

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

**MAMOGRAFİ GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE
ÖRÜNTÜ TANIMA TEMELLİ BİR KARAR DESTEK SİSTEMİ**

YÜKSEK LİSANS TEZİ

**Esmâ KARABULUT
(06131101)**

Anabilim Dalı : Elektronik ve Bilgisayar Eğitimi

Programı: Bilgisayar Sistemleri Eğitimi

Tez Danışmanı: Doç. Dr. İbrahim TÜRKOĞLU

Tezin Enstitüye Verildiği Tarih: 18 Aralık 2009

ARALIK-2009

**TC
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAMOGRAFİ GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE
ÖRÜNTÜ TANIMA TEMELLİ BİR KARAR DESTEK SİSTEMİ**

**YÜKSEK LİSANS TEZİ
Esma KARABULUT
(06131101)**

**Tezin Enstitüye Verildiği Tarih: 18 Aralık 2009
Tezin Savunulduğu Tarih: 29 Aralık 2009**

Tez Danışmanı : Doç. Dr. İbrahim TÜRKOĞLU (F.Ü.)

Diğer Jüri Üyeleri : Prof. Dr. Z. Hakan AKPOLAT (F.Ü.)

Yrd. Doç. Dr. Ahmet ÇINAR (F.Ü.)

ARALIK-2009

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

**MAMOGRAFİ GÖRÜNTÜLERİNİN DEĞERLENDİRİLMESİNDE
ÖRÜNTÜ TANIMA TEMELLİ BİR KARAR DESTEK SİSTEMİ**

**YÜKSEK LİSANS TEZİ
Esma KARABULUT**

Anabilim Dalı: Elektronik ve Bilgisayar Eğitimi

Programı: Bilgisayar Sistemleri Eğitimi

ARALIK-2009

ÖNSÖZ

Lisans ve Yüksek Lisans eğitimim boyunca ve tez çalışmam sürecinde ilgi ve yardımını esirgemeyen danışman hocam Sayın Doç. Dr. İbrahim TÜRKOĞLU'na, verilerin analizindeki yardımlarından dolayı Yrd. Doç Dr. Engin AVCI'ya ve tüm hocalarıma, mamografi verilerinin sağlanması ve incelenmesindeki yardımlarından dolayı ağabeyim Dr. Koray KARABULUT'a, tüm eğitim yaşamım boyunca maddi ve manevi desteklerini esirgemeyen anneme ve babama, yüksek lisans eğitimim ve tez çalışmam sürecinde sabır ve özveriyle beni desteklediği için eşime ayrıca teşekkür ederim.

Esmâ KARABULUT
ELAZIĞ – 2009

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	I
İÇİNDEKİLER	II
ÖZET	IV
ABSTRACT	V
ŞEKİLLER LİSTESİ.....	VI
TABLOLAR LİSTESİ.....	VIII
KISALTMALAR LİSTESİ.....	IX
SEMBOLLER LİSTESİ.....	X
1. GİRİŞ	1
1.1 Amaç.....	2
1.2 Literatür Taraması ve Değerlendirme.....	2
1.3 Tezin Organizasyonu.....	4
2. MEME KANSERİ VE MAMOGRAFİ.....	5
2.1 Meme Tümörleri ve Mikrokalsifikasyonlar	5
2.2 Mamografi	8
2.3 Mamografinin Çeşitleri	9
2.4 Mamografinin Çekim Safhaları	9
2.5 Mamografi Çekilirken Alınan Görüntüler	11
2.6 Meme Kanserinin Bilgisayarla Teşhisi.....	12
3. ÖRÜNTÜ TANIMA.....	15
3.1 Ön İşlem Süreci	16
3.1.1 Bölütleme	17
3.2 Özellik Çıkarma Süreci	19
3.2.1 Dalgacık Dönüşümü	20
3.2.2 Entropi Hesaplama Teknikleri.....	24
3.3 Sınıflandırma Süreci	25
3.3.1 Yapay Sinir Ağı Sınıflandırıcıları.....	26
4. MAMOGRAFİ GÖRÜNTÜLERİ İÇİN GELİŞTİRİLEN KARAR	
DESTEK SİSTEMİ.....	33
4.1 Mamografi Görüntülerin Elde Edilmesi	35
4.2 Ön İşlem Süreci	35

	<u>Sayfa No</u>
4.3 Özellik Çıkarma Süreci	38
4.4 Sınıflandırma Süreci	41
5. SONUÇLAR VE TARTIŞMA	44
5.1 Öneriler	45
KAYNAKLAR.....	46
ÖZGEÇMİŞ.....	51

ÖZET

Meme kanseri kadınlarda, erken ölüme yol açan kanser türlerinin başında gelir. Literatürde, radyologların gözünden kaçan meme kanseri vakalarının %10-%25 olduğunu görülmektedir. Bilişim teknolojisinin gelişmesiyle, bilgisayarların uzmanlarca karar destek sistemi olarak kullanımı da yaygınlaşmıştır. Özellikle tıp alanında bu tür sistemler teşhis amaçlı olarak doktorlarca kullanılmaktadır.

Şüpheli bir bölgeyi gösteren bilgisayar destekli sistem, bir tümörün doktorun gözünden kaçmasını önleyebilir. Bu tür sistemler doktor yerine değil, doktora “ikinci fikir” ya da “ön-okuyucu” olarak destek bilgisi sunar ve böylece birden fazla uzmanın aynı vakayı incelemesine gerek kalmamasını sağlar.

Bu tez çalışmasında, memenin röntgeninin alınması ile elde edilen mamografi görüntülerinin ön işlem, özellik çıkarma ve sınıflama süreçlerini içeren bir örüntü tanıma sistemi ile değerlendirilmesi amaçlanmıştır. Bunun için, ön işlem sürecinde histogram temelli bölütleme, özellik çıkarma sürecinde bölütlenmiş mamografi görüntüsünün dalgacık dönüşümü ve shannon entropi hesaplama, sınıflama sürecinde ise entropi özellik değerlerinin geri yayılım yapay sinir ağı kullanılarak mamografi görüntüsünün tanınması gerçekleştirilmiştir. Geliştirilen karar destek sisteminin uygulaması, 82 mamografi görüntüsü üzerinde denenmiştir. Test sonuçları, önerilen uygulama sisteminin başarımının %86 doğrulukta olduğunu göstermiştir.

Anahtar Kelimeler: Mamografi Görüntüleri, Örüntü Tanıma, Dalgacık Dönüşümü, Entropi, Yapay Sinir Ağları.

ABSTRACT

A Decision Support System Based on Pattern Recognition for Evaluating of Mammographic Images

Breast cancer is one of the leading causes of early mortality in women. Retrospective studies have shown that in current breast cancer screening between 10% to 25% of tumors are missed by radiologists. By the development of computer technology, today, computer aided systems are being used in order to give support to the experts in their province. Especially, medical science profits so much from these kinds of developments. Computer aid systems are becoming prevalent for doctors in diagnosis.

A computer-aided detection system that prompts suspicious regions can draw attention of the radiologist to a tumor he might otherwise have overlooked. The use of computer aid diagnosis methods as a “second opinion” or as a “pre-reader” strategy has been proposed, may reduce the observer variation.

Within the scope of this study, it is aimed to evaluate the segmentation of mammogram images with a pattern recognition system mainly of three operations; pre-treatment, feature extraction and classification. In order to this, in pre-treatment process, histogram based segmentation; in feature extraction process, wavelet transformation of segmented mammogram images and shannon entropy, and during classification process entropy feature by using backprobagation artificial neural networks recognition of mammogram images is carried out. The use of developed decision support system is tried on 82 mammogram images. The test results have shown that the success of the proposed system is 86%.

Keywords: Mammographic Images, Pattern Recognition, Wavelet Transform, Entropy, Artificial Neural Networks.

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1. (a) Epitel dokusu ile diğer dokular arasındaki normal ilişki, (b) In situ kanser, (c) Invaziv kanser.....	6
Şekil 2.2. Mikrokalsifikasyonlar	7
Şekil 2.3. Meme tümörü çeşitleri	8
Şekil 2.4. Mamografi çekim işlemi	10
Şekil 2.5.(a) Normal mamografi, (b) Tümör içeren mamografi, (c) Mikrokalsifikasyon içeren mamografi.....	10
Şekil 2.6. Mamografi çekim yönleri.....	11
Şekil 2.7. Farklı açılardan çekilmiş mamografi görüntüleri.....	12
Şekil 2.8. Bilgisayarlı teşhis süreci.....	13
Şekil 3.1. Örüntü tanıma kavramı.....	16
Şekil 3.2. Gri seviye histogramı (a) Tek eşik değer (b) Çok seviyeli eşik değer	18
Şekil 3.3. Dalgacık dönüşümünün blok diyagramı	22
Şekil 3.4. DD ayrışımı (a) Tek seviyeli ayrışım (b) İki seviyeli ayrışım	22
Şekil 3.5. Yaygın olarak kullanılan dalgacık aileleri.....	23
Şekil 3.6. Akıllı sınıflama yapısı	26
Şekil 3.7. Bir nöron hücresinin matematiksel modeli	26
Şekil 3.8. Etkinleştirme fonksiyonları (a)Lineer, (b) Rampa, (c) Basamak, (d) Sigmoid.....	27
Şekil 3.9. Çok katmanlı yapay sinir ağı.....	30
Şekil 3.10. Yapay sinir ağı örüntü sınıflandırıcıları.	32
Şekil 4.1. Geliştirilen uygulama sistemi.....	34
Şekil 4.2. Farklı meme tümörü yapıları.....	34
Şekil 4.3.Gürültü temizleme işlemi	36
Şekil 4.4. Pencerelemiş (a) selim, (b) habis mamografi görüntüleri	36
Şekil 4.5. Habis mamograma ait histogram.....	37
Şekil 4.6. Selim mamograma ait histogram.....	37
Şekil 4.7. a) Mamografi görüntüsü, b) Bölütlenmiş mamografi görüntüsü	38

Şekil 4.8. Dalgacık dönüşümü ile alt bantlara ayrıştırılmış mamografi görüntüleri a) Selim mamografi görüntüsü, b) Habis mamografi görüntüsü, c) Mikrokalifikasyonlu mamografi görüntüsü.....	39
Şekil 4.9. YSA modelinin eğitim başarımı.....	42

TABLÖLAR LİSTESİ

Sayfa No

Tablo 4.1. Mamografi görüntülerine ait özellik vektörü	40
Tablo 4.2. Yapay sinir ağının yapısı.....	41
Tablo 4.3. Sınıflandırma Sonuçları ve Başarı Oranları	42

KISALTMALAR LİSTESİ

ADD	: Ayrık Dalgacık Dönüşümü
ÇKA	: Çok Katmanlı Algılayıcı
DD	: Dalgacık Dönüşümü
EEG	: Elektro Ensefalografi
FD	: Fourier Dönüşümü
HFD	: Hızlı Fourier Dönüşümü
JPEG	: Joint Photographic Experts Group
KZFD	: Kısa Zamanlı Fourier Dönüşümü
SMF	: Standart Mamogram Formu
SDD	: Sürekli Dalgacık Dönüşümü
MEG	: Magneto Ensefalografi
NMR	: Nükleer Manyetik Rezonans
YSA	: Yapay Sinir Ağı
ZFG	: Zaman Frekans Gösterimi

SEMBOLLER LİSTESİ

$w^{(k)}$	Karar uzayındaki her bir sınıf
F	Giriş ve karar uzayı arasındaki özellik uzayı
(x,y)	Eğitim çifti
φ	Sınıflandırıcının adaptif parametreler kümesi
J	Amaç fonksiyonu
$E[.]$	Sınıflandırma hatası
$f(.)$	Yaklaşım fonksiyonu
ψ	Eğitim girişi
$\psi\Omega$	İstenen çıkış
$\varphi\Delta$	Düzenlenen kurallar
$T[.]$	Eğitimin şartlar kümesi
w_{ij}	Yapay sinir ağı ağırlıkları
$T_x(t,f)$	Zaman – frekans gösterimi
$E(s)$	Entropi ifadesi
ε	i) Entropi eşik değeri, ii) Momentum katsayısı
$i\theta$	i. işlem elemanının eşik değeri
$a(.)$	Etkinleştirme fonksiyonu
m	Dalgacık ayrışım seviyesi
A	Dalgacık ayrışımının yaklaşık katsayısı
H	Dalgacık ayrışımının detay katsayısı (Horizontal)
D	Dalgacık ayrışımının detay katsayısı (Diagonal)
V	Dalgacık ayrışımının detay katsayısı (Vertical)
$X(f)$	İşaretin Fourier dönüşümü
$F(.)$	Dalgacık sinir ağı etkinleştirme fonksiyonu

1. GİRİŞ

Meme kanseri, tüm dünyada, kadınlarda sıkça, erkeklerde ise seyrek olarak görülen ve ölüme yol açan bir kanser türüdür [1]. Dünya Sağlık Örgütü'ne bildirilen rakamlara göre, ortalama 100.000 nüfuslu bir ülkede 1000 veya daha fazla sayıda kadın meme kanserinden ölmektedir [2]. Türkiye'de de kadınlarda en sık rastlanan kanser tipi meme kanseridir ve Türkiye insidans hızı orta derecede yüksek olan ülkeler arasındadır [3]. Kadınlarda en sık görülen kanser tipi olup ölümcül olmasına rağmen, erken teşhis yöntemleri ve multidisipliner tedavi yaklaşımları ile sağkalım oranları önemli ölçüde artmıştır. Tarama mamografileri ile meme kanserinin erken tanısı mümkün olabilmektedir. Yapılan çalışmalarda mamografinin, 1 cm ve daha küçük çaplı kitleleri saptama gücüne sahip olduğu ortaya konmuştur [4-6].

Mamografi, memenin çeşitli açılardan röntgeninin alınmasıdır ve erken meme kanseri teşhisinde en iyi görüntüleme tekniğidir. Yaklaşık olarak meme kanserlerinin %80-85'i mamografi görüntülerinin incelenmesi ile elde edilirken, yapılan çalışmalar göstermiştir ki görüntülenen tümörlerin %10-25'i radyologlar tarafından gözden kaçırılmıştır [1,7].

Mamografiyle yapılan incelemeler sonucunda erken yapılan teşhisin, meme kanserinin ölüm riskini %30 oranında azalttığı bilinmektedir [8]. Mamografinin maliyetinin oldukça düşük olması, bu yöntemin yaygın olarak kullanımını sağlamıştır. Kanserinin ilk aşamalarında görülen mikrokalsifikasyon öbeklerinin bile mamografilerde görüntülenebilir oluşu da mamografinin erken teşhiste rolünü artırmıştır. Mikrokalsifikasyonlar, kanserli hücrelerin etkisiyle beliren ve genellikle öbekler halinde görülen küçük kalsiyum birikimleridir. Bunlar, mammogramlar üzerinde parlak noktalar halinde belirirler. Mikrokalsifikasyonlar 0.1 mm'den 5 mm yarı çapa kadar değişen büyüklüklerde bulunabilirler [9].

Maliyetinin düşük olması ve erken teşhiste etkili olmasından ve 40 yaşını geçmiş kadınlarda yılda en az bir kez mamografi yaptırtmanın doktorlarca tavsiye edilmesinden dolayı, mamografiye başvuru artmış ve bu durum bir doktorun incelemesi gereken vaka sayısının da doğru orantılı olarak artmasına neden olmuştur. Özellikle doku içine gömülmüş mikrokalsifikasyonların belirlenmesi dikkat gerektiren bir süreç olduğundan ve

artan sayıda mamogramın, sınırlı sayıda radyolog ve doktor tarafından incelenmesi gerektiğinden, yanlış teşhisler, ölüme neden olabilen hatalara yol açabilmektedir. Mamogramlardan daha iyi yararlanabilmek ve teşhislerdeki doğruluk oranını arttırabilmek için, doktora yardımcı olacak bilgisayar destekli bir karar destek sisteminin geliştirilmesi, hem süreci kısaltacak hem de tanının doğru bir şekilde verilmesine yardımcı olacaktır.

1.1 Amaç

Tez çalışmasının amacı, radyologlara mamografi görüntülerinin değerlendirilmesinde yardımcı ve güvenilir bir bilgi sunmaktır. Böylece iş yoğunluğundan veya dikkatten kaçabilecek tümörlü mamogram görüntülerinin sayısı azaltılacaktır. Geliştirilecek karar destek sistemi, mamograf görüntülerinin otomatik olarak selim(normal) veya habis (anormal) olarak sınıflandırılacaktır. Bu yardımcı teşhis sistemi için, örüntü tanıma yaklaşımı temel alınarak önışlem, özellik çıkarma ve sınıflama süreçlerini içeren bir uygulama sistemi geliştirilmesi hedeflenmektedir.

1.2 Literatür Taraması ve Değerlendirme

Meme yoğunluğu üzerine çalışmaların kaynağı Wolfe'un meme dokusu ve meme kanseri arasındaki bağıntıyı ortaya koyduğu çalışmalara dayanmaktadır. Bu çalışmada Wolfe meme parankimasını 4 gruba ayırmıştır [10]. Miller ve Astley yağlı ve yoğun meme yapılarını ayırt etmek için doku tabanlı öznitelikler kullanmıştır. Byng, fraktal boyut üzerine ölçümler kullanmıştır. Bovis and Singh, uzamsal uri seviyesi bağımlılık (Spatial Gray Level Dependency) matrislerinden öznitelikleri çıkarmışlardır [15]. Son zamanlarda, Petroudi mamografik görünümüleri yakalayabilmek için tekstonları kullanmıştır [12]. Zwiggelaar, yeniden görünme matrisleri kullanarak mamografileri yoğunluklarına göre bölütlemiştir. Yoğunluk sınıflandırma için yoğunluk bölgesinin boyutu gibi şekilsel özellikleri kullanılmıştır [13]. 1996'da Highnam ve Brady hacimsel bir ölçüt olarak hint gösterimini öne sürmüştür. Çalışmalarında, her pikselin yağ dokusunu SMF (Standart Mammogram Form) kullanarak nicel ölçekleme yapmışlardır [14]. Hacimsel gösterimler 3 boyutlu meme görüntülerinden meme yoğunluğunun belirlenmesinde sık kullanılan

öznitelikler olmuştur [14,15]. Oliver, meme parankima yoğunluğunun belirlenmesi için morfolojik ve doku özniteliklerini kullanmıştır. Meme görüntülerinden öznitelik çıkarımı için, Swiniarski Haar dalgacıklarını ve bağımsız bileşen analizi yöntemlerini kullanmıştır [16]. Mencattini, pekiştirilmiş görüntülerden çıkarılmış 13 Haralic doku özneliği kullanmıştır [17]. Brake, Karssemeijer ve Hendriks'te spikül ve kitlelerin belirlenmesi için benek seviyesi (piksel-seviye) yöntemi kullanılmıştır. Her benek için 3 spikül ve 2 kitle varlığı ile ilgili olmak üzere 5 öznitelik tanımlanmıştır [18,19]. Sheshadri ve Kandaswamy ortalama değer, standart sapma, düzgünlük (smoothness), 3. moment, benzerlik (uniformity) ve dağınım (entropi) özniteliklerini kullanarak meme durum tipini belirlemeye çalışmışlardır [20]. Petroudi ve Brady başka bir çalışmalarında eş seviyeli çerçeve eşlemleri kullanarak meme tiplerini ayırt etmeye çalışmışlardır. Bu yöntemle görüntülerin topografik ve geometrik yapıları incelenmektedir [21,14]. Groshong ve Kegelmayer mammogram görüntülerindeki kitleleri bulmak için Hough dönüşümü kullanmışlardır [22]. Kitle saptaması için birçok çalışma grubu Gausların Laplaslarını veya Gauss Farklarını kullanmaktadır [23-25]. Li vd., tümör tespiti için Markov Random alanlarını kullanmışlardır [26]. Lefebvre vd., mikrokalsifikasyonların segmentasyonunda Fraktal yaklaşımı kullanırken, Qian vd., Dalgacık Dönüşümlerinden yararlanmıştır [27]. Petrick vd., yoğunluğa bağlı kontrast genişletme filtrelerini kullanmıştır [28]. Li vd., bir başka çalışmada morfolojik iyileştirme ve içeriksel bölütleme yöntemlerinden faydalanmışlardır [29]. Ertaş ve Gülçür bütün mamografi görüntüsünün yoğun olup olmadığının tespitine yönelik olarak nispi işleme özelliği eğrileri (ROC) oluşturulmuş, Youden ölçütü hesaplanmış ve sonuçta da optimum asimetri değeri bulunmuştur [30]. Zhang vd., özellik çıkarmada genetik algoritmaları kullanmıştır [31].

Meme görüntülerinden kanser araştırması çalışmaları üzerinde yapılan çalışmalarda sıklıkla karşılaşılan durum, bölütlenmiş görüntülerden çeşitli özniteliklerin çıkarımına dayanmaktadır. Bu öznitelikler, ortalama, standart sapma gibi istatistiksel özniteliklerden, dalgacık katsayıları gibi karmaşık özniteliklere kadar çeşitlilik göstermektedir.

Yapay Sinir Ağları (YSA) ise mikrokalsifikasyon kümelerinin tespitinde sık kullanılmaktadır [32]. Bu yöntemle YSA, değişen boyutlarda, geriye yayılım (back-probagation) algoritması yoluyla eğitilerek uygulanmaktadır. Genellikle teşhis aşamasında radyologlara önemli ölçüde yardımcı olduğundan dolayı yaygın olarak kullanılmaktadır. YSA uygulamalarının sonucunda elde edilen sonucun nereden, nasıl çıkarıldığının bilinmemesi ve algoritmaların eğitimlerinin zaman alıcı ve zor olması gibi dezavantajları

olmasına rağmen öğrenebilir olmaları ve hiç karşılaşmadıkları sorunları çözebilmeleri oldukça önemli avantajlarından [32].

1.3 Tezin Organizasyonu

Tez aşağıdaki bölümlerden oluşmuştur:

Birinci bölümde, teze genel bir bakış açısı kazanmaya yönelik olarak temel bilgiler verilmiş, meme kanserinin ülkemizde ve dünyadaki yaygınlık oranları incelenmiştir. Erken tanının meme kanseri teşhisindeki önemi vurgulanarak, literatür çalışmaları irdelenmiştir.

İkinci bölümde, meme görüntüleme yöntemlerinden mamografinin tanımı, mamografi türleri, çekim safhaları ve meme tümörü özellikleri açıklanmıştır.

Üçüncü bölümde, örüntü tanıma kavramı tanımlanarak, önişlem, bölütleme, filtreleme, özellik çıkarımı, entropi hesaplama, dalgacık dönüşümü gibi örüntü tanıma sistemi içinde yer alabilecek bileşenler açıklanmıştır. Örüntü tanıma türleri verilerek, özellikle akıllı örüntü tanıma yapısı üzerinde durulmuş ve sahip olması gereken özellikler vurgulanmıştır.

Dördüncü bölümde, geliştirilen karar destek sistemi uygulamasına yer verilmiş ve uygulamanın sonucunda elde edilen başarımlar oranları açıklanmıştır.

Beşinci bölümde ise, elde edilen sonuçlar irdelenerek katkılar vurgulanmıştır. Ayrıca ileride yapılabilecek benzeri çalışmalar ve uygulama alanları için öneriler tartışılmıştır.

2. MEME KANSERİ VE MAMOGRAFI

2.1 Meme Tümörleri ve Mikrokalsifikasyonlar


Vücuttaki her organ değişik hücrelerden meydana gelmiştir. Bu hücreler ihtiyaç olduğunda, belli bir düzen içinde bölünür ve çoğalırlar. Bu olay vücudu sağlıklı tutar. Hücrelerin kontrolsüz olarak bölünmesi ve ihtiyacın ötesinde çoğalması sonucu kitle oluşur. Bu kitle tümördür. Tümörler selim (normal) ya da habis (anormal) olabilirler. Selim tümörler iyi huyludurlar, habis tümörler ise kanserlerdir. Bir tümörün selim ya da habis olduğu patolojik tetkik sonucu anlaşılır [33].

Selim tümörler kanser değildir. Cerrahi olarak alınabilirler ve tekrar ortaya çıkmazlar. En önemlisi selim tümör hücreleri diğer dokuları istila etmez ve vücudun başka yerlerine doğru yayılmazlar. Selim tümörler yaşamı tehdit etmezler. Habis tümörler ise kanserdirler. Kanser hücreleri de kontrol dışı büyür ve bölünürler ancak selim tümörlerden çok daha hızlı çoğalıp büyürler. Yakındaki doku ve organları da istila edip harap ederler. Ayrıca, kanser hücreleri habis tümörden kopup kan dolaşımına veya lenfatik dolaşıma dökülebilir. Meme kanserinde, vücudun başka yerlerinde tümör hücreleri bu şekilde gelişir [33].

Kanser hücrelerinin uzak dokulara yayılmasına metastaz denir. Karaciğer, kemikler, beyin dokusu meme kanserinin en sık metastaz yaptığı yerlerdir. Meme dokusu süt bezleri, süt kanalları, bunları çevreleyen yağ dokusundan oluşmaktadır. Meme kanserleri bu dokulardan ortaya çıkar. Her dokunun kanseri farklı özelliktedir, tedavisi ve hastalığın ilerleyiş biçimi farklıdır. Süt bezlerinden ortaya çıkan kanserlere lobular karsinoma, süt bezlerinden ortaya çıkan meme kanserlerine ise duktal karsinoma denmektedir. Kanser hücrelerinin lokalize veya çevre dokuya yayılmalarına bakılarak in situ kanser ve invaziv kanser terimleri de kullanılmaktadır. Meme kanseri denince tek bir hastalık anlaşılmalıdır [33].

Birkaç çeşit meme kanseri vardır. En sık görüleni süt kanallarından çıkar ve duktal kanser denir. Diğer bir tip ise süt üreten keseciklerden gelişir ve lobüler kanserdir. Diğer meme kanseri tipleri çok nadir görülür. Kanser hücrelerinin lokalize veya çevre dokuya yayılmalarına bakılarak in situ kanser ve invaziv kanser terimleri de kullanılmaktadır.

İnvaziv kanser çevre dokuya yayılmış, diğer bir deyişle kanser hücreleri başladıkları doku dışına çıkmıştır. Bu kanserler artık yandaş ya da uzak bölgelere yayılabileceklerdir. Bu tip kanserlerin tedavisi daha zor ve karmaşıktır. İn situ kanser yayılmamış anlamındadır ve bu evrede yakalanan kanser oranı çok olmakla beraber genellikle sadece cerrahi yolla tam olarak tedavi edilebilmektedirler. Epitel dokusu ile diğer dokular arasındaki normal ilişki Şekil 2.1(a)'da, İn situ kanser Şekil 2.1(b)'de, İnvaziv kanser ise Şekil 2.1(c)'de gösterilmiştir[34].



Şekil 2.1. (a) Epitel dokusu ile diğer dokular arasındaki normal ilişki, (b) İn situ kanser, (c) İnvaziv kanser


Kanser hücreleri meme dokusu dışına çıktıysa, öncelikle koltuk altı lenf ganglionlarını tutar. Kanser hücreleri vücudun diğer bölgelerine de örneğin kemiklere, akciğere veya karaciğere ulaşmış olabilirler. Başka organlara yayılmış olan kanser de çıktığı organın adıyla anılır. Meme kanseri, başka bir organa bulaşmışsa, örneğin karaciğeri tutmuşsa, buna metastatik meme kanseri denir.

Radyologlar mamogram görüntüsünü değerlendirirken mammogram üzerindeki kanser belirtilerine bakarlar. Bu belirtiler küçük parlak noktalar olarak beliren kalsiyum birikintileri (mikrokalsifikasyonlar), belirgin olarak görülen kitleler (tümörler) ve memenin doku bütünlüğünde görülen yapısal bozulmalar olarak sıralanabilir. Özellikle mikrokalsifikasyonlar meme kanserinin en erken belirtilerindendir.

Mikrokalsifikasyonlar mamogramlarda parlak noktalar olarak görünmekte ve kanserli dokularda çoğunlukla kümeler halinde bulunmaktadır.


Mikrokalsifikasyon mamografilerin büyük çoğunluğunda rastlanan bir bulgu olup mamografi, mikrokalsifikasyon saptanmasında kullanılan tek diagnostik modalitedir. Tüm kanser olgularının %30-40'ında mikrokalsifikasyon görülmesi erken tanıda mamografinin önemini vurgulamaktadır [35,36].

Mikrokalsifikasyonların genellikle selim patolojilerde görülmesi, bununla birlikte radyolojik olarak selim ile habis mikrokalsifikasyonların ayırımının güç olması, selim-habis ayırımında kullanılacak bazı parametrelerin geliştirilmesini sağlamıştır. Bu parametreler arasında mikrokalsifikasyonun lokalizasyonu, sayısı, yoğunluğu, boyutu ve şekli, mikrokalsifikasyon kümesinin boyutu ve dağılım örüntüsü yer almaktadır [35,37]. Mikrokalsifikasyonlar; selim, habis ve ara grup olarak sınıflandırılabilir. Şekil 2.2'de mikrokalsifikasyonların mamogramlarda nasıl görüldüğü gösterilmiştir.



Şekil 2.2. Mikrokalsifikasyonlar

Tümörler de mamogramlar üzerinde farklı şekillerde görünürler. Görüntülenen tümörün şekli, onun habis ya da selim olarak nitelendirilmesinde fikir verebilir ancak kesin tanı patolojik incelemeden sonra konur. Meme tümörlerinin şekillerine ve kenar özelliklerine göre adlandırılış biçimleri Şekil 2.3'te gösterilmiştir.



Şekil 2.3. Meme tümörü çeşitleri

2.2 Mamografi

Mamografi, meme dokusunun özel olarak tasarlanmış röntgen cihazları tarafından, düşük dozajlı X-ışınlarıyla yüksek kontrastlı ve yüksek yoğunluklu filmler üzerine alınan görüntüsüdür [38].

Meme kanserinin tedavisinin başarıya ulaşmasında erken teşhis çok önemlidir ve bu da mamografi sayesinde ucuz ve hızlı bir şekilde sağlanabilir. Mamografi meme kanserini erken tespit etmede yeri doldurulamaz bir tetkik şeklidir. Sadece mamografi sayesinde en ufak değişimler anlaşılıp elle muayenede fark edilemeyen nodüllerin büyümesi tespit edilebilir. Yine sadece mamografi ile başlangıç aşamasındaki kanserleri teşhis etmek mümkündür. Kanserli olma şüphesi bulunan kitlenin tespiti sonrasında, bunun kanserli olup olmadığının belirlenmesinde de mamografi kullanılabilir [38].

Biyopsi, kanser olmasından şüphelenilen dokunun laboratuvar şartları altında kanser olup olmadığının belirlenmesi işlemidir. Bir anormalliğin bulunması durumunda, özel bir mamografi türü (Stereotactic Mamografi) yardımıyla yapılan biyopsi, teşhisin doğrulanması amacıyla kullanılır [38].

2.3 Mamografinin Çeşitleri

Mamografi genel olarak iki bölümde incelenebilir. Birincisi, hastalık olup olmadığını belirlemek amacıyla yaptırılan kontrol amaçlı mamografi, ikincisi de hastalık riski taşıyan memeye uygulanan tanı amaçlı mamografidir.

Kontrol amaçlı mamografi, hiç bir şikâyeti olmayan kadınlarda olası meme kanserlerini erken aşamada teşhis etmek için kullanılır.


Tanı amaçlı mamografi, kuşkulu dokunun tam yerini, boyutunu belirlemek ve çevre dokuyla lenf bezlerini görüntülemek amacı ile yapılır. Tanı amaçlı bir mamografide meme, kontrol amaçlı mamografide olduğundan daha fazla açıdan görüntülenir [38].

2.4 Mamografinin Çekim Safhaları

Mamografi çekilirken, işlemi gerçekleştiren uzman, hastayı gerekli konuma getirerek her bir memeyi ayrıca görüntüler. Her çekimde meme, fotoğrafik bir filmin üstüne konumlandırılır ve şeffaf iki levha arasına sıkıştırılır. Bu işlem memenin düzleşmesine neden olur ve daha fazla doku parçasının üst üste gelmeden görüntülenmesini sağlar.


Bazı durumlarda uzmanlar, mamografiden önce, meme derisi üzerine yapışkan yer belirleyiciler koymaktadırlar. Bunlar mamogramlar üzerinde belirgin bir işaret yaratırlar. Bu işaretlemenin amaçlarından biri, kanserle ilişkisi olmayan, örneğin daha önce yapılan bir ameliyatın izleri gibi oluşumların işaretlenmesidir. Benzer işaretler, şüpheli bölümleri belirtmek için de kullanılmaktadır. Mamogramdaki yer bilgisini pekiştirmek için, meme ucuna da bir işaretleyici konulabilir [38].

Mamogram çekilirken, Şekil 2.5'te gösterildiği gibi bir X-ışını kaynağı çalıştırılır ve oluşan ışınlar sıkıştırılmış olan memenin içinden geçerek, alttaki fotoğraf filmine ulaşır. Film üzerinde bulunan özel bir fosfor tabakası, üzerine düşen X-ışınlarının gücüne göre parlar ve parlaklık fotoğraf filmi tarafından kaydedilir. X-ışınları, farklı yoğunluktaki ve tipteki dokulardaki soğurulma oranı farklı olduğu için, memenin içyapısı görüntülenmiş olur [38].



Şekil 2.4. Mamografi çekim işlemi

Meme, yağ, lif dokusu ve salgı bezlerinden oluşmuştur. İyi huylu tümörler ve kanser olan kitleler de dâhil olmak üzere, meme kitleleri mammogram filmi üzerinde beyaz bölgeler olarak görünürler. Yağ, mamogram filmi üzerinde siyah olarak görünür. Bunun dışındaki her şey (salgı bezleri, bağ dokusu, tümörler, mikrokalsifikasyon gibi diğer önemli anormallikler) mamogram filmi üzerinde farklı gri tonları olarak belirir [38]. Şekil 2.6(a)'da normal bir mamografi, Şekil 2.6(b)'de kenarları düzensiz bir tümör oluşumu, Şekil 2.6(c)'de ise işaret teli ile işaretlenmiş bir mamografideki mikrokalsifikasyonlar görülmektedir.



Şekil 2.5.(a) Normal mamografi, (b) Tümör içeren mamografi, (c) Mikrokalsifikasyon içeren mamografi

Mamografi filminin işlenmesi normal bir fotoğraf filminin işlenmesinden farklı değildir. İşlenmiş olan mamogramlar, radyologlar tarafından değerlendirilir. Radyologlar

her iki memenin mamografisini birbiriyle ve yeni mamogramları aynı hastanın eskiden alınmış mamogramlarıyla karşılaştırırlar. Değerlendirmede gölgelere ve meme dokusu yoğunluğunun dağılımına bakılır [38].


Mamogram parmak izi gibidir, kadından kadına farklılık gösterir. Ayrıca farklı zamanlarda çekilen mamogramlar da birbirine benzemez. Fakat uzman bir radyolog bunları kullanabilir. Daha önce çekilmiş mamogramlarla yeni çekilen arasındaki küçük farklar kansere erken aşamada tanı konmasını sağlayabilir [38].

2.5 Mamografi Çekilirken Alınan Görüntüler


Kontrol amaçlı mamografi yapılırken, sağ ve sol memeler ayrıca görüntülenir. Bu işlem sırasında;

- Üstten (Cranial-Caudal CC),
- Bir açıyla, eğimli olarak yandan (MedioLateral-Oblique, MLO),
- Dışarıdan içeriye doğru yandan alınan Lateromedial (LM),
- Memenin ortasından dışarıya doğru alınan Mediolateral (ML),
- Büyütülerek yukarıdan alınan CC,
- Problem görülen alan sıkıştırılarak alınan görüntüler vardır.

Şekil 2.7’de mamografi çekim yönleri, Şekil 2.8’de ise farklı açılardan çekilmiş mamografiler görülmektedir.



Şekil 2.6. Mamografi çekim yönleri



Şekil 2.7. Farklı açılardan çekilmiş mamografi görüntüleri

Tanı amaçlı yapılan mamografide her iki meme ayrı ayrı görüntülenir. Bu işlem sırasında kontrol amaçlı mamografide alınan görüntülere ek olarak, problem ile ilintili ek görüntüler alınır. Bunlara ek olarak bazen, her iki memenin iç kısmını görüntülemek amacıyla "vadi görüntüsü" alınır. Bu görüntü alınırken her iki meme de görüntüleme yerine konur ve aralarındaki bölge ile içe bakan kısımları görüntülenir. Bu görüntülerde normal olmayan yoğunlukta dokular saptandığında, daha detaylı görüntüleme işlemlerine başvurulur [38].

Mamografi bazen de BI-RADS adı verilen kriterlerle rapor edilir. BI-RADS 0: ek tetkik gerektirdiğini, BI-RADS 1; negatif mamografi, BI-RADS 2; iyi huylu değişimleri, BI-RADS 3: muhtemel iyi huylu değişiklik olduğunu ancak belli aralıklarla kontrol gerektiğini, BI-RADS 4; şüpheli kanser kriterlerin bulunduğunu biyopsi yapılmasının gündeme gelebileceğini gösterir. BI-RADS 5; kesin kanser kriterlerinin var olduğunu mutlaka biyopsi yapılmasını belirtir. Bu gruptaki hastalarda kanser bulunma oranı oldukça yüksektir [34].

2.6 Meme Kanserinin Bilgisayarla Teşhisi


Erken tanının olası kanser tedavisinde ilk ve en önemli aşama olduğunun benimsenmesi; hastanelerin mamografi ünitelerine başvurularda, beraberinde de radyologların günlük iş yükünde artışı getirmiştir.

Mamografide erken teşhiste kullanılabilecek kanser belirtileri, meme dokusunun yapısında bozulmalar, iki meme arasında görülen yapısal farklılıklar ve mikrokalsifikasyon

öbeklerinin gözlenmesidir. Bu belirtiler uzmanlar tarafından aranarak hastalık tespit edilmeye çalışılır. Bazı durumlarda, mikrokalsifikasyonlar, gözle görülemeyecek kadar küçük ya da meme dokusunun içine iyice gömülmüş durumda olabilmektedir. Özellikle bu gibi durumlarda tek başına olmasa da doktorun karar vermesine yardımcı olabilecek bir “Karar Destek Sistemi”ne ihtiyaç vardır.

Mamogramların bilgisayar tarafından analizinde de bazı güçlüklerle karşılaşılabilir. Düzgün dağılımı olmayan zeminler üzerinde, düşük piksel değerlerine sahip küçük boyutlarda mikrokalsifikasyonlar içermesi, yoğunluk bakımından normal dokularla tümörlü dokular arasındaki farkın az olması ve bu yüzden tümör alanları ve onların arka zeminleri arasındaki kontrast farklılıklarının düşük seviyelerde olması bu güçlüklerden bazılarıdır. Ayrıca tümörlerin ilk aşamasındaki belirtiler gözle görülemeyecek kadar küçük olabilir, bu da mamogramların yüksek çözünürlüğe sahip olmalarını gerektirir. Bu durum işlenmesi gereken veri miktarını artırır [39].

Bilgisayarlı tespit süreci Şekil 2.9’da gösterildiği gibi üç aşamadan oluşur. İlk olarak ön hazırlık sürecinde tüm görüntü işlenir. Böylece teşhiste kullanılmayan özelliklerin ortadan kaldırılması amaçlanır. Bundan sonraki bölütleme aşamasında belirtilerin görüntü üzerindeki yerleri belirlenir. En son aşamadaki karar verme sürecinde, bulunan belirtilerin kanser işaretleri olup olmadıklarına karar verilir.



Şekil 2.8. Bilgisayarlı teşhis süreci

Mamogramın incelenmesinde, tümör olduğu düşünülen kitleyi ya da şüpheli alanı bulabilmek için bazı noktalara dikkat edilmesi gerekmektedir. Genellikle şüpheli alan;

- Çevresindeki dokudan daha parlaktır,
- Düzgün bir dağılıma sahiptir,
- Değişik boyutlarda ama genellikle dairesel şekildedir,
- Bulanık kenarlara sahiptir.

Her şüpheli alanın tümör içermesi zorunluluğu yoktur. İyi huylu tümör ya da radyologun daha detaylı incelemek için seçtiği bir alan olabilir [40].

3. ÖRÜNTÜ TANIMA

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir verilerdir. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama biçimleridir.

Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel adlandırmalardır. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri içermektedir. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanınması, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler.

Belirli bir sesi veya yüzü tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin birçoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinelerin yapmasını arzularlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makineleri gerçekleştirmek için, çok boyutlu bir mühendislik disiplindir [41].

Örüntü tanıma olayını şu şekilde irdelleyebiliriz; aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesneleri bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırılmasıdır. Bu bağlamda, örüntü tanımanın en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir [41].

Örüntü tanıma birçok mühendislik, tıp, askeri ve bilim alanlarında ses tanıma, radar hedef sınıflama, biyomedikal kontrol, veri madenciliği gibi uygulamalarda kullanılmaktadır [41].


Örüntü tanıma uygulamalarına, makine öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimler de verilmektedir.

Örüntü tanıma süreci Şekil 3.1’de gösterildiği gibi üç süreçten oluşmaktadır:

1.İşaret / Görüntü / Veri İşleme: Ön işlem aşamasıdır. İşaret, veri veya görüntünün filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır.

2.Özellik Çıkarma: İşaret ve görüntünün veri boyutunun indirgendiği ve tanımlayıcı anahtar özniteliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar. Günümüz örüntü tanıma çalışmalarının odak noktasını oluşturmaktadır.

3.Sınıflandırma: Çıkarılan özellik kümesinin indirgendiği ve formüle edildiği tanımlayıcı karar aşamasıdır. Bu aşama aynı zamanda çıkarılan özniteliklerin güçlülüğünü de belirler [41].



Şekil 3.1. Örüntü tanıma kavramı

Aşağıdaki bölümlerde, bu tez çalışmasında olduğu gibi, örüntü olarak görüntülerin kullanılması durumunda, yukarıda verilen örüntü tanıma yaklaşımının süreçlerinin içeriksel yapıları açıklanmıştır.

3.1 Ön İşlem Süreci

Bu süreçte, sayısal hale getirilmiş görüntü üzerinde teşhisi zorlaştıracı sorunların (gürültü, kontrast düşüklüğü, vb.) ortadan kaldırılarak sistemin daha doğru sonuç verebilmesi için gerekli olan görüntü kalitesinin elde edilmesi amaçlanır. Buna ilave olarak görüntü üzerinde teşhiste kullanılmayan özellikler bastırılır. Görüntülerdeki şüpheli bölgelerin ayrıntılarını korurken arka plan gürültüsünün temizlenmesi, mamogramlar üzerindeki görüntü iyileştirme için yaygın olarak kullanılan yöntemlerdir.

3.1.1 Bölütleme

Bölütleme neticesinde sadece aranan bölümlerin tutulması ve gereksiz kısımların görüntüden çıkarılması hedeflenir. İyi bölütlenmiş bir görüntünün özellikleri şu şekilde sıralanabilir:


- Gri ton ya da doku gibi bir özellik açısından bölütlenmiş bir görüntüde düzenli ve türdeş bölgelerin elde edilmesi,
- Bölge içlerinin basit olması ve küçük delikler içermesi,
- Birbirine yakın fakat farklı bölgelerin düzgün oldukları özellik açısından farklı değerler alması,
- Bölge sınırlarının basit olması, girinti çıkıntı olmaması ve bölge sınırlarının uzamsal olarak doğru konumda bulunmasıdır.

Görüntü bölütleme yöntemlerinden en önemlisi görüntünün sadece parlaklık bilgisinin göz önüne alınması ile bölütleme işleminin gerçekleştirildiği eşikleme işlemidir. Bir diğer bölütleme işlemi de farklı yüzeylerin veya bölgelerin yan yana gelmeleriyle oluşan bölgelerin bulunmasıdır [42].

3.1.1.1. Histogram Temelli Görüntü Bölütleme

Sezgisel özellikleri ve kolayca uygulanabilir oluşu, imge eşiklemeyi, imge bölütleme uygulamaları içinde merkezi bir konuma yerleştirmiştir [43]. Şekil 3.2(a)'daki gri seviye histogramının, karanlık bir arka plana ve daha aydınlık bir görüntüye sahip olan $f(x,y)$ imgesine ait olduğunu varsayarsak, bu durumda arka planın ve nesnenin piksellerinin gri seviyesi değerlerinin iki baskın bölgede guruplaştığı görülecektir. İmgenin, arka plandan ayrıştırılmasının en basit yolu, bu iki gurubu ayırabilecek bir T eşik değerinin seçilebilmesidir.

Herhangi bir (x,y) noktası için, $f(x,y) > T$ ise nokta nesneye aittir, aksi durumda nokta arka plan ögesidir. Şekil 3.2(b)'de bu yaklaşımın en genel hali görülmektedir. Burada birden fazla seviyeli eşikleme ile bir (x,y) noktası, eğer $T1 < f(x,y) < T2$ ise birinci nesneye, $f(x,y) > T2$ ise ikinci nesneye ve $f(x,y) < T1$ ise arka plan olarak ayrıştırılmaktadır.



Şekil 3.2. Gri seviye histogramı **(a)** Tek eşik değeri **(b)** Çok seviyeli eşik değeri

Eşikleme, ayrıca bir $T=T[x,y, p(x,y), f(x,y)]$ fonksiyonunun işlevi olarak gösterilebilir. Bu durumda $f(x,y)$, (x,y) noktasının gri-seviyesi değerini, $p(x,y)$ ise o noktasının yerel bir özelliğini gösterir. Örneğin merkezi (x,y) ve onun komşuluğunda olan diğer piksellerin ortalama değerini gösterebilir. Eşiklenmiş bir imge denklem (3.1)'deki gibi tanımlanır:

$$g(x,y) = \begin{cases} 1 & f(x,y) > T \\ 0 & f(x,y) \leq T \end{cases} \quad (3.1)$$

Böylece 1 olarak etiketlenen pikseller nesneyi gösterirken, 0 ile etiketlenen pikseller arka planı gösterecektir. T değeri sadece $f(x,y)$ değerine bağlı ise, buna global eşikleme denir. Diğer taraftan T hem $f(x,y)$ hem de $p(x,y)$ değerlerine bağlı ise bu da yerel eşikleme olarak adlandırılır. Ayrıca eğer T , x ve y uzaysal koordinatlara bağlı ise, bu tür eşikleme dinamik veya uyarlamalı olarak adlandırılır [44].

3.1.1.2. Tüm Görüntüyü Gri Seviye Eşikleme

Genel eşikleme yöntemiyle, gri seviye histogram oluşturulduktan sonra, histogramın en yüksek noktasının daha önceden belirlenmiş bir yüzdesinden daha büyük olan pikseller aynen bırakılırken diğer pikseller sabit bir değere eşitlenir [45]. Burada bölütleme, görüntünün piksel piksel taranarak her bir piksellin parlaklık değerinin seçilen

eşik değerdan büyük veya küçük oluşuna göre arka plan veya örüntü olarak etiketlenmesi ile gerçekleştirilir. T eşik değerdan küçük gri-seviyesi değerdne sahip bütün pikseller 0 yani siyah, bu değerdan büyük pikseller ise 255 yani beyaz olarak yeniden düzenlenir.

Bölgesel gri seviye eşiklemeye göre daha kısa zamanda uygulanabilir ancak farklı nitelikte bölgeler içeren görüntüleri uygulanması hatalı sonuçlar verebilir.

3.1.1.3. Bölgesel Gri Seviye Eşikleme

Bu yöntemde bir piksel merkeze alınarak, bunun çevresindeki alanda ortalama ve standart sapma hesaplanır. Eğer merkezdeki pikselin değeri, ortalamadan büyükse, standart sapmanın daha önceden belirlenmiş katıyla çarpılıp yerine yazılır, eğer küçükse sabit bir değere atanır [39]. Bu şekilde, görüntünün bölgesel özellikleri kullanılarak siyah-beyaz bir görüntü oluşturulur. I orijinal görüntü, $Tk(I)$ bu görüntüden elde edilmiş eşik görüntüsü olmak üzere, gri seviye eşikleme işlemi denklem (3.2)'deki gibi ifade edilebilir.

$$Tk(I) = \begin{cases} (\alpha * \sigma), & I(\rho) \geq k \\ \beta, & I(\rho) < k \end{cases} \quad (3.2)$$

Burada σ işlenen pencerenin standart sapmasını, α ve β pozitif sabit tamsayıları göstermektedir.

3.2 Özellik Çıkarma Süreci

Özellik çıkarma örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır [41]. Özellik çıkarmanın ana sebepleri:

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

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

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

4.Örüntü sınıflandırma sisteminin, sistem içi veya dışındaki kontrolsüz girişimlerden etkilenmemesini sağlayacak bir özellik çıkarımı kararlı bir yapının oluşmasında etken olacaktır. Bu tür kararlı özellikler, sınıflandırıcının genelleme ve ayrışım yeteneğinin yüksek olmasında önemlidirler.

Örüntü özelliklerini belirlemede ana problem verilen esas örüntüden en iyi özellikleri seçmektir. Bunun için iki yaklaşım vardır: Doğrudan ve dolaylı olarak. Birinci metot güçlü yapısal bağlantılara sahip olan ve basit yapılı belirli örüntü tanıma problemlerine uygulanabilmektedir. Dolaylı metotlarda ise denklem (3.3)'teki gibi formüle edilebilen bir dönüşüm veya gösterim tekniği ile daha kullanışlı bir yapıdan özellik çıkarımı yapılmaktadır. Böylece t uzayından, f uzayına bir dönüşüm gerçekleştirilir.

$$f = F(t) \quad (3.3)$$

3.2.1 Dalgacık Dönüşümü

Bir sistemden elde edilen işaretlerin analizinde kullanılan dönüşümlerden en çok bilineni Fourier dönüşümüdür.

$$x(t) = \sum_{k=-\infty}^{\infty} c_k e^{jk(2\pi/T)} \\ c_k = \frac{1}{T} \int_T x(t) e^{-jk(2\pi/T)t} dt \quad (3.4)$$

Denklem (3.4)'te kullanılan $x(t)$ analiz edilecek işaret, T işaretin periyodu, c_k , $x(t)$ nin spektral bileşenlerini gösteren Fourier katsayısıdır. FD, zaman bilgisi içermeden bir

işaretin spektral bileşenleri hakkında bilgi verir. Bu yüzden, spektral bileşenleri zamanla değişen durağan olmayan işaretler için kullanışlı değildir. Bu nedenle işaretlerin analizinde zaman-frekans gösterimine (ZFG) gerek duyulmuştur. Bu konuda Fourier dönüşümünde yapılan ilk değişiklik, işaretin bir zaman-sınırlayıcı pencere fonksiyonuyla çarpılarak durağan olarak kabul edilen birbirine bitişik bölütlere ayrılmasıdır. Her bir bölütün Fourier dönüşümünün alınmasıyla Kısa Süreli Fourier Dönüşümü (KSFD) elde edilir. KSFD’de ortaya çıkan en büyük sorun tüm işaretler için sabit bir pencere fonksiyonu kullanıldığından tüm frekanslarda sabit bir çözünürlüğün oluşmasıdır. Çünkü işaretin hangi anında hangi spektral bileşenlerin ortaya çıkacağı bilinememektedir. Sadece belli bir zaman aralığındaki frekans bandı bulunabilir. Bu yüzden işaretin belli bir zaman aralığındaki frekans bandını bulabilmek ve durağan olmayan işaretlerdeki süreksizliklerin yerini daha iyi tespit edebilmek için Dalgacık Dönüşümü (DD) kullanılan bir yöntem denklem (3.5)’deki şekilde öne sürülmüştür. DD değişik uzunlukta pencereler kullanarak değişken zaman ve frekans çözünürlüğü sağlamaktadır.


$$W(a,b) = \frac{1}{\sqrt{a}} \int x(t) \psi^* \left(\frac{t-b}{a} \right) dt$$

$$x(t) = \frac{C_\psi}{a^2} \int_{a>0} \int_b W(a,b) \psi^* \left(\frac{t-b}{a} \right) da db \quad (3.5)$$

$a > 0$ ve b sabit dönüşüm parametreleri, ψ ana dalgacık (mother wavelet), C_ψ , ψ ya bağlı bir sabit ve $\psi(a,b) x(t)$ ’nin Sürekli Dalgacık Dönüşümüdür.


Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır. İşaretin süreksizliklere ve keskin, sivri uçlara sahip olduğu fiziksel durumları incelemede, Fourier metotlarına göre daha avantajlıdır. Dalgacıklar matematik, kuantum fiziği, elektrik mühendisliği ve sismik jeoloji alanlarından bağımsız olarak geliştirilmişlerdir. Dalgacık dönüşümü, fonksiyonları, operatörleri veya veriyi farklı frekanstaki bileşenlerine ayıran ve ayrı ayrı her bileşen üzerinde çalışmamıza izin veren bir araçtır [41].

Dalgacık dönüşümüyle yaklaşık ve detay olmak üzere iki işaret elde edilir. Yaklaşık Aile detay D ile gösterilir. Yaklaşık (A), işaretin yüksek skala–düşük frekans bileşenlerinden oluşur. Detaylar (D) ise işaretin düşük skala–yüksek frekans bileşenleridir. Dalgacık Dönüşümünün en basit blok diyagramı Şekil 3.3’te gösterilmiştir.



Şekil 3.3. Dalgacık dönüşümünün blok diyagramı

Dalgacık dönüşümüyle istenilen seviyede ayrışım yapılır. Çok seviyeli ayrışım da elde edilen detay (D) ve yaklaşık (A) katsayılarından yaklaşık katsayısı ile ayrışımaya devam edilir ve bunun sonucunda yeniden A, D işaretleri elde edilebilir. Ayrışım n seviyesine kadar yapılabilir ve buna “Dalgacık ayrıştırma ağacı” adı verilir. 2-düzeyle bir dalgacık paket ağaç yapısı Şekil 3.4’te gösterilmiştir. Dalgacık dönüşümü kullanılarak yapılan ayrıştırmada en küçük detaylar ortaya çıkarılır [44].



Şekil 3.4. DD ayrışımı (a) Tek seviyeli ayrışım (b) İki seviyeli ayrışım


Dalgacık dönüşümlerini mikrokalsifikasyonların tespitinde kullanma fikri ilk olarak McLeod [40] tarafından ortaya atılmıştır. Dalgacık dönüşümü, belirli frekans bantlarındaki mikrokalsifikasyon belirtilerinin algılanabileceği düşüncesine dayanır ve frekans alanına geçirilen görüntünün bazı frekansları tespit için kullanılır.

Olası mikrokalsifikasyonların, mamogramların dalgacık ayrışımıyla tespiti ilk olarak Daubechies’in 3 seviyeli dalgacıkları kullanılarak başarılmıştır. Araştırmalar,

mikrokalsifikasyon işaretinin en temiz gösterimiyle gürültünün etkisinden kaynaklanan belirsizlik arasındaki maksimum ödümlenmenin sekizinci seviye olduğunu göstermiştir. Bu dönüşüm, görüntünün örtüşen piksel bölgeleri üzerinden uygulanır [46].

Yeniden oluşturulan görüntüye, eşlenen uzamsal süzgeçler uygulanır. Bu işlem işarettaki mikrokalsifikasyonları ortadan kaldırmadan, geri kalan yapısal bilgilerin kuvvetini düşürür. Bundan sonra arka plandaki bilgileri ortadan kaldırmak ve görüntüyü ikili sisteme dönüştürmek için, görüntü istatistiklerinden hesaplanan bir eşik değeri uygulanır. Kümelerin değerlendirilmesi, eşiklenmiş görüntüdeki her bir nesnenin merkezindeki 1 cm^2 'lik alanın istatistiklerini kontrol eden bir yöntemle gerçekleştirilir. Eğer istatistikler önceden belirlenmiş bir değerin altındaysa nesne görüntüden ayrılır, üstündeyse görüntüde bırakılır. Bu yöntem yukarıda belirtilen ölçütleri temel alarak kümelerin ayrıştırılmasında iyi sonuç vermesine rağmen nesne sayma algoritmalarına göre daha az tercih edilir [47].

Şekil 3.5'te en yaygın olarak kullanılan dalgacık ailelerinin bir kısmı verilmiştir.



Şekil 3.5. Yaygın olarak kullanılan dalgacık aileleri

3.2.2 Entropi Hesaplama Teknikleri

Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. İşaret/görüntü işlemede, özellikle haberleşme sahasında ilk olarak Shannon kullanmıştır [48]. Entropi tabanlı kriterler verilen bir işaret/görüntü gösteriminin özellikleri ile ilgili bilgileri tanımlar. Entropi ölçüm metodu durağan olmayan bir işaretin düzensizlik derecesini ölçmek için ideal bir araç olarak görünmektedir. Ayrıca, entropi kavramı bir olayın içerdiği bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır. Bu yönü ile görüntü içeriğinin ölçülmesinde de kullanımı mümkündür.

Son yıllarda, entropi görüntü işleme alanında da yaygın olarak kullanılan bir kavram haline gelmiştir. Bunlardan bazıları; JPEG (Joint Photographic Experts Group) görüntü kodlamada oluşabilecek gürültüyü tespit etmek, histopatolojik görüntülerinde değerlendirilmesi, [42], endoskopik görüntülerden kanserli dokunun ayırt edilmesi [44], radar işaretlerinden elde edilen görüntülerin sınıflandırılmasında [49], EEG (Elektroensefalografi) işaretlerinin spektral entropilerini kullanarak anestezi derinliği tahmin etmek ve MEG (Magneto Ensefalografi) biyomedikal görüntülerin yeniden yapılandırılmasında norm entropi metodu kullanarak yüksek kalitede MEG görüntüleri elde etmektir.

İşaret/görüntü işlemede yaygın olarak kullanılan entropi hesaplama türleri: Shannon, Norm, Eşik (Threshold), Logaritmik Enerji ve Sure metotlarıdır [50]. Denklem (3.6–3.10)'daki entropi yöntemlerinde, s işareti ve s_i de işaretin i . katsayısını göstermektedir.

1. Shannon Entropi:

$$E(s) = -\sum_i s_i^2 \cdot \log_2(s_i^2) \quad \text{ve} \quad \log(0) = 0 \quad \text{kabul edilerek} \quad (3.6)$$

2. Norm Entropi:

$$E(s) = \sum_i |s_i|^p \quad \text{ve} \quad 1 \leq p < 2 \quad (3.7)$$

3. Logaritmik Enerji Entropi:

$$E(s) = \sum_i \log_2(s_i^2) \quad \text{ve} \quad \log(0) = 0 \quad \text{kabul edilerek} \quad (3.8)$$

4. Eşik Entropi:

ε pozitif bir eşik değeri olup $|s_i| > \varepsilon \Rightarrow E(s_i) = 1$ ve $|s_i| \leq \varepsilon \Rightarrow E(s_i) = 0$

tanımlanmak üzere

$$E(s) = \sum_i E(s_i) \quad (3.9)$$

5. Sure Entropi:

ε pozitif bir eşik değeri olup


$$|s_i| \leq \varepsilon \Rightarrow E(s) = \sum_i \min(s_i^2, \varepsilon^2) \quad (3.10)$$

Bu entropi hesaplama tekniklerinin, görüntü işlemedeki kesin kullanım alanları belirli olmayıp, uygulamalara göre başarımları değişmektedir.

3.3 Sınıflandırma Süreci

Sınıflandırma aşamasının amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar.


Örüntü sınıflandırıcılarını geleneksel ve akıllı olarak gruplara ayırmak mümkündür. Geleneksel sınıflandırma algoritmaları istatistiksel bir yapı olan Bayes karar teorisi üzerine kuruludur. Bunların dezavantajları, özellik uzayını sınıflandırma uzayına dönüştürürken, bir gürültünün çıkması ve her bir sınıf için hata kriterinin belli olmamasıdır. Geleneksel sınıflandırıcılara; çok değişkenli Gauss modelleri, en yakın komşu, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları örnek olarak verilebilir [51]. Buna karşın akıllı sınıflandırma yapıları genellikle YSA tabanlı olup, günümüzde en yaygın kullanılan ve başarımını ispatlamış çok güçlü sınıflandırıcı türleridirler. Özellikle de genelleme yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir. Şekil 3.6.'da akıllı sınıflandırma yapısı gösterilmektedir [41].



Şekil 3.6. Akıllı sınıflama yapısı

3.3.1 Yapay Sinir Ağı Sınıflandırıcıları

Yapay sinir ağları biyolojik nöron hücresinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş bir hesaplama sistemi olup, örüntü tanımda çok kuvvetli sınıflandırıcılardır. Yapay sinir ağları, özellikle bilgisayar teknolojisinin gelişmesi ile mühendislik sahasında çok geniş bir uygulama alanı bulmuştur [50-53]. Şekil 3.7’de biyolojik nörondan esinlenerek ortaya konmuş işlem elemanının basit bir matematiksel modeli gösterilmiştir [41]. Bu modelde, i . işlem elemanının çıkışı denklem (3.11)’de verilmiştir.




Şekil 3.7. Bir nöron hücresinin matematiksel modeli

$$y(t+1) = a \left(\sum_{j=1}^m w_{ij} x_j(t) - \theta_i \right) \quad (3.11)$$

Burada $a()$ etkinleştirme fonksiyonu, θ_i ise i . işlem elemanının eşik değeridir. İşlem elemanlarının bilgi işlemleri iki kısımdan oluşur: giriş ve çıkış. Bir işlem elemanı dışardan almış olduğu x_j giriş bilgilerini bağlı bulundukları w_{ij} ağırlıkları üzerinden birleştirerek bir net değeri üretir. i . işlem elemanının net değeri denklem (3.12) ile hesaplanır.

$$f_i \triangleq net_i = \sum_{j=1}^m w_{ij} x_j - \theta_i \quad (3.12)$$

Her bir işlem elemanının ikinci süreci, net değerini bir $a(.)$ etkinleştirme fonksiyonundan geçirerek çıkış değerini bulmaktır. Etkinleştirme fonksiyonları işlem elemanlarının çok geniş aralıktaki çıkışını belli aralıklara çekmektedir. Böylece her bir işlem elemanının tepkisi yumuşak olmaktadır ve bağlantı ağırlıklarının değişimlerinin de daha küçük değerlerde olması sağlanır. Dolayısıyla yapay sinir ağının eğitiminde, hata değişiminin ıraksaması engellenerek kararlılığa ulaşmasına yardımcı olunur. Çok yaygın olarak kullanılan bazı etkinleştirme fonksiyonları: lineer, rampa, basamak ve sigmoid gibi fonksiyonlardır. Şekil 3.8’de bu fonksiyonlar gösterilmiştir [41].



Şekil 3.8. Etkinleştirme fonksiyonları (a)Lineer, (b) Rampa, (c) Basamak, (d) Sigmoid

Yapay sinir ağı örüntü sınıflandırıcılarını hem popüler yapan, hem de geleneksel sınıflandırma metodlarından ayıran bir takım temel özellikleri vardır. Bunlar aşağıda sıralanmaktadır [54]:

1.Doğrusal Olmama: YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik tüm ağı yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlere çözüm getirmektedir.

2.Öğrenme: Yapay sinir ağları, örüntüler hakkındaki ilişkiyi belirli bir algoritmaya dayanarak çözmek yerine o ilişkiyi gösteren örüntü örneklerini incelemek suretiyle çözümler üretirler. Burada, sınıflandırılacak örüntü ile alakalı sinir ağına örneklerden başka hiç bir ön bilginin verilmemiş olması dikkat çekicidir. Ağ, kendisine gösterilen örnekleri tekrar tekrar inceleyerek aradaki ilişkiyi kavramaya çalışır. Her yeni örnek, ağıın sahip olduğu bilgiye bir yenisini ekler ve bu işlem tekrar ettikçe ilgili örüntü sınıflandırma problemi hakkında bazı genellemeler yapılır.

2.Genelleme: Alışlagelmiş bir takım sınıflandırma karakteristiklerinde, istenen çıkışı üretmek için tam olarak doğru girişlere gereksinim duyulmasıdır. Öte yandan yapay sinir ağları, girişlerinde değişimler olsa bile doğru çıkışı üretebilirler. Yani sistem, daha önce o tipten hiç bir şey görmemiş olmasına rağmen, insanlar gibi tamam olmayan veya kısmen hatalı girişlerle bile, doğru tanımlama yapabilmektedir. Bu da işaret etmektedir ki, yapay sinir ağları kendilerine gösterilen bir örüntüyü daha önce öğrendikleri ile mukayese ederek ve aradaki benzerlikleri ortaya koyarak, belirli sınıflara ayırma özelliklerine sahiptirler.

3.Uyarlanabilirlik: YSA ağırlıkları, uygulanan probleme göre değiştirilir. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir. Değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, işaret işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

4.Çıkarım Yapma: Yapay sinir ağları tam doğru olmayan bir eğitime kümesinden, tam doğruyu çıkarabilirler. Ses örüntülerini tanımak için eğitilmiş bir yapay sinir ağına, gürültü tarafından bozulmuş ses verilebilir. Buna rağmen eğitimden sonra, sistem girişi bozuk ses olmasına rağmen, çıkışta ses mükemmel bir şekilde oluşturulabilir. Yani sistem,

eğitim kümesinin özünü çıkarıp saklamıştır. Böylece, eksik veya gürültülü girişlere karşın uygun şekilde cevap verebilmektedir.


5.Hata Toleransı: Verilerde eğer bir eksiklik söz konusu olursa, geleneksel yöntemler çalışmazlar. Daha önce belirtildiği üzere, iyi eğitilmiş ve genelleme kapasitesi yüksek bir sinir ağı, kendisine takdim edilen veriler eksik olsa da karar verme işlemine devam eder. Aynı şekilde, yapay sinir ağı üzerinde birtakım problemler ve bozukluklar olabilir. Geleneksel sistemlerin tersine yapay sinir ağları, bu durumda da çalışmalarına devam ederler. Verilerdeki eksiklik veya yapay sinir ağındaki yapısal bozukluk arttıkça yapay sinir ağının performansı yavaş yavaş azalmaya başlar. Fakat sistem fonksiyonunu tamamen durdurmaz ve mutlaka bir sonuç üretilir. Bu özellikler yapay sinir ağının yapısından kaynaklanmaktadır. Çünkü ağın sahip olduğu bilgi, ağ üzerindeki hücrelerin birbiri ile olan bağlantıları üzerine dağıtılmıştır. Zaten böyle bir durumda tek bir bağlantı ve onun üzerindeki bilgi, başlı başına hiçbir zaman bir mana ifade etmez. Ancak, bir grup halinde ve tam olarak bağlantıların birlikte düşünülmesi sonucu anlamlı bilgiler üretilir. Bundan dolayı birkaç bağlantının etkisiz hale gelmesi, sonucu ya etkilemez veya performansı yavaş yavaş düşürür. Yapay sinir ağı, sahip olduğu diğer bağlantılar nedeniyle işlevine devam eder. Geleneksel sistemlerin ardışıl çalışmalarından dolayı, sistemdeki en küçük bir hatanın veya bozulmanın ulaşabileceği boyutlar düşünülürse, bu özelliğin ne kadar önemli olduğu ortaya çıkar.

6. Hız: Gerçek zaman uygulamalarında bilgi işleme hızı önemli bir yer teşkil eder. Sistemlerin her geçen gün biraz daha karmaşık olduğu, dolayısı ile daha fazla hacimde veriyi daha verimli bir şekilde işleme gerekliliği, yeni yazılım/donanım sistemlerinin zorunluluğunu ortaya çıkarmıştır. Yapay sinir ağlarının da, yine birbirlerine bağlı ve paralel işlem elemanlarından oluştuğundan böyle hızlı işleyebilmeleri, bu ağlara özellikle endüstriyel hayatta çok önemli olan gerçek zamanlı çalışma kabiliyeti kazandırır.

Yapay sinir ağlarının görevlerini gerçekleştirmede, sahip oldukları fiziksel yapının da önemi vardır. Farklı yapılaşma, işlem elemanlarının birbirleri ile olan bağlantılarından ve uygulanan öğrenme kuralından kaynaklanmaktadır. İşlem elemanları ya tamamen birbirleri ile bağlantılı veya yerel olarak gruplar halinde bağlantılı olabildikleri gibi değişik şekilde de birbirleri ile bağlanabilmektedirler. Bilgi akışı bu bağlantılar üzerinden tek yönlü olduğu gibi, çift yönlü de olabilir. Bir grup işlem elemanı bir araya gelerek bir katman oluştururlar. Genel itibariyle yapay sinir ağlarında 3 tür katman bulunur. Sinir ağının dış dünya ile bağlantısını kuran girdi katmanı, gelen bilgileri işleme kabiliyetine

sahip ara katmanlar ve sinir ağıının kararlarını dış dünyaya aktaran bir çıktı katmanı. Girdi katmanında çoğu zaman bilgi işleme söz konusu olmaz. Bu katmandaki işlem elemanları aldıkları bilgiyi herhangi bir değişikliğe uğratmadan ara katmandaki işlem elemanlarına aktarırlar. Burada sözü edilen bilgi, sinir ağıının işlem elemanları arasındaki bağlantı hatları üzerinde bulunan ağırlıklarla ifade edilir. Dolayısı ile bilgi, bütün ağı dağıtılmış demektir. Bu bilgiler, yapay sinir ağıının belleğidir veya diğer bir deyişle yapay sinir ağıları eğitildikten sonra kullanılacağı sistem için bir veri tabanıdır.

Tüm YSA modellerini bir örüntü sınıflandırıcısı olarak kullanmak mümkündür, fakat en yaygın kullanılan ve en güçlü örüntü sınıflandırıcısı çok katmanlı ileri beslemeli ağı olup, tüm yapay sinir ağı uygulamalarının %90'ını kaplamaktadır [41]. Şekil 3.9'da çok katmanlı yapay sinir ağıının genel yapısı verilmiştir.




Şekil 3.9. Çok katmanlı yapay sinir ağı.

Çok katmanlı ağılarda veriler, giriş katmanı tarafından kabul edilirler. Ağı içindeki işlemler sonucunda çıkış katmanında oluşan cevap ile giriş verisine karşı istenen cevap karşılaştırılır. Hesaplanan cevap ile istenen cevap arasında herhangi bir farklılık varsa, katmanlar arasında bulunan ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Yapay sinir ağıının girişindeki veriler, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkış cevapları, istenen cevaplarla karşılaştırılarak, sonuçta hata işareti elde edilir. Hata işareti, ara katmanlardan çıkış katmanına olan ağırlıkları değiştirmekte de kullanılır. Fakat bunu yaparken, giriş katmanından ara katmana gelen ağırlığın değiştirilip değiştirilemediğini düşünmek gerekir. Ara katmanlarda ne tür bir çıkış istendiği bilinemeyeceği için, ara katmanların çıkışında hata işaretinin verilmesi kolay değildir. Bunun yerine her bir işlem elemanın, çıkış işlem elemanının hatalarına olan etkisi bilinmelidir. Bu hatalı birim için, gizli birime bağlı olan çıkış birimlerinin hata işaretlerinin

ağırlıkları toplamı alınarak ayarlama yapılır. Çok sayıda ara katmana sahip sistemlerde her katmanın hata işaretleri, bir önceki katmanın düzeltilmiş hata işaretlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde giriş seviyesine varana kadar devam eder. Sistem, sonuçta yine hatalar yapar, fakat bu hatalardan bir şey öğrenip istenen cevabı bulana kadar işlem tekrarlanır. Bu yöntem ise hata geri yayılım algoritması denir [41].

Yaygın olarak kullanılan çok katmanlı ileri beslemeli YSA 'nın eğitiminde çeşitli eğitim algoritmaları kullanılmakla birlikte en başarılı sonuçlar geri yayılım (backpropagation) algoritmaları ile elde edilmiştir. Bu algoritma, eğitim düşme metoduna dayalıdır. Çok katmanlı YSA yapısı ve geri yayılım algoritması tüm YSA çalışmalarında geniş bir yer tutar. Çok katmanlı YSA yapısının kaç katmanlı olacağı ve katmanlarda kaç nöron bulunacağı, etkinleştirme fonksiyon türü seçimi genellikle uygulamalara bağlıdır. Geri yayılım öğrenme algoritmalı çok katmanlı YSA, geniş giriş vektörüne sahip olan örüntü tanıma çalışmalarında en iyi başarımın elde edildiği yapıdır. Çünkü örüntü sınıflandırıcılarından beklenen ayrımı yapabilirler [41].

Örüntü sınıflandırıcısı olarak kullanılan YSA türleri hiyerarşik bir biçimde Şekil 3.10'da gösterilmiştir.



Şekil 3.10. Yapay sinir ağı örüntü sınıflandırıcıları.

4. MAMOGRAFİ GÖRÜNTÜLERİ İÇİN GELİŞTİRİLEN KARAR DESTEK SİSTEMİ

Tez çalışmasının odağını oluşturan karar destek sistemi kavramının literatürde çeşitli tanımlamaları bulunmaktadır [55]. Bunlar;

Karar vermeyi kolaylaştırmak, daha etkili ve doğru karar vermek için tasarlanan; değişik model ve uygulamaları kapsamı içinde bulunduran sistemlere karar destek sistemleri denir.

Karar destek sistemleri karar verici için bir analiz sunar ve bu analize dayanarak bir karar tavsiyesinde bulunur.

Temel olarak işletme içinde alınacak üst düzey kararların sağlıklı ve gerekçeli alınmasını sağlayan yazılımlara karar destek sistemleri adı verilmektedir.

Karar destek sistemleri, değişik kaynaklardan topladığı bilgileri düzenleyerek, kararı modelleyerek, bilgileri analiz ederek ve değerlendirme sonuçlarını sunarak belirli modeller kullanımı ile karar vericiye seçim sırasında destek veren bilgisayar temelli bir sistemdir.


Karar destek sistemleri, kullanıcının bilme ve kavrama ile ilgili bilişsel yeteneklerini geliştirerek karar vermesine yardımcı olmak amacı ile özel olarak tasarlanmış bir sistemdir.

Yukarıdaki tanımlar çerçevesinde bu bölümde de, tez çalışmasında mamografi görüntülerinin değerlendirilmesi için geliştirilen bir karar destek sisteminin uygulama süreci verilmiştir. Bunun için, Matlab (Lisans No: 585775) bilgisayar ortamında çeşitli programlar kodlanmıştır. Uygulama sürecinin geliştirilmesinde, literatür araştırmalarından yola çıkılarak örüntü tanıma yaklaşımına dayalı sistem tasarımı esas alınmıştır. Söz konusu sistemin yapısı, bileşenleri ve her bir bileşenin içeriği Şekil 4.1’de verilmiştir.

Geliştirilen uygulama sisteminin ön işlem sürecinde, mamografi görüntülerinden özellik çıkarma sürecinde daha güvenilir ve belirleyici özellikler elde edebilmek için 4 farklı işlem yapılmıştır. Özellik çıkarma sürecinde ise, mamografi görüntülerindeki tümör yapılarının Şekil 4.2’de de görüleceği üzere çok farklılık sergilemesinden dolayı, bilimsel literatürde bu tür karmaşık örüntülerde başarılı sonuçlar veren dalgacık dönüşümü ve entropi hesaplama teknikleri kullanılmıştır. Son olarak sınıflama sürecinde, yapay zekâ tekniklerinden yapay sinir ağı kullanıldığı için sisteme akıllılık özelliği kazandırılmıştır.



Şekil 4.1. Geliştirilen uygulama sistemi




Şekil 4.2. Farklı meme tümörü yapıları

4.1 Mamografi Görüntülerin Elde Edilmesi

Mamografi görüntüleri için, Düzce Özel Hayri Sivrikaya Hastanesi Radyoloji kliniğinden doktor gözetiminde alınmıştır. Ayrıca MIAS (The mini-MIAS database of mammograms) veri tabanından (<http://peipa.essex.ac.uk/info/mias.html>) ve McGill (Interactive Mammography Analysis Web Tutorial) veri tabanından (<http://sprojects.mmi.mcgill.ca/mammography/cases.htm>) alınan 60 hastaya ait mamografi görüntüsü kullanılmıştır. Bu mamografi görüntülerinde, hangilerinin normal veya hangilerinin hastalıklı oldukları uzman tarafından belirtilmiştir.


4.2 Önilem Süreci

Mamografi görüntüleri, doğrudan kullanılmaya elverişli görüntüler değildir. Bu aşamada, görüntü üzerinde teşhisi zorlaştıracı sorunların (gürültü, kontrast düşüklüğü, vb.) ortadan kaldırılarak, özellik çıkarma sürecinin daha verimli çalışabilmesi ve güçlü özellikler elde edilebilmesi için arzu edilen görüntü kalitesini yakalamak amaçlanmıştır. Görüntülerdeki şüpheli bölgeler ayrıntılarını korurken arka plan gürültüsünün temizlenmesi, görüntünün iyileştirilmesi işlemleri gerçekleştirilmiştir. Şekil 4.3'te de gürültülü ve temizlenmiş mamografi görüntüleri verilmiştir.





Şekil 4.3. Gürültü temizleme işlemi

60 hastadan elde edilen mamografi görüntüleri, işleme sürecinin hızlandırılması ve örnek sayısının artırılması için, görüntülerdeki tümörlü dokuyu da kapsayacak şekilde 325x325 piksellik örtüşmeyen pencerelere bölünmüştür. Böylece örnek veri tabanı 82 adet mamografi görüntüsünden oluşmuştur. Bu 82 adet mamografi görüntüsünden 56'sı selim, 26'sı ise habis türüdür. Şekil 4.4'te 325x325 piksellik mamografi görüntüsü örnekleri görülmektedir.




(a) (b)
Şekil 4.4. Pencerelemiş (a) selim, (b) habis mamografi görüntüleri

Pencerelemiş mamografi görüntülerinde istenmeyen arka planların çıkarılması için histogram tekniği kullanılmıştır. Şekil 4.5'te ve Şekil 4.6'da pencerelemiş mamografi görüntülerinin histogramları çıkarılmıştır.




Şekil 4.5.Habis mamograma ait histogram



Şekil 4.6. Selim mamograma ait histogram

Mamografi görüntüsünde istenmeyen arka planı ve süt kanallarını tümör dokusundan ayırmak için bölütleme işlemi gerçekleştirilmiştir. Histogram tabanlı bölütleme işleminde, histogramların tepe noktalarından ortalama bir değer alınarak eşik değeri (T) 180 olarak seçilmiştir. .


Her bir pencerede incelenmesi gereken kısımlar T eşik değeri baz alınarak bölütlenmiş, belirgin duruma getirilmiştir. Şekil 4.7(a)'da ve Şekil 4.7(b)'de görüntülerin bölütleme işleminden önceki ve sonraki durumları gösterilmiştir.



Şekil 4.7. a) Mamografi görüntüsü, b) Bölütlenmiş mamografi görüntüsü

4.3 Özellik Çıkarma Süreci

Mamografi görüntülerinden özellik çıkarma işlemi için, dalgacık dönüşümü ve entropi hesaplama teknikleri uygulanmıştır. Dalgacık dönüşümü ile her bir pencerelenmiş mamografi görüntüsü 4 alt bant da ayrıştırılmıştır. Bu alt bantlar A yaklaşık katsayılı alt bant görüntüyü, H, V ve D ise sırası ile yatay, dikey ve diyagonal detay katsayılı alt bant görüntülerini içermektedir. Şekil 4.8(a)'da normal, Şekil 4.8(b)'de tümör içeren, Şekil 4.8(c)'de ise mikrokalsifikasyon içeren mamogramlara ait orijinal görüntü, eşiklenmiş görüntü, dalgacık dönüşümü ile yaklaşık-yatay-dikey-diyagonal bantlara ayrıştırılmış görüntü örnekleri sırasıyla verilmiştir.



Şekil 4.8. Dalgacık dönüşümü ile alt bantlara ayrıştırılmış mamografi görüntüleri a) Selim mamografi görüntüsü, b) Habis mamografi görüntüsü, c) Miokalsifikasyonlu mamografi görüntüsü

Özellik çıkarma sürecinin bir sonraki adımında, mamografi görüntülerindeki bilgi miktarlarının ölçülmesi için entropi hesaplama tekniğinin kullanılmasıdır. Bunun için, bölütlenmiş mamografi görüntüsünün ve bu bölütlenmiş mamografi görüntüsüne dalgacık dönüşümü uygulanarak elde edilen alt bant görüntülerinin bilgi içerikleri entropi hesaplama tekniklerinden olan shannon entropi ile hesaplanmıştır.

Tablo 4.1 mamografi görüntülerinin entropi değerleri kullanılarak çıkarılmış özellik vektörlerini göstermektedir. Böylece her bir mamografi görüntüsü için elde edilen özellik vektörü:

$$\text{Özellik Vektörü} = [V1, V2, V3, V4, V5]$$

V1: Bölütlenmiş mamografi görüntüsünün entropi değeri,

V2: Bölütlenmiş mamografi görüntüsünün dalgacık dönüşümünün A yaklaşık katsayılı alt bant görüntüsünün entropi değeri,

V3: Bölütlenmiş mamografi görüntüsünün dalgacık dönüşümünün H-yatay detay katsayılı alt bant görüntüsünün entropi değeri,

V4: Bölütlenmiş mamografi görüntüsünün dalgacık dönüşümünün V-dikey detay katsayılı alt bant görüntüsünün entropi değeri,

V5: Bölütlenmiş mamografi görüntüsünün dalgacık dönüşümünün D-diagonal detay katsayılı alt bant görüntüsünün entropi değeri.

Tablo 4.1. Mamografi görüntülerine ait özellik vektörü

Görüntü	V1	V2	V2	V3	V4
Selim	0.73735	3.49416	0.766312	0.777033	0.733953
	0.994158	2.97887	0.343197	0.340858	0.329021
	0.914489	3.03775	0.456823	0.452792	0.450233
	0.95113	2.555	0.312527	0.304522	0.307037
	0.914489	3.03775	0.456823	0.452792	0.450233
Habis	0.273005	2.96224	0.70352	0.685133	0.665623
	0.390462	1.48775	0.174174	0.174775	0.168574
	0.521968	2.41933	0.401072	0.494418	0.392666
	0.459211	1.90474	0.272956	0.28224	0.270964
	0.0219748	0.47846	0.0614619	0.0637904	0.058005


4.4 Sınıflandırma Süreci

Sınıflandırma sürecinde yapay sinir ağları ile sınıflandırma yapılmıştır. İleri beslemeli ve çok katmanlı yapay sinir ağında, hata geri yayma öğrenme algoritması kullanılmıştır. Söz konusu yapay sinir ağının yapısı ile ilgili bilgiler Tablo 4.2. de görülmektedir. Özellik vektörünün boyutu ile aynı sayıda giriş katmanında nöron kullanılmıştır. Ara katman olarak tek ara katman tercih edilmiş, fakat verilen veri kümesine göre giriş ve çıkış arasındaki doğrusallığı sağlamak üzere ara katmanda yapılan çeşitli denemeler sonucunda en uygun 25 nöron kullanılması gerektiği bulunmuştur. Çıkış katmanında ise tek nöron kullanılmış olup, bu nöronun çıkışı mamografi görüntüsüne göre kararı oluşturmaktadır. Buna göre, çıkış sıfır (0) ise selim, bir (1) ise habis türlü mamografi görüntüsü kararı verilmektedir.

Tablo 4.2. Yapay sinir ağının yapısı

YSA Yapısı	
YSA modeli	Çok Katmanlı, İleri Beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 5 Gizli : 25 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Rastgele
Etkinleştirme fonksiyonları	Tanjant sigmoid
YSA Eğitim Parametreleri	
Öğrenme kuralı	Hata Geri Yayınım
Öğrenme oranı	0.06
Toplam karesel hata	0.000001

Şekil 4.9’te yapay sinir ağının eğitim sürecine ait bir başarıım grafiği verilmiştir. Grafikten görüleceği üzere, toplam karesel hata değeri istenen değere 91 eğitim iterasyonu sonucunda ulaşmıştır. Hatanın değişiminde ani kırılmalar bulunmadığından sistemde ezberleme durumu gözlenmemiştir.



Şekil 4.9. YSA modelinin eğitim başarımı

Yapay sinir ağının eğitim ve test süreçleri için iki katlı çapraz geçerlilik kriteri kullanılmıştır. Yapılan uygulamalarda elde edilen başarımlar Tablo 4.3'te verilmiştir.

Tablo 4.3. Sınıflandırma sonuçları ve başarı oranları

Uyg. No	Eğitim		Test		Sınıflandırma				Başarım %
					Selim		Habis		
1	Veri Seti–1		Veri Seti–2		Doğru	Yanlış	Doğru	Yanlış	85
	Habis	Selim	Habis	Selim	25	3	10	3	
	13	28	13	28					
2	Veri Seti–1		Veri Seti–2		23	5	13	0	87
	Habis	Selim	Habis	Selim					
	13	28	13	28					
ORTALAMA									86

İki katlı çapraz geçerlilik test kriteri için, veri kümesi eşit içerikli ve rast gele seçimli olarak iki parçaya bölünmüştür: veri seti-1, veri seti-2. İlk önce veri seti-1 ile YSA eğitilmiş, veri seti-2 ile de YSA test edilmiştir. Sonra ise, veri seti-2 ile YSA eğitilmiş, veri seti-1 ile de YSA test edilmiştir.

Veri seti-1 ile YSA eğitilip, veri seti-2 ile de test edildikten sonra; 28 selim görüntüden 25'i, doğru, 3 yanlış sınıflandırılırken; 13 habis görüntüden 10'u doğru, 3'ü yanlış sınıflandırılmıştır. Bu durumda 1 no'lu uygulamanın başarımının %85 olduğu görülmüştür.

Veri seti-2 ile YSA eğitilip, veri seti-1 ile de test edildikten sonra; 28 selim görüntüden 23'i, doğru, 5 yanlış sınıflandırılırken; 13 habis görüntünün tamamı doğru sınıflandırılmıştır. Bu durumda 2 no'lu uygulamanın başarımının ise %87 olduğu görülmüştür.

Bu sonuçlara göre, geliştirilen mamografi görüntülerini değerlendirme uygulama sisteminin başarımı ortalama olarak %86 olarak bulunmuştur.

5. SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında mamografi görüntülerini değerlendirmesin de uzmana yardımcı olacak ön işleme, özellik çıkarma ve sınıflandırma süreçlerini içeren örüntü tanıma yaklaşımı temelli bir karar destek uygulama sistemi geliştirilmiştir. Geliştirilen uygulamada sistemin başarımı %86 olarak bulunmuştur.

Mamografi görüntüleri, üç boyutlu bir nesnenin iki boyutlu bir filme yansıtılmasıyla elde edildiğinden değişik dokular üst üste gelebilmekte ve bu farklı zeminler üzerine yerleşmiş düşük kontrastlı özelliklerin görülmesi diğer dokular tarafından engellenmektedir. Şüpheli bölgelerin zemini, dokular ve kanallar gibi anatomik yapılardan oluşan bir görüntüdür. Ayrıca, görüntüleme sırasındaki istenmeyen yan etkiler, diğer bir deyişle gürültü de eklenince irdelenmesi gereken veri miktarı artmaktadır. Arka plan ve tümör değerleri birbirine çok yakın görüntülerde bölütleme işlemi yapılırken, kullanılan histogram tabanlı bölütleme algoritmasının bazı hatalı değerler verdiği belirlenmiştir. Dolayısıyla bölütleme işleminde yapılan yanlışlıklar dalgacık dönüşümü, entropi hesaplama ve sınıflandırma işlemlerine de yansımaktadır.

Veriyi farklı frekanstaki bileşenlerine ayıran ve ayrı ayrı her bileşen üzerinde çalışılmasına izin veren bir araç olduğundan, mamogram gibi arka plan ve tümör görüntüleri birbirine çok yakın görüntülerde daha detaylı incelemeyi sağlayabilmek için dalgacık dönüşümü kullanılmıştır. Eşikleme işlemi ile gürültü ve gereksiz detaylardan arındırılan mamografi görüntüleri için tek seviyeli dalgacık ayrışımı yeterli olmuştur.

Entropi hesaplama tekniklerinin, görüntü işlemedeki kesin kullanım alanları belirli olmayıp, uygulamalara göre başarımları değiştiğinden Sure, Logaritmik, Norm ve Shannon teknikleri ile entropi hesaplaması yapıldığında mamografi görüntüleri için en başarılı bilgi ölçümünün, Shannon entropi hesaplama tekniği ile elde edildiği görülmüştür. Literatürde de bu tür görüntüler için Shannon entropi hesaplama tekniğinin uygulandığı görülmüştür.

Kitleler ve mikrokalsifikasyonlar, süt bezleri yoğun olan (glandüler yapıda) bir memenin mamogramındansa, yağlı bir memenin mamogramında daha kolay ayırt edilebilmektedir. Bu tez çalışmasında oluşturulan veri tabanındaki görüntüler her iki türden dokuya sahip örnekler içerdiğinden, bölütleme aşamasında baz alınan tek bir ortalama eşik değeri yerine, her bir görüntü için ayrı ayrı hesaplanan eşik değerler kullanılması durumunda hatanın daha da düşeceği muhtemeldir.

5.1 Öneriler

Sınıflandırma safhasında kullanılan yapay sinir ağının çıkışları, giriş görüntüsünün entropi değerlerine göre, habis ya da selim olarak tasarlanmıştır. Ancak çıkış bilgisi habis kararı verilen bir görüntüde, tümör veya mikrokalsifikasyonların lokasyonu hakkında bir bilgilendirme yapılmamaktadır. Bu bilgilendirmenin de yapılabilmesi için bu çalışmaya ek olarak matematiksel morfoloji uygulamaları ile alan belirleme yapılabilir. Bir başka yöntem olarak bulanık sınıflandırıcılar, mamogramlar üzerinde kitle tespitinde kullanılabilir.

Görüntüdeki anormal dokuların tespit aşamasında, görüntüdeki bölgelerin yoğunluk değerleri de baz alınarak bölgeleri yoğunluk bilgilerine göre ayırmak mümkün olabilir. Belirgin olmayan kitle sınırlarından dolayı farklı gölgelerdeki piksel değerlerine ise bulanık küme ilkeleri uygulanarak mamografi görüntüsü iyileştirildikten sonra, özellik çıkarma ve sınıflama sürecine tabi tutulması ile doğru karar verme başarımı artırılabilir. Başarımı artırmanın bir diğer yolu ise veri kümesindeki örnek sayısının çoğaltılması ile olasıdır.

KAYNAKLAR

1. **Younesi, F., Alam, N.R., Zoroofi, R.A., Ahmadian, A. and Guiti, M.,** 2007. Engineering in Medicine and Biology Society, *29th Annual International Conference of the IEEE*, 22-26 Augustus 2007, p. 5638 - 5640a.
2. **Curtis, M.,** 1999. *Global Breast Cancer Mortality Statistics*, May-July 1999, 140.
3. **Tuncer, A.M.,** 2004, *T.C. Sağlık Bakanlığı Kanseri Savaş Dairesi Başkanlığı Kadınlarda Meme Kanseri Taramaları İçin Ulusal Standartlar*, Ankara.
4. **Kitamura, Y., Ohno, Y., Kasahara, S., Murata, K., Sugiyama, H., Oshima, A., Tsukuma, H., Ajiki, W. and Hasegawa, T.,** 2005. Statistical estimation of the number of breast cancer patients with disabilities resulting from surgery. *Breast cancer* 2005;12:130-134. PMID: 15858444.
5. **Bassett, LW, Manjikian V.,** 1990. Mammography and breast cancer screening. *Surg Clin North Am*, 70:775-800. (PMID: 2196705).
6. **Balcı, P., Güneş, N., Koçdor, M.A., Erkan, N., Seçil, M. ve Dicle, O.,** 1997. Nonpalpabl kitle lezyonlarında preoperatif lokalizasyon sonuçları: Lezyonların Mamografik Analizi, *Meme Hastalıkları Dergisi*, **4**, 123-127.
7. **Heywang, H., Köbrunner, S., Schreer, I., Dershaw, D.,** 1997. Diagnostic Breast Imaging, *Thieme Medical Publishers*.
8. **Chan, H., Doi, K., Galhotra, S., Vyborny, C.J., MacMahon, H., Jokich P.,** 1987. Image features analysis and computer-aided diagnosis in digital radiography, I. Automated dedection of microcalcifications in mammography, *Medical Physics*, **14**, 538-547.
9. **Cihan, İ.K.,** 2002, Topolojik Ortanca Yöntemi ile Mammogramlarda Kanseri Teşhisi, Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
10. **McLeod, G., Parkin, G.,** 1996. Automatic detection of clustered microcalcifications using wavelets, *Third International Workshop on Digital Mammography*, Chicago.
11. **Brake, G.M., Karssemeijer, N. and Hendriks, J.H.C.L.,** 2000. Automatic Method to Discriminate Malignant Masses from Normal Tissue in Digital Mammograms, *Phys. Med. Biol.*, **45**, 2000.
12. **Groshong, B.R., Kegelmeier, W.P.,** 1976. Evaluation of a Hough Transform Method for Circumscribed Lesion Detection, *Digital Mammography*, Elsevier.

13. **Highnam, R., Brady, M., Shepstone, B.,** 1976. A Representation for Mammographic Image Representation, *Dig.Mammography*.
14. **Bovis, K., Singh, S.,** 2002. Classification of mammographic breast density using a combined classifier paradigm, *Int.Work. on Dig. Mammography*.
15. **Lai, S.M., Li, X., Bischof, B.F.,** 1989. On Techniques for Detecting Circumscribed Masses in Mammograms, *IEEE Trans. On Med. Image*, **8**.
16. **Mencattini, A., Rabottino, G., Salmeri, M., Caselli, F., Lojacono, R.,** 2008. Features Extraction for Microcalcification Clusters Classification in Digital Mammograms, *IMEKO*.
17. **Ng, S.L., Bischof, W.F.,** 1992. Automated Detection and Classification of Breast Tumors, *Comput. Biomed. Res.*, **25**.
18. **Petroudi, S., Brady, M.,** 2006. Breast Density Dependent Computer Aided Detection, *LNCS*, **4046**.
19. **Zwiggelaar, R., Blot, L., Raba, D. and Denton, E.R.E.,** 2003. Set Permutation-Occurrence Matrix Based Texture Segmentation, *Conf. On Patt. Rec. And Image Anal*.
20. **Petroudi, S., Kadir, T., Brady, M.,** 2003. Automatic Classification of Mammographic Parenchymal Patterns: A Statistical Approach, *IEEE Conf. Eng. Med. Biol. Soc.*, **2**.
21. **Sheshadri, H.S., Kandaswamy, A.,** 2006. Breast Tissue Classification Using Statistical Feature Extraction of Mammograms, *Med. Imag. and Info. Sci.*, **23**.
22. **Swiniarski, R., Skowron, A.,** 2003. Rough Sets Methods in Feature Selection and Recognition, *Pattern Recognition Letters*, **24(6)**.
23. **Sahiner, B., Chan, H.P., Petrick, N., Wei, D., Helvie, M.A., Adler, D.D., Goodsit, M.M.,** 1996. Classification of Mass and Normal Tissue: A convolution Neural Network Classifier with Spatial Domain and Texture Images, *IEEE Trans.Med. Image*, **15**.
24. **Tromans, C., Brady, M.,** 2006. An Alternative Approach To Measuring Volumetric Mammographic Breast Density, *LNCS*, **4046**.
25. **Wolfe, J.N.,** 1976. Risk for Breast Cancer Development Determined by Mammographic Parenchymal Pattern, *Cancer*, **37**.
26. **Li, H.D., Kallergi, M., Clarke, L.P., Jain, V.K., Clark, R.A.,** 1995. Markov Random Field for Tumor Detection in Digital Mammography, *IEEE Transactions on Medical Imaging*, **14**, 565-576.

27. Lefebvre, F., Benali, H., Gilles, R., Kahn, E., Di Paola, R. 1995. A Fractal Approach to the Segmentation of Microcalcifications in Digital Mammograms, *Medical Physics*, **22**, 381-390.
28. Patrick, N., Chan, H.P., Sahiner, B., Wei, D., 1996. An Adaptive Density-Weighted Contrast Enhancement Filter for Mammographic Breast Mass Detection, *IEEE Transactions on Medical Imaging*, **15**, 59-67.
29. H. Li, H. Wang, Y., Liu, K.J.R., Lo, S.C.B., Freedman, M.T., 2001. Computerized Radiographic Mass Detection - Part I: Lesion Site Selection by Morphological Enhancement and Contextual Segmentation, *IEEE Transactions on Medical Imaging*, **20**, 289-301.
30. Ertaş, G., Gülçür, H.Ö., 2001. Yoğun Mamografi Görüntülerinin Asimetri Değeri İle Tespiti, 9. Sinyal İşleme ve Uygulamaları (SİU) Kurultayı, **200-206**, KKTC..
31. Zhang, P., Verma, B., Kumar, K., 2005. Neural vs. Statistical Classifier in Conjunction with Genetic Algorithm Based Feature Selection, *Pattern Recognition Letters*, **26**, 909-919.
32. Wu, Y., Giger, M.I., Doi, K., Vyborny, Cj., Schmidt, Ra., Metz, Ce., 1993. Artificial Neural Networks in Mammography: Application to Decision Making in The Diagnosis of Breast Cancer, *Radiology*, **187**, 81-87.
33. www.gata.edu.tr/cerrahibilimler/kadindogum/sss/meme7.html, 10 Nisan 2008.
34. www.adnanisgor.com/genelkanser5genetiketmenmetin.html, Kanser Hastalığına Genel Bakış, 20 Nisan 2008.
35. Heywang-Köbrunner, S.H., Schreer, I., Dershaw, D.D., 1997. Diagnostic Breast Imaging, *Thieme*.
36. Friedrich, M., Sickles, E.A., 1997. Radiological Diagnosis of Breast, *Springer*.
37. Ng, K.H., Looi, L.M., Bradley, D.A., 1996. Microcalcification clustering parameters in breast disease: a morphometric analysis of radiographs of excision specimen, *Br J Radiol*, **69(820)**, 326-334.
38. www.baskent.edu.tr/~ihaberal/lb/son/jinekoloji_mamografi.php?lk=2 , 17 Nisan 2008.
39. A survey of preprocessing and feature extraction techniques for radiographic images, 1971. *IEEE Trans. Comput.*, **C20**, 1032-1044.
40. Kobatake, H., Murakami, M., Takeo, H., Nawano, S., 1999. Computerized detection of malignancy tumors on digital mammograms, *IEEE Trans. Med. Imag.*, **18**, 396-378.

41. **Turkoğlu, İ.**, 2002. Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, *Doktora Tezi*, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
42. **Toraman, S.**, 2006. Histopatolojik İmgelerin Değerlendirilmesinde Örüntü Tanıma Temelli Karar Destek Sistemleri, *Yüksek Lisans Tezi*, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
43. **Gonzales, R. C., Woods, R. E.**, 2001. Digital Images Processing, *Prentical Hall*.
44. **Şengür, A.**, 2004. Sayısal Görüntü Bölütleme Teknikleri ve Uygulamaları, *Doktora Tezi*, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
45. **Giger, M.L.**, 1993. Syllabus: 79th Scientific Assembly of the Radiological Society of North America, *Computer aided diagnosis*, s. 283-298.
46. **Li, X.**, 2000. Edge directed statistical inference with applications to image processing, *Doktora Tezi*, Princeton Üniversitesi.
47. **Cihan, İ. K.**, 2002. Topolojik Ortanca Yöntemi ile Mammogramlarda Kanser Teşhisi, Topolojik Ortanca Yöntemi ile Mamogramlarda Kanser Teşhisi, Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
48. **Shannon, C.E.**, 1948. A mathematical theory of communication, *Bell System Technology Journal*, **27**, 379-423.
49. **AVI, E.**, 2005. Akıllı Radar ile Hedef Tanıma Sistemi, *Doktora Tezi*, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
50. **Türkoğlu, İ., Hanbay, D.**, 2001. Yapay Sinir Ağı ve HFD Kullanarak DTMF Sinyal Örüntülerini Tanıma Sistemi, Elektrik - Elektronik – Bilgisayar Mühendisliği 9. Ulusal Kongresi, 431-434, Kocaeli.
51. **Kil, D.H., Shin, F.B.**, 1996. Pattern Recognition and Prediction with Applications to Signal Characterization, *AIP Press*, USA, 417.
52. **Principe, J.C., Euliano, N.R., Lefebvre, W.C.**, 2000. Neural and Adaptive Systems. John Wiley & Sons, New York.
53. **Şengür, A., Türkoğlu, İ., İnce, M.C.**, 2005. Eğiticişiz Yapay Sinir Ağları ile Görüntü Bölütleme Uygulamaları, *IEEE 13. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, 271-274, Kayseri..
54. **Türkoğlu, İ.**, 1996. Yapay Sinir Ağları İle Nesne Tanıma, *Y. Lisans Tezi*, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.

55. www.sagliknet.saglik.gov.tr/portal_pages/notlogin/saglikcilar/saglikcilar_kds_nedir.htm, Karar Destek Sistemi Nedir, 01 Kasım 2009.

ÖZGEÇMİŞ

Esmâ KARABULUT

Fırat Üniversitesi
Teknik Eğitim Fakültesi
Elektronik ve Bilgisayar Eğitimi Bölümü
23119, Elazığ
E-posta : esmakar@hotmail.com

- 1979** Elazığ’da doğdu.
- 1989 – 1996** Elazığ Anadolu Lisesi’nden mezun oldu.
- 1996 – 2000** Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Eğitimi, Bilgisayar Öğretmenliği Bölümünden mezun oldu.
- 2000 – 2004** İstanbul – Etiler Rüştü Akın Anadolu Meslek Lisesi’nde Bilgisayar Öğretmeni olarak çalıştı
- 2004 – ...** İstanbul-Çapa Anadolu Öğretmen Lisesi’nde Bilgisayar Öğretmeni olarak halen çalışmaktadır