} \sum_{j=0}^{m-1} T(i, j) I(x-i, y-j) \quad (\text{IV.11})$$

Burada $*$ işareti konvolüsyon işlemini temsil etmektedir. Konvolüsyon işlemi sonucunda şablona benzeyen yapılar daha güçlenirler. Bu yapıların piksel değerleri yüksek pozitif değerler alırken, şablona benzemeyen yapıların piksel değerleri yüksek negatif değerler alır. Bu yüzden konvolüsyon işleminden geçirilmiş C görüntüsünden kitleye benzer yapıları elde etmek amacıyla şu karar kuralı kullanılmıştır:

$$\text{EĞER } C(x, y) > 1 \text{ İSE}$$

$$C(x, y) = 1$$

$$\text{DEĞİLSE}$$

$$C(x, y) = -1$$

Konvolüsyon ve karar kuralının ardından çıktı görüntüsü olan C ve hedef görüntü A arasındaki amaç fonksiyonu hesaplanmıştır. Bu işlem popülasyondaki her bir kromozoma ait olan şablon kümeleri ile tekrar edilmiştir. Bu çalışmada kullanılan amaç fonksiyonu denklem (IV.12)'de görülmektedir [101].

$$amac(T) = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} C_{i,j} \oplus A_{i,j} \quad (IV.12)$$

Bu fonksiyonda $\oplus$ sembolü C ve A 'nın pikselleri arasındaki XOR işlemi temsil etmektedir. Amaç fonksiyonunun bu şekilde hesaplanmasından sonra, her bir kromozom için uygunluk değeri denklem (IV.13) ile hesaplanmıştır:


$$uygunluk(T) = M \times N - amac(T) \quad (IV.13)$$

Durdurma kriteri olarak denklem (IV.14) kullanılmıştır:


$$durdurmakriteri = 0.99 \times M \times N \quad (IV.14)$$

4. Basamak. Çaprazlama ve Mutasyon: Çaprazlama ve mutasyon ile yeni bir kuşağın oluşması sağlanmıştır. Durdurma kriteri sağlandığında ve genetik algoritma sonlandığında, en iyi T kitle şablonu elde edilmiştir. T kitle şablonunun eğitilmesi çalışmasının akış diyagramı Şekil IV.20'de görülmektedir.

Gerçek meme kitlelerinin morfolojileri kullanılarak normal yapılardan ayrılması için bu çalışmada şablon eşleme yöntemi kullanılmıştır. Mamografi görüntüsü kitle şablonu ile taranmış ve şablona benzeyen yapılar aranmıştır. Böylece çok küçük, çok ince veya çok uzun yapılar elenmiştir. Kitle şablonunun değerlerinin hesaplanması için genetik algoritma eniyileme yöntemi olarak kullanılmıştır. En iyi T kitle şablonunun bulunmasının ardından, ilgi alanlarından oluşan görüntü T şablon ile konvolüsyon işlemine tutulmuş ve gerçek kitlelerin bulunması için karar kuralı uygulanmıştır. HYSA şablonları ile bölütlenmiş meme bölgesindeki kitlelerin GA ile eğitilmiş şablon ile bulunması çalışmasının akış diyagramı Şekil IV.21'de görülmektedir.



Şekil IV.20. T kitle şablonunun eğitimi çalışmasının akış diyagramları



Şekil IV.21. HYSAB Şablonları İle Bölütlenmiş Meme Bölgesindeki Kitlelerin GA İle Eğitilmiş Şablon İle Bulunması Çalışmasının Akış Diyagramı.

BÖLÜM V

AKCİĞER BT GÖRÜNTÜLERİNDEKİ NODÜLLERİ TESPİT EDEN BDT YAZILIMLARININ TASARIMI

V.1. GİRİŞ

Bu bölümde tez kapsamında gerçekleştirilen akciğer BT görüntüleri üzerine yapılan çalışmalar açıklanmaktadır. Bu çalışmalar,

- kural tabanlı bölütlendirme kullanılarak akciğer bölgesinin elde edilmesi,
- hücresel yapay sinir ağları şablonları kullanılarak akciğer bölgesinin bölütlendirilmesi,
- morfolojik özellikler kullanılarak nodüllerin tespit edilmesi,
- şablon eşleme tekniği kullanılarak nodüllerin tespit edilmesi,
- genetik algoritma eğitimi ile en iyi şablon değerlerinin hesaplanması
- konvolüsyon tabanlı şablon eşleme yöntemi ile nodüllerin tespit edilmesi


başlıkları altında anlatılmaktadır.

V.2. AKCİĞER BİLGİSAYARLI TOMOGRAFİ (BT) GÖRÜNTÜLERİNDEKİ NODÜLLERİN TESPİT EDİLMESİ

Tez çalışması kapsamında akciğer BT görüntülerindeki nodüllerin tespit edilmesi amacıyla çeşitli yöntemler kullanılmıştır. Bu bölümde akciğer BT görüntüleri üzerinde gerçekleştirilen çalışmaların her biri alt bölümler halinde detaylı bir şekilde anlatılmaktadır.

V.2.1. Akciğer BT Görüntülerindeki Nodüllerin Kural Tabanlı Tespiti


Tez çalışmalarının ilk dönemlerinde gerçekleştirilen bu çalışmada EMAR İleri Görüntüleme ve Tanı Merkezinden alınan akciğer BT'leri kullanılmıştır. Şekil V.1'de görüldüğü gibi bu çalışmanın ilk aşaması bölüm III.3'de anlatılan yöntemle 8 yönlü arama yapılarak ilgi alanlarının bulunmasıdır. İki farklı ilgi alanı görüntüsü elde edilir. Örneğin Şekil V.2 için ilk ilgi alanı görüntüsü "*minimum uzunluk eşiği*" için 1 piksel ve "*maksimum uzunluk eşiği*" için 5 piksel değerleri atanarak Şekil V.3'de görüldüğü gibi elde edilir. Bu görüntüde görüldüğü gibi tüm yapılar nodüle benzer özellikler göstermektedir. Bu görüntüde nodülleri diğer yapılardan ayırmak mümkün değildir. Bu nedenle ikinci bir ilgi alanı görüntüsü "*minimum uzunluk eşiği*" için 0 piksel ve "*maksimum uzunluk eşiği*" için 5 piksel değerleri atanarak Şekil V.4'de görüldüğü gibi elde edilir. Nodüllerin sınıflandırılması amacıyla "*minimum uzunluk eşiği*" için 0 piksel verilerek elde edilen görüntüdeki ilgi alanlarının morfolojik özellikleri incelenir ve nodül özelliği göstermeyen yapılar "*minimum uzunluk eşiği*" için 1 piksel verilerek elde edilen görüntüden silinir.




Şekil V.1. Akciğer BT Görüntü Kesitlerindeki Nodüllerin Kural Tabanlı Tespitine Genel Bakış



Şekil V.2. 7 Adet Nodül İçeren Akciğer BT Kesiti




Şekil V.3. “Minimum Uzunluk Eşiği” 1 Piksel ve “Maximum Uzunluk Eşiği” 5 Piksel İçin İlgili Alanları



Şekil V.4. “Minimum Uzunluk Eşiği” 0 Piksel ve “Maximum Uzunluk Eşiği” 5 Piksel İçin İlgili Alanları


“*minimum uzunluk eşiği*” için 1 piksel verilerek elde edilen Şekil V.3’deki tüm ilgi alanlarının Şekil V.4’deki morfolojik özellikleri bölüm IV.2.1’de anlatılan iki kural kullanılarak incelenir. Bu kurallar yapıların öklid uzunluklarını ve biçim miktarlarını değerlendirir. Şekil V.4’deki bir ilgi alanı yapısı için her iki kural da geçerli ise yani, öklid uzunluğu “*öklid uzunluk eşiği*” değerinden büyük ve biçim miktarı da “*biçim eşiği*” değerinden büyük ise söz konusu yapı damardır. Bu yapı “*minimum uzunluk eşiği*” için 1 piksel verilerek elde edilen Şekil V.3’deki ilgi alanı görüntüsünden çıkartılır. Bu işlem Şekil V.3’deki tüm ilgi alanı yapıları için tekrar edilirse, sonuçta sadece nodülü bulunduran Şekil V.5’deki sonuç görüntüsü elde edilir. Akciğer nodüllerinin kural tabanlı tespiti çalışmasının akış diyagramı Şekil V.6’da görülmektedir.




Şekil V.5. Tespit Edilen Akciğer Nodülleri

V.2.2. Şablon Eşleme Yöntemiyle Nodüllerin Tespiti

Bu çalışmada LIDC veri setinden alınan akciğer BT kesitleri kullanılmıştır. Ayrıca önceki çalışmadan farklı olarak bu çalışmada öncelikle ilgi alanlarının alt ve üst kesitlerdeki konum değişimleri ele alınarak bir ön sınıflandırma gerçekleştirilmiş ve böylece ilgi alanı sayısı büyük oranda azaltılmıştır. Ardından kalan ilgi alanlarından nodülleri elde etmek amacıyla şablon eşleme yöntemi kullanılmıştır. Şablon eşleme işleminde benzerlik ölçümü olarak eşleşmede oluşan hatayı ölçen ve karar veren kural tabanlı bir yöntem kullanılmıştır. Bu çalışmada kullanılan yöntem Şekil V.7’de detaylı bir şekilde verilmiştir.




Şekil V.6. Akciğer Nodüllerinin Kural Tabanlı Tespiti Çalışmasının Akış Diyagramı



Şekil V.7. Nodüllerin Şablon Eşleme Yöntemiyle Tespiti

Radyoloji uzmanları ve BDT sistemleri için akciğer nodülü tespitinde karşılaşılan başlıca sorun seri kesit görüntülerinde karşılaşılan nodül büyüklüğünde görünümü ve nodülünkine benzer piksel yoğunluğu olan pek çok nesne olmasıdır. Bu nesnelerin çoğu seri kesitler boyunca devam eden damarlardır. Silindirik yapıya sahip bu damarlar bir kesite bakıldığında dairesel yapıda ve nodüle benzer çapta görülürler. Literatürdeki pek çok çalışmanın zayıf noktası 2 boyutlu görüntü özellikleriyle çalışmaları ve yüzlerce aday bölge ile uğraşmalarıdır. Bu yüzlerce aday bölge içinde zaman harcayan BDT sistemleri çok fazla miktarda yanlış pozitif sonuç buldukları gibi bu yanlış pozitifleri elemek amacıyla doğru pozitif bazı sonuçları da kaybetmektedirler [73].

Bu çalışmada kullanılan yöntem bu sorunu çözme düşüncesiyle ortaya çıkmıştır. Ardışık görüntülerde damarlar genelde çapraz bir şekilde durmaktadırlar ve kesitlere tek tek bakıldığında kesitler arasında kayma hareketi yaptıkları görülürken, gerçek akciğer nodülleri her kesitte aynı konumda görülmektedir. Nodül büyüklüklerinin hızla arttığı, birkaç kesitte sabit kaldıktan sonra hızla azaldığı görülmektedir. Bu çalışmanın esas dayanağı bu oluşumdur. Çalışmanın ilk aşaması olan ilgi alanlarının tespiti işlemi Şekil V.8'de 3'lü seri kesitler üzerinde görülmektedir. Şekil V.8 a, b ve c'de görülen seri akciğer BT görüntüleri üzerinde 8 yönlü tarama işlemi gerçekleştirildiğinde sırasıyla Şekil V.8 d, e ve f'de görülen ilgi alanları elde edilmiştir. Şekil V.8 a, b ve c'deki görüntülerde nodülün yeri daire içine alınarak gösterilmiştir. Dikkat edilecek olursa nodüllerin genel özelliği gereği aynı nodülü içeren her görüntüde nodül farklı büyüklüklerde de olsa aynı konumlarda yer almaktadır.



Şekil V.8. (a), (b), (c) Seri Akciğer BT Kesitleri, (d), (e), (f) Her Kesit İçin Bulunan İlgi Alanları


Seri görüntülerde damarların büyüklükleri aynı kalırken dairesel görünümeleri her kesitte konum değiştirmektedir. Fakat akciğer nodülleri her kesitte yaklaşık olarak aynı konumda yer almaktadır. İlgi alanlarının bu ilk sınıflandırılmasında BDT sistemi seri kesitlerdeki konum değişim miktarını ölçmektedir. İlgi alanlarının merkez noktalarının kesit içindeki konumlarını bulmak için tüm ilgi alanları bölüm

III.4’de detaylı bir şekilde anlatılan BBE tekniği kullanılarak etiketlenmiştir. BBE sayesinde tüm piksel koordinatları bilinen bir ilgi alanının merkez noktası hesaplanır. Şekil V.9’da olduğu gibi bir kesitteki ilgi alanı analiz edilirken, alttaki ve üstteki kesitlerdeki tüm ilgi alanlarının merkezleri ile olan öklid uzaklıkları hesaplanır. Bu uzaklıklardan en küçükleri (Ed_{minust} ve Ed_{minalt}) “konum değişim eşiği” ile karşılaştırılır ve adayların her biri şu karar kuralı ile sınıflandırılır:


$$\begin{aligned} &EĞER \quad Ed_{minust} > T_{lc} \quad VEYA \quad Ed_{minalt} > T_{lc} \quad İSE \\ &\quad \quad \quad normal \\ &DEĞİLSE \\ &\quad \quad \quad nodül adayı \end{aligned}$$

Burada Ed_{minust} ve Ed_{minalt} değerleri analiz edilen ilgi alanının sırasıyla üstteki ve alttaki kesitlerden konum değiştirme miktarlarıdır. T_{lc} ise “konum değişim eşiği” değeridir. Bu kural sonucunda normal yapı olarak sınıflandırılan yapılar ilgi alanı görüntüsünden silinir. Böylece inceleme altındaki Şekil V.8(b)’deki akciğer BT görüntüsündeki ilgi alanları Şekil V.10’b de görüldüğü şekilde elde edilmiş olur. Şekil V.10, Şekil V.8’b kesitindeki ilgi alanlarının konum değişimine göre sınıflandırma işleminden önceki ve sonraki görüntülerini vermektedir.

Bu noktadaki amaç ilgi alanlarının nodül veya normal yapı olarak sınıflandırılmasıdır. Önceki aşamada bulunmuş olan ilgi alanları incelendiğinde farklı morfolojik yapılarda oldukları gözlemlenmiştir. Yapısal özellikleri kullanarak nodülleri normal yapılardan ayırmak için Şekil V.10(a)’da görülmekte olan şablon kullanılmıştır. Şablon ilgi alanları bulunmuş BT görüntüleri üzerinde dolaştırılır ve benzer şekiller aranır. Şablon siyah ve beyaz piksellerden oluşmaktadır. Siyah pikseller akciğer nodülünü temsil ederken, beyaz pikseller “minimum yoğunluk eşiği” ile “maksimum yoğunluk eşiği” değer aralığı dışında yoğunluğa sahip pikselleri temsil etmektedir.



Şekil V.9. İlgi Alanlarının Konum Değişimlerinin Analiz Edilmesi.




Şekil V.10. (a) Şekil V.8(b)'deki BT İçin Bulunan İlgi Alanları, (b) İlgi Alanlarının Konum Değişimlerine Göre Sınıflandırılması

Şekil V.10(b)'deki inceleme altındaki kesit sol üst köşeden başlanarak piksel piksel taranır. Şekil V.11(c), nodül tespitinde 8 x 8 piksellik şablonun kullanılmasını göstermektedir. Bu eşleme işleminde 2 çeşit hata oluşur. “beyaz piksel hatası” ($E_{beyazpiksel}$) olarak adlandırılan koyu gri renkteki pikseller ilgi alanında olan fakat şablondaki nodülde parçası olmayan piksellerdir. “siyah piksel hatası” ($E_{siyahpiksel}$)


olarak adlandırılan gri renkteki pikseller şablondaki nodülde olan fakat ilgi alanın parçası olmayan piksellerdir. Şekil V.10(b)'deki her piksel için bu hata değerleri kullanılarak şablondaki nodüle benzer şekiller aranmıştır. Benzerlik 2 eşik değeri kullanılarak kontrol edilmiştir. Bunlar beyaz hata eşik değeri ($T_{beyazhata}$) ve siyah hata eşik değeri ($T_{siyahhata}$)'dir. Eşik değerleri küçük, ince ve uzun şekilleri önleyecek şekilde seçilmiştir ve şu kural tanımlanmıştır:

$EĞER \ E_{beyazpiksel} > T_{beyazhata} \ VE \ E_{siyahpiksel} < T_{siyahhata} \quad İSE$
nodül
 $DEĞİLSE$
Normal

Bu kuralda nodül olarak tespit edilen benzer şekillerin koordinatları kaydedilir ve bu koordinatlar gerçek akciğer nodülleri oluşturur. Şekil V.10(b)'nin şablon ile piksel piksel taranması ile nodüller tespit edilmiş olur. Akciğer nodüllerinin şablon eşleme yöntemiyle tespiti çalışmasının akış diyagramı Şekil V.12'de görülmektedir.




Şekil V.11. (a) Nodül Şablonu, (b) Gerçek Akciğer Nodülü, (C) Şablon Kullanılarak Nodülün Bir Parçasının Tespit Edilmesi



Şekil V.12. Akciğer Nodüllerinin Şablon Eşleme Yöntemiyle Tespiti Çalışmasının Akış Diyagramı

V.2.3. Akciğer Bölgesinin Bölütlendirilmesi ve Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemiyle Nodüllerin Tespit Edilmesi

Bu çalışmada akciğer BT'lerindeki nodülleri tespit etmek amacıyla tasarlanan BDT sisteminin blok şeması Şekil V.13'de görülmektedir. Öncelikle ilgi alanı sayısını ve hesaplama süresini azaltmak amacıyla akciğer bölgesinin bölütlendirilmesi gerçekleştirilmiştir. Blok I'de görülen bölütlendirme amacıyla iki farklı yöntem kullanılmıştır. Bu yöntemler kural-tabanlı yaklaşım ve genetik algoritma kullanılarak eğitilen hücresel yapay sinir ağı şablonları kullanılarak gerçekleştirilen şablon eşleme yaklaşımıdır. Blok II'de görüldüğü gibi akciğer kesitlerindeki piksellerin yoğunluk değerlerinin kullanıldığı ve eşikleme tabanlı 8 yönlü tarama işlemi ile ilgi alanları bulunmuştur. Bu ilgi alanlarının sayısının azaltılması için ilk sınıflandırma olarak eşikleme tabanlı konum değişim ölçümü yapılmıştır. Ardından blok III'deki şablon eşleme yöntemi ile nodüller tespit edilmiştir. Şablonu oluşturan değerler genetik algoritmalar kullanılarak eğitilmiştir. Böylece gerçek akciğer nodülleri tespit edilmiştir.



Şekil V.13. Bölütlendirilmiş Akciğer Bölgesinde GA İle Eğitilen Şablonlar Kullanılarak Akciğer Nodül Tespiti Aşamalarının Gösterimi

V.2.3.1. Akciğer Bölgesinin Kural Tabanlı Bölütlendirilmesi

Kural tabanlı bölütlendirmede kullanılan işlem basamakları şu şekildedir:

1-) *Eşikleme*: Şekil V.14(a)'de görüldüğü gibi nodüller, kemikler ve damarlar diğer yapılardan daha açık renktedir. Bu daha büyük HU değerlerine sahip olduklarını göstermektedir. Bu yüzden akciğer bölgesinin kabaca elde edilmesi için öncelikle eşikleme yöntemi uygulanmıştır. $I(x,y)$ ile ifade edilen Şekil V.14(a)'daki

görüntüye aşağıdaki kural uygulanırsa Şekil V.14(b)'deki görüntü elde edilir. Bu kuralda 1 beyaz rengi temsil ederken, 0 siyah rengi temsil etmektedir.

$$EĞER \quad I(x,y) < -500 \text{ HU} \quad İSE$$

$$I(x,y) = 1$$

$$DEĞİLSE$$

$$I(x,y) = 0$$

2-) *Etiketleme ve küçük siyah yapıların çıkarılması:* Şekil V.14(b)'de görüldüğü üzere beyaz akciğer bölgesinde nodül ve damar parçalarını temsil eden küçük siyah yapılar bulunmaktadır. Bunları çıkarmak için siyah yapılar bağlantılı bileşen etiketleme (BBE) yöntemi kullanılarak etiketlenmiş ve her yapıyı oluşturan piksellerin koordinatları kaydedilmiştir.

Şekil V.14(b)'de görülen akciğer bölgesindeki tüm siyah yapılar etiketlendikten sonra, aşağıdaki kural kullanılarak büyüklükleri incelenmiştir. k . siyah yapının piksel cinsinden büyüklüğünü temsil eden $S(k)$ değeri 150 pikselden küçük ise k . yapının görüntüdeki piksel değerlerini temsil eden $I(x,y)$ değerine 1 atanır. Böylece küçük olan siyah yapılar Şekil V.14(b)'den çıkartılarak Şekil V.14(c) elde edilmiş olunur.

$$EĞER \quad S(k) < 150 \text{ piksel} \quad İSE \quad I(x,y) = 1$$

3-) *Etiketleme ve akciğer bölgesinin elde edilmesi:* Şekil V.14(c)'deki akciğer bölgesini elde etmek için beyaz renkteki yapılar BBE kullanılarak etiketlenmiş ve morfolojileri incelenmiştir. Şekil V.14(c)'de görüldüğü gibi akciğer bölgesinin en-boy oranı diğer yapılarınkinden küçüktür. Yapıların özellikleri aşağıdaki kural ile incelenmiştir. Bu kuralda $EBO(k)$ k . yapının en-boy oranını, $G(k)$ k . yapının genişliğini ve $I(x,y)$ da k . yapının görüntüdeki piksel değerlerini temsil etmektedir. Bu kurala göre en-boy oranı 1.5'dan büyük olan veya genişliği 50 pikselden küçük olan yapılar çıkartılmış ve sonuçta akciğer bölgesi elde edilmiştir.

$$EĞER \quad EBO(k) > 1.5 \quad VEYA \quad G(k) < 50 \text{ pixels} \quad İSE \quad I(x,y) = 0$$

Bu 3 basamağın ardından Şekil V.14(a)'daki akciğer bölgesi Şekil V.14(d) ve Şekil V.14(e)'de görüldüğü gibi elde edilmiştir. Akciğer bölgesinin kural tabanlı bölütlendirilmesi çalışmasının akış diyagramı Şekil V.15'de görülmektedir.




(a)



(b)



(c)




(d)



(e)

Şekil V.14. Akciğer Bölgesinin Kural-Tabanlı Bölütlendirme Basamakları, (a) BT Görüntüsü, (b) Eşikleme, (c) Etiketleme ve Akciğer Bölgesindeki Küçük Siyah Yapıların Çıkarılması, (d) Etiketleme ve Akciğer Bölgesinin Elde Edilmesi, (e) Akciğer Bölgesinin BT Görüntüsü.



Şekil V.15. Akciğer Bölgesinin Kural Tabanlı Bölütlendirilmesi Çalışmasının Akış Diyagramı

V.2.3.2. Akciğer Bölgesinin Hücresel Yapay Sinir Ağı Şablonları Kullanılarak Bölütlendirilmesi

Akciğer bölgesini bölütlendirecek HYSA şablonlarının eğitimi için kullanılan genetik algoritma işlem basamakları şu şekildedir:

1. *Basamak. İlk popülasyonun oluşturulması:* Başlangıç popülasyon matrisi $m \times n$ boyutlarında rasgele oluşturulmuştur.

2. *Basamak. HYSA şablonlarının oluşturulması:* Bu basamağın detayları bölüm IV.2.3’de anlatılmaktadır.


Akciğer bölgesinin bölütlendirilmesi için A ve B şablonları için komşuluk derecesi olarak 10 değeri kullanılmıştır. Şablonların simetrik olması için her bir şablon 66 değişkenden oluşmuştur. Böylece S değişken vektörü A şablonu için 66 değişken, B şablonu için 66 değişken ve I şablonu için 1 değişken olmak üzere toplam 133 değişkene sahiptir. 21 x 21 piksel boyutlarındaki A ve B şablonları şu şekildedir.

$$A = \begin{bmatrix} A_0 & A_1 & A_2 & A_3 & A_4 & A_5 & A_6 & A_7 & A_8 & A_9 & A_{10} & A_9 & A_8 & A_7 & A_6 & A_5 & A_4 & A_3 & A_2 & A_1 & A_0 \\ A_1 & A_{11} & A_{12} & A_{13} & A_{14} & A_{15} & A_{16} & A_{17} & A_{18} & A_{19} & A_{20} & A_{19} & A_{18} & A_{17} & A_{16} & A_{15} & A_{14} & A_{13} & A_{12} & A_{11} & A_1 \\ A_2 & A_{12} & A_{21} & A_{22} & A_{23} & A_{24} & A_{25} & A_{26} & A_{27} & A_{28} & A_{29} & A_{28} & A_{27} & A_{26} & A_{25} & A_{24} & A_{23} & A_{22} & A_{21} & A_{12} & A_2 \\ A_3 & A_{13} & A_{22} & A_{30} & A_{31} & A_{32} & A_{33} & A_{34} & A_{35} & A_{36} & A_{37} & A_{36} & A_{35} & A_{34} & A_{33} & A_{32} & A_{31} & A_{30} & A_{22} & A_{13} & A_3 \\ A_4 & A_{14} & A_{23} & A_{31} & A_{38} & A_{39} & A_{40} & A_{41} & A_{42} & A_{43} & A_{44} & A_{43} & A_{42} & A_{41} & A_{40} & A_{39} & A_{38} & A_{31} & A_{23} & A_{14} & A_4 \\ A_5 & A_{15} & A_{24} & A_{32} & A_{39} & A_{45} & A_{46} & A_{47} & A_{48} & A_{49} & A_{50} & A_{49} & A_{48} & A_{47} & A_{46} & A_{45} & A_{39} & A_{32} & A_{24} & A_{15} & A_5 \\ A_6 & A_{16} & A_{25} & A_{33} & A_{40} & A_{46} & A_{51} & A_{52} & A_{53} & A_{54} & A_{55} & A_{54} & A_{53} & A_{52} & A_{51} & A_{46} & A_{40} & A_{33} & A_{25} & A_{16} & A_6 \\ A_7 & A_{17} & A_{26} & A_{34} & A_{41} & A_{47} & A_{52} & A_{56} & A_{57} & A_{58} & A_{59} & A_{58} & A_{57} & A_{56} & A_{52} & A_{47} & A_{41} & A_{34} & A_{26} & A_{17} & A_7 \\ A_8 & A_{18} & A_{27} & A_{35} & A_{42} & A_{48} & A_{53} & A_{57} & A_{60} & A_{61} & A_{62} & A_{61} & A_{60} & A_{57} & A_{53} & A_{48} & A_{42} & A_{35} & A_{27} & A_{18} & A_8 \\ A_9 & A_{19} & A_{28} & A_{36} & A_{43} & A_{49} & A_{54} & A_{58} & A_{61} & A_{63} & A_{64} & A_{63} & A_{61} & A_{58} & A_{54} & A_{49} & A_{43} & A_{36} & A_{28} & A_{19} & A_9 \\ A_{10} & A_{20} & A_{29} & A_{37} & A_{44} & A_{50} & A_{55} & A_{59} & A_{62} & A_{64} & A_{65} & A_{64} & A_{62} & A_{59} & A_{55} & A_{50} & A_{44} & A_{37} & A_{29} & A_{20} & A_{10} \\ A_9 & A_{19} & A_{28} & A_{36} & A_{43} & A_{49} & A_{54} & A_{58} & A_{61} & A_{63} & A_{64} & A_{63} & A_{61} & A_{58} & A_{54} & A_{49} & A_{43} & A_{36} & A_{28} & A_{19} & A_9 \\ A_8 & A_{18} & A_{27} & A_{35} & A_{42} & A_{48} & A_{53} & A_{57} & A_{60} & A_{61} & A_{62} & A_{61} & A_{60} & A_{57} & A_{53} & A_{48} & A_{42} & A_{35} & A_{27} & A_{18} & A_8 \\ A_7 & A_{17} & A_{26} & A_{34} & A_{41} & A_{47} & A_{52} & A_{56} & A_{57} & A_{58} & A_{59} & A_{58} & A_{57} & A_{56} & A_{52} & A_{47} & A_{41} & A_{34} & A_{26} & A_{17} & A_7 \\ A_6 & A_{16} & A_{25} & A_{33} & A_{40} & A_{46} & A_{51} & A_{52} & A_{53} & A_{54} & A_{55} & A_{54} & A_{53} & A_{52} & A_{51} & A_{46} & A_{40} & A_{33} & A_{25} & A_{16} & A_6 \\ A_5 & A_{15} & A_{24} & A_{32} & A_{39} & A_{45} & A_{46} & A_{47} & A_{48} & A_{49} & A_{50} & A_{49} & A_{48} & A_{47} & A_{46} & A_{45} & A_{39} & A_{32} & A_{24} & A_{15} & A_5 \\ A_4 & A_{14} & A_{23} & A_{31} & A_{38} & A_{39} & A_{40} & A_{41} & A_{42} & A_{43} & A_{44} & A_{43} & A_{42} & A_{41} & A_{40} & A_{39} & A_{38} & A_{31} & A_{23} & A_{14} & A_4 \\ A_3 & A_{13} & A_{22} & A_{30} & A_{31} & A_{32} & A_{33} & A_{34} & A_{35} & A_{36} & A_{37} & A_{36} & A_{35} & A_{34} & A_{33} & A_{32} & A_{31} & A_{30} & A_{22} & A_{13} & A_3 \\ A_2 & A_{12} & A_{21} & A_{22} & A_{23} & A_{24} & A_{25} & A_{26} & A_{27} & A_{28} & A_{29} & A_{28} & A_{27} & A_{26} & A_{25} & A_{24} & A_{23} & A_{22} & A_{21} & A_{12} & A_2 \\ A_1 & A_{11} & A_{12} & A_{13} & A_{14} & A_{15} & A_{16} & A_{17} & A_{18} & A_{19} & A_{20} & A_{19} & A_{18} & A_{17} & A_{16} & A_{15} & A_{14} & A_{13} & A_{12} & A_{11} & A_1 \\ A_0 & A_1 & A_2 & A_3 & A_4 & A_5 & A_6 & A_7 & A_8 & A_9 & A_{10} & A_9 & A_8 & A_7 & A_6 & A_5 & A_4 & A_3 & A_2 & A_1 & A_0 \end{bmatrix}$$


$$B = \begin{bmatrix} B0 & B1 & B2 & B3 & B4 & B5 & B6 & B7 & B8 & B9 & B10 & B9 & B8 & B7 & B6 & B5 & B4 & B3 & B2 & B1 & B0 \\ B1 & B11 & B12 & B13 & B14 & B15 & B16 & B17 & B18 & B19 & B20 & B19 & B18 & B17 & B16 & B15 & B14 & B13 & B12 & B11 & B1 \\ B2 & B12 & B21 & B22 & B23 & B24 & B25 & B26 & B27 & B28 & B29 & B28 & B27 & B26 & B25 & B24 & B23 & B22 & B21 & B2 & B2 \\ B3 & B13 & B22 & B30 & B31 & B32 & B33 & B34 & B35 & B36 & B37 & B36 & B35 & B34 & B33 & B32 & B31 & B30 & B22 & B13 & B3 \\ B4 & B14 & B23 & B31 & B38 & B39 & B40 & B41 & B42 & B43 & B44 & B43 & B42 & B41 & B40 & B39 & B38 & B31 & B23 & B14 & B4 \\ B5 & B15 & B24 & B32 & B39 & B45 & B46 & B47 & B48 & B49 & B50 & B49 & B48 & B47 & B46 & B45 & B39 & B32 & B24 & B15 & B5 \\ B6 & B16 & B25 & B33 & B40 & B46 & B51 & B52 & B53 & B54 & B55 & B54 & B53 & B52 & B51 & B46 & B40 & B33 & B25 & B16 & B6 \\ B7 & B17 & B26 & B34 & B41 & B47 & B52 & B56 & B57 & B58 & B59 & B58 & B57 & B56 & B52 & B47 & B41 & B34 & B26 & B17 & B7 \\ B8 & B18 & B27 & B35 & B42 & B48 & B53 & B57 & B60 & B61 & B62 & B61 & B60 & B57 & B53 & B48 & B42 & B35 & B27 & B18 & B8 \\ B9 & B19 & B28 & B36 & B43 & B49 & B54 & B58 & B61 & B63 & B64 & B63 & B61 & B58 & B54 & B49 & B43 & B36 & B28 & B19 & B9 \\ B10 & B20 & B29 & B37 & B44 & B50 & B55 & B59 & B62 & B64 & B65 & B64 & B62 & B59 & B55 & B50 & B44 & B37 & B29 & B20 & B10 \\ B9 & B19 & B28 & B36 & B43 & B49 & B54 & B58 & B61 & B63 & B64 & B63 & B61 & B58 & B54 & B49 & B43 & B36 & B28 & B19 & B9 \\ B8 & B18 & B27 & B35 & B42 & B48 & B53 & B57 & B60 & B61 & B62 & B61 & B60 & B57 & B53 & B48 & B42 & B35 & B27 & B18 & B8 \\ B7 & B17 & B26 & B34 & B41 & B47 & B52 & B56 & B57 & B58 & B59 & B58 & B57 & B56 & B52 & B47 & B41 & B34 & B26 & B17 & B7 \\ B6 & B16 & B25 & B33 & B40 & B46 & B51 & B52 & B53 & B54 & B55 & B54 & B53 & B52 & B51 & B46 & B40 & B33 & B25 & B16 & B6 \\ B5 & B15 & B24 & B32 & B39 & B45 & B46 & B47 & B48 & B49 & B50 & B49 & B48 & B47 & B46 & B45 & B39 & B32 & B24 & B15 & B5 \\ B4 & B14 & B23 & B31 & B38 & B39 & B40 & B41 & B42 & B43 & B44 & B43 & B42 & B41 & B40 & B39 & B38 & B31 & B23 & B14 & B4 \\ B3 & B13 & B22 & B30 & B31 & B32 & B33 & B34 & B35 & B36 & B37 & B36 & B35 & B34 & B33 & B32 & B31 & B30 & B22 & B13 & B3 \\ B2 & B12 & B21 & B22 & B23 & B24 & B25 & B26 & B27 & B28 & B29 & B28 & B27 & B26 & B25 & B24 & B23 & B22 & B21 & B12 & B2 \\ B1 & B11 & B12 & B13 & B14 & B15 & B16 & B17 & B18 & B19 & B20 & B19 & B18 & B17 & B16 & B15 & B14 & B13 & B12 & B11 & B1 \\ B0 & B1 & B2 & B3 & B4 & B5 & B6 & B7 & B8 & B9 & B10 & B9 & B8 & B7 & B6 & B5 & B4 & B3 & B2 & B1 & B0 \end{bmatrix}$$

3. Basamak olan amaç ve uygunluk fonksiyonlarının hesaplanması ve 4. basamak olan çaprazlama ve mutasyon basamaklarının detayları bölüm IV.2.3’de anlatılmaktadır. Akciğer bölgesinin bölütlendirilmesi amacıyla HYSA şablonlarının eğitilmesi çalışmasının akış diyagramı Şekil V.16’da görülmektedir.

Şekil V.17(a)’daki akciğer BT görüntüsüne bölüm V.2.3.1’de anlatılan eşikleme kuralı uygulanarak Şekil V.17(b)’deki eşiklenmiş görüntü elde edilir. Bu görüntü, eğitilmiş A, B ve I şablonları ile çalışan HYSA girişine uygulandığında Şekil V.17(c)’deki görüntü elde edilir. Şekil V.17(d)’de orijinal akciğer BT görüntüsündeki akciğer bölgesini göstermektedir.



Şekil V.16. Akciğer Bölgesinin Bölütlendirilmesi Amacıyla HYSA Şablonlarının Eğitilmesi Çalışmasının Akış Diyagramı



Şekil V.17. (a) Orijinal akciğer BT Görüntüsü, (b) HYSA'nın Girişini Oluşturan Eşiklenmiş Görüntü, (c) HYSA Kullanılarak Bölütlendirilmiş Akciğer Bölgesi, (d) Akciğer Bölgesinin Orijinal Görüntüsü.

V.2.3.3. Bölütlendirilmiş Akciğer Bölgesindeki Nodüllerin Genetik Algoritma Kullanılarak Eğitilmiş Şablon İle Tespit Edilmesi

Akciğer bölgesinin Şekil V.17(d)'de görüldüğü gibi bölütlendirilmesinin ardından, elde edilen bu görüntüye bölüm III.3'de anlatılan 8 yönlü ilgi alanı arama yöntemi uygulanarak ilgi alanları bulunmuştur. Ardından bir önceki çalışmada kullanılan ve bölüm V.2.2'de anlatılan seri kesitlerde ilgi alanların konum değişimlerinin analiz edilerek sınıflandırılması yöntemi kullanılarak ilgi alanlarının ilk sınıflandırılması gerçekleştirilmiştir.

İlgi alanları arasındaki gerçek akciğer nodüllerini tespit etmek amacıyla ikinci sınıflandırma aşamasında kullanılacak olan nodül şablonunun eğitimi için gerçekleştirilen genetik algoritma basamakları şu şekildedir:

1. *Basamak. İlk popülasyonun oluşturulması:* Başlangıç popülasyon matrisi $m \times n$ boyutlarında rastsal olarak oluşturulmuştur.

2. *Basamak. HYSA şablonlarının oluşturulması:* Kromozomlar nodül şablonu olan T şablonunun ikili kodlanmasından oluşturulmuştur. Şablon değerleri ise $[-1,1]$ değer aralığında kromozom kodlarının çözülmesiyle hesaplanmıştır. 8×8 piksel boyutlarında olan T nodül şablonu şu şekildedir.

$$T = \begin{bmatrix} t_6 & t_7 & t_8 & t_9 & t_9 & t_8 & t_7 & t_6 \\ t_7 & t_3 & t_4 & t_5 & t_5 & t_4 & t_3 & t_7 \\ t_8 & t_4 & t_1 & t_2 & t_2 & t_1 & t_4 & t_8 \\ t_9 & t_5 & t_2 & t_0 & t_0 & t_2 & t_5 & t_9 \\ t_9 & t_5 & t_2 & t_0 & t_0 & t_2 & t_5 & t_9 \\ t_8 & t_4 & t_1 & t_2 & t_2 & t_1 & t_4 & t_8 \\ t_7 & t_3 & t_4 & t_5 & t_5 & t_4 & t_3 & t_7 \\ t_6 & t_7 & t_8 & t_9 & t_9 & t_8 & t_7 & t_6 \end{bmatrix}$$


Görüldüğü üzere T şablonunun simetrik olmasından dolayı S ile ifade edilen değişkenlerin sayısı 10 olur ve S 'nin her bir elemanı ikili olarak kodlanmıştır:

$$S = [t_0 \ t_1 \ t_2 \ t_3 \ t_4 \ t_5 \ t_6 \ t_7 \ t_8 \ t_9]$$


3. Basamak olan amaç ve uygunluk fonksiyonlarının hesaplanması ve 4. basamak olan çaprazlama ve mutasyon basamaklarının detayları bölüm IV.2.3'de anlatılmaktadır. T nodül şablonunun eğitilmesi çalışmasının akış diyagramı Şekil V.18'de görülmektedir.

Bu çalışmada gerçek akciğer nodüllerini normal yapılardan ayrılması için şablon eşleme yöntemi kullanılmıştır. Çok küçük, çok ince veya çok uzun yapıların çıkarılması amacıyla kullanılan nodül şablonunun değerlerinin hesaplanması için genetik algoritma eniyileme yöntemi olarak kullanılmıştır. En iyi T nodül şablonunun bulunmasının ardından, ilgi alanlarından oluşan görüntünün T şablon ile konvolüsyonu ve gerçek nodüllerin bulunması için karar kuralı uygulanmıştır.

Bölütlenmiş akciğer bölgesindeki nodüllerin GA ile eğitilmiş şablon ile bulunması çalışmasının akış diyagramı Şekil V.19’da görülmektedir.



Şekil V.18. T nodül şablonunun eğitimi çalışmasının akış diyagramları



Şekil V.19. Bölütlenmiş Akciğer Bölgesindeki Nodülleri GA İle Eğitilmiş Şablon İle Bulunması Çalışmasının Akış Diyagramı.

BÖLÜM VI

SONUÇLAR

VI.1. GİRİŞ

Bu bölümde, tez çalışması kapsamında gerçekleştirilen ve bölüm IV ve V’de anlatılan BDT yazılımlarının sonuçları detaylı olarak incelenmektedir. Sonuçlar iki bölüm halinde verilmektedir. Birinci bölümde mamografi görüntülerinde kitle tespiti için kullanılan yöntemlerin sonuçları, ikinci bölümde ise akciğer BT görüntülerindeki nodüllerin tespiti için kullanılan yöntemlerin sonuçları verilmektedir.

Mamografi görüntülerindeki ve akciğer BT görüntülerindeki anormallikleri tespit eden yöntemler Matlab programlama dili kullanılarak geliştirilmiştir. Matlab yazılımının görüntü işleme ve genetik algoritma paketlerinden faydalanılmıştır. Ayrıca akciğer kesitlerinin görüntülenmesi amacıyla Dicomworks yazılımı kullanılmıştır. Yöntemler Intel Celeron 1.40 GHz işlemciye, 768 MB RAM belleğe, 128 MB bellekli ekran kartına sahip ve üzerinde Windows XP Professional kurulu HP marka bir dizüstü bilgisayarda geliştirilmiştir.

VI.2. MAMOGRAFİ GÖRÜNTÜLERİNDEKİ KİTLELERİN TESPİT EDİLMESİ ÇALIŞMALARININ SONUÇLARI

Tez çalışması kapsamında mamografi görüntülerindeki kitlelerin tespit edilmesi amacıyla kullanılan yöntemler bölüm IV’de anlatılmıştır. Bu yöntemlerin

mamografi görüntülerine uygulanmasıyla elde edilen sonuçlar bu bölümde açıklanmaktadır.

VI.2.1. Mamografi Görüntülerindeki Kitlelerin Kural Tabanlı Tespiti Çalışmasının Sonuçları

İlgi alanlarının uzunluk, kalınlık ve biçim gibi morfolojik özelliklerinin kural tabanlı analiz edildiği bu çalışmada 52 adet mamografi görüntüsü kullanılmıştır. Bu 52 görüntüden 22 tanesi sınırları düzgün kitle içerirken, 19 adet görüntüde spiküler kitle bulunmaktadır. Geri kalan görüntüler normal görüntülerdir. İlgi alanlarının tespit edilmesi amacıyla “*minimum uzunluk eşiği*” ve “*maksimum uzunluk eşiği*” için uygun değerler atanarak 332 adet ilgi alanı belirlenmiştir. Bu ilgi alanları BBE yöntemi ile etiketlendikten sonra her birinin morfolojik özellikleri belirlenen kurallar aracılığıyla incelenerek sınıflandırılmışlardır. Elde edilen sonuçlar Tablo VI.1’de görülmektedir. Şekil VI.1’de bir mamografi görüntüsünde ilgi alanlarının ve kitlenin tespiti görülmektedir.


Tablo VI.1. Kitlelerin Kural Tabanlı Tespiti Çalışmasının Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	38 adet Doğru pozitif	15 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	5 adet Yanlış negatif	274 adet Doğru negatif
Duyarlılık		% 88.3	
Görüntü başına düşen YP oranı		0.288	


VI.2.2. Şablon Eşleme Yöntemiyle Kitlelerin Tespiti Çalışmasının Sonuçları

Şablon eşleme yöntemi kullanılarak meme kitlelerinin tespit edildiği bu çalışmada sınırları düzgün kitle içeren 22 görüntü, spiküler kitle içeren 19 görüntü ve 11 adet normal görüntü olmak üzere toplam 52 adet görüntü kullanılmıştır. Şekil VI.2(a)’da spiküler kitle içeren bir mamografi görüntüsünü görülmektedir. İlgi

alanları, tespit edilen kitle ve orijinal görüntüdeki yeri sırasıyla Şekil VI.2(b), VI.2(c) ve VI.2(d)'de görülmektedir.



Şekil VI.1. (a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, (b) Belirlenmiş İlgi Alanları, (c) Kural Tabanlı Yaklaşım İle Kitle Olarak Sınıflandırılmış İlgi Alanı, (d) Mamografi Görüntüsü Üzerinde Tespit Edilen Kitle



Şekil VI.2. (a) Sınırları Düzgün Kitle İçeren Mamografi Görüntüsü, b) Belirlenmiş İlgi Alanları, c) Şablon Eşleme Yöntemi İle Kitle Olarak Sınıflandırılmış İlgi Alanı, d) Mamografi Görüntüsü Üzerinde Tespit Edilen Kitle

İlgi alanı belirleme yöntemleriyle BDT sisteminin işini kolaylaştıran 332 kitle adayı belirlenmiştir. Bu adaylardan çoğu damar gibi normal yapı parçalarıdır. Bu ilgi alanlarının sınıflandırılması çapları 30 piksel (30 x 30 piksel boyutlarında), 20 piksel (20 x 20 piksel boyutlarında) ve 10 piksel (10 x 10 piksel boyutlarında) olan 3 adet şablon ile gerçekleştirilmiştir ve elde edilen sonuçlar da sırasıyla Tablo VI.2, Tablo VI.3 ve Tablo VI.4’de görülmektedir.

Tablo VI.2. Kitlelerin 30 Piksel Çapındaki Şablon Kullanılarak Tespiti Çalışmasının Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	35 adet Doğru pozitif	17 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	8 adet Yanlış negatif	272 adet Doğru negatif
Duyarlılık		% 81.3	
Görüntü başına düşen YP oranı		0.33	


Tablo VI.3. Kitlelerin 20 Piksel Çapındaki Şablon Kullanılarak Tespiti Çalışmasının Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	39 adet Doğru pozitif	36 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	4 adet Yanlış negatif	253 adet Doğru negatif
Duyarlılık		% 90	
Görüntü başına düşen YP oranı		0.7	


Tablo VI.4. Kitlelerin 10 Piksel Çapındaki Şablon Kullanılarak Tespiti Çalışmasının Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	40 adet Doğru pozitif	68 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	3 adet Yanlış negatif	221 adet Doğru negatif
Duyarlılık		% 93	
Görüntü başına düşen YP oranı		1.3	


İlgi alanlarının bu şablonlarla taranması sonucunda elde edilen doğru pozitif oranları Şekil VI.3’de, yanlış pozitif oranları da Şekil VI.4’de görülmektedir. Elde edilen duyarlılık ile görüntü başına düşen yanlış pozitif oranı arasındaki ilişkiyi gösteren eğri Şekil VI.5’de görülmektedir.



Şekil VI.3. Şablon Eşleme Yöntemiyle Kitle Tespiti Çalışmasında Şablon Çapı İle Görüntü Başına Düşen Doğru Pozitif Oranı Grafiği



Şekil VI.4. Şablon Eşleme Yöntemiyle Kitle Tespiti Çalışmasında Şablon Çapı İle Görüntü Başına Düşen Yanlış Pozitif Oranı Grafiği



Şekil VI.5. Şablon Eşleme Yöntemiyle Kitle Tespitinde Yazılımın Performansını Gösteren FROC (Free-Response Receiver Operating Characteristic) Eğrisi

VI.2.3. Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemleriyle Meme Bölgesinin Bölütlendirilmesi ve Kitlelerin Tespit Edilmesi Çalışmasının Sonuçları

Bu çalışmada gerçekleştirilen BDT yazılımı sınırları düzgün kitle içeren 22 görüntü, spiküler kitle içeren 19 görüntü ve 11 adet normal görüntü olmak üzere toplam 52 adet görüntü üzerinde test edilmiştir. Meme bölgesinin bölütlendirilmesi için genetik algoritma ile eğitilmiş HYSA şablonları kullanılmıştır. Bölüm IV.2.3’de anlatıldığı gibi gerçekleştirilen eğitim işlemi sonucunda elde edilen genetik algoritma parametreleri Tablo VI.5’de görülmektedir. A ve B şablonları da aşağıda görülmektedir. I şablonun değeri de -4.1373 olarak elde edilmiştir.

Bölütlendirilmiş meme bölgesi üzerinde 8 yönlü tarama yapılarak 273 adet ilgi alanı bulunmuştur. Bu ilgi alanlarının sınıflandırılması için boyutları 16 x 16 piksel olan T kitle şablonu kullanılmıştır. T şablonu değerlerinin hesaplanması için genetik algoritma kullanılmıştır. Eğitim işlemi sonucunda elde edilen genetik algoritma parametreleri Tablo VI.6’da ve kitle şablonunun değerleri de Tablo VI.7’de görülmektedir.

Tablo VI.5. Meme Bölgesinin Bölütlendirilmesinde Kullanılan HYSA Şablonlarının GA ile Eğitim Parametreleri

Parametreler:	Değerler
Popülasyon başına düşen kromozom sayısı	100
Değişken başına düşen Bit sayısı	8
Değişken sayısı	43
Kromozom uzunluğu	344
Popülasyondaki toplam bit sayısı	34400
Üreme için kullanılan çaprazlama olasılığı	70%
Mutasyon olasılığı	1%
Kuşak farkı	98%
Şablon parametreleri değer aralığı	[-5, 5]

$$A = \begin{bmatrix} -2.49 & 3.43 & -0.84 & 0.10 & 1.24 & 4.45 & 1.24 & 0.10 & -0.84 & 3.43 & -2.49 \\ 3.43 & 2.14 & 4.06 & 3.78 & 1.86 & 1.78 & 1.86 & 3.78 & 4.06 & 2.14 & 3.43 \\ -0.84 & 4.06 & -1.12 & 2.25 & 3.08 & 3.12 & 3.08 & 2.25 & -1.12 & 4.06 & -0.84 \\ 0.10 & 3.78 & 2.25 & -4.61 & 2.88 & -4.53 & 2.88 & -4.61 & 2.25 & 3.78 & 0.10 \\ 1.24 & 1.86 & 3.08 & 2.88 & 4.37 & -3.24 & 4.37 & 2.88 & 3.08 & 1.86 & 1.24 \\ 4.45 & 1.78 & 3.12 & -4.53 & -3.24 & 2.45 & -3.24 & -4.53 & 3.12 & 1.78 & 4.45 \\ 1.24 & 1.86 & 3.08 & 2.88 & 4.37 & -3.24 & 4.37 & 2.88 & 3.08 & 1.86 & 1.24 \\ 0.10 & 3.78 & 2.25 & -4.61 & 2.88 & -4.53 & 2.88 & -4.61 & 2.25 & 3.78 & 0.10 \\ -0.84 & 4.06 & -1.12 & 2.25 & 3.08 & 3.12 & 3.08 & 2.25 & -1.12 & 4.06 & -0.84 \\ 3.43 & 2.14 & 4.06 & 3.78 & 1.86 & 1.78 & 1.86 & 3.78 & 4.06 & 2.14 & 3.43 \\ -2.49 & 3.43 & -0.84 & 0.10 & 1.24 & 4.45 & 1.24 & 0.10 & -0.84 & 3.43 & -2.49 \end{bmatrix}$$

$$B = \begin{bmatrix} -0.88 & -0.29 & -3.63 & 2.61 & -3.63 & 2.69 & -3.63 & 2.61 & -3.63 & -0.29 & -0.88 \\ -0.29 & -3.27 & 0.49 & -0.18 & -1.55 & -4.02 & -1.55 & -0.18 & 0.49 & -3.27 & -0.29 \\ -3.63 & 0.49 & -3.35 & 1.75 & 0.88 & 3.39 & 0.88 & 1.75 & -3.35 & 0.49 & -3.63 \\ 2.61 & -0.18 & 1.75 & 2.69 & 1.16 & 1.08 & 1.16 & 2.69 & 1.75 & -0.18 & 2.61 \\ -3.63 & -1.55 & 0.88 & 1.16 & -2.33 & 4.92 & -2.33 & 1.16 & 0.88 & -1.55 & -3.63 \\ 2.69 & -4.02 & 3.39 & 1.08 & 4.92 & 4.61 & 4.92 & 1.08 & 3.39 & -4.02 & 2.69 \\ -3.63 & -1.55 & 0.88 & 1.16 & -2.33 & 4.92 & -2.33 & 1.16 & 0.88 & -1.55 & -3.63 \\ 2.61 & -0.18 & 1.75 & 2.69 & 1.16 & 1.08 & 1.16 & 2.69 & 1.75 & -0.18 & 2.61 \\ -3.63 & 0.49 & -3.35 & 1.75 & 0.88 & 3.39 & 0.88 & 1.75 & -3.35 & 0.49 & -3.63 \\ -0.29 & -3.27 & 0.49 & -0.18 & -1.55 & -4.02 & -1.55 & -0.18 & 0.49 & -3.27 & -0.29 \\ -0.88 & -0.29 & -3.63 & 2.61 & -3.63 & 2.69 & -3.63 & 2.61 & -3.63 & -0.29 & -0.88 \end{bmatrix}$$

Tablo VI.6. Kitle Şablonu Eğitimi İçin Kullanılan Genetik Algoritma Parametreleri

Parametreler:	Değerler
Popülasyon başına düşen kromozom sayısı	100
Değişken başına düşen Bit sayısı	8
Değişken sayısı	36
Kromozom uzunluğu	288
Popülasyondaki toplam bit sayısı	28800
Üreme için kullanılan çaprazlama olasılığı	70%
Mutasyon olasılığı	1%
Kuşak farkı	98%
Şablon parametreleri değer aralığı	[-1, 1]

Tablo VI.7. Genetik Algoritma İle Hesaplanmış Kitle Şablonu Değerleri


Parametre	Değerler	Parametre	Değerler
T_0	0.92941	t_{18}	0.05098
T_1	0.17647	t_{19}	-0.42745
T_2	0.98431	t_{20}	-0.85098
T_3	0.12157	t_{21}	-0.16863
T_4	0.1451	t_{22}	-0.066667
T_5	0.56863	t_{23}	0.69412
T_6	0.81176	t_{24}	0.41961
T_7	0.95294	t_{25}	-0.48235
T_8	0.23922	t_{26}	-0.45098
T_9	-0.15294	t_{27}	0.92157
T_{10}	0.62353	t_{28}	0.16863
T_{11}	0.51373	t_{29}	0.11373
T_{12}	0.17647	t_{30}	0.0039216
T_{13}	0.019608	t_{31}	-0.42745
T_{14}	0.43529	t_{32}	-0.67059
T_{15}	0.69412	t_{33}	-0.80392
T_{16}	0.38039	t_{34}	0.2
T_{17}	-0.2549	t_{35}	0.74118

İlgi alanlarından oluşan görüntü ile T şablonunun konvolüsyonu sonucunda ilgi alanları kural tabanlı sistem tarafından sınıflandırılmıştır. Elde edilen sonuçlar Tablo VI.8’de görülmektedir.


Tablo VI.8. Genetik Algoritma Kullanılarak Eğitilmiş Şablon Eşleme Yöntemleriyle Kitlelerin Tespit Edilmesi Çalışmasının Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	41 adet Doğru pozitif	48 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	2 adet Yanlış negatif	182 adet Doğru negatif
Duyarlılık		% 95.3	
Görüntü başına düşen YP oranı		0.92	


Şekil VI.6’da meme bölgesinin bölütlendirilmesi, ilgi alanlarının bulunması ve kitlelerin tespiti ile ilgili bir örnek görülmektedir. Şekil VI.6(a) spiküler kitle içeren bir mamogramı göstermektedir. Bu mamogramdan elde edilen meme bölgesi Şekil VI.6(b)’de, meme bölgesinden çıkarılan ilgi alanları da Şekil VI.6(c)’de görülmektedir. Bu ilgi alanları şablon ile karşılaştırılır ve benzer olanlar kitle olarak sınıflandırılmış ve Şekil VI.6(d)’de gösterilmiştir. Orijinal mamografi görüntü üzerindeki kitlenin yeri Şekil VI.6(e)’de görülmektedir.




(a)




(b)



(c)



(d)



(e)

Şekil VI.6. (a) Spiküler Kitle İçeren Mamografi Görüntüsü, (b) Bölütlendirilmiş Meme Bölgesi, (c) Meme Bölgesinde Belirlenmiş İlgi Alanları, (d) Şablon Eşleme Yöntemi İle Kitle Olarak Sınıflandırılmış İlgi Alanı, (e) Mamografi Görüntüsü Üzerinde Tespit Edilen Kitle

VI.3. AKCİĞER BİLGİSAYARLI TOMOGRAFİ (BT) GÖRÜNTÜLERİNDEKİ NODÜLLERİN TESPİT EDİLMESİ ÇALIŞMALARININ SONUÇLARI

Tez çalışması kapsamında akciğer BT görüntülerindeki nodüllerin tespit edilmesi amacıyla kullanılan yöntemler bölüm V’de anlatılmıştır. Bu bölümde akciğer BT kesitleri üzerinde gerçekleştirilen çalışmaların sonuçları ayrı ayrı ve detaylı bir şekilde anlatılmaktadır.


VI.3.1. Akciğer BT Görüntülerindeki Nodüllerin Kural Tabanlı Tespiti Çalışmasının Sonuçları

Detayları bölüm V.2.1’de anlatılan bu çalışmada EMAR İleri Görüntüleme ve Tanı Merkezinden alınan akciğer BT’leri kullanılmıştır. Gerçekleştirilen BDT yazılımı 61 nodül içeren 22 adet anormal görüntü ve 13 adet normal görüntü üzerinde test edilmiştir. 8 yönlü arama işlemi sırasında “*minimum uzunluk eşiği*” için 0 ve 1 piksel değerleri verilerek her kesit için iki farklı ilgi alanı görüntüsü elde edilmiştir. Bu ilgi alanları üzerinde “*öklid uzunluk eşiği*” ve “*biçim eşiği*” değerlerinin kullanıldığı kural tabanlı sınıflandırma gerçekleştirilerek nodüller tespit edilmiştir. Bu sınıflandırma işlemi sırasında çeşitli “*öklid uzunluk eşiği*” ve “*biçim eşiği*” değerleri için Tablo VI.9’da görülen farklı sonuçlar elde edilmiştir.


Bu sonuçlar ışığında yazılımın performansını ortaya koyan duyarlılık ile görüntü başına düşen yanlış pozitif miktarını gösteren FROC eğrisi Şekil VI.7’de görülmektedir. Şekil VI.8, Şekil V.2’de verilen örnek bir akciğer kesitinde Şekil V.5’de görüldüğü tespit edilmiş olan nodülleri ve bir adet YP yapıyı göstermektedir. Nodüller beyaz dairelerle, YP ise siyah daire içinde görülmektedir.

Tablo VI.9. Akciğer Nodüllerinin Kural Tabanlı Tespiti Çalışmasının Sonuçları

<i>“öklid uzunluk eşiği”</i>	<i>“biçim eşiği”</i>	duyarlılık	YP/görüntü
7 piksel	1.20	0.76	0.142
9 piksel	1.45	0.84	0.257
11 piksel	1.60	0.89	0.457
13 piksel	1.80	0.93	0.828
15 piksel	2	0.95	1.4



Şekil VI.7. Yazılımın Nodül Tespit Performansını Gösteren FROC Eğrisi



Şekil VI.8. Kural Tabanlı Yöntem ile BT Kesitinde Tespit Edilen Nodüller

VI.3.2. Şablon Eşleme Yöntemiyle Nodüllerin Tespiti Çalışmasının Sonuçları

Bölüm V.2.2’de detaylı bir şekilde anlatılan bu çalışmada geliştirilen yazılımın performansı, LIDC veri setinde bulunan 12 hastaya ait 123 adet normal ve 153 adet anormal görüntü kullanılarak ölçülmüştür. Her anormal görüntüde 1 adet nodül bulunmaktadır. İlgi alanı belirleme yöntemleri kullanılarak ilk aşamada 4896 adet ilgi alanı belirlenmiştir. Ardından ilgi alanların seri kesitlerdeki konum değişim miktarlarının ölçüldüğü ilk sınıflandırma aşamasında ilgi alanı sayısı 1254’e düşmüştür. Son olarak şablon eşleme tekniğinin kullanıldığı ikinci sınıflandırma aşamasında çapları 8, 14 ve 20 piksel olan üç farklı şablon kullanılmıştır ve elde edilen sonuçlar sırasıyla Tablo VI.10, Tablo VI.11 ve Tablo VI.12’de görülmektedir.

Tablo VI.10. Akciğer Nodüllerinin 8 Piksel Çapındaki Şablon İle Tespit Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	139 adet Doğru pozitif	193 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	14 adet Yanlış negatif	908 adet Doğru negatif
Duyarlılık		% 90.9	
Görüntü başına düşen YP oranı		0.7	


Tablo VI.11. Akciğer Nodüllerinin 14 Piksel Çapındaki Şablon İle Tespit Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	144 adet Doğru pozitif	272 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	9 adet Yanlış negatif	829 adet Doğru negatif
Duyarlılık		% 94.1	
Görüntü başına düşen YP oranı		0.98	


Tablo VI.12. Akciğer Nodüllerinin 20 Piksel Çapındaki Şablon İle Tespit Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	146 adet Doğru pozitif	323 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	7 adet Yanlış negatif	778 adet Doğru negatif
Duyarlılık		% 95.4	
Görüntü başına düşen YP oranı		1.17	


İlgi alanlarının bu şablonlar ile taranması ile Şekil VI.9 ve VI.10’de görüldüğü gibi farklı doğru pozitif ve yanlış pozitif oranları elde edilmiştir. Şekil VI.11’de ise yazılımın performansını ortaya koyan duyarlılık ile görüntü başına düşen yanlış pozitif miktarını gösteren FROC eğrisi görülmektedir.



Şekil VI.9. Şablon Eşleme Yöntemiyle Nodül Tespitinde Şablon Çapı İle Görüntü Başına Düşen Doğru Pozitif Oranı Grafiği




Şekil VI.10. Şablon Eşleme Yöntemiyle Nodül Tespitinde Şablon Çapı İle Görüntü Başına Düşen Yanlış Pozitif Oranı Grafiği



Şekil VI.11. Şablon Eşleme Yöntemiyle Nodül Tespitinde Yazılımın Performansını Gösteren FROC (Free-Response Receiver Operating Characteristic) Eğrisi

Şekil VI.12(a)'da nodül içeren bir akciğer BT görüntüsünü görülmektedir. Konum değişimi ile sınıflandırılmış ilgi alanları, tespit edilen nodül ve orijinal görüntüdeki yeri sırasıyla Şekil VI.12(b), VI.12(c) ve VI.12(d)'de görülmektedir.



Şekil VI.12. (a) Nodül İçeren Akciğer BT Görüntüsü, (b) 8 Yönlü Arama ve Konum Değişimi Ölçümü Kullanılarak Belirlenmiş İlgi Alanları, (c) Şablon Eşleme Yöntemi İle Nodül Olarak Sınıflandırılmış İlgi Alanı, (d) BT Görüntüsü Üzerinde Tespit Edilen Nodül.

VI.3.3. Bölütlendirilmiş Akciğer Bölgesindeki Nodüllerin Genetik Algoritma Kullanılarak Eğitilmiş Şablon İle Tespit Edilmesi Çalışmasının Sonuçları

Bölüm V.2.3.3’de anlatıldığı gibi bu çalışmada nodüller şablon eşleme yöntemiyle tespit edilmiştir. Bu şablon eşleme yönteminde kullanılan 8 x 8 piksel boyutlarındaki T şablonun değerlerinin hesaplanması amacıyla genetik algoritma kullanılmıştır. Eğitim işlemi sonucunda elde edilen genetik algoritma parametreleri Tablo VI.13’de görülmektedir. Ayrıca T nodül şablonu da aşağıda bulunmaktadır. Önerilen sistemin değerlendirilmesi için LIDC veri setinden 12 hastaya ait 123 adet normal ve 153 adet anormal görüntü kullanılmıştır.

Tablo VI.13. Nodül Şablonu Eğitimi İçin Kullanılan Genetik Algoritma Parametreleri

Parametreler:	Değerler
Popülasyon başına düşen kromozom sayısı	100
Değişken başına düşen Bit sayısı	8
Değişken sayısı	10
Kromozom uzunluğu	80
Popülasyondaki toplam bit sayısı	8000
Üreme için kullanılan çaprazlama olasılığı	70%
Mutasyon olasılığı	1%
Kuşak farkı	98%
Şablon parametreleri değer aralığı	[-1, 1]

$$T = \begin{bmatrix} -0.15294 & 0.76471 & 0.84314 & -0.92941 & -0.92941 & 0.84314 & 0.76471 & -0.15294 \\ 0.76471 & 0.41176 & -0.11373 & -0.05098 & -0.05098 & -0.11373 & 0.41176 & 0.76471 \\ 0.84314 & -0.11373 & 0.27843 & 0.019608 & 0.019608 & 0.27843 & -0.11373 & 0.84314 \\ -0.92941 & -0.05098 & 0.019608 & 0.38039 & 0.38039 & 0.019608 & -0.05098 & -0.92941 \\ -0.92941 & -0.05098 & 0.019608 & 0.38039 & 0.38039 & 0.019608 & -0.05098 & -0.92941 \\ 0.84314 & -0.11373 & 0.27843 & 0.019608 & 0.019608 & 0.27843 & -0.11373 & 0.84314 \\ 0.76471 & 0.41176 & -0.11373 & -0.05098 & -0.05098 & -0.11373 & 0.41176 & 0.76471 \\ -0.15294 & 0.76471 & 0.84314 & -0.92941 & -0.92941 & 0.84314 & 0.76471 & -0.15294 \end{bmatrix}$$

Tez kapsamında diğer nodül tespit çalışmalarından farklı olarak akciğer bölgesinin bölütlendirilmesi amacıyla bu çalışmada gibi iki farklı yöntem kullanılmıştır. Bu yöntemler kural-tabanlı yaklaşım ve genetik algoritma kullanılarak eğitilen hücresel yapay sinir ağı şablonları kullanılarak gerçekleştirilen şablon eşleme yaklaşımıdır. Bu iki farklı yöntem ile elde edilen sonuçlar ayrı bölümler halinde anlatılmaktadır.

VI.3.3.1. Akciğer Bölgesinin Kural Tabanlı Bölütlendirilmesi ile Elde Edilen Sonuçlar


Bölüm V.2.3.1’de anlatılan kural tabanlı bölütlendirme yöntemiyle elde edilmiş akciğer bölgesinde 8 yönlü tarama yapılırken “*minimum uzunluk eşiği*” ve “*maksimum uzunluk eşiği*” için uygun değerler kullanılarak 3656 adet ilgi alanı bulunmuştur. Konum değişimleri incelenerek gerçekleştirilen birinci sınıflandırma yöntemi kullanılarak ilgi alanı sayısı 967’ye düşürülmüştür. Ve son olarak boyutları

8 x 8 piksel olan T nodül şablonu ile ikinci sınıflandırma gerçekleştirilmiştir ve Tablo VI.14’deki sonuçlar elde edilmiştir.

Tablo VI.14. Kural Tabanlı Bölütlendirilmiş Akciğer Bölgesindeki Nodüllerin GA İle Eğitilmiş Şablon ile Tespiti Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	143 adet Doğru pozitif	164 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	10 adet Yanlış negatif	650 adet Doğru negatif
Duyarlılık		%93.4	
Görüntü başına düşen YP oranı		0.594	

Şekil VI.13(a)’da bulunan BT görüntüsü için akciğer bölgesi Şekil VI.13(b)’de ve tespit edilen ilgi alanları Şekil VI.13(c)’de görüldüğü gibi elde edilmiştir. Bu ilgi alanlarının sınıflanması sonucu tespit edilen nodül Şekil VI.13(d)’de, orijinal görüntüdeki yeri ise Şekil VI.13.(e)’de görülmektedir.



Şekil VI.13. (a) Orijinal Akciğer BT Görüntüsü, (b) Bölütlendirilmiş Akciğer Bölgesi, (c) Bölütlendirilmiş Akciğer Bölgesinde Konum Değişimlerini İnceleyerek Sınıflandırma Sonucu Tespit Edilmiş İlgili Alanları, (d) Konvolüsyon Sonucu Tespit Edilen Nodül, (e) Nodülün Orijinal Görüntüdeki Yeri.

VI.3.3.2. Akciğer Bölgesinin HYSA Şablonları Kullanılarak Bölütlendirilmesi ile Elde Edilen Sonuçlar

Akciğer bölgesinin bölütlendirilmesi için genetik algoritma ile eğitilmiş HYSA şablonları kullanılmıştır. Eğitim işlemi sonucunda elde edilen genetik algoritma parametreleri Tablo VI.15’de, A ve B şablonları da aşağıda görülmektedir. I şablonun değeri de -0.34902 olarak elde edilmiştir.

Tablo VI.15. Akciğer Bölgesinin Bölütlendirilmesinde Kullanılan HYSA Şablonlarının GA ile Eğitim Parametreleri

Parametreler:	Değerler
Popülasyon başına düşen kromozom sayısı	100
Değişken başına düşen Bit sayısı	8
Değişken sayısı	133
Kromozom uzunluğu	1064
Popülasyondaki toplam bit sayısı	106400
Üreme için kullanılan çaprazlama olasılığı	70%
Mutasyon olasılığı	1%
Kuşak farkı	98%
Şablon parametreleri değer aralığı	[-1, 1]

A=

-0.25	-0.46	-0.07	0.36	0.05	0.30	0.58	-0.16	-0.23	0.45	0.79	0.45	-0.23	-0.16	0.58	0.30	0.05	0.36	-0.07	-0.46	-0.25
-0.46	0.57	0.53	-0.51	0.61	0.78	-0.13	0.84	-0.92	0.31	0.53	0.31	-0.92	0.84	-0.13	0.78	0.61	-0.51	0.53	0.57	-0.46
-0.07	0.53	0.34	0.73	0.03	-0.55	0.77	0.85	-0.51	-0.32	0.00	-0.32	-0.51	0.85	0.77	-0.55	0.03	0.73	0.34	0.53	-0.07
0.36	-0.51	0.73	-0.91	0.49	0.29	0.58	-0.41	0.56	0.82	0.06	0.82	0.56	-0.41	0.58	0.29	0.49	-0.91	0.73	-0.51	0.36
0.05	0.61	0.03	0.49	0.26	0.28	0.62	0.17	-0.86	0.22	0.46	0.22	-0.86	0.17	0.62	0.28	0.26	0.49	0.03	0.61	0.05
0.30	0.78	-0.55	0.29	0.28	-0.83	0.14	-0.75	0.95	1.00	1.00	1.00	0.95	-0.75	0.14	-0.83	0.28	0.29	-0.55	0.78	0.30
0.58	-0.13	0.77	0.58	0.62	0.14	-0.93	0.47	-0.06	-0.04	-0.78	-0.04	-0.06	0.47	-0.93	0.14	0.62	0.58	0.77	-0.13	0.58
-0.16	0.84	0.85	-0.41	0.17	-0.75	0.47	0.83	-0.41	0.66	0.07	0.66	-0.41	0.83	0.47	-0.75	0.17	-0.41	0.85	0.84	-0.16
-0.23	-0.92	-0.51	0.56	-0.86	0.95	-0.06	-0.41	1.00	0.71	-0.30	0.71	1.00	-0.41	-0.06	0.95	-0.86	0.56	-0.51	-0.92	-0.23
0.45	0.31	-0.32	0.82	0.22	1.00	-0.04	0.66	0.71	-0.20	0.33	-0.20	0.71	0.66	-0.04	1.00	0.22	0.82	-0.32	0.31	0.45
0.79	0.53	0.00	0.06	0.46	1.00	-0.78	0.07	-0.30	0.33	0.87	0.33	-0.30	0.07	-0.78	1.00	0.46	0.06	0.00	0.53	0.79
0.45	0.31	-0.32	0.82	0.22	1.00	-0.04	0.66	0.71	-0.20	0.33	-0.20	0.71	0.66	-0.04	1.00	0.22	0.82	-0.32	0.31	0.45
-0.23	-0.92	-0.51	0.56	-0.86	0.95	-0.06	-0.41	1.00	0.71	-0.30	0.71	1.00	-0.41	-0.06	0.95	-0.86	0.56	-0.51	-0.92	-0.23
-0.16	0.84	0.85	-0.41	0.17	-0.75	0.47	0.83	-0.41	0.66	0.07	0.66	-0.41	0.83	0.47	-0.75	0.17	-0.41	0.85	0.84	-0.16
0.58	-0.13	0.77	0.58	0.62	0.14	-0.93	0.47	-0.06	-0.04	-0.78	-0.04	-0.06	0.47	-0.93	0.14	0.62	0.58	0.77	-0.13	0.58
0.30	0.78	-0.55	0.29	0.28	-0.83	0.14	-0.75	0.95	1.00	1.00	1.00	0.95	-0.75	0.14	-0.83	0.28	0.29	-0.55	0.78	0.30
0.05	0.61	0.03	0.49	0.26	0.28	0.62	0.17	-0.86	0.22	0.46	0.22	-0.86	0.17	0.62	0.28	0.26	0.49	0.03	0.61	0.05
0.36	-0.51	0.73	-0.91	0.49	0.29	0.58	-0.41	0.56	0.82	0.06	0.82	0.56	-0.41	0.58	0.29	0.49	-0.91	0.73	-0.51	0.36
-0.07	0.53	0.34	0.73	0.03	-0.55	0.77	0.85	-0.51	-0.32	0.00	-0.32	-0.51	0.85	0.77	-0.55	0.03	0.73	0.34	0.53	-0.07
-0.46	0.57	0.53	-0.51	0.61	0.78	-0.13	0.84	-0.92	0.31	0.53	0.31	-0.92	0.84	-0.13	0.78	0.61	-0.51	0.53	0.57	-0.46
-0.25	-0.46	-0.07	0.36	0.05	0.30	0.58	-0.16	-0.23	0.45	0.79	0.45	-0.23	-0.16	0.58	0.30	0.05	0.36	-0.07	-0.46	-0.25

B=	0.71	-0.94	-0.03	-0.50	0.76	-0.44	-0.80	-0.92	-0.54	-0.91	0.82	-0.91	-0.54	-0.92	-0.80	-0.44	0.76	-0.50	-0.03	-0.94	0.71
	-0.94	0.40	-0.33	-0.95	-0.15	0.75	-0.65	-0.55	-0.58	0.06	0.47	0.06	-0.58	-0.55	-0.65	0.75	-0.15	-0.95	-0.33	0.40	-0.94
	-0.03	-0.33	-0.91	0.12	0.99	-0.56	0.90	0.77	-0.42	0.81	0.55	0.81	-0.42	0.77	0.90	-0.56	0.99	0.12	-0.91	-0.33	-0.03
	-0.50	-0.95	0.12	0.22	0.35	-0.76	-0.62	0.70	0.40	0.26	0.69	0.26	0.40	0.70	-0.62	-0.76	0.35	0.22	0.12	-0.95	-0.50
	0.76	-0.15	0.99	0.35	0.48	-0.97	-0.90	-0.47	-0.25	-1.00	0.14	-1.00	-0.25	-0.47	-0.90	-0.97	0.48	0.35	0.99	-0.15	0.76
	-0.44	0.75	-0.56	-0.76	-0.97	-0.63	0.53	-0.11	-0.53	-0.81	-0.55	-0.81	-0.53	-0.11	0.53	-0.63	-0.97	-0.76	-0.56	0.75	-0.44
	-0.80	-0.65	0.90	-0.62	-0.90	0.53	0.00	-0.62	0.63	-0.22	0.52	-0.22	0.63	-0.62	0.00	0.53	-0.90	-0.62	0.90	-0.65	-0.80
	-0.92	-0.55	0.77	0.70	-0.47	-0.11	-0.62	-0.01	0.64	0.52	0.62	0.52	0.64	-0.01	-0.62	-0.11	-0.47	0.70	0.77	-0.55	-0.92
	-0.54	-0.58	-0.42	0.40	-0.25	-0.53	0.63	0.64	-0.91	0.51	-0.30	0.51	-0.91	0.64	0.63	-0.53	-0.25	0.40	-0.42	-0.58	-0.54
	-0.91	0.06	0.81	0.26	-1.00	-0.81	-0.22	0.52	0.51	0.95	0.73	0.95	0.51	0.52	-0.22	-0.81	-1.00	0.26	0.81	0.06	-0.91
	0.82	0.47	0.55	0.69	0.14	-0.55	0.52	0.62	-0.30	0.73	0.87	0.73	-0.30	0.62	0.52	-0.55	0.14	0.69	0.55	0.47	0.82
	-0.91	0.06	0.81	0.26	-1.00	-0.81	-0.22	0.52	0.51	0.95	0.73	0.95	0.51	0.52	-0.22	-0.81	-1.00	0.26	0.81	0.06	-0.91
	-0.54	-0.58	-0.42	0.40	-0.25	-0.53	0.63	0.64	-0.91	0.51	-0.30	0.51	-0.91	0.64	0.63	-0.53	-0.25	0.40	-0.42	-0.58	-0.54
	-0.92	-0.55	0.77	0.70	-0.47	-0.11	-0.62	-0.01	0.64	0.52	0.62	0.52	0.64	-0.01	-0.62	-0.11	-0.47	0.70	0.77	-0.55	-0.92
	-0.80	-0.65	0.90	-0.62	-0.90	0.53	0.00	-0.62	0.63	-0.22	0.52	-0.22	0.63	-0.62	0.00	0.53	-0.90	-0.62	0.90	-0.65	-0.80
	-0.44	0.75	-0.56	-0.76	-0.97	-0.63	0.53	-0.11	-0.53	-0.81	-0.55	-0.81	-0.53	-0.11	0.53	-0.63	-0.97	-0.76	-0.56	0.75	-0.44
	0.76	-0.15	0.99	0.35	0.48	-0.97	-0.90	-0.47	-0.25	-1.00	0.14	-1.00	-0.25	-0.47	-0.90	-0.97	0.48	0.35	0.99	-0.15	0.76
	-0.50	-0.95	0.12	0.22	0.35	-0.76	-0.62	0.70	0.40	0.26	0.69	0.26	0.40	0.70	-0.62	-0.76	0.35	0.22	0.12	-0.95	-0.50
	-0.03	-0.33	-0.91	0.12	0.99	-0.56	0.90	0.77	-0.42	0.81	0.55	0.81	-0.42	0.77	0.90	-0.56	0.99	0.12	-0.91	-0.33	-0.03
	-0.94	0.40	-0.33	-0.95	-0.15	0.75	-0.65	-0.55	-0.58	0.06	0.47	0.06	-0.58	-0.55	-0.65	0.75	-0.15	-0.95	-0.33	0.40	-0.94
	0.71	-0.94	-0.03	-0.50	0.76	-0.44	-0.80	-0.92	-0.54	-0.91	0.82	-0.91	-0.54	-0.92	-0.80	-0.44	0.76	-0.50	-0.03	-0.94	0.71

Başlangıçta akciğer bölgesinde ilgi alanı belirleme yöntemleri ile 3601 adet ilgi alanı bulunmuştur. Konum değişimleri incelenerek gerçekleştirilen birinci sınıflandırma yöntemi kullanılarak ilgi alanı sayısı 941'e düşürülmüştür. Ve son olarak boyutları 8 x 8 piksel olan T nodül şablonu ile ikinci sınıflandırma gerçekleştirilmiştir ve elde edilen sonuçlar Tablo VI.16'da görülmektedir.

Tablo VI.16. GA İle Eğitilmiş Şablonlar Kullanılarak Akciğer Bölgesinin Bölütlendirilmesi ve Nodüllerin Tespiti Sonuçları

		Gerçek Bulgu	
		<i>Hasta (H^+)</i>	<i>Hasta Değil (H^-)</i>
BDT Gözlemi	<i>Pozitif (T^+)</i>	139 adet Doğru pozitif	162 adet Yanlış pozitif
	<i>Negatif (T^-)</i>	14 adet Yanlış negatif	626 adet Doğru negatif
Duyarlılık		%91	
Görüntü başına düşen YP oranı		0.587	

BÖLÜM VII

DEĞERLENDİRME VE ÖNERİLER

VII.1. DEĞERLENDİRME

Bu çalışmada tasarlanan BDT yazılımları sayesinde mamografi görüntülerindeki kitlelerin ve akciğer BT görüntülerindeki nodüllerin otomatik tespit edilmesi sağlanmıştır. Bu amaç doğrultusunda üç farklı yöntem kullanılmıştır. Bu yöntemler gerekli düzenlemeler yapılarak hem mamografi görüntülerine, hem de akciğer görüntülerine uygulanmıştır. İlgili alanlarının tespit edilmesi aşamasında aynı altyapının kullanıldığı yöntemlerde, ilgili alanlarının sınıflandırılması aşamasında morfolojik özelliklerin incelendiği farklı yaklaşımlar entegre edilmiştir. Kullanılan her yöntem, medikal görüntüleme tekniklerindeki ilerlemeye ayak uydurarak bir öncekinden daha yüksek hıza ve daha yüksek duyarlılığa sahip olma amacına ulaşmıştır.

Medikal görüntülerin analizinde bölütleme çok önemli kavramdır. Bölütleme işlemi sonucu arama yapılacak alan daraltılmış olur. Gri seviyeli mamogram görüntülerinde yoğun olan meme açık renkte iken görüntü arka planı daha koyu bir renge sahiptir. Vücudumuzun hava deposu olan akciğerler, BT kesitlerinde koyu renkte iken akciğeri çevreleyen dokular açık renktedir. Aradaki bu kontrast farkı geleneksel bölütleme yöntemlerinin temelini oluşturmaktadır. Kural tabanlı eşikleme yöntemi en yaygın kullanılan yöntemdir. Kullanılan diğer yöntemler ise yoğunluk değişimini kontrol eden histogram tabanlı ve alan büyütme tabanlı bölütlemelerdir. Bu tez çalışmasında akciğer BT'lerinde ve mamogramlarda akciğer ve meme bölgelerinin bölütlendirilmesi için hücresel sinir ağı şablonları kullanılmıştır. Genetik algoritma aracılığıyla eğitilmiş hücresel yapay sinir ağı şablonlarının kullanıldığı

konvolüsyon tabanlı şablon eşleme yöntemi ile akciğer ve meme bölgeleri bölütlendirilmiştir.

Bölütlenmiş görüntüde anormal yapı özelliği gösteren ilgi alanlarının belirlenmesi önemli diğer bir konudur. İlgi alanlarının belirlenmesi için literatürde çeşitli teknikler kullanılmaktadır. Benzer yoğunluktaki birleşik yapıları bulmayı hedefleyen gri seviyeli eşikleme yöntemi, morfolojik özelliklerin incelenmesi için konvolüsyon tabanlı filtrelerin kullanıldığı yöntemler ve yoğunluk değerlerini inceleyen bulanık mantık ve k-ortalama kümeleme yöntemleri ilgi alanlarının belirlenmesinde kullanılan yöntemlerdir. Bu tez çalışmasında akciğer BT'lerindeki ve mamogramlardaki ilgi alanlarının tespiti için yoğunluk değerlerinin incelendiği gri seviyeli eşikleme yönteminin kullanıldığı bir filtreleme yöntemi kullanılmıştır. Bu yöntem kapsamında, analiz edilen akciğer BT ve mamogram görüntülerindeki her piksel için yoğunluk değerlerinin sorgulandığı 8 yönlü tarama yapılarak ilgi alanlarının tespit edilmesi gerçekleştirilmiştir. Ayrıca seri kesitlerden oluşan akciğer görüntülerindeki ilgi alanlarının konum değişimlerinin analiz edilmesi yöntemi ile, ilgi alanlarının ön sınıflandırılması gerçekleştirilerek de akciğer nodül tespit işleminin hızlandırılması sağlanmıştır.

Anormallik tespitinde son adım olarak gerçekleştirilen ilgi alanlarının sınıflandırılmasında literatürde kullanılan çeşitli yöntemler şunlardır: kural tabanlı sınıflama, şablon eşleme, en yakın komşu kümelemesi, Markov rastgele alanları, yapay sinir ağları ve Bayes sınıflandırıcı yöntemleridir. Özellikle gri seviyeli özelliklerin ve şekilsel özelliklerin hesaplanarak sınıflama yapılması en yaygın tekniklerdendir. Bu tez çalışmasında kullanılan şablon eşleme tekniği de literatürde sıkça karşılaşılan bir yöntemdir. Şablon eşleme tekniği, büyük bir görüntüde şablon görüntüsüne benzeyen küçük parçaların bulunması esasına dayanmaktadır. Bu teknikte önemli olan benzerlik kriteri olarak kullanılan ölçüm yöntemidir. Literatürde benzerlik ölçümü olarak kullanılan yöntemler şunlardır: korelasyon ölçümleri, karşılıklı bilgi ölçümü, gradyan farkı, örüntü yoğunluğu, rank dönüşümü, Gamma katsayısı ve Jaccard ölçümü. Bu tez çalışmasındaki şablon eşleme tekniğinde benzerlik ölçümü olarak eşikleme tabanlı bir yöntem kullanılmıştır. Bu yöntemde benzerliği ölçmek için 2 farklı hata kuralı kullanılmıştır. Sınıflama yöntemi sırasında şablona olan benzerliği ölçmek için kullanılan yöntemle ilgi alanının morfolojik özelliklerine de karar verilebilmektedir. Yine bu tez çalışması kapsamında gerçekleştirilen diğer bir şablon eşleme tekniğinde, kullanılan şablon değerlerinin

hesaplanması için genetik algoritma yöntemi kullanılmıştır. Benzerlik ölçümü olarak konvolüsyon yönteminin kullanıldığı bu çalışmada şablon değerlerinin optimizasyonu sağlanmıştır.

Mamografi görüntülerine uygulanan yöntemler, elde edilen sonuçlar ve görüntü başına düşen anormallik tespit süreleri karşılaştırmalı olarak Tablo VII.1’de görülmektedir. Bu yöntemler içerisinde duyarlılığı düşük olmasına rağmen görüntü başına düşen yanlış pozitif oranı 0.288 ile en iyi olan yöntem ilk olarak uygulanan kural tabanlı yöntem olmuştur. Öncelikle meme bölgesinin bölütlendirildiği, ardından elde edilen ilgi alanlarının eğitilmiş şablon ile sınıflandırıldığı yöntem %95.3 duyarlılık oranıyla en başarılı çalışma olmuştur. Yine bu çalışma sonucun en kısa sürede elde edilmesi açısından da en başarılı çalışmadır. Şablon eşleme yönteminde kullanılan 10, 20 ve 30 piksel çaplarındaki şablonlar ile farklı duyarlılık ve yanlış pozitif oranları elde edilmiştir. Şablon büyüklüğü azaldıkça doğru pozitif oranının ve sistem duyarlılığının arttığı görülmektedir. Buna rağmen yine şablon küçüldükçe görüntü başına düşen yanlış pozitif oranının da arttığı görülmektedir. Bu durumun sebebi kitleleri oluşturan yapıların kendilerinden küçük şablonlar ile eşlenmesi ve benzerlik ölçümünde uygulanan kriterler olarak açıklanabilir.

Tablo VII.1. Tez Kapsamında Gerçekleştirilen Kitle Tespit Çalışmalarının Karşılaştırılması

Yöntem	Görüntü Sayısı	İlgi Alanı Sayısı	Duyarlılık	YP/ Görüntü	Süre/ Görüntü
Kural-Tabanlı	52	332	%88.3	0.288	9 dk. 22 sn.
Şablon Eşleme (10x10 piksel)	52	332	%93	1.3	2 dk. 56 sn.
Şablon Eşleme (20x20 piksel)	52	332	%90	0.7	7 dk. 57 sn.
Şablon Eşleme (30x30 piksel)	52	332	%81.3	0.33	18 dk. 26 sn.
Bölütlenmiş Bölgede, Eğitilmiş Şablon ile Tespit (16x16 piksel)	52	273	%95.3	0.92	1 dk. 8 sn.

Tez çalışması kapsamında mamografi görüntüleri üzerinde yapılan çalışmalarda MIAS veri seti kullanılmıştır. Kitle tespit çalışmalarının değerlendirilmesinde literatürde MIAS veri seti kullanılarak yapılmış çalışmalar da kriter olarak kullanılmıştır. Bu veri seti kullanılarak gerçekleştirilen çalışmalardan elde edilebilenlerin sonuçları Tablo VII.2’de görülmektedir. Bu tez kapsamında yapılan kitle tespit çalışmaları tablodaki çalışmalar ile karşılaştırıldığında gerek duyarlılık gerekse de görüntü başına düşen yanlış pozitif oranlarıyla başarılı oldukları görülmektedir.

Tablo VII.2. Literatürde MIAS Veri Seti Kullanılarak Yapılan Çalışmalar

Çalışma	Yöntem	Görüntü Sayısı	Duyarlılık	YP/ Görüntü
Zhang ve Foo [107]	Bölge büyütme	56	%95	1.9
Gulrud ve Loland [108]	Örüntü özelliklerinin incelenmesi, çok kanallı filtreleme	19	%73.68	0.21
Christoyianni vd.[109]	Yapay sinir ağları, karar yapıları	76	%75.2	-
Bowis vd. [110]	Örüntü analizi, Çok Katmanlı Algılayıcı	144	%77	0.25
Liu vd. [111]	Wavelet dönüşümleri, ikili ağaç	38	%84.2 %100	1 2.2
Christoyianni vd. [112]	İstatistiksel eşikleme, medyan filtreleme, yapay sinir ağları	22	%90.9	2.1
Cao vd. [113]	Vicinal Support Vector Machine (SVM)	90	%84	-
Mudigonda vd. [114]	Gri seviyeli matrisler ile örüntü analizi, mantıksal regresyon yöntemi	56	%85	2.45

Akciğer BT görüntülerine uygulanan yöntemler, elde edilen sonuçlar ve görüntü başına düşen anormallik tespit süreleri karşılaştırmalı olarak Tablo VII.3’de görülmektedir. Akciğer BT görüntülerindeki ilk çalışmalar 6 mm kalınlığında ve her birinin arasında 1mm’lik boşluklar bulunan veri seti üzerinde yapılmıştır. Diğer çalışmalardan farklı bir veri setinin kullanıldığı kural tabanlı yöntemde elde edilen ilgi alanı sayısı ve süre/görüntü değerleri karşılaştırma tablosunda dikkate alınmamıştır. Günümüz modern BT yöntemleriyle elde edilen 0.625 mm kalınlığındaki kesitlerin kullanıldığı çalışma olan ve 8, 14 ve 20 piksel çaplarındaki şablonların kullanıldığı şablon eşleme yönteminde farklı duyarlılık ve yanlış pozitif oranları elde edilmiştir. Şablon büyüklüğü arttıkça doğru pozitif oranının ve sistem duyarlılığının arttığı görülmektedir. Ancak yine şablon büyüdükçe görüntü başına düşen yanlış pozitif oranının da arttığı görülmektedir. 20 piksel çapındaki şablon kullanıldığında bu kalınlıktaki seri kesitlerde nodüllerin tespitinde oldukça iyi bir performans sayılabilecek görüntü başına 1.17 yanlış pozitif oranıyla %95.4 duyarlılık elde edilmiştir. HYSA şablonları kullanılarak akciğer bölgesinin bölütlendirildiği ve ardından GA ile eğitilmiş şablon kullanılarak nodüllerin tespit edildiği çalışma gerek hız gerekse de görüntü başına düşen yanlış pozitif oranları açısından en başarılı yöntem olmuştur.

Tez çalışması kapsamında akciğer BT görüntüleri üzerinde yapılan çalışmalarda LIDC veri seti kullanılmıştır. Akciğer nodülü tespit çalışmalarının değerlendirilmesinde literatürde LIDC veri seti kullanılarak yapılmış çalışmalar da dikkate alınmıştır. Ancak bu veri seti halen geliştirilmekte olan bir veri seti olduğu için yayınlanmış sadece 1 adet çalışmaya ulaşılabilmiştir. Bu çalışmanın detayları Tablo VII.4’de görülmektedir. Bu tez kapsamında yapılan akciğer nodül tespit çalışmaları tablodaki çalışma ile karşılaştırıldığında incelenen nodül büyüklüklerinin farklı olduğu görülmektedir. Ancak tez çalışmalarında daha iyi duyarlılık ve görüntü başına düşen yanlış pozitif oranları elde edilmiştir.

Tablo VII.3. Tez kapsamında gerçekleştirilen akciğer nodülü tespit çalışmalarının karşılaştırılması

Yöntem	Veri Seti	Görüntü Sayısı	İlgi Alanı Sayısı	Sınıflanmış İlgi Alanları	Duyarlılık	YP/ Görüntü	Süre/ Görüntü
Kural Tabanlı	EMAR	35	-	-	%89	0.45	-
Şablon Eşleme (8x8 piksel)	LIDC	276	4896	1254	%90.9	0.7	3 dk 16 sn.
Şablon Eşleme (14x14 piksel)	LIDC	276	4896	1254	%94.1	0.98	4 dk 9 sn.
Şablon Eşleme (20x20 piksel)	LIDC	276	4896	1254	%95.4	1.17	4 dk. 38 sn.
Kural Tabanlı Bölütleme ve Eğitilmiş Şablon ile Tespit (8x8 piksel)	LIDC	276	3656	967	%93.4	0.59	2 dk. 41 sn.
HYSA ile Bölütleme ve Eğitilmiş Şablon ile Tespit (8x8 piksel)	LIDC	276	3601	941	%90.8	0.58	2 dk. 16 sn.

Tablo VII.4. Literatürde LIDC Veri Seti Kullanılarak Yapılan Çalışmalar

Çalışma	Yöntem	Görüntü Sayısı	Nodül Büyüklüğü	Duyarlılık	YP/ Görüntü
Korfiatis vd. [115]	Eşikleme, filtreleme, Support Vector Machine (SVM) sınıflandırıcısı	279	3 mm -25 mm	%85	5

Sonuç olarak tez kapsamında kullanılan yöntemler gerçek hasta görüntülerine uygulanarak elde edilen veriler uzman radyoloji uzmanlarının teşhisleri ile karşılaştırılarak performans değerlendirmeleri yapılmıştır. Bu değerlendirme sonucunda elde edilen yüksek duyarlılık ile önerilen BDT sistemlerinin doktorların teşhis performanslarını arttıracığı görülmektedir.

VII.2. ÖNERİLER

Bu tez çalışması kapsamında radyolojideki önemli sorunlardan olan mamografi görüntülerindeki kitlelerin ve akciğer BT görüntülerindeki nodüllerin yerlerinin tespitinde önemli sonuçlar elde edilmiştir. İlerleyen çalışmalarda konumları belirlenen bu anormalliklerin benign – malign ayrımı için çalışmalar yapılabilir. Yine araştırma konularından bir diğeri de bu tez kapsamında kullanılan yöntemlerin diğer medikal görüntülerindeki anormalliklerin tespitinde kullanılmasıdır. Özellikle meme MR ve spiral BT kolonografi kesitlerinde bölütlendirme ve bu görüntülerdeki tümör, polip ve kitle gibi anormalliklerin tespitinde başarılı olacağı düşünülmektedir.

KAYNAKLAR

- [1] Tuncel, E.: “Radyolojiye Giriş”, Uludağ Üniversitesi, Radyoloji Anabilim Dalı Ders Notları, **(2006)** 3-64.
- [2] Dhawan, A.P.: “Medical Image Analysis”, IEEE Series in Biomedical Engineering, John Wiley & Sons, New Jersey, USA, **(2003)** 2-16.
- [3] Prince, J.L.; Links, J.M.: “Medical Imaging Signals and Systems”, Pearson Prentice Hall Bioengineering, New Jersey, USA, **(2006)** 3-13.
- [4] Bushberg, J.R.; Seibert, J.A.; Leidholdt, E.M.; Bone, J.M.: “The Essential Physics of Medical Imaging”, Lippincott Williams & Wilkins, Philadelphia, USA, (2002) 3-82.
- [5] http://en.wikipedia.org/wiki/Wilhelm_Conrad_R%C3%B6ntgen (Erişim tarihi: Ocak **2005**)
- [6] <http://www.roentgen-museum.de> (Erişim tarihi: Temmuz **2006**)
- [7] <http://en.wikipedia.org/wiki/Radiography> (Erişim tarihi: Mart **2005**)
- [8] <http://en.wikipedia.org/wiki/Mammography> (Erişim tarihi: Mart **2005**)
- [9] Sample, J.T.: “Computer Assisted Screening of Digital Mammogram Images”, *PhD Thesis*, Louisiana State University, USA, (2003) 6-19.
- [10] <http://akciger0.tripod.com/link6.html> (Erişim tarihi: Temmuz **2006**)
- [11] <http://en.wikipedia.org/wiki/Fluoroscopy> (Erişim tarihi: Temmuz **2006**)
- [12] http://en.wikipedia.org/wiki/Computed_tomography (Erişim tarihi: Mart **2005**)
- [13] <http://www.fpnotebook.com> (Erişim tarihi: Kasım **2004**)
- [14] http://en.wikipedia.org/wiki/Magnetic_resonance_imaging (Erişim tarihi: Temmuz **2006**)
- [15] http://www.gentili.net/FBI/knee_-_mri.htm (Erişim tarihi: Ağustos **2006**)
- [16] <http://www.parkavenueradiologists.com/mriscans.htm> (Erişim tarihi: Ağustos **2006**)

- [17] http://en.wikipedia.org/wiki/Medical_ultrasonography (Erişim tarihi: Ağustos 2006)
- [18] Zana, F.; Klein, J.C.: "Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation," *IEEE Trans. Image Process.*, 10 (2001) 1010–1019.
- [19] Poli, R.; Valli, G.; "An algorithm for real-time vessel enhancement and detection," *Comput. Meth. Programs Biomed.*, 52 (1996) 1–22.
- [20] Karssemeijer, N.; Brake, G.M.; "Detection of stellate distortions in mammograms," *IEEE Trans. Med. Imag.*, 15 (1996).
- [21] Polakowski, W.E.; Cournoyer, D.A.; Rogers, S.K.; "Computer-aided breast cancer detection and diagnosis of masses using difference of Gaussians and derivative-based feature saliency," *IEEE Trans. Med. Imag.*, 16 (1997) 811–819.
- [22] Brzakovic, D.; Luo, X.M.; Brzakovic, P.: "An approach to automated detection of tumors in mammograms," *IEEE Trans. Med. Imag.*, 9 (1990) 233–241.
- [23] Armato, S.; Giger, M.; MacMahon, H.: "Automated detection of lung nodules in CT scans: preliminary results," *Med. Phys.*, 28 (2001) 1552–1561.
- [24] Zhao, B.; Gamsu, G.; Ginsberg, M.S.; Jiang, L.; Schwartz, L.H.; "Automatic detection of small lung nodules on CT utilizing a local density maximum algorithm," *J. Appl. Clin. Med. Phys.*, 4 (2003) 248–260.
- [25] Li, H.D.; Kallergi, M.; Clarke, L.P.; Jain, V.K.; Clark, R.A.; "Markov random field for tumor detection in digital mammography," *IEEE Trans. Med. Imag.*, 14 (1995) 565–576.
- [26] Yim, P.; Choyke, P.; Summers, R.; "Gray-scale skeletonization of small vessels in magnetic resonance angiography," *IEEE Trans. Med. Imag.*, 19 (2000) 568–576.
- [27] Petrick, N., Chan, H.P.; Sahiner B.; "Combined adaptive enhancement and regiongrowing segmentation of breast masses on digitized mammograms," *Medical Physics* 26 (1999) 1642–1654.
- [28] Timp, S.; Karssemeijer, N., "A new 2D segmentation method based on dynamic programming applied to computer aided detection in mammography," *Med. Physics*, 31 (2004) 958–971.

- [29] Kupinski, M.A.; Giger, M.L.: “Automated Seeded Lesion Segmentation on Digital Mammograms,” *IEEE Trans. Med. Imag.*, 17 **(1998)** 510–517.
- [30] Agam, G.; Dinstein, I.: “Regulated morphological operations,” *Pattern Recogn.*, 32 **(1999)** 947–971.
- [31] Eiho, S.; Qian, Y.: “Detection of coronary artery tree using morphological operator,” *Comput. Cardiol.*, **(1997)** 525–528.
- [32] Wilkinson, M.; Westenberg, M.: “Shape preserving filament enhancement filtering,” in *Proc. Int. Conf. Medical Image Computing and Computer Aided Intervention*, Utrecht, The Netherlands, **(2001)** 770–777.
- [33] Meijster, A.; Westenberg, M.; Wilkinson, M.: “Interactive shape preserving filtering and visualization of volumetric data,” in *Proc. IASTED Conf. Signal Image Process.*, Kauai, HI, **(2002)** 640–643.
- [34] Li, H.; Wang, Y.; Liu, K.J.: “Computerized radiographic mass detection—part I: Lesion site selection by morphological enhancement and contextual segmentation,” *IEEE Trans. Med. Imag.*, 20 **(2001)** 289–301.
- [35] Kegelmeyer, W.P.; Pruneda, J.M.; Bourland, P.D.: “Computer-aided mammographic screening for spiculated lesions,” *Radiology*, 191 **(1994)** 331–337.
- [36] Matsubara, T.; Fujita, H.; Endo, T.: “Development of mass detection algorithm based on adaptive thresholding technique in digital mammograms,” Doi, K.; Giger, M.L; eds. Elsevier, Amsterdam, The Netherlands, **(1996)** 391– 396.
- [37] Wu, C.; Agam, G.; Roy, A.S.; Armato, S.G.: “Regulated morphology approach to fuzzy shape analysis with application to blood vessel extraction in thoracic CT scans,” *Proc. SPIE*, 5370, Fitzpatrick, J.M; Sonka, M.; Eds., Medical Imaging’04, **(2004)** 1262–1270.
- [38] Yan, C.; Hirano, S.; Hata, Y.: “Extraction of blood vessel in CT angiography image aided by fuzzy logic,” in *Proc. Int. Conf. Signal Processing*, Beijing, China, 2 **(2000)** 926–929.
- [39] Guliato, D.; Rangayyan, R.M.; Zuffo, J.A.: “Detection of breast tumor boundaries using iso-intensity contours and dynamic thresholding,” *Proc. 4th Int. Workshop Digital Mammography* **(1998)** 253–260.
- [40] Qian, W.; Li L.; Clarke L.: “Comparison of adaptive and non adaptive cad methods for mass detection,” *Academic Radiol.*, 6 **(1999)** 471–480.

- [41] Ko, J.P.; Rusinek, H; Naidich, D.P.; McGuinness, G.; Rubinowitz, A.N.; Leitman, B.S.; Martino, J.M.: "Wavelet compression of low-dose chest CT data: effect on lung nodule detection", *Radiology*, **(2003)** 228-270
- [42] Yoshida, H.: "Multiscale edge-guided wavelet snake model for delineation of pulmonary nodules in chest radiographs", *Journal of Electronic Imaging*. 12 **(2003)** 69-80.
- [43] Lo, S.C.; Makariou, E.; Chan, H.P.; Freedman, M.T.; Dorfman, D.D.; Berbaum, K.: "Integer Wavelet Compression Guided by a Computer-Aided Detection System in Mammography", *SPIE, Med. Imaging*, 4322 **(2001)** 643-648.
- [44] Sahiner, B.; Chan, H.P.; Petrick, N.: "Classification of mass and normal breast tissue: a convolution neural network classifier with spatial domain and texture images," *IEEE Trans. Med. Imag.* 15 **(1996)** 598–610.
- [45] Kupinski, M.A.; Giger, M.L.: "Investigation of regularized neural networks for the computerized detection of mass lesions in digital mammograms," *Proceedings of the 19th Annual International Conference of the IEEE* **(1997)**.
- [46] Kinoshita, S.K.; Azevedo, P.M.; Slaets, A.F.F.: "Detection and characterization of mammographic masses by artificial neural network," *Proc. 4th Int. Workshop Digital Mammography* **(1998)**.
- [47] Giger M. L.; Bae K. T.; MacMahon H.: "Computerized detection of pulmonary nodules in computed tomography images," *Investigat. Radiol.*, vol. 29, pp 459-65.
- [48] Armato SG III, Giger ML, Moran CJ, MacMahon H, Blackburn JT, Doi K. "Computerized detection of pulmonary nodules on CT scans", *Radiographics* **(1999)**; 19: 1303-11.
- [49] Lin D.; Yan C.: "Lung Nodules Identification Rules Extraction with Neural Fuzzy", *Neural Information Processing*, 4, **(2002)**, 2049-2053.
- [50] Kanazawa K.; Kawata Y.; Niki N.: "Computer-aided diagnostic system for pulmonary nodules based on helical CT images", *Computer-aided diagnosis medical imaging*, **(1999)**.
- [51] Wiemker R, Rogalla P, Zwartkruis A, Blaffert T. Computer Aided Lung Nodule Detection on High. Resolution CT Data. *Proc SPIE Medical Imaging*. 2002; 4684: 677–688.

- [52] Penedo M.; Carreira M.; Mosquera A.; Cabello D: "Computer-aided diagnosis: a neural-network-based approach to. lung nodule detection," *IEEE Trans. Med. Imag.*, vol. 17, no. 6 **(1998)** 872-880.
- [53] Brzakovic, D.; Neskovic, M.: "Mammogram screening using multiresolution-based image segmentation", *International Journal of Pattern Recognition and Artificial Intelligence*, 7 **(1993)** 1437-1460.
- [54] Petrick, N.; Chan, H.P.; Wei, D.: "An adaptive density-weighted contrast enhancement filter for mammographic breast mass detection", *IEEE Transactions on Medical Imaging*, 15 **(1996)** 59-67.
- [55] Chan, H.; Wei, D.; Helvie, N.; Sahiner, B.; Adler, D.; Goodsitt, M.; Petrick, N.: "Computer-aided Classification of Mammographic Masses and Normal Tissue: Linear Discriminant Analysis in Texture Feature Space", *Physical Medical Biology*, 40 **(1995)** 857 – 876.
- [56] Yin, F.; Giger, M.; Vyborny, C.; Doi, K.; Schmidt, R.: "Comparison of Bilateral-Subtraction and Single-Image Processing Techniques in the Computerized Detection of Mammographic Masses", *Investigative Radiology*, 28 **(1993)** 473-481.
- [57] Ryan, W.J.; Reed, J.E.; Swensen, S.J.; Sheedy, P.F.: "Automatic Detection of Pulmonary Nodules in CT", *Proc. Computer Assisted Radiology*, **(1996)** 385-389.
- [58] Kanazawa, K.; Kubo, M.; Niki, N.; Satoh, H.; Ohmatsu, H.; Eguchi, K.; Moriyama, N.: "Computer Assisted Lung Cancer Diagnosis Based On Helical Images," *Image Analysis Applications and Computer Graphics: Proc. Third Int'l Computer Science Conf.*, Springer-Verlag, Berlin, **(1995)** 323-330.
- [59] Giger, M.L.; Ahn, N.; Doi, K.; MacMahon, H.; Metz, C.E.: "Computerized Detection of Pulmonary Nodules in Digital Chest Images: Use of Morphological Filters in Reducing False Positive Detections," *Medical Physics*, 17 **(1990)** 861-865.
- [60] Ko, J.P.; Naidich, D.P.: "Lung nodule detection and characterization with multislice CT", *Radiologic Clinics of North America*, 41 **(2003)** 575-597.
- [61] Armato, S.G.; Giger, M.L.; Moran, C.J.; Blackburn, J.T.; Doi, K.; MacMahon, H.: "Computerized detection of pulmonary nodules on CT scans," *Radiographics*, 19 **(1999)** 1303–1311.

- [62] McNitt-Gray, M.F.; Brown, M.S.; Goldin, J.G.; Suh, R.D.; Sayre, J.W.; Aberle, D.R.: "Patient-specific models for lung nodule detection and surveillance in CT images", *IEEE Trans Med Imaging* 20 **(2001)** 1242-1250.
- [63] Kawata, Y.; Kanazawa, K.; Niki, N.; Satoh, H.; Ohmatsu, H.; Kakinuma, R.; Kaneko, M.; Moriyama, N.; Eguchi, K.: "Computer-aided diagnosis for pulmonary nodules based on helical CT images", *Comput Med Imaging Graph* 22 **(1998)** 157-167.
- [64] Reeves, A.; Kostis, W.; Yankelewitz, D.; Henschke, C.: "Three-dimensional shape characterization of solitary pulmonary nodules from helical CT scans," in *Proceedings of the International Conference on Computer Assisted Radiography and Surgery CARS'99, Paris, (1999)* 83-87.
- [65] Penedo, M.G.; Carreira, M.J.; Mosquera, A.; Cabello, D.: "Computer-aided diagnosis: a neural-network-based approach to lung nodule detection", *IEEE Transactions on Medical Imaging*, 17 **(1998)** 872-880.
- [66] Xu, X.W.; Doi, K.; Kobayashi, T.; MacMahon, H.; Giger, M.: "Development of an improved CAD scheme for automated detection of lung nodules in digital chest images", *Med. Phys.*, 24 **(1997)** 1395–1403.
- [67] Lo, S.C.; Lou, S.L.A.; Lin, J.S.; Freedman, M.; Chien, M.V.; Mun, S.K.: "Artificial convolutional neural network techniques and applications for lung nodule detection", *IEEE Trans. Med. Imag.*, 14 **(1995)** 711–718.
- [68] Hatanaka, Y.; Hara, T.; Fujita, H.; Kasai, S.; Endo, T.; Iwase, T.: "Development of an automated method for detecting mammographic masses with a partial loss of region", *IEEE Transactions on Medical Imaging*, 20 **(2001)** 1209-1214.
- [69] Hadjiiski, M.; Chan, H.P.; Sahiner, B.; Petrick, N.; Helvie, M.A.: "Automated registration of breast lesions in temporal pairs of mammograms for interval change analysis—local affine transformation for improved localization," *Med. Phys.*, 28, **(2001)** 1070–1079.
- [70] Lee, Y.; Hara, T.; Fujita, H.: "Automated Detection of Pulmonary Nodules in Helical CT Images Based on an Improved Template-Matching Technique", *IEEE Trans. Med.*, 20 **(2001)** 595-604 .
- [71] Tourassi, G.D.; Vargas-Voracek, R.; Catarious, D.M.; Floyd, C.E.: "Computer-assisted detection of mammographic masses: a template matching scheme based on mutual information", *Medical Physics*, 30 **(2003)** 2123-2130.

- [72] Farag, A.A.; El-Baz, A.; Gimel'farb, G.L.; Falk, R.: "Detection and Recognition of Lung Abnormalities Using Deformable Templates", *IEEE Proceedings of the 17th International Conference on Pattern Recognition (ICPR'04)*, 3 (2004) 738-741.
- [73] Wang, P.; DeNunzio, A.; Okunieff, P.; O'Dell, W.G.: "Metastatic lung tumor early detection using 3D template matching", *International Journal of Radiation Oncology, Biology, Physics*, (2005).
- [74] Xiangwei Zhang, "Computer aided detection of pulmonary nodules in helical CT images", Doktora Tezi, 2005.
- [75] Brown, Matthew S.; McNitt-Gray, Michael F.; Goldin, JG: "Patient-specific models for lung nodule detection and surveillance in CT images", *IEEE Trans Med Imaging*, 20(12):1242–1250, Dec. 2001
- [76] Lee, Y.; Hara, T.; Fujita, H.; Itoh, S.; Ishigaki, T.: "Automated detection of pulmonary nodules in helical CT images based on an improved template-matching technique", *MedImg* (20), No. 7, July 2001, pp. 595-604.
- [77] Suckling, J.; Parker, J.; Dance, D.; Astley, S.; Hutt, I.; Boggis, C.: "The mammographic images analysis society digital mammogram database", *Exerpta Medica*, 1069 (1994) 375–378.
- [78] Samuel, G.; Armato, III.; Geoffrey, M.; Michael, F.; Charles, R.; David, Y.: "Lung image database consortium –Developing a resource for the medical imaging research community", *Radiology*, (2004) 739-748.
- [79] Ronse, C.; Devijver, P.A.: "Connected components in binary images: the detection problem", Research Studies Press, NY: Wiley, (1984).
- [80] Manohar, M.; Ramapriyan, H.K.: "Connected Component Labeling of Binary Images on a Mesh Connected Massively Parallel Processor," *Computer Vision, Graphics, and Image Processing*, 45 (1989) 133-149.
- [81] Stefano, L.D.; Bulgarelli, A.: "A simple and efficient connected components labeling algorithm", *Proceedings of International Conference on Image Analysis and Processing*, (1999) 322-327.
- [82] <http://www-cs-students.stanford.edu/~robles/ee368/matching.html> (Erişim tarihi: Ocak 2005)
- [83] Filev, P.; Hadjiiski, L.; Sahiner, B.; Chan, H.; Helvie, M.: "Comparison of similarity measures for the task of template matching of masses on serial mammograms", *Med Phys*. 32 (2005) 515-29.

- [84] <http://mathworld.wolfram.com/Convolution.html> (Eriřim tarihi: Ocak **2005**)
- [85] <http://en.wikipedia.org/wiki/Convolution> (Eriřim tarihi: Ocak **2005**)
- [86] <http://www.dspguide.com/pdfbook.htm> (Eriřim tarihi: Temmuz **2006**)
- [87] Simon, H.: "Adaptive Filter Theory", Prentice Hall, (**1986**).
- [88] Holland, J.H.: "Adaption in Natural and Artificial Systems", MIT Press, Cambridge, MA, (**1975**).
- [89] Goldberg, D.E.: "Genetic Algorithms in Search, Optimization and Machine Learning", Addison-Wesley, USA, (**1989**).
- [90] Yeniay, Ö.: "An Overview of Genetic Algorithms", *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 2 (**2001**) 37-49.
- [91] Iřlier, A.A.: "Üretim Hücrelerinin Bir Genetik Algoritma Kullanılarak Oluřturulması", *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 2 (**2001**) 137-157.
- [92] Engin, O.: "Akıř Tipi Çizelgeleme Problemlerinin Genetik Algoritma ile Çözüm Performansının Arttırılmasında Parametre Optimizasyonu", İTÜ, Fen Bilimleri Enstitüsü, Doktora Tezi, (**2001**).
- [93] Jang, J.S.R.: "Neuro-Fuzzy and Soft Computing: A Computational Approach To Learning and Machine Intelligence", Chapter 7: Derivative-Free Optimization, Prentice-Hall, USA, (**1997**) 173-196.
- [94] Yeo, M.F.; Agyel, E.O.: "Optimising Engineering Problems Using Genetic Algorithms", *Engineering Computations*, 15 (**1996**) 268-280.
- [95] Fıęlalı, A.; Engin, O.: "Genetik Algoritmalarla Akıř Tipi Çizelgelemede Üreme Yöntemi Optimizasyonu", *İTÜ Dergisi*, (**2002**) 1-6.
- [96] Braysy, O.: "Local Search and Variable Neighborhood Search Algorithms for The Vehicle Routing Problem With Time Windows", PH D Thesis, (**2001**).
- [97] Fung, R.Y.K.; Tang, J.; Wang, D.: "Extension Of A Hybrid Genetic Algorithm For Nonlinear Programming Problems With Equality And Inequality Constraints", *Computers & Operations Research*, 29 (**2001**) 261-274.
- [98] Özmen, A.: "Hücreyel Yapay sinir aęı ve görüntü işleme uygulamaları", *Doktora tezi*, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, (**2001**).
- [99] Simon, H.: "Neural Networks", A Comprehensive Foundation Second Edition", Prentice-Hall Inc.,New Jersey, (**1999**).

- [100] Suzuki, H.; Matsimoto, T.; Chua, L.O.: "A CNN Handwritten Character Recognizer", *International Journal of Circuit Theory and Applications*, 20 (1992) 601-612.
- [101] Matsumoto, T.; Chua, L.O.; Yokohama, T.; "Image Thinning with a Cellular Neural Network", *IEEE Transactions on Circuits and Systems*, 37 (1990) 638–640.
- [102] Matsumoto, T.; Chua, L.O.; Suzuki, H.: "CNN Cloning Template: Connected Component Detector", *IEEE Transactions on Circuits and Systems*, 37 (1990) 633–635.
- [103] Matsumoto, T.; Chua, L.O.; Suzuki, H.: "CNN Cloning Template: Shadow Detector", *IEEE Transactions on Circuits and Systems*, 37 (1990) 1070–1073.
- [104] Roska, T.: "Detecting Moving and Standing Objects Using Cellular Neural Networks", *International Journal of Circuit Theory and Applications*, 20 (1992) 613-628.
- [105] Shi, B.E.; Roska, T.; Chua, L.O.: "Design of Linear Cellular Neural Networks for Motion Sensitive Filtering", *IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing*, 40 (1993) 320-331.
- [106] Chua, L.O.; Yang, L.: "Cellular Neural Networks: Applications", *IEEE Transactions on Circuits and Systems*, 35 (1988) 1273 – 1290.
- [107] Zhang, H.; Foo, S.W.: "Computer Aided Detection of Breast Masses from Digitized Mammograms", *IEICE Transactions on Information and Systems*, (2006) 1955-1961.
- [108] Gulsrud, T.O.; Loland, E.: "Multichannel filtering for texture feature extraction in digital mammograms," in *Proc. 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, (1996) 1153-1154.
- [109] Christoyianni, I.; Dermatas, E.; Kokkinakis, G.: "Fast Detection of Masses in Digitized Mammograms", *IEEE International Conference On Acoustics Speech And Signal Processing*, 4 (1999) 2355-2358.
- [110] Bovis K.; Singh S.; Fieldsend J.; Pinder C.: "Identification of masses in digital mammograms with MLP and RBF Nets", *IJCNN*, 1 (2000) 342-347.
- [111] Liu S.; Babbs C.F.; Delp E.J.: "Multiresolution Detection Of Spiculated Lesions In Digital Mammograms", *IEEE Transactions On Image Processing*, 10 (2001) 874-884.

- [112] Christoyianni I.; Dermatas E.; Kokkinakis G.K.: “Automatic detection of abnormal tissue in mammography”, *ICIP*, 2 **(2001)** 877-880.
- [113] Cao A.; Song Q.; Yang X.; Liu S.; Guo C.: “Mammographic mass detection by vicinal support vector machine”, *IEEE International Joint Conference on Neural Networks*, 3 **(2004)** 1953-1958.
- [114] Mudigonda, N.R.; Rangayyan, R.M.; Leo Desautels, J.E.: “Detection of breast masses in mammograms by density slicing and texture flow-field analysis”, *IEEE Transactions on Medical Imaging*, 20 **(2001)** 1215-1227.
- [115] Korfiatis P.; Kalogeropoulou C.; Costaridou L.: “Computer Aided Detection of Lung Nodules in Multislice Computed Tomography ”, *ITAB*, **(2006)**.

ÖZGEÇMİŞ

Serhat ÖZEKES, 22 Temmuz 1978 tarihinde Washington D.C.'de dünyaya geldi. Lisans öğrenimini 2000 yılında Marmara Üniversitesi Teknik Eğitim Fakültesi Bilgisayar ve Kontrol Öğretmenliği bölümünde, Yüksek Lisans öğrenimini de 2002 yılında Marmara Üniversitesi Fen Bilimleri Enstitüsü Elektronik - Bilgisayar Eğitimi Anabilim Dalı Bilgisayar - Kontrol Eğitimi programında tamamladı ve aynı bölümde doktora öğrenimine başladı. Halen İstanbul Ticaret Üniversitesi Meslek Yüksek Okulu Bilgisayar Teknolojisi ve Programlama bölümünde öğretim görevlisi olarak çalışmaktadır.