




**T.C.**

**SELÇUK ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

# GÖRÜNTÜ ZENGİNLEŞTİRME VE HÜCRESEL YSA KULLANARAK MEME KANSERİ TEŞHİSİ

**Levent CİVCİK**

**DOKTORA TEZİ**

**Elektrik-Elektronik Müh. Anabilim Dalı**

**Ekim-2013**
**KONYA**
**Her Hakkı Saklıdır**

# ÖZET

## DOKTORA TEZİ

## GÖRÜNTÜ ZENGİNLEŞTİRME VE HÜCRESEL YSA KULLANARAK MEME KANSERİ TEŞHİSİ

**Levent CİVCİK**

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü**
**Elektrik-Elektronik Müh. Anabilim Dalı**

**Danışman: Doç. Dr. Yüksel ÖZBAY**

**2013, 154 Sayfa**

**Jüri**
**Doç. Dr. Yüksel ÖZBAY**
**Doç. Dr. Halis ALTUN**
**Doç. Dr. Salih GÜNEŞ**
**Doç. Dr. Ganime Dilek EMLİK**
**Yrd. Doç. Dr. Murat CEYLAN**

Meme kanseri dünya genelinde yaygın bir sorundur. Türkiye'de meme kanseri her 8-10 kadından birisinde görülmekte ve Türk kadınları arasında akciğer kanserinden sonra ölüme neden olma açısından ikinci sırada yer almaktadır. Meme kanserinin en önemli belirtisi memede oluşan mikrokalsifikasyonlardır. Bununla beraber memede görünen kitlelerin benign (iyi huylu) veya malign (kötü huylu) olmasına göre sınıflandırılabilmesi hastalığın tedavisinde önemli bir rol oynamaktadır.

Meme kanserini belirlemede çeşitli görüntüleme yöntemleri kullanılmaktadır. Mamografi, bu görüntüleme yöntemleri içinde en yaygın ve ucuz olanıdır. Fakat başarı yüzdesi uzman doktorun tecrübe ve dikkatine bağlıdır. Kadınlarda meme kanseri vakalarının erken teşhisi için mamogram görüntülerindeki mikrokalsifikasyonların ve kitlelerin sınıflandırılmasında, uzmanlara yardımcı olacak bir karar destek sistemi geliştirilmesi bu tez çalışmasında hedeflenmiştir.

Geliştirilen Karar Destek Sistemi, ön işlem, güçlendirme, bölütleme ve sınıflandırma aşamalarından oluşmaktadır. Ön işlem adımında sayısal veya sayısallaştırılmış mamogram görüntüleri üzerinde görüntü boyutunun ayarlanması işlemi yapılmıştır. Daha sonra görüntü üzerinde gri formata dönüştürme, görüntü netleştirme işlemi uygulanmıştır. Güçlendirme aşamasında, mamogram görüntüleri için yeni geliştirilen Otomatik Kitle Yoğunluğunun Güçlendirilmesi (ALIE) algoritması uygulanmıştır. Bu algoritma histogram temellidir ve mamogram görüntülerindeki arka planın yoğunluk seviyesini düşürürken, anormal bölgelerin yoğunluk seviyesini güçlendirmektedir. Güçlendirme işleminde mamogram görüntüsündeki pektoral kas ve etiketli bölgelerin görüntüden çıkarımı opsiyoneldir. Bölütleme adımında, genetik algoritma ile eğitilmiş Hücresel Yapay Sinir Ağları (HYSA) kullanılarak mikrokalsifikasyon ve tümörler belirlenmiştir. HYSA'nın parametrelerinin belirlenmesi işleminde Genetik Algoritma için uygunluk fonksiyonu olarak korelasyon fonksiyonu kullanılmıştır. Sınıflandırma aşamasında, kitleleri ve mikrokalsifikasyonları belirlemek için görüntüler üzerinde şekil analizi kullanılarak sınıflandırma yapılmıştır. Mikrokalsifikasyon taneciklerinin ve kitlelerin mamogram görüntüleri üzerinde belirlenmesi amacıyla şekil analizine dayalı bir sınıflandırma fonksiyonu kullanılmıştır.

Tez çalışmasında geliştirilen Karar Destek Sistemi, MIAS (The Mammography Image Analysis Society) veri tabanındaki etiketlenmiş 100 adet mamogram görüntü ve Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji anabilim dalından 84 hastadan alınan etiketlenmiş, 286 adet mamogram görüntüden oluşan veri seti kullanılarak test edilmiştir. Geliştirilen Karar Destek Sistemi hastane verilerinden alınan 261 mamogram görüntünün 238'ini doğru, 23'ünü yanlış sınıflandırarak %93.1 duyarlılık ve %91.3 doğruluk değerine, MIAS verilerinden alınan 100 mamogram görüntünün 82'sini doğru, 18'ini yanlış sınıflandırarak %91.0 duyarlılık ve %82.0 doğruluk değerine ulaşmıştır. Hastane verilerinden 25 mamogram (261 mamogram görüntüden farklı) görüntü üzerinde, geliştirilen Karar Destek Sistemi ve uzman radyoloğun sınıflandırma değerlendirmesi yapılmıştır. Karar Destek Sistemi hastane verilerinden alınan 25 mamogram görüntünün 23'ünü doğru, 2'sini yanlış sınıflandırarak %95.2 duyarlılık ve %92.0 doğruluk değerine ulaşmıştır.

**Anahtar Kelimeler:** Genetik Algoritma (GA), Görüntü Güçlendirme, Hücresel Yapay Sinir Ağı (HYSA), Mamogram, Mikrokalsifikasyon, Otomatik Kitle Yoğunluğunun Güçlendirilmesi (ALIE), Pektoral Kas.

# ABSTRACT

## Ph.D. THESIS

## DIAGNOSIS OF BREAST CANCER USING IMAGE ENHANCEMENT AND CELLULAR NEURAL NETWORKS

**Levent CİVCİK**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE
OF SELÇUK UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN ELECTRICAL-ELECTRONICS ENGINEERING**

**Advisor: Assoc. Prof. Dr. Yüksel ÖZBAY**

**2013, 154 Pages**

**Jury**
**Assoc. Prof. Dr. Yüksel ÖZBAY**
**Assoc. Prof. Dr. Dr. Halis ALTUN**
**Assoc. Prof. Dr. Salih GÜNEŞ**
**Assoc. Prof. Dr. Ganime Dilek EMLİK**
**Assist. Prof. Dr. Murat CEYLAN**

Breast cancer is a common problem in global scale. It is seen in one of every 8 to 10 women in Turkey. Among the Turkish women in top 10 cancers, the incidence of breast cancer ranked second after lung cancer in terms of cause of death. The most important symptom of breast cancer is microcalcifications in breast. However, classification of the masses in breast as malignant or benign plays an important role in the treatment of the disease.

There are various imaging modalities used in determining breast cancer. Mammography is the most common and the cheapest one of these imaging methods. However, the percentage of success depends on the experience and the attention of the attending. This thesis aimed to develop a decision support system for helping early detection of breast cancer among women and classification of microcalcifications and masses in mammogram images.

The Developed Decision Support System consists of pre-processing, enhancement, segmentation and classification stages. Pre-processing step of the algorithm is image size adjustment of digital or digitized images and conversion to the gray image format and image sharpening processes are also applied. In the enhancement stage, the newly developed Automated Lesion Intensity Mammogram Images Enhancer (ALIE) algorithm is applied. This algorithm is based on the histogram analysis and it reduces the intensity level of the background while strengthening the abnormal regions in the mammogram images. In the enhancement process, extraction of the pectoral muscle and the labeled regions from mammogram images is optional. In the Segmentation step microcalcifications and tumors are determined using Cellular Neural Network (CNN) trained with genetic algorithm. In the process of determining the parameters of the CNN's the correlation function is used as the fitness function for Genetic Algorithm. In the Classification phase, a function based on shape analysis of the emphasized images is used to classify the masses and microcalcifications.

In this thesis the developed Decision Support System was tested with a data set consist of 100 mammogram images from MIAS (The Mammography Image Analysis Society), 286 images obtained from 84 patients from the Necmettin Erbakan University, Meram Medical Faculty Department of Radiology. The developed Decision Support System achieved 91.3% accuracy and 93.1% sensitivity rates by classifying 238 correctly and 23 incorrectly of 261 mammogram images obtained from hospital data. It also achieved 82.0% accuracy and 91.0% sensitivity rates by classifying 82 correctly and 18 incorrectly of 100 mammogram images obtained from MIAS database. 25 mammogram images, obtained from hospital database (different than the 261 mammogram images) was classified and evaluated by an expert radiologist and the developed decision support system. The test is performed with an experienced radiologist and the developed Decision Support System achieved 92.0% accuracy and 95.2% sensitivity rates by classifying 23 correctly and 2 incorrectly of 25 mammogram images obtained from hospital data.

**Keywords:** Automated Lesion Intensity Enhancer (ALIE), Cellular Neural Network (CNN), Genetic Algorithm (GA), Image Enhancement, Mammograms, Microcalcification, Pectoral Muscle.

# ÖNSÖZ

Doktora tez çalışmalarım sürecinde, mamogram görüntülerinin değerlendirilmesi ve çalışmanın yönlendirilmesinde yardımlarını esirgemeyen Doç. Dr. Ganime Dilek EMLİK'e, bilgi ve deneyimlerini benimle paylaşan danışmanım Doç. Dr. Yüksel ÖZBAY'a, yardımlarından dolayı Burak YILMAZ'a teşekkür ederim.

Tez süresince sonsuz bir sabırla her türlü desteklerini esirgemeyen eşime ve çocuklarıma teşekkür ederim.

Levent CİVCİK
KONYA-2013

## İÇİNDEKİLER

**ÖZET** ..... **i**

**ABSTRACT** ..... **iii**

**ÖNSÖZ** ..... **v**

**İÇİNDEKİLER** ..... **vi**

**SİMGELER VE KISALTMALAR** ..... **ix**

**ŞEKİLLER LİSTESİ** ..... **xi**

**ÇİZELGELER LİSTESİ** ..... **xv**

**1. GİRİŞ** ..... **1**

1.1. Tez Konusunun Tanıtılması ..... 2
1.2. Tezin Amacı ve Önemi ..... 3
1.3. Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi ..... 4

**2. MEME KANSERİ VE MAMOGRAFİ** ..... **8**

2.1. Memenin Anatomisi ..... 8
2.2. Meme Kanseri ..... 11
2.3. Meme Kanserinde Tanı Yöntemleri ..... 12
2.3.1. Fiziki muayene ..... 13
2.3.2. Klinik bulgular ..... 13
2.3.3. Görüntüleme yöntemleri ..... 14
2.3.4. Meme biyopsisi ..... 19
2.4. Meme Kanserinde Evrelendirme ..... 21

**3. MİKROKALSİFİKASYONLAR** ..... **26**

**4. UYGULANAN YAPAY ZEKA TEKNİKLERİ** ..... **33**

4.1. Hücresel Yapay Sinir Ağları (HYSA) ..... 33
4.1.1. HYSA mimarisi ..... 33
4.1.2. Hücresel yapay sinir ağlarında komşuluk ilişkisi ..... 35
4.1.3. Hücresel yapay sinir ağlarında konvolüsyon ilişkisi ..... 36
4.1.4. Hücresel yapay sinir ağlarının devresel gösterimi ..... 38
4.1.5. Hücresel yapay sinir ağlarında öğrenme ..... 40
4.1.6. RPLA öğrenme algoritması ..... 41
4.1.7. Hücresel yapay sinir ağlarında kararlılık ..... 45
4.1.8. Hücresel yapay sinir ağlarının sürekli zaman analizi ..... 46
4.2. Genetik Algoritmalar ..... 47
4.2.1. Başlangıç popülasyonunun belirlenmesi ..... 50
4.2.2. Uygunluk değerlerinin bulunması ..... 50
4.2.3. Seçim ..... 50
4.2.4. Çaprazlama ..... 52
4.2.5. Mutasyon ..... 53

**5. MAMOGRAM ÜZERİNDE GÖRÜNTÜ İŞLEME TEKNİKLERİ ..... 54**

5.1. Görüntü İyileştirme ..... 54
5.1.1. Parlaklık ..... 55
5.1.2. Karşıtlık ..... 55
5.1.3. Eşikleme ..... 56
5.1.4. Negatifleştirme ..... 57
5.1.5. Piksel komşuluk işlemleri ..... 58
5.2. Kenar Bulma ..... 59
5.2.1. Gradyan tabanlı kenar belirleme algoritmaları ..... 60
5.2.2. Laplacian tabanlı kenar belirleme algoritmaları ..... 62
5.2.3. Canny kenar belirleme algoritması ..... 63
5.3. Süzgeçleme İşlemleri ..... 65
5.3.1. Ortanca süzgeçleme ..... 65
5.3.2. Gauss bulanıklık algoritması ..... 67
5.4. Histogram ..... 69
5.5. Mamogram Görüntülerinin Güçlendirilmesi ..... 70
5.5.1. CLAHE (Contrast Limited Adaptive Histogram Equalization) ..... 71
5.5.2. HE (Histogram Equalization) ..... 75
5.5.3. US (Unsharp Mask) ..... 76

**6. MAMOGRAM GÖRÜNTÜLERİ İÇİN GELİŞTİRİLEN KARAR DESTEK SİSTEMİ ..... 78**

6.1. Tez Çalışmasında Kullanılan Veri Setleri ..... 79
6.1.1. MIAS veri seti ..... 79
6.1.2. Hastaneden alınan veri seti ..... 81
6.2. Mamogram Görüntüleri İçin Geliştirilen Karar Destek Sistemin Yapısı ..... 83
6.2.1. Ön işlem aşaması ..... 85
6.2.2. Pektoral kas ve etiketli bölgelerin çıkarılması ..... 86
6.2.3. Mamogram görüntülerinde mikrokalsifikasyon ve kitlelerin bölütlenmesi ..... 94
6.2.4. Mamogram görüntülerinde mikrokalsifikasyon ve kitlelerin sınıflandırılması . 100
6.3. Sınıflandırma Performanslarının Değerlendirilmesi ..... 111
6.4. Karar Destek Sistemi İçin Geliştirilen Programlar ..... 117
6.4.1. HYSA parametrelerinin belirlenmesi için geliştirilen program ..... 117
6.4.2. Lezyonları belirlemek ve sınıflandırmak için geliştirilen program ..... 120

**7. MAMOGRAM GÖRÜNTÜLERİNİN GÜÇLENDİRİLMESİ ..... 122**

7.1. Görüntü Güçlendirme ..... 122
7.1.1.Uzaysal yöntemler ..... 123
7.1.2.Dönüşüm yöntemleri ..... 125
7.2 Mamogram Görüntülerinde Kitle Yoğunluğunun Otomatik Olarak Güçlendirilmesi……..126

**8. SONUÇLAR ve ÖNERİLER ..... 138**

8.1. Sonuçlar ..... 138
8.2. Öneriler ..... 142

**KAYNAKLAR** ..... **143**

**EKLER** ..... **153**

**ÖZGEÇMİŞ** ..... **154**

## SİMGELER ve KISALTMALAR LİSTESİ

| | |
|---|---|
| ACS: | Amerikan Kanser Derneği |
| KETEM: | Kanser Erken Teşhis-Tarama ve Eğitim Merkezi |
| MR: | Manyetik Rezonans |
| PET: | Positron Emission Tomography |
| CT: | Computed Tomography |
| ROI: | Region of Interest Processing |
| MRF: | Markov Random Field |
| YSA: | Yapay Sinir Ağı |
| EP: | Evolutionary Programlama |
| PNN: | Probabilistic Neural Networks |
| BPNN: | Back Propagation Neural Networks |
| GA: | Genetik Algoritma |
| NPSO: | New Particle Swarm Optimizasyon |
| CLA: | Renkli Etiketleme Algoritması |
| DVM: | Destek Vektör Makinesi |
| CC: | Cranial-Caudal |
| MLO: | Medio Lateral-Oblique |
| LM: | Latero medial |
| ML: | Medio lateral |
| BI-RADS: | Breast Imaging and Reporting Data Systems |
| US: | Ultrasonografi |
| UICC: | Union International Contre leCancer |
| AJCC: | American Joint Committee on Cancer |
| LCIS: | Lobüler carcinoma in situ |
| DCIS: | Ductal carcinoma in situ |
| ACR: | The American College of Radiology |
| $\mu_A$: | $A$ bulanık kümesi için üyelik fonksiyonu |
| HYSA: | Hücresel Yapay Sinir Ağları |
| RPLA: | Recurrent Perceptron Learning Algorithm |
| $\varepsilon[w]$: | Hata Fonksiyonu |
| w : | Ağırlık Katsayıları Vektörü |
| EC: | Evrimsel Hesaplama |

| | |
|---|---|
| GP: | Genetik Programlama |
| EP: | Evrimsel Programlama |
| EV: | Evrimsel Strateji |
| LoG: | Laplacian of Gaussian |
| $\sigma$: | Gaussian Standart Sapması |
| $p(r_k)$: | $r_k$'nın meydana gelme olasılığı |
| CLAHE: | Contrast Limited Adaptive Histogram Equalization |
| HE: | Histogram Equalization |
| US: | Unsharp Mask |
| LHE: | Local Histogram Equalization |
| AHE: | Adaptive Histogram Equalization |
| KDS: | Karar Destek Sistemi |
| ALIE: | Automated Lesion Intensity Enhancer |
| MIAS: | The Mammography Image Analysis Society |
| RGB: | Red Green Blue |
| CNN: | Cellular Neural Networks |
| EME: | Enhancement Measure |
| AMBE: | Absolute Mean Brightness Error |
| UIQI: | Universal Image Quality Index |
| ROC: | Receiver Operating Characteristic Curve |
| DP: | Doğru Pozitif |
| DN: | Doğru Negatif |
| YP: | Yanlış Pozitif |
| YN: | Yanlış Negatif |

# ŞEKİLLER LİSTESİ


Şekil 2.1. Meme dokusunun tabakaları …… 8

Şekil 2.2 Memenin anatomisi…… 9

Şekil 2.3. Meme kadranları…… 10

Şekil 2.4. Lenfatikler…… 11

Şekil 2.5. Meme kanserinin elle muayenesi…….. 13

Şekil 2.6. Mamografi çekim işlemi…… 16

Şekil 2.7. (a) Normal bir mamografi (b) Mikrokalsifikasyon kümecikleri içeren bir mamografi…… 16

Şekil 2.8. Eksizyonal biyopsi…… 20

Şekil 2.9. Sentinel lenf nod biyopsisi…… 20

Şekil 2.10. Basit mastektomi……. 21

Şekil 2.11. Evre 0 - ductal carcinoma in situ kanser hücreleri……..... 24

Şekil 2.12. Kanserin kanal dışına sıçraması ve yakındaki meme dokusuna yayılması …….. 24

Şekil 2.13. Meme kanserinin evreleri…… 25

Şekil 3.1. Grup oluşturan, ince çizgisel dallanma gösteren kalsifikasyonlar …….. 26

Şekil 3.2. Kanama ve fibrozis alanları içerisinde kistik genişlemiş meme duktusları yanında Liesegang ring tipi kalsifikasyonlar (H.E. x 100) ……..…….. 28

Şekil 3.3. Apokrin metaplazi gösteren duktus yapıları içerisinde çok sayıda Liesegang ring tipi kalsifikasyonlar (H.E. x 200) ……..…… 28

Şekil 3.4. (a) Belirsiz (Amorf) kalsifikasyonlar (b) Heterojen (granüler) kalsifikasyonlar (c) Dallanma gösteren (casting) kalsifikasyonlar (d) Bening kalsifikasyonlar …… 32

Şekil 4.1. 4x4 Boyutunda bir hücresel yapay sinir ağı gösterimi……..…..…… 34

Şekil 4.2. Bir hücrenin dinamik yapısı……... 34

Şekil 4.3. Hücresel yapay sinir ağlarında (HYSA) r=1, r=2, r=3 komşuluğu için hücre ilişkileri ……. 35

Şekil 4.4. Bir hücre yapısının devresel olarak gösterilmesi ……. 38

Şekil 4.5. Parça-parça doğrusal çıkış karakteristiği……..……..…….…… 39

Şekil 4.6. Genetik algoritma akış diyagramı yapısı……..……...…… 49

Şekil 5.1. (a) Orijinal mamogram görüntüsü (b) b=-80 değeri almış mamogram görüntüsü (c) b=80 değeri almış mamogram görüntüsü ……..……..... 55

Şekil 5.2. (a) Orijinal mamogram görüntüsü (b) a=-45 değeri almış mamogram görüntüsü (c) a=95 değeri almış mamogram görüntüsü …….…. 56

Şekil 5.3. (a) Orijinal mamogram görüntüsü (b) Eşik değeri =85 belirlenmiş mamogram görüntüsü (c) Eşik değeri =190 belirlenmiş mamogram görüntüsü ……..…….. 57

Şekil 5.4. (a) Orijinal mamogram görüntüsü (b) Negatifleştirilmiş mamogram görüntüsü…. 58

Şekil 5.5. Görüntü üzerinde konvolüsyon işlemi……..……. 59

Şekil 5.6. Gradyan tabanlı kenar belirleme operatörleri (a) Roberts operatörleri (b) Prewitt operatörleri (c) Sobel operatörleri …… 61

Şekil 5.7. Laplacian maskeleri……...……...…… 62

Şekil 5.8. LoG maskeleri……...…… 63

Şekil 5.9.(a) Orijinal mamogram görüntüsü (b) Ortanca süzgeçleme uygulanmış mamogram görüntüsü…….……..…… 67

Şekil 5.10 $\sigma = 1$için gauss fonksiyonu……..……...……. 68

Şekil 5.11. (a) Orijinal mamogram görüntüsü (b) Gauss bulanıklık algoritması uygulanmış mamogram görüntüsü…….……...… 68

Şekil 5.12. (a) Orijinal mamogram görüntüsü (b) Mamogram görüntüsünün histogramı…….…..……. 69

Şekil 5.13. (a) Orijinal histogram (b) Kırpılmış histogram……... 73

Şekil 5.14. (a) H6.4_BR5 nolu ham görüntü (b) CLAHE algoritması ile güçlendirilmiş H6.4_BR5 nolu görüntü……..…….……..…..... 74

Şekil 5.15. (a) H6.4_BR5 nolu ham görüntü (b) HE algoritması ile güçlendirilmiş H6.4_BR5 nolu görüntü……..……...…… 76

Şekil 5.16. (a) H6.4_BR5 nolu ham görüntü (b) US algoritması ile güçlendirilmiş H6.4_BR5 nolu görüntü…….…… 77

Şekil 6.1. Hastane veri tabanından seçilen BI-RADS sınıflandırması yapılmış bazı mamogram görüntüleri (a) H1.1_BR1 indeksli görüntü (b) H1.4_BR1 indeksli görüntü (c) H13.2_BR2 indeksli görüntü (d) H4.4_BR3 indeksli görüntü (e) H9.2_BR3 indeksli görüntü (f) H19.3_BR4 indeksli görüntü (g) H17.2_BR4 indeksli görüntü (h) H3.3_BR5 indeksli görüntü (i) H5.2_BR5 indeksli görüntü……. 82

Şekil 6.2. Mamogram görüntüleri için geliştirilen Karar Destek Sisteminin (KDS) blok şeması …….. 84

Şekil 6.3. Ön işlem aşamasının blok diyagramı ……...…… 85

Şekil 6.4. (a) 2400 x 3000 piksel çözünürlüğünde H3.1_BR4 indeksli ham görüntü (b) 512 x 512 piksel çözünürlüğüne düşürülmüş, gri formatlı ve netleştirilme işlemi uygulanmış H3.1_BR4 indeksli görüntü ……..…… 86

Şekil 6.5. (a) 2400 x 3000 piksel çözünürlüğünde pektoral kas bölgesine sahip olmayan, etiketli H2.8_BR2 indeksli görüntü (b) 2400 x 3000 piksel çözünürlüğünde pektoral kas bölgesine sahip, etiketli H17.2_BR1 indeksli görüntü..……..…… 87

Şekil 6.6. (a) MIAS mdb231 nolu orijinal mamogram görüntüsü (b) MIAS mdb231 nolu orijinal mamogram görüntüsünün histogramı ..…….…… 88

Şekil 6.7. Pektoral kas ve istenmeyen etiketli bölgelerin mamogram görüntüsünden çıkarılmasının akış şeması ……..... 90

Şekil 6.8. (a) mdb210 nolu mamogram görüntüsü (b) Etiketli bölgeleri çıkarmak için oluşturulan maske (c) Etiketli bölgeleri çıkarılmış mdb210 nolu mamogram görüntüsü (d) Pektoral kas bölgesinin ikili kodlu maskesi (e) Etiketli bölgeleri ve pektoral kas bölgesi çıkarılmış mdb210 nolu mamogram …….…… 91

Şekil 6.9. Mamogram görüntülerinden HYSA algoritması kullanılarak etiketli bölgelerin ve pektoral kas bölgesinin çıkarılma işleminin blok yapısı ……..…… 93

Şekil 6.10. HYSA parametrelerinin kromozom yapısının vektör formunda gösterimi..... 96

Şekil 6.11. Eğitim için kullanılan giriş görüntü seti ……...…..…… 97

Şekil 6.12. Eğitim için kullanılan çıkış görüntü seti…….……. 98

Şekil 6.13. HYSA parametrelerinin eğitilmesi için kullanılan genetik algoritmanın akış diyagramı ……..……...……. 99

Şekil 6.14. Memede rastlanan tümör çeşitlerinin modelleri (a) Round (b) Oval (c) Lobulated (d) Irregular (e) Architectural Distortion (f) Circumscribed (g) Obscured (h) Micro-lobulated (ı) ill-defined (i) Spiculated ……..…….……. 101

Şekil 6.15. (a) Spiculated tipi tümör (b) Architectural Distortion tipi tümör (Heath ve ark., 2000)…….……. 102

Şekil 6.16. Kitlenin şekil analizi açısından örneklenmesi……...……..…… 103

Şekil 6.17. Bir mamogram görüntünün güçlendirme, bölütleme ve sınıflandırma işleminin blok yapısı……...…….…….. 110

Şekil 6.18. Hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin radyolog tarafından sınıflandırılması…… 114

Şekil 6.19. Hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin geliştirilen KDS yapısı ile sınıflandırılması.. 114

Şekil 6.20. HYSA parametrelerinin belirlenmesi için geliştirilen programın arayüzü …… 119

Şekil 6.21. Lezyonları belirlemek ve sınıflandırmak için geliştirilen programın ara yüzü….. 121

Şekil 7.1. Kontrast ayarlama yöntemi kullanarak görüntü güçlendirme (a) Orjinal görüntü (b) Tanımlanan haritalama (c) Güçlendirilmiş görüntü …….. 124

Şekil 7.2. ALIE güçlendirme algoritmasının akış şeması .....……..... 129

Şekil 7.3. (a) Original mdb222 nolu mamogram görüntüsü (b) Mikrokalsifikasyonlu bölgenin görüntüsü (c) Algoritma sonucu elde edilen mikrokalsifikasyonlu bölgenin görüntüsü ……. 131

Şekil 7.4. (a) Kaynak görüntünün histogramı (b) ALIE güçlendirme algoritması uygulandıktan sonra elde edilen görüntünün histogramı ……...…...…… 131

Şekil 7.5. ALIE, CLAHE, HE ve US güçlendirme algoritmalarının arasındaki ve Radyologların ALIE güçlendirme algoritması ile güçlendirilen MIAS görüntülerini değerlendirmedeki performanslarının ROC eğrileri ..... 137

# ÇİZELGELER LİSTESİ


Çizelge 2.1. BIRADS sınıflaması ..... 17

Çizelge 2.2. Meme kanserinde klinik TNM evrelemesi ..... 22

Çizelge 3.1. BI-RADS kriterlerine göre mikrokalsifikasyonların şekilleri ..... 30

Çizelge 3.2. BI-RADS kriterlerine göre mikrokalsifikasyonların dağılımları ..... 31

Çizelge 3.3. BI-RADS sınıflandırmasına göre mikrokalsifikasyonlara eşlik eden bulgular..... 31

Çizelge 3.4. BI-RADS sonuç kategorileri..... 31

Çizelge 4.1. Kromozomların uygunluk değerlerine göre sıralanışı..... 51

Çizelge 6.1. MIAS veri tabanı ..... 80

Çizelge 6.2. Mamogram görüntülerindeki BI-RADS sınıflandırması..... 81

Çizelge 6.3. Hastane veri tabanındaki bazı görüntülerden elde edilen şekil ve doku analizi parametrelerine ait değerler (piksel cinsinden) ..... 107

Çizelge 6.4. MIAS veri tabanındaki bazı görüntülerden elde edilen şekil ve doku analizi parametrelerine ait değerler (piksel cinsinden)..... 108

Çizelge 6.5. Sınıflayıcılar için karmaşıklık matrisi..... 111

Çizelge 6.6. Geliştirilen KDS yapısı ile uzman bir Radyoloğun hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması ..... 113

Çizelge 6.7. Geliştirilen KDS yapısının hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntüleri sınıflandırmadaki performans karşılaştırılması ..... 116

Çizelge 6.8. Geliştirilen KDS yapısının MIAS veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntüleri sınıflandırmadaki performans karşılaştırılması ..... 117

Çizelge 7.1. Geliştirilen ALIE algoritmasının CLAHE, HE ve US algoritmaları ile EME, AMBE ve UIQI performans değerlendirme kriterleri açısından karşılaştırması..... 134

Çizelge 7.2. ALIE algoritmasının EME, AMBE ve UIQI performans kriterleri açısından doku yapısına göre karşılaştırılması..... 135

Çizelge 7.3. Güçlendirme algoritmaları ile Radyologların, mikrokalsifikasyon ve kitleleri sınıflandırma performans karşılaştırması ..... 137

Çizelge 8.1. Hastane veri tabanındaki görüntülerden elde edilen şekil ve doku analizi parametrelerine ait ortalama değerler ……... 140

Çizelge 8.2. MIAS veri tabanındaki görüntülerden elde edilen şekil ve doku analizi parametrelerine ait ortalama değerler ……..…… 140

# 1. GİRİŞ

Meme kanseri dünya genelinde kadınlar arasında en çok görülen (Stewart ve ark., 2004) ve Türkiye'de kadınlarda en sık rastlanan kanser tipidir. Türkiye, kadınlarda meme kanseri insidans (belirli bir nüfusta belirli bir zaman dilimi içerisinde belirli bir hastalık veya hastalıkların yeni olgularının sayısı) hızı orta derecede yüksek olan ülkeler arasındadır (Tuncer, 2007) . Globocan 2002 verilerine göre ülkemizdeki kadınlarda en sık görülme ve en sık ölümlere neden olan kanserler meme, kolorektal (kalın bağırsağın makata yakın son bölümü) ve mide kanseri olarak bildirilmiştir (Eroğlu ve ark., 2010). Dünyada ölüm nedenleri içinde ikinci sırada olan kanser 2030 yılında hızla artarak ölüm nedenleri arasında birinci sıraya yükselmesi öngörülmektedir (Tuncer, 2007).

Dünya Sağlık Örgütü'nün verilerine göre, ortalama 100.000 nüfuslu bir ülkede 1000 veya daha fazla kadın meme kanserinden ölmektedir (Karabulut, 2009). Amerikan Kanser Derneği (ACS)'nin 1991'de yapmış olduğu bir çalışmaya göre, tüm malign (kötü huylu) tanıların %29'unu, ölümlerin ise %16'sını meme kanserinin oluşturduğunu belirlemiştir (Fisher, 1994).

Tüm dünyada olduğu gibi ülkemizde de meme kanseri en önemli sağlık problemlerinden birisidir. Sağlık Bakanlığı ülkemizdeki kanser vakalarındaki artışları, özellikle de meme kanserindeki artışları durdurmak ve koruyucu önlemler alma çalışmalarına hız vermiştir. Ocak 2007 ile Mayıs 2008 tarihleri arasında Konya Eğitim ve Araştırma Hastanesi bünyesinde bulunan Kanser Erken Teşhis Tarama ve Eğitim Merkezi (KETEM), meme kanseri taraması için başvuran 5000 kadın üzerinde geriye dönük oldukça detaylı bir çalışma yapmış, bu çalışmada meme kanseri riskinin hızla arttığı ve meme kanseri vakalarının görülme yaşının düştüğü belirlenmiştir. Orta yaş (45) ve orta yaş altı kadınlarda meme kanseri risk oranı %5.6 olarak belirlenmiştir (Eroğlu ve ark., 2010).

Tez çalışmasında, meme kanserinin en önemli belirtilerinden biri olan mikrokalsifikasyonların belirlenmesi, benign (iyi huylu) ve malign (kötü huylu) nodüllerin sınıflandırılması temel alınmıştır. Tez çalışması 8 bölümden oluşmaktadır.

Birinci bölümde, tez konusunun tanıtımı yapılmış, tezin amacı ve önemi açıklanmıştır. Bu konuda yapılan çalışmaların tarihsel gelişimleri sunulmuştur. İkinci bölümde, meme kanseri ve mamografi hakkında bilgi verilmiştir. Meme kanseri tanı yöntemleri fiziki

muayene, klinik bulgular, mamografi, ultrasonografi ve meme biyopsisi açısından anlatılmıştır. Ayrıca meme kanserinde evrelendirme süreçleri verilmiştir. Üçüncü bölümde mikrokalsifikasyonlar hakkında detaylı bilgiler verilmiş, BI-RADS kriterlerine göre mikrokalsifikasyonların şekilleri, dağılımları ve kategorileri sınıflandırılmıştır. Dördüncü bölümde, mamogram görüntülerine uygulanabilen yapay zekâ tekniklerinden hücresel yapay sinir ağları (HYSA) ve genetik algoritmalar (GA) açıklanmıştır. Beşinci bölümde görüntü işleme tekniklerinin mamogram verileri üzerine uygulanmaları ele alınmıştır. Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji bölümündeki bazı hastalardan alınan görüntülere parlaklık, karşıtlık, eşikleme, negatifleştirme gibi işlemler uygulanmıştır. Altıncı bölümde, mamogram görüntüleri için geliştirilen Karar Destek Sistemi (KDS) verilmiştir. Öncelikle kullanılan veri setleri açıklanmış, ön işlem aşamasından geçirilen görüntülerden pektoral kas ve istenmeyen bölgelerin çıkarılması adım adım anlatılmıştır. Mamogram görüntüleri üzerindeki mikrokalsifikasyon ve kitlelerin belirlenmesi ve sınıflandırması tüm detaylarıyla verilmiştir. Karar destek sistemi (KDS) için geliştirilen programların ara-yüz kullanımı anlatılmıştır. Yedinci bölümde, mikrokalsifikasyon ve kitlelerin daha kolay tespit edilmesi için bu tezde geliştirilen otomatik kitle yoğunluğunun güçlendirilmesi algoritması ALIE'nin (Automated Lesion Intensity Enhancer) pseuedo kodları ve akış şeması verilerek açıklanmıştır. Geliştirilen ALIE algoritmasının CLAHE, HE ve US algoritmaları ile EME, AMBE ve UIQI performans kriterleri açısından karşılaştırması yapılmıştır. Sekizinci bölümde, yapılan çalışmanın sonuçları irdelenmiş, bu sonuçlar üzerinde değerlendirmeler yapılmıştır. İleride yapılabilecek çalışmalarla bu yapıyı geliştirmek için farklı yapay-zeka metotları üzerinde çalışmaların yapılabileceği belirtilmiştir.

### 1.1. Tez Konusunun Tanıtılması

Gerçekleştirilen tez çalışmasında, radyologların meme kanserini belirleme ve kesin tanı koymalarına yardımcı olmak için yeni akıllı bir karar destek sistemi (KDS) tasarlanmıştır. Bu yeni sistem ile mamogram görüntülerini inceleyen radyologlara, kitlelerin benign (iyi huylu) veya malign (kötü huylu) olup olmadığına karar vermede yardımcı olacaktır. Ayrıca meme kanserinin en önemli belirtilerinden birisi olan ve glandular meme dokularında görülmesi zor olan mikrokalsifikasyonların daha net görülmesi için de yeni geliştirilen güçlendirme algoritması uygulanmıştır.

Geliştirilen karar destek sistemi (KDS), dört temel aşamadan oluşmaktadır. Bu yapı ön işlem, güçlendirme, bölütleme ve sınıflandırma aşamalarından oluşmaktadır. Ön işlem adımında sayısal (digital) veya sayısallaştırılmış (digitized) mamogram görüntüleri üzerinde görüntü boyutunun ayarlanması işlemi yapılmıştır. MIAS veri tabanındaki 1024 x 1024 piksel çözünürlüğündeki görüntüler ve hastaneden alınan 2400 x 3000 piksel çözünürlüğündeki görüntüler 512 x 512 piksel çözünürlüğüne düşürülmüştür. Daha sonra görüntü üzerinde gri formata dönüştürme, görüntü netleştirme gibi işlemler uygulanmıştır.

Güçlendirme aşamasında, mamogram görüntüleri için yeni geliştirilen ALIE algoritması uygulanmıştır. Bu algoritma histogram temelli ve otomatik olarak kitle yoğunluğunun güçlendirilmesi üzerine geliştirilen bir algoritmadır. ALIE algoritması mamogram görüntüleri üzerinde bulunan etiketli bölgeleri çıkarmakta, isteğe bağlı olarak da mamogram görüntülerinden pektoral kas bölgeleri çıkartılarak güçlendirme yapılmıştır.

Bölütleme adımında, genetik algoritma ile eğitilmiş HYSA kullanılarak mikrokalsifikasyon ve tümörler belirlenmiştir. HSYA'nın parametrelerini belirlemede kullanılan genetik algoritmanın uygunluk fonksiyonu olarak korelasyon fonksiyonu kullanılmıştır.

Sınıflandırma aşamasında, kitleleri ve mikrokalsifikasyonları belirlemek için görüntüler üzerinde şekil analizi kullanılarak sınıflandırma yapılmıştır. Mikrokalsifikasyon taneciklerinin ve kitlelerin mamogram görüntüleri üzerinde belirlenmesi amacıyla parçalı bir sınıflandırma fonksiyonu oluşturulmuştur. Şekil analizi için uzama, yoğunluk, eğim, yönelim gibi parametreler hesaplanarak sınıflandırma işlemi gerçekleştirilmiştir.

## 1.2. Tezin Amacı ve Önemi

Meme kanseri, kadınlarda en sık görülen ve ölüm nedeni olan kanserdir, tüm kadın kanserlerinin yaklaşık dörtte birini teşkil eder (Parkin ve ark., 2002). Türkiye'de meme kanseri her 8-10 kadından birisinde görülmekte ve dolayısıyla Türk kadınları arasında akciğer kanserinden sonra ölüme neden olma açısından ikinci sıradadır (Kaleli, 2007). Türkiye'de, en önemli sağlık problemlerinden biri olan meme kanseri, %24 gibi oldukça büyük bir oran teşkil etmekte ve kadınlarda en sık rastlanan kanser türü arasında ilk sırada gelmektedir (Tuncer, 2007). Erken teşhis ve gelişen tedavi yöntemlerinin etkisine bağlı olarak, son yıllarda

meme kanserine bağlı ölüm oranları düşmektedir. Bundan dolayı meme kanserinin erken teşhisi kadınların hayatında çok önemli rol oynamaktadır.

Kanserlerin semptomlara (belirti) yol açmadan teşhis edilmesi ana hedeftir. Meme kanserinin çeşidi ve yayılma hızı, hastalar için başarılı bir tedavi açısından en önemli faktörlerdir. Dolayısıyla meme kanseri için erken tanı, her sene binlerce hayatı kurtarmaktadır. Kadınlarda meme kanserinin semptomlara yol açmadan erken teşhisi için klinik meme testi, kişisel meme testi, görüntüleme testleri (mamogramlar, manyetik resonans görüntüleme, meme ultrasonu, PET scan metodu, CT scan metodu vs.) ve biyopsi gibi farklı tanı metotları vardır (Demirkazık, 1997).

MR gibi yöntemler kanseri belirlemede oldukça etkilidirler. Fakat yüksek maliyet sebebinden dolayı her şüpheli hastaya uygulanamamaktadır. Mamografi tekniği daha yaygın ve ucuzdur. Fakat başarı yüzdesi uzman doktorun başarısına bağlıdır.

Son yıllarda ülkemizde Sağlık Bakanlığı meme, kolon, rahim ve cilt kanserlerini tarama ve erken teşhis etmek için bütün illerde Kanser Erken Teşhis Merkez'leri (KETEM) kurmuştur. 40 yaş üstü bayanların yılda bir kez kontrol edilmeleri düşünülmüştür. Çok geniş bir alanı kapsayan bu çalışmada, maliyet açısından en uygun olan mamogram görüntüleme kullanılmaktadır. Dünya genelinde yaklaşık olarak meme kanserinin %80-85'i mamografi görüntüleme tekniği ile yapılmakta ve tümörlerin %10-25'i radyologlar tarafından gözden kaçırılmaktadır (Karabulut, 2009).

Bu tezde, hızla artan meme kanseri vakalarının erken teşhisi ve kanserin evresi hakkında, görüntü işleme ve yapay zekâ metotlarını kullanarak uzmanlara yardımcı olacak karar destek sistemi geliştirilmesi hedeflenmektedir.

### 1.3. Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi

Görüntü işleme teknikleri kullanılarak meme kanseri ile ilgili oldukça fazla çalışma yapılmıştır. Bu konu üzerine yapılmış ilk çalışmalardan birisi Winsberg ve ark.'na (1967) aittir. Winsberg ve ark. düşük çözünürlükteki görüntüler üzerindeki büyük kitleleri belirlemeyi başarmışlardır. Ackerman ve Gose (1972), radyologlar tarafından işaretlenen şüpheli bölgeleri sınıflandıran bir bilgisayar tekniği geliştirmişlerdir. Spiesberger (1979) sayısal mamogram görüntüleri üzerinde bilgisayar destekli bir görüntüleme algoritması

geliştirmiştir. Mikrokalsifikasyonların varlığını belirlemede çapraz-korelasyon katsayısını kullanmıştır. Çapraz-korelasyon katsayısı 0.65 eşik değerini aşınca, mikrokalsifikasyonun bulunduğu kabul edilmiştir. Hand ve ark. (1979), Semmlow ve ark. (1980) şüpheli bölgelerin belirlenmesi ve sınıflandırılması üzerine çok çeşitli araştırmalar yapmışlardır. Genel ve özel niteliklerin kullanılmasıyla şüpheli bölgelerin sınıflandırılması ve meme sınırının belirlenmesi üzerine çalışmışlardır.

Fam ve ark. (1988) belirgin kümelenmiş kalsifikasyonların saptanmasında yeni bir yöntem önermişlerdir. Çalışmaları piksel yoğunluğunu temel almıştır. Piksellerdeki ortalama değer ve sapma oranına göre algoritmaları yoğunluk değişimini hesaplayarak kalsifikasyonları belirlemeye çalışmışlardır. Algoritmalarının en büyük problemi, kullanıcıların dışardan birçok değişkenleri girmek zorunda olmalarıydı. Yabashi ve ark. (1989) Sobel, Laplacian ve Hill-climbing gibi görüntü güçlendirme teknikleri üzerine çalışmışlar ve mamogram görüntülerine de bu güçlendirme tekniklerini başarıyla uygulamışlardır.

Lai ve ark. (1989) kitleleri belirlemede yeni bir metot geliştirmişlerdir. Bu metotla, önce selective median filtre ile ön-işlem uygulanan mamogram görüntülerinin belirlenmiş bölgelerine şablon maske uygulamış, daha sonra da false pozitive oranını azaltmak için lokal komşuluk ve bölge histogram testleri uygulamışlardır. Brazakovic ve ark. (1990) belirleme tekniği olarak çoklu-çözünürlük ve bulanık mantık temelli bir yapı, sınıflandırmada ise alan, şekil, sınır mesafesi, sınır yoğunluk değişimine bağlı özellikler kullanmışlardır. Giger ve ark. (1990) kitlelerin analizi için iki-taraflı çıkarım ve dairesellik ölçümü kullanmışlardır. Gri seviye histogram analizi ve iki-taraflı çıkarım metodu da Yin ve ark. (1990) tarafından şüpheli kitlelerin belirlenmesinde ele alınmıştır. Lau ve Bischof (1991) memenin yapısındaki asimetriyi kullanarak çeşitli sonuçlara erişmişlerdir. Memelerin B-spline modelini kullanarak görüntüleri normalize etmişler, daha sonra parlaklık, pürüzlülük ve yön gibi nitelikleri ölçerek memedeki tümörleri belirlemeye çalışmışlardır.

Kegelmeyer (1993) şüpheli lezyonları belirlemede doku özellikleri ve yerel sınır özelliklerini ele alarak ikili karar ağaç yapısını kullanmıştır. Doku ve fractal özellikler Priebe ve ark. (1994) memedeki anormal gelişmeleri belirlemede kullanmışlardır. Petrosian ve ark. (1994) normal ve anormal dokuları sınıflandırmada spatial gri-seviye temelli kullanışlı bir doku özelliği geliştirmişlerdir. Petrosian ve ark. metodlarını 135 ilgili bölgeye (ROI) uyguladıklarında, eğitim adımında %89 duyarlılık (sensivity) ve %76 belirlilik (specificity), test adımında ise %76 duyarlılık ve %64 belirlilik gibi bir sonuç elde etmişlerdir.

Woods and Bowyer (1994) moment, contrast, uyumluluk (compactness), yerel sınır uyumu (local edge orientation) gibi nitelikler de dahil 24 adet özellik çıkarım değişkenini kitleleri sınıflandırmada kullanmıştır. Parr ve ark. (1994) spikule olmuş lezyonları belirlemede Gabor kuvvetlendirme tekniğini kullanarak spikule oranını belirlemeye çalışmışlardır. Li ve ark. (1995) sayısal mamogramlardaki tümörleri belirlemede düzenlenmiş Markov Random Field (MRF)'i kullanmak suretiyle adaptif bir eşikleme ve segmentasyon geliştirmişlerdir. Çalışmaları sonucunda kullandıkları 95 görüntüden kitleleri belirlemede %90 duyarlılığa ulaşmışlardır.

Pohlman ve ark. (1995) meme lezyonlarının benign veya malignant olma durumlarına göre sınıflandırmayı şekil temelli bir yapıda sunmuştur. Bu çalışmada tümörün değerlendirilmesi, tümör şeklinin uzun ve kısa mesafelerine göre yapılmıştır. Lefebvre ve ark. (1995) mikrokalsifikasyonların belirlenmesinde fraktal bir yaklaşım kullanmışlardır. Meme dokusu ve meme kanseri arasındaki ilişkinin incelendiği bu çalışma, daha sonra yapılan pek çok çalışmaların temelini teşkil etmiştir. Wang ve Karayiannis (1998) çalışmalarında, görüntü bozulmasını ele alan wavelet temelli, sayısal mamogramlarda mikrokalsifikasyon belirlenmesini incelemişlerdir.

Lo ve ark. (1999) meme kanserini teşhis etmede iki Yapay Sinir Ağı (YSA) kullanmışlardır. Bunlardan ilki ağ bağlantılarını ve ağırlık değerlerini mutasyona uğratabilen bir olasılık optimizasyon tekniği olan Evolutionary Programlama (EP)'dir. İkincisi ise Optimum Bayesian Karar verme tekniğini kullanan Probabilistic Neural Networks (PNN)'dir. Bu tekniklerin klasik Back-propagation ağlardan daha başarılı oldukları görülmüştür. Bovis ve Singh (2000) 144 meme görüntüsü üzerinde yaptıkları çalışmada, doku öznitelikleri çıkartılarak mamogramlardaki kitlelerin belirlenmesi amaçlanmıştır. Şüpheli bölgeler iki taraflı sağ ve sol meme görüntülerinin birbirlerinden çıkarılmasıyla belirlenmiştir. Yu ve Guan (2000) ilk adımda mikrokalsifikasyonlu piksellerin belirlenmesi ikinci adımda da mikrokalsifikasyon içeren objelerin belirlenmesi temelli bir çalışma yapmışlardır. Sınıflandırmada 105 mikrokalsifikasyon içeren 40 mamogram görüntüsü ile Multilayer Feedforward neural networks yapısını kullanmışlardır.

Sahiner ve ark. (2001) çalışmalarında kitlelerin malignant veya benign olmalarına göre sınıflandırma yapmışlardır. 102 hastadan alınan 249 mamaogram görüntüsü kullanılmıştır. Verma ve Zakos (2001) çalışmalarında bulanık ağlar ve nitelik çıkarma temeline dayalı, sayısal mamogramlarda mikrokalsifikasyon desenlerinin belirlenmesi ve teşhisi üzerine

çalışmışlardır. Bulanık ağlar mikrokalsifikasyon desenlerinin belirlenmesinde, yapay sinir ağları ise kitlelerin malignant veya benign olduğunu sınıflandırmada kullanılmıştır. Sınıflandırmada kullanılan back-propagation yapay ağlar (BPNN) ile sistem %88.9 oranında sınıflandırmada başarı sağlanmıştır.

Wirth ve ark. (2004) sayısal mamogramlarda mikrokalsifikasyonları belirlemede morfolojik analizine dayanan bir güçlendirme algoritması geliştirmiştirler. Çalışmalarında arka plan gürültülerini izole etmede morfolojik ön-işlem ve mikrokalsifikasyonları belirlemede morfolojik güçlendirme kullanmışlardır. Mamogramlarda görülen kitleleri belirlemede Perceptron Average yapay ağlar yayılım stratejisi ve diğer yayılım stratejilerini Wu ve ark. (2004) ortaya koymuşlardır. Simple Average, Perceptron Average ve Weighted Average gibi yayılım kuralları karşılaştırılmıştır. Zhang ve ark. (2004) çalışmalarında yapay sinir ağları temelli bir sınıflandırma kullanılarak Neural-Genetic bir algoritma oluşturmuşlardır. Jiang ve ark. (2006) sayısal mamogramlardaki mikrokalsifikasyon kümelerini belirlemede genetik algoritma yapısı sunulmuştur. Sunulan genetik algoritma (GA) yapısında, giriş görüntüsünün piksellerinin ortalama ve standart sapmaları alınarak nitelik domenine dönüştürülmüştür. GA için gerekli değişkenler bu domenden elde edilmiştir. Hanmandlu ve ark. (2008) kitleleri belirlemede arka planın çıkartılması, bulanık temelli doku analizi ve entropik eşikleme adımlarından oluşan bir segmentasyon yapmışlardır. Mikrokalsifikasyonların belirlenmesinde ise laplasian temelli Gauss filtreleme ve kontras temelli eşikleme kullanmışlardır. Geetha ve ark. (2008) sayısal mamogramlarda mikrokalsifikasyonların erken safhada belirlenmesi için nitelik çıkarmada, genetik algoritma (GA) ve New Particle Swarm Optimizasyon (NPSO) algoritması karşılaştırılarak kullanılmıştır.

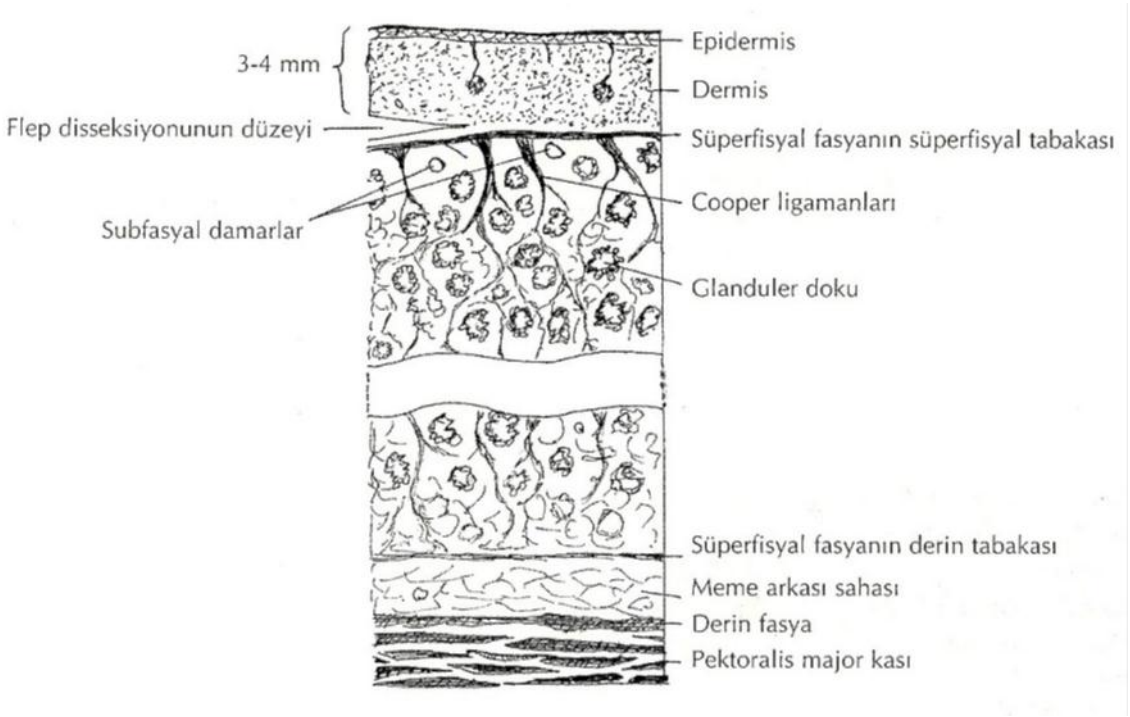
Zhao ve ark. (2010) mikrokalsifikasyon kümelerini otomatik olarak bulan k-means temelli bir küme algoritması üzerinde çalışmışlardır. Bu çalışmalarında 30 mamografik görüntü kullanmışlardır. Kandaswamy ve ark. (2010) mikrokalsifikasyon tespiti için çok aşamalı bir adaptif algoritma kullandılar. Yapı, danışmanlı öğrenmeye dayalı bir adaptif yapay zekâ sistemidir. Görüntülerin bölütlenmesinde Renkli Etiketleme Algoritması (CLA) kullanılmıştır. Dheeba ve Selvi (2011) dijital mamogram görüntülerindeki mikrokalsifikasyon kümelerinin tespiti için Destek Vektör Makinesi (DVM) kullanarak yeni bir sınıflandırma geliştirmişlerdir.

# 2. MEME KANSERİ VE MAMOGRAFİ

## 2.1. Memenin Anatomisi

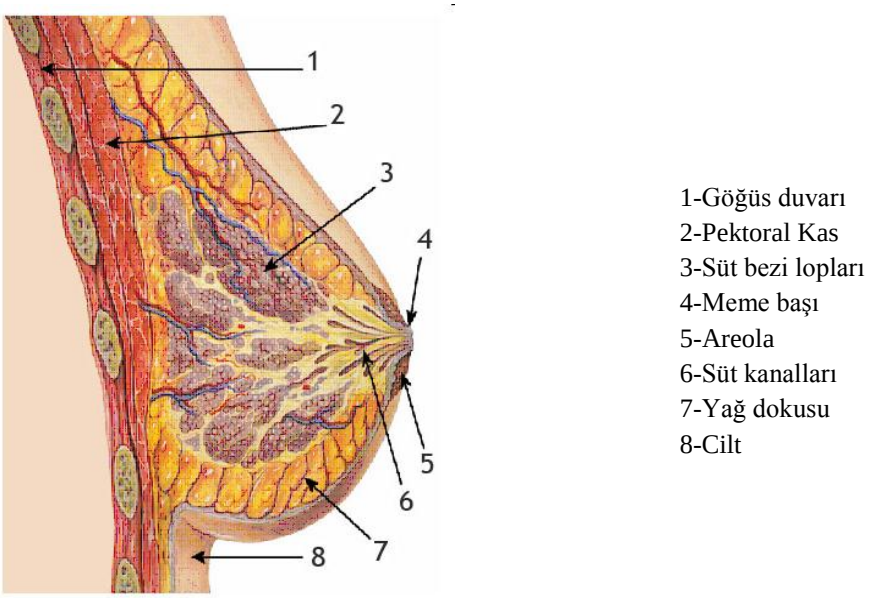
Memeler, göğüs kafesinin önünde, kas ve kemikten oluşan destekleyici bir sistemin üzerinde yerleşmiştir. Erişkin bir kadında meme glandı, genellikle ön göğüs duvarının dış pektoral fasyasının dış ve derin tabakaları arasında bulunur (Spratt ve Tabin, 1995). Bu meme glandının yapısı Şekil 2.1.'de gösterilmiştir. Memeler 2. ile 7. kaburgalar arasında yer alarak, içte sternumun kenarından dışta ön ve yan orta aksiller çizgiye kadar uzanırlar.

Memenin yukarı aşağı çapı ortalama 10-12 cm ve santral bölgede maksimum kalınlığı 5-7 cm dir. Laktasyonda olmayan bir memenin ağırlığı 150-200 gram, laktasyonda ise 400-500 gram kadardır (Spratt ve Tabin, 1995). Memenin çapları ve sınırları kadından kadına değişebileceği gibi aynı kadında da gebelik, emzirme, şişmanlama, zayıflama ve yaşlılık nedeniyle farklılık gösterebilir.




**Şekil 2.1.** Meme dokusunun tabakaları (Spratt ve Tabin, 1995)

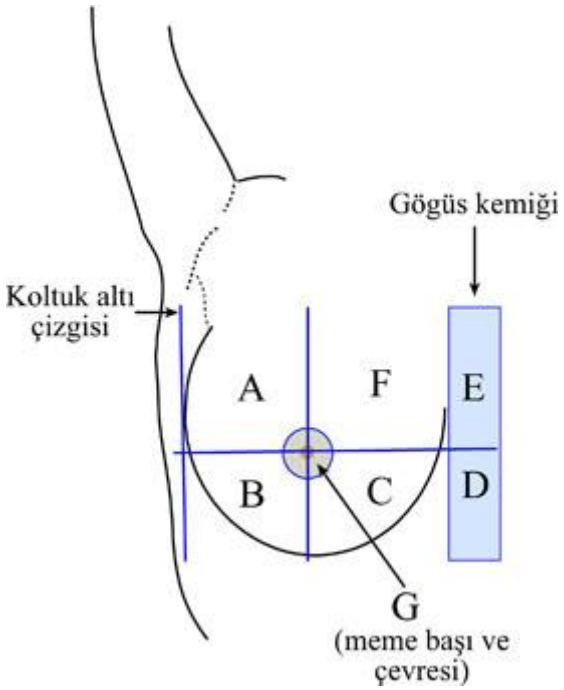
Memeler, süt üreten bezler (loblar) ve burada üretilen sütü meme başına taşıyan kanallar, yağ dokusu, kan ve lenf damarlarından oluşur. Her lob kendisinden daha küçük boyuttaki lobüllerde sonlanır. Lobüller ise yine süt salgılama ile görevli süt keseciklerinde sonlanır. Memenin lenf damarlarının büyük bölümü koltuk altı (aksilla) lenf bezlerine açılır. Lenf bezleri fasulye şeklinde olup, enfeksiyonlarla ve diğer hastalıklarla savaşta önemli olan bağışıklık sistemi hücrelerinden oluşurlar. Bu bezler aynı zamanda, bütün vücuda yayılmış ve birbiriyle ilişkili bezlerden meydana gelen lenfatik sistemi oluştururlar. Lenf damarları vücudumuzda kirli kan taşıyan damarlara benzer olup, kan yerine lenf sıvısı taşırlar. Hastalıklara karşı vücudu koruyan lenf sıvısı renksizdir. Meme dokusunun yapısı, büyüklüğü ve şekli kişiden kişiye değişir. Memenin anatomisi Şekil 2.2'de gösterilmiştir (Kalaycı ve ark., 2002).




**Şekil 2.2.** Memenin anatomisi (Kalaycı ve ark., 2002)

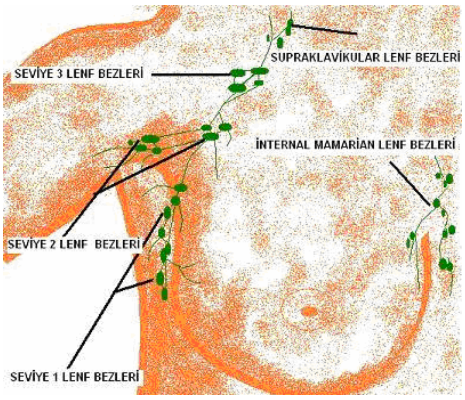
Göğüs duvarı, kaslardan meme derisine uzanan ince bantla lobları birbirinden ayırır. Her lob tek bir ana kanal tarafından boşaltılır. Bu ana kanallar birbirlerine bağlanarak meme başına açılırlar. Memelerin hemen hemen orta bölümüne rastlayan bu bölge, meme derisinden daha fazla pigment içerdiğinden rengi koyudur. Rengin koyuluğu östrojen seviyesinin yükselmesi ile artar (Kalaycı ve ark., 2002). Tüm meme yapılarının etrafı yağ ve fibröz doku adı verilen destek dokular ile çevrilidir.

Memenin tarifi yapılırken Şekil 2.3.'de gösterildiği gibi meme şemaları kullanılır. Bu şemalarda memenin temel olarak 5 kadrana ayrıldığı görülür. Buna göre; A üst dış kadran, B alt dış kadran, C alt iç kadran, F üst iç kadran, G ise meme başı ve çevresindeki koyu renkli bölgeyi (areola) sembolize eder. Memenin şekli ve büyüklüğü bireyden bireye göre değişir. Bazen aynı bireyde bile her iki memenin şekli ve büyüklüğü farklı olabilir (İşgör, 2013).




**Şekil 2.3.** Meme kadranları (İşgör, 2013)

Memede, Şekil 2.4.'te görüldüğü gibi lenfatik bir dağılım söz konusudur. Lenf, lenf bezleri boyunca dolaşan ve kan dolaşımı ile birleşen doku sıvısına verilen addır. Lenf bezleri vücudun doğal defansı olan bağışıklık sisteminin parçasıdır.




**Şekil 2.4.** Lenfatikler (Demirel, 2008)

Memeden gelen lenf sıvısının büyük çoğunluğu koltuk altında yerleşmiş olan aksiller lenf bezlerine dökülür. Kalan bölümü ise göğüs duvarı içerisine yerleşmiş olan internal mamarian lenf nodlarına, çok az bir kısmı ise karına ve sırtın yanlarında bulunan lenf bezlerine dökülür. Koltuk altında memeden gelen lenfi alan 10-30 adet lenf bezi bulunmaktadır. Aksiller lenf bezleri koltuk altındaki yerleşimlerine göre 3 seviye olarak sınıflandırılırlar. Seviye 1 bezler, koltuk altının alt kısmında pektoralis minor olarak adlandırılan göğüs kasının aşağısında yerleşmişlerdir. Seviye 2 bezler, koltuk altında merkezde ve bu kasın hemen arkasında yerleşmişlerdir. Seviye 3 bezler ise, bu kasın üzerinde bulunurlar. Lenf memeden koltuk altına yol alırken ilk önce seviye 1 bezlere döküldükten sonra diğer seviyedeki bezlere ulaşır. Meme kanseri hücreleri lenf sıvısı içerisinde ilerleyerek lenf bezlerinde kümelenirler.

## 2.2. Meme Kanseri

Vücudun organ ve dokuları, hücre adı verilen çok küçük yapılardan oluşmaktadır. Bu hücreler belirli şartlarda bölünür ve çoğalırlar. Hücrelerin kontrolsüz bir şekilde bölünmesi ve normal şartların üstünde çoğalması kanser hastalığıdır. Vücudun her bir bölümündeki hücreler görünüş ve işleyiş açısından farklı olsalar da kendilerini çoğaltma ve onarım açısından benzerdir. Normal hücrelerdeki bölünme, belirli bir sırada ve kontrollü olarak gerçekleşir. Ancak bazı nedenlerle bu işlemler kontrol dışına çıkar, hücreler bölünmeye devam eder. Kontrolsüz ve düzensiz çoğalan hücreler bulundukları organda tümör denilen bir kitle oluşturur. Tümörler (kitleler) iyi veya kötü huylu olabilirler.

İyi huylu (selim) tümörler kanser değildir. Genellikle bulundukları yerden cerrahi olarak çıkartıldıklarında yeniden oluşmazlar. Bu tümörleri oluşturan hücreler başka dokulara yayılmazlar ve kanser yapıcı özellikte değildirler. Kötü huylu (habis) tümörlere kanser hücreleri denir. Bu hücreler kontrolsüz olarak artar ve tedavide geç kalınırsa veya müdahale edilemez ise çevre dokulara yayılıp, bu dokuları tahrip edebilirler.

Kötü huylu (habis) tümörlerin farklı dokulara yayılmasına metastaz denir. Bu durumlarda hücreler kendi bölgesinden uzaklaşır, kan ve lenf sıvısı aracılığıyla vücudun diğer organlarına yayılırlar. Hücreler yeni bölgelere ulaştıklarında bölünmeye devam eder ve yeni kötü huylu (habis) tümör oluştururlar. Meme kanserinin en fazla metastaz yaptığı yerler kemikler, karaciğer ve beyin dokusudur.

Meme kanseri, memedeki süt bezleri (lopları) ve süt kanallarını (duktusları) oluşturan hücrelerin kontrolsüz çoğalarak, çevre dokulara ve vücudun başka bölgelerindeki organlara yayılarak çoğalmayı sürdüren bir hastalıktır.

Meme kanserinin birkaç çeşidi vardır. En sık görüleni, süt kanallarından kaynaklanır ve "duktal kanser" olarak adlandırılır. Süt bezlerinden gelişen kanser ise "lobüler kanser" olarak adlandırılmaktadır. Lobüler kansere duktal kansere göre daha az rastlanmaktadır.

Kanser hücreleri lenf ve kan damarları yolu ile vücudun diğer bölümlerine yayılır. Kanser hücreleri meme dokusu dışına çıktığında, öncelikle koltuk altı lenf bezlerini tutmaktadır. Çünkü memedeki lenf damarları, meme dokusundan gelen lenf sıvısını koltuk altındaki lenf bezlerine taşır. Kanser hücreleri koltuk altı veya diğer lenf bezlerine ulaştığında burada büyümeye devam eder ve şişlik oluştururlar. Kanser hücreleri lenf bezlerine ulaşırsa, vücudun diğer bölgelerine (kemiklere, akciğere ya da karaciğere) yayılma olasılığı artar.

## 2.3. Meme Kanserinde Tanı Yöntemleri

Meme kanserinde hasta açısından en iyi durum erken tanı ve tedavidir. Bu amaçla hastaya sırasıyla aşağıdaki yöntemlerin bazıları veya tamamı uygulanır:

1. Fiziki Muayene
2. Klinik Bulgular
3. Görüntüleme Yöntemleri
    a. Mamografi
    b. Ultrasonografi
    c. Bilgisayarlı Tomografi
    d. Manyetik Rezonans Görüntüleme (MRG)
4. Meme Biyopsisi

### 2.3.1. Fiziki muayene

Meme kanserinin erken belirlenmesi için 20-40 yaşlarındaki aseptomatik kadınların her 3 yılda bir, 40 yaşında sonra ise her yıl memenin hekimler tarafından fizik muayenesi önerilmektedir. Şekil 2.5.'de meme kanserinin elle muayenesi dörülmektedir.



**Şekil 2.5.** Meme kanserinin elle muayenesi

### 2.3.2. Klinik bulgular

Meme kanserli kadınların büyük çoğunluğunda ilk bulgu memede bir kitlenin varlığıdır. Genellikle kitle serttir, hareketsizdir, ancak etrafındaki meme dokusu ile birlikte hareket eder. Memedeki her kitlede deri retraksiyonunun olup olmadığı mutlaka araştırılmalıdır. Deri retraksiyonunun varlığı memedeki kitlenin, çok büyük olasılıkla kanser olduğunu işaret eder.

Tümörün lenf akımından yavaşlamaya neden olması deride portakal kabuğu görünümü oluşmasına yol açabilir. Meme santral kadranında yer alan tümörlerde meme başı içeri çekilebilir (meme başı retraksiyonu), meme başında asimetrik bir görünüm de oluşabilir.

Hastaların dikkat etmesi gereken durumlar şunlardır:

1- Memede kitle
2- Memede anormal büyüme
3- Bir memenin diğerinden daha aşağıda olması
4- Meme başında çekilme
5- Meme cildinde ödem ve kızartı
6- Meme başında kanlı akıntı
7- Meme başında renk değişikliği
8- Koltuk altı lenf nodlarında büyüme

### 2.3.3. Görüntüleme yöntemleri

Görüntüleme yöntemleri olarak mamografi, ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans görüntüleme (MRI) en fazla kullanılan yöntemlerdir. Özellikle mamografi, ucuz olması sebebiyle dünya genelinde en fazla kullanılan yöntemlerden biridir.

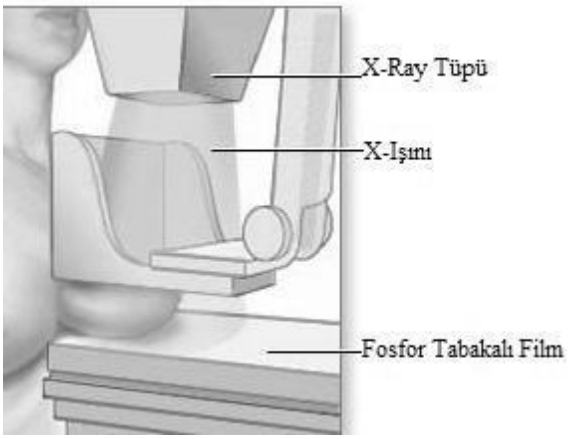
#### a. Mamografi:

Mamografi, meme dokusunun özel olarak tasarlanmış röntgen cihazları tarafından, düşük dozajlı X-ışınlarıyla yüksek kontrastlı ve yüksek yoğunluklu filmler üzerine alınan görüntüsüdür. Meme kanserinin tedavisinin başarıya ulaşmasında erken teşhis çok önemlidir. Bu işlem mamografi sayesinde ucuz ve hızlı bir şekilde sağlanabilir. Mamografi ile en ufak değişimler anlaşılıp, elle muayenede fark edilemeyen nodüllerin büyümesi tespit edilebilir. Mamografi, meme kanserinin erken teşhisinde mevcut en kullanışlı, hesaplı ve düşük radyasyonlu ve göreli olarak doğru olan bir yöntemdir. (Mini ve Tessamma, 2003). Tespit edilen kitlenin kanserli olup olmadığının belirlenmesinde de mamografi kullanılabilir. Bu görüntüleme yönteminin yanlış negatiflik oranı %10 ile %20 arasında değişmektedir.

Duyarlılık ırk, östrojen tedavisi, yaş ve meme yoğunluğu ile ilgilidir. Duyarlılık 40 yaş altında %54, 40-49 yaş arasında %77, 50-64 yaş arasında %78, 64 yaştan büyük kadınlarda %81 oranlarında görülür (Sayman, 2006).

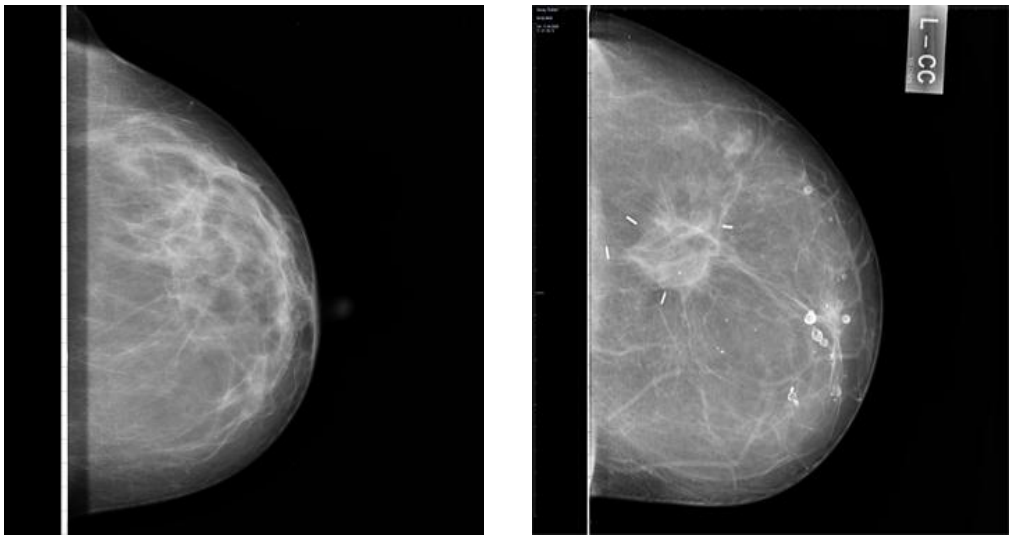
Mamografi genel olarak iki bölümde incelenebilir. Birincisi, hastalık olup olmadığını belirlemek amacıyla yaptırılan kontrol amaçlı mamografi, ikincisi de hastalık riski taşıyan memeye uygulanan tanı amaçlı mamografidir. Kontrol amaçlı mamografi, hiç bir şikâyeti olmayan kadınlarda olası meme kanserlerini 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.

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 oluştururlar. Bu işaretlemenin amaçlarından biri, kanserle ilişiği 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. Mamogram çekilirken, Şekil 2.6.'da 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.




**Şekil 2.6.** Mamografi çekim işlemi

Meme, yağ, lif dokusu ve salgı bezlerinden oluşmuştur. İyi huylu tümörler ve kanser olan kitleler de dahil olmak üzere, meme kitleleri mamogram 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. Şekil 2.7. (a)'da Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Bölümü'nden alınan normal bir mamografi, Şekil 2.7. (b)'de Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Bölümü'nden alınan mikrokalsifikasyonlu bir mamografi görülmektedir.




**(a)** **(b)**

**Şekil 2.7. (a)** Normal bir mamografi **(b)** Mikrokalsifikasyon kümecikleri içeren bir mamografi

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) ve memenin ortasından dışarıya doğru alınan Mediolateral (ML) görüntüler vardır.

Mamografi, BIRADS (Breast Imaging and Reporting Data Systems) adı verilen kriterlerle rapor edilir. Bu sınıflama aşağıdaki Çizelge 2.1.'de verilmiştir (Meme Sağlığı Dergisi, 2007).

**Çizelge 2.1.** BIRADS sınıflaması

| | |
|---|---|
| Kategori 0 | İlave görüntüleme yöntemlerine ihtiyaç var |
| Kategori 1 | Normal mamogram |
| Kategori 2 | Benign bulgular |
| Kategori 3 | Muhtemelen benign bulgular |
| Kategori 4 | Şüpheli bulgular<br>4A: Hafif derecede kuşkulu<br>4B: Orta derecede kuşkulu<br>4C: İleri derecede kuşkulu |
| Kategori 5 | Yüksek olasılık ile malignite düşündüren bulgular |
| Kategori 6 | Malign olduğu bilinen (biyopsi ile verifiye) ancak henüz kesin tedavi uygulanmamış olgular |

## b. Ultrasonografi:

Ultrasonografi (US), meme hastalıkları tanısında kullanılan önemli bir görüntüleme yöntemidir. Ultrasonografi, ultrasonik dalgaları bilgi taşıyıcısı olarak kullanır. Bu dalgalar, 1 MHz ile 10 MHz frekansları arasında, duyulamayan dalgalardır. Ultrason görüntüleri, dokular ve dokular arasındaki küçük yapılardan enerjinin geriye saçılımı yoluyla oluşturulur. Bu yöntem, özellikle yüksek frekanslarda, yüksek çözünürlüklü görüntüler oluşturur ve iyonlaştırıcı radyasyon gerektirmez. Bu görüntüleme yönteminin zayıf olduğu yönleri ise, yumuşak dokuların göreceli olarak zayıf kontrastlı olması, gaz ve kemiklerin ultrason dalgalarının geçişini engellemesi nedeniyle bazı organların görüntülenmesinin zorlaşmasıdır (Ammari, 2008).

Meme ultrasonografi raporlamasında da BIRADS değerlendirme kriterinin kullanımı, ultrasonografi bulgularının tanımlanmasında dil birliğini sağlamak, klinisyenlere net sonuç vermek ve doğruluğu arttırmak açısından yararlı standart bir terminoloji imkanı sağlamaktadır (Öztürk ve Demirkazık, 2007).

**c. Bilgisayarlı Tomografi (BT):**

BT, 1970'li yılların başlarından itibaren kullanılan ve bilgisayar yardımıyla elde edilen ilk medikal görüntüleme yöntemidir. Bilgisayarlı tomografi x-ışını (röntgen) kullanılarak vücudun incelenen bölgesinin kesitsel görüntüsünü oluşturmaya yönelik radyolojik teşhis yöntemidir. İnceleme sırasında hasta bilgisayarlı tomografi cihazının masasında hareket etmeksizin yatar. Masa manuel ya da uzaktan kumanda ile cihazın "gantry" adı verilen açıklığına sokulur. Cihaz bir bilgisayara bağlıdır. X-ışını kaynağı incelenecek hasta etrafında 360 derecelik bir dönüş hareketi gerçekleştirirken "gantry" boyunca dizilmiş dedektörler tarafından x-ışını demetinin vücudu geçen kısmı saptanarak elde edilen veriler bir bilgisayar tarafından işlenir. Sonuçta dokuların birbiri ardı sıra gri tonlarda kesitsel görüntüleri oluşturulur (Prince ve Links, 2006).

**d. Manyetik Rezonans Görüntüleme (MRG):**

Manyetik rezonans görüntüleme (MRG) büyük mıknatıslarla oluşturulan güçlü manyetik alan içinde radyo dalgaları kullanılarak belirli anatomik yapıları, diğer yapılardan net olarak ayırt etmek, sağlıklı ve hastalıklı dokular arasındaki farklılıkları saptamak ve tanımlamak için kullanılan bir tıbbi tekniktir. İlk kez 1973 yılında Paul Lauterbur tarafından gösterilmiştir.

Manyetik rezonans görüntüleme (MRG) insan vücudunun yüksek kontrast çözünürlükte görüntülenmesine olanak sağlayan bir görüntüleme tekniğidir. MRG güçlü bir magnet ve radyo dalgaları ile X-ışını veya diğer radyasyonları kullanmadan vücudun organ ve yapılarını detaylı görüntülenmesini sağlayan güvenli bir tanısal uygulamadır. İnsan vücudunun yaklaşık %63'ünde yer alan hidrojen atom çekirdekleri MR sinyalinin kaynağını oluşturur (Oyar, 2008).

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. Manyetik Rezonans Görüntüleme, göğüs kanserinin erken teşhisinde önemli rol oynayan geleneksel x-ışınlı mamografiye alternatif bir yöntem olarak kullanılmaktadır.

### 2.3.4. Meme biyopsisi

Biyopsi, kanser olmasından şüphelenilen dokunun laboratuvar şartları altında kanser olup olmadığının belirlenmesi işlemidir. Biyopsi, şüphelenilen dokudan alınan örneğin mikroskop altında incelenmesidir. Meme muayenesinde, mamografi, ultrosonografi ya da diğer tetkiklerde şüpheli bir kitle saptanırsa doktor biyopsi yapmaya karar verir. Biyopsi, şüpheli kitlenin kanser olup olmadığı konusunda kesin bilgi verir. Birkaç çeşit meme biyopsisi vardır. Biyopsi iğne ile yapılabildiği gibi cerrahi bir işlem de gerektirebilir. Kanser tanısında genellikle ilk adım olarak cerrahi biyopsiden çok iğne biyopsisi tercih edilir.

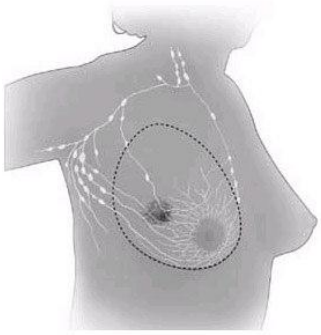
İğne biyopsisi hızlı bir şekilde tanı konulmasını sağlar. Ayrıca herhangi bir cerrahi işlem yapılmadan önce doktorla tedavi seçeneklerinizin tartışılmasına imkan verir. Ancak güvenirliği (değeri) cerrahi biyopsiden daha azdır. İğne biyopsisi; ince iğne biyopsisi ve kesici iğne biyopsisi olmak üzere iki şekilde yapılır.

*İnce İğne Biyopsisi:* Ultrason eşliğinde görerek ya da dokunarak ince bir iğne ile şüpheli kitle içerisinden enjektöre hücrelerin çekilmesi ve incelenmesi işlemidir.

*Kesici İğne (Kor) Biyopsisi:* Daha büyük bir iğne kullanılarak kitleden küçük parçalar şeklinde doku örnekleri alınması ve incelenmesidir. Yaygın olarak yapılan kesici iğne (kor) biyopsidir.

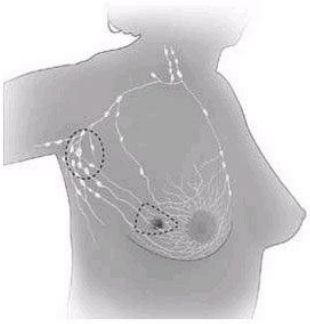
*Açık (cerrahi-ekzisyonel) biyopsisi:* Bazı hastalarda iğne biyopsisinden sonra açık (cerrahi-ekzisyonel) biyopsi gerekebilir. Açık biyopsi, küçük bir cerrahi işlemle memedeki kitlenin tümünün çıkarılarak incelenmesidir. Şekil 2.8.'de eksizyonal biyopsi bölgesi

görülmektedir (Demirel, 2008). Hastanın durumuna göre iğne biyopsisi yapılmadan cerrahi biyopsi de yapılabilir.



**Şekil 2.8.** Eksizyonal biyopsi (Demirel, 2008)

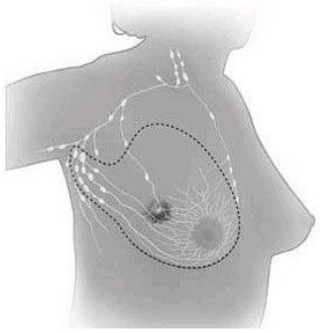
*Sentinel lenf bezi biyopsisi:* Kanser hücreleri meme dokusu dışına çıktığında, öncelikle koltuk altındaki lenf bezlerine yayılır. Çünkü memedeki lenf damarları meme dokusundan gelen lenf sıvısını koltuk altındaki lenf bezlerine taşır. Kitlenin bulunduğu yerden, lenf damarları yolu ile yayılacağı ilk lenf bezine haberci anlamına gelen "sentinel" lenf bezi denilmektedir. Sentinel lenf bezi biyopsisi hastalığın koltuk altı lenf bezlerine yayılıp yayılmadığını değerlendirmek amacıyla yapılır. Şekil 2.9.'da eksizyonal biyopsi bölgesi görülmektedir (Demirel, 2008).



**Şekil 2.9.** Sentinel lenf nod biyopsisi (Demirel, 2008)

Ameliyat öncesinde ışın yayan (radyoaktif) madde, memedeki kitle çevresine veya kitle çıkartılmışsa bu bölgenin çevresine küçük bir iğne ile verilir ve filmler çekilir. Ameliyat sırasında da cerrah memedeki kitle veya kitle çıkartılmışsa bu bölgenin çevresine mavi boya verir. Lenf damarları bu maddeleri (mavi boyayı ve radyoaktif maddeyi) bekçi lenf bezine taşır. Bekçi lenf bezinin maviye boyanması ve ışın yayan maddeyi tutması doktorun bekçi lenf bezini saptamasını sağlar. Doktor saptadığı lenf bezini çıkartarak incelemeye gönderir. Eğer bekçi lenf bezi hastalığı içermiyorsa, diğer lenf bezlerinde hastalık olma olasılığı çok azdır. Bu nedenle bekçi lenf bezinde hastalık yoksa koltuk altı lenf bezleriniz alınmaz. Ancak daha ileri incelemeye gereksinim vardır. İleri incelemede bekçi lenf bezine yayılım saptanırsa lenf bezleriniz çıkarılır.

*Modifiye radikal mastektomi*: Cerrahın göğsün tümünü, koltuk altındaki lenf nodlarının çoğu veya tümünü aldığı bir yöntemdir. Göğüs kasının küçüğü de lenf nodlarının alınımını kolaylaştırmak için alınabilir. Şekil 2.10.'da basit mastektomi görülmektedir.



**Şekil 2.10**. Basit mastektomi

## 2.4. Meme Kanserinde Evrelendirme

Meme kanserli hastalar doktora başvurduklarında kanserleri çeşitli yaygınlık derecelerinde bulunabilir. Kanserin yaygınlığını gösteren sınıflamaya evreleme denilmektedir. Evreleme yapmanın üç yararı vardır: 1. Tedavi önerileri evrelere göre yapılır, bu nedenle tedavi seçimi ve planlaması kolaylaşır. 2. Hastanın prognozu hakkında bilgi edinilir. 3. Bir hasta serisinde tedavi etkinliğinin değerlendirilmesi evre gruplarına göre yapılırsa, diğer bildirilmiş serilerdeki sonuçlarla karşılaştırılması doğru şekilde yapılabilir. Evreleme klinik

patolojik olarak ikiye ayrılabilir. Klinik evrelemede palpasyon, inspeksiyon ve radyolojik bulgular kullanılarak tümör ve periferik lenf bezlerinin durumu göz önüne alınır.

Patolojik evrelemede tümörün boyutu ve aksiller disseksiyonla çıkartılan lenf bezlerinin metastazla tutulmuş olması makroskobik ve mikroskobik olarak değerlendirmeye alınır. Günümüzde evrelemede en sık kullanılan sistem UICC (Union International Contre le Cancer) ve AJCC (American Joint Committee on Cancer) tarafından benimsenmiş olan TNM sınıflamasıdır. T, primer tümörü; N, periferik lenf bezlerini; M, uzak metastazı temsil eder. Klinik ve patalojik T evresi aynı kriterlere dayanır. Klinik evrelemede palpasyon ve radyolojik bulgular patolojik evrelemede ise tümörün makroskobik ölçümü kullanılır. N evrelemesinde, klinik evreleme için aksilla ve mammaria interna bölgesindeki palpasyon bulguları kullanılırken, patolojik evrelemede disseke edilmiş gangliyonların mikroskobik incelenmesi sonucunda elde edilen bulgular geçerlidir. Klinik evreleme, hastanın operebilitesini göstermek bakımından ameliyat öncesinde yapılırsa değerlidir. Patolojik evreleme ise postoperatif olarak yapılır ve adjuvan tedaviye gerek olup olmadığını gösterir. Benzer prognoza sahip çeşitli TNM evreleri bir araya getirilerek evre grupları oluşturulur. Çizelge 2.2.'de meme kanserinde klinik TNM evrelemesi verilmiştir.

**Çizelge 2.2.** Meme kanserinde klinik TNM evrelemesi

| **Primer Tümör (T)** |
|---|
| TX: Tanımlanamayan primer tümör |
| T0: Primer tümör bulgusu yok. |
| T1: En büyük çapı 2 cm veya daha az tümör |
| T1a: En büyük çapı 0.5 cm veya daha az tümör |
| T1b: En büyük çapı 0.5 cm'den büyük, 1 cm'den küçük tümör |
| T1c: En büyük çapı 1 cm'den büyük, 2 cm'den küçük tümör |
| T2: En büyük çapı 2 cm'den büyük fakat 5 cm'den küçük tümör |
| T3: En büyük çapı 5 cm'den büyük tümör |
| T4: Boyutu ne olursa olsun, göğüs duvarı veya cilde direk yayılım gösteren tümör |
| T4a: Göğüs duvarına yayılım |
| T4b: Ödem (peau d'orange görünümü), meme derisinin ülserasyonu veya aynı memede deri nodülleri |
| T4c: iki özelliğin birlikte olması (T4a ve T4b) |
| T4d: inflamatuar karsinom |

**Bölgesel Lenf Nodları (N)**

NX: Bölgesel lenf bezleri değerlendirilemiyor

NO: Bölgesel lenf bezi metastazı yok

N1: Aynı tarafta lenf bezlerine hareketli metastaz varlığı

N2: Aynı tarafta birbirine veya çevre yapılara fikse lenf bezi metastazı

N3: Aynı taraf internal mammaria lenf bezlerine metastaz

**Uzak Metastaz (M)**

MX: Uzak metastaz varlığı değerlendirilemiyor

M0: Uzak metastaz yok

M1: Uzak metastaz var

**Patolojik Sınıflandırma**

Pno: Bölgesel lenf nodu metastazi yok

PN1: Mobil, ipsilateral aksiller lenf nod (ları) na metastaz

PN1a: Sadece mikrometastaz (Hiçbirisi 0.2 cm' den büyük değil)

PN1b: Lenf nod (ları) na metastaz, herhangi birisi 0.2 cm'den büyük olabilir.

PN1bi: 1-3 lenf nod (ları) na metastaz, herhangi birisi 0.2 cm'den büyük ama hepsi de 2 cm' den küçük

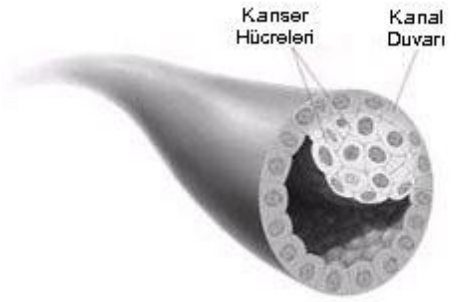
PN1bii: 4 veya daha fazla lenf noduna metastaz, herhangi birisi 0.2 cm' den büyük ama hepsi de 2 cm'den küçük.

PN1biii: Lenf nodu kapsülünün de atake olduğu metastaz, ancak büyüklük olarak 2 cm' den küçük

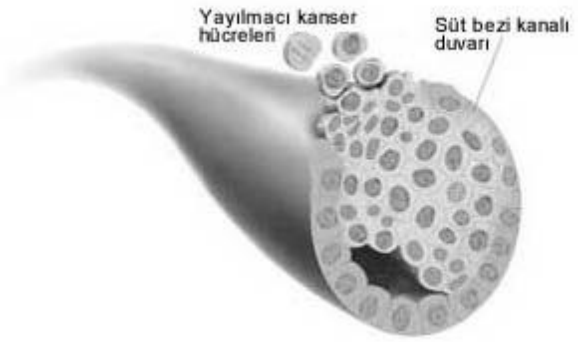
PN1biv: 2 cm veya 2 cm' den büyük lenf nodu metastazı

PN2: Birbirine ya da diğer yapılara fikse ipsilateral aksiller nod (lar) a metastaz

Evre 0'a carcinoma in situ denilmektedir. Lobüler carcinoma in situ (LCIS) lobüldeki anormal hücrelere karşılık gelmektedir. Bu anormal hücreler yüksek riskin işaretçisidir. LCIS olan kadının, ilerde her iki memesinde de yayılabilen kanser olma riskinin yüksek olduğu anlamına gelir. Ductal carcinoma in situ (DCIS) kanaldaki kanser öncesi durumdur. DCIS aynı zamanda intraductal carcinoma olarak da adlandırılır. Anormal hücreler, kanalın dışına çıkıp etrafındaki meme dokusuna Şekil 2.11.'de gösterildiği gibi yayılmamıştır. Fakat bazen DCIS tedavi edilmezse yayılabilen kanser olur. Şekil 2.12.'de ise kanser hücrelerinin kanal dışına yayıldığı durum gösterilmektedir (Demirel, 2008).




**Şekil 2.11.** Evre 0 - ductal carcinoma in situ kanser hücreleri




**Şekil 2.12.** Kanserin kanal dışına sıçraması ve yakındaki meme dokusuna yayılması

Evre I yayılabilen meme kanserinin başlangıç safhasıdır. 1. evre tümörün 2 cm'den fazla geniş olmadığı ve kanser hücrelerinin memeden başka yere (lenf bezlerine) yayılmadığı durumdur.

Evre II'de memedeki tümörün çapı 2 cm'den küçük ancak kanser koltuk altındaki lenf bezlerine sıçramış veya tümörün çapı 2-5 cm arasında ve kanser koltuk altına sıçramıştır. Tümör 5 cm'den büyük ama koltuk altındaki lenf bezlerine sıçramamıştır.

Evre III'de tümör büyük olabilir fakat meme dışına ve yakındaki lenf bezlerine yayılmamıştır. Bu lokal gelişmiş kanserdir. IIIA Evresi, memedeki kanserin çapının 5cm'den küçük olduğu ve koltuk altındaki lenf bezlerine ve çevredeki dokuya yapıştığı durumdur. Ya da tümör çapının 5cm'den fazla ve koltuk altındaki lenf bezlerine yayılmış olduğu durumdur.

IIIB evresi, tümörün göğüs duvarına veya meme derisine doğru büyümüş veya göğüs kemiğinin (sternum) altındaki lenf bezlerine yayılmış olduğu durumdur. Inflamatuvar meme kanseri, IIIB evresindeki meme kanserinin bir tipidir. Meme derisi kızarmış gözükür, çünkü kanser hücreleri meme derisinin lenf kanallarını tıkamıştır. IIIC Evresi, kanserin göğüs kemiğinin altındaki ve koltuk altındaki lenf bezlerine yayıldığı veya köprücük kemiğinin altında veya üstündeki lenf bezlerine yayıldığı durumdur.

Evre IV uzak metastatik kanserdir. Kanser vücudun diğer bölgelerine sıçramıştır. Tekrarlayan kanser, tedaviden sonra tekrar oluşan kanserdir. Kanser, lokal (meme veya göğüs duvarında) olarak veya vücudun herhangi bir bölgesinde (kemik, karaciğer, akciğer gibi) tekrarlayabilir. Şekil 2.13.'de meme kanserinin evreleri görülmektedir (Norman, 2013).

.

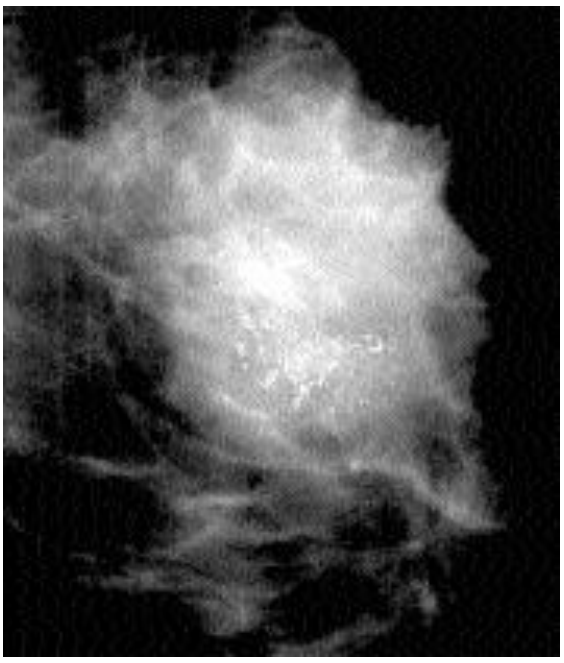



**Şekil 2.13.** Meme kanserinin evreleri

# 3. MİKROKALSİFİKASYONLAR

Mamografi, meme kanserinin erken saptanmasında taramalarda kullanılan etkin yöntemlerden birisidir. Meme kanserini belirlemede bazı önemli göstergeler vardır. En önemli semptomlardan birisi de kalsiyum kümecikleri olarak adlandırılan mikrokalsifikasyonlardır. Mikrokalsifikasyonlar genellikle 0.1 mm – 2 mm aralığında, küçük parlak noktacıklar olarak görülürler. Mikrokalsifikasyonlar 1$cm^2$ alandan daha küçük, üç ya da daha fazla görülen kalsiyum kümecikleridir (Hernández-Cisneros ve Yerashima-Marin, 2006) .

Mikrokalsifikasyonlar genellikle mamografilerde rastlanan bir bulgu olup, radyologları karar vermede yönlendiren kalsiyum kümecikleridir. Meme kanseri olgularının %30-40'ında mikrokalsifikasyon görülmesi erken tanıda mamografinin ne kadar önemli olduğunu göstermektedir (Heywang ve ark., 1997). Şekil 3.1.'de grup oluşturan, ince çizgisel dallanma gösteren kalsifikasyonlar görülmektedir.

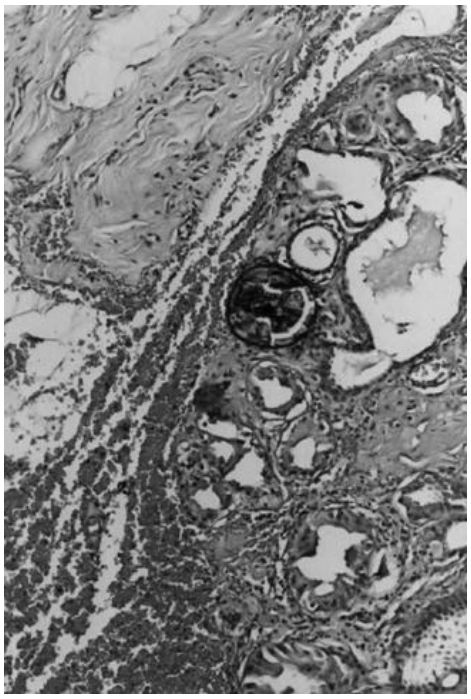


**Şekil 3.1.** Grup oluşturan, ince çizgisel dallanma gösteren kalsifikasyonlar

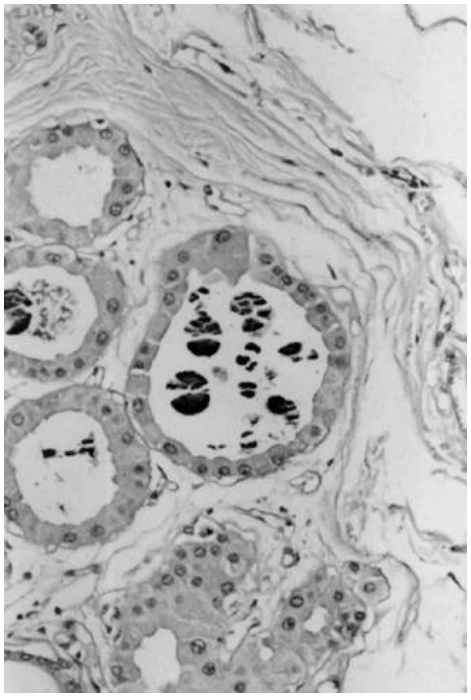
Meme kanserleri, kalsiyum kümeciklerinin oluşumuna neden olan malign tipte neoplazmlardır. Kalsiyumun meydana gelme nedeni açık değildir. Bazı tümörlerde kalsiyum nekroz bölgesinde yer alırken, bazılarında canlı tümör hücreleri tarafından üretilir. Çoğunlukla kalsifikasyon kitlenin içerisinde görülürler (Liberman ve ark., 1994). Özellikle lobüler karsinoma insitularda görüldüğü gibi çevre dokuda da bulunabilirler (Colbassani ve ark., 1982). Homer ve arkadaşlarının mamografik kitleye rastlanmaksızın mikrokalsifikasyon bulunan 40 histopatolojik tanılı olguda yaptıkları çalışmada, mikrokalsifikasyonların %63'ü tümör içi, %32'si tümör ve çevre doku içinde, %5'i 13 mm uzaklık içindeki tümör dışı çevre dokuda bulunmuştur (Homer ve ark., 1989).

Mikrokalsifikasyonlar, karsinomları da içeren çeşitli meme lezyonlarının önemli bir özelliğidir. Mamografik olarak belirlenen lezyonun benign veya malign olduğunu saptamak için, mikrokalsifikasyonların görünümü (boyut ve şekil), sayısı ve dağılım özellikleri radyologlar için son derece değerlidir. Ancak kesin tanı için lezyonun histopatolojik incelemesi gerekir.

Kalsifikasyonlar granüler ve nekroz alanlarının içinde görülen (Tip 1) ya da granüler ve eozinofilik granüllü küçük bir kor ve ender olarak ince kenarlı mavimsi materyalle çevrilmiş olabilir (Tip 2). Tip 2 granüler kalsifikasyonlar, Tip 1 kalsifikasyonlardan daha az bazofiliktir. Mikrokalsifikasyonları oluşturan bileşenler, çok az fosfor ya da alüminyum, silikon, potasyum, titanyum, sülfür gibi elementlerdir. Aşağıdaki Şekil 3.2.'de ve Şekil 3.3.'de Liesegang ring tipi kalsifikasyonlar görülmektedir (Erkul ve ark., 2005).



**Şekil 3.2.** Kanama ve fibrozis alanları içerisinde kistik genişlemiş meme duktusları yanında Liesegang ring tipi kalsifikasyonlar (H.E. x 100)



**Şekil 3.3.** Apokrin metaplazi gösteren duktus yapıları içerisinde çok sayıda Liesegang ring tipi kalsifikasyonlar (H.E. x 200)

Memede mikrokalsifikasyonların tespit edilmesinde etkili bir görüntüleme yöntemi olan mamografi ile elde edilmiş bazı mamogramlarda, kitle olmadığı halde görülen mikrokalsifikasyonlar, benigniteden maligniteye geçişi işaret edebilir. Özellikle mamogramlarda izole mikrokalsifikasyonlarla karşılaşıldığında çoğu zaman uygulanacak yöntemde belirsizlik yaşanır (Park ve ark., 2000). Bundan dolayı memedeki mikrokalsifikasyonların özelliklerine bakılarak benign-malign ayrımı çok iyi bir şekilde yapılmalıdır.

Mikrokalsifikasyonların değerlendirilmesinde radyologlar arasında farklılıklar görülmekle birlikte, mümkün olduğu kadar standart bir değerlendirme yapılmalı, klinisyenlere net bir sonuç verilmelidir.

Mamografi raporlarını radyologların kendi ifadeleriyle yazması hem radyologlar, hem de radyologlarla klinisyenler arasında uyumsuzluk oluşturmaktadır. Klinisyenlerin raporlardaki yorumları tam olarak anlamaları mümkün olmayınca aktarılan bilginin önemi de azalmaktadır. Her radyolog mamografik bulgularını ve mikrokalsifikasyonları kendi yöntemiyle verdiğinde ve sonuçları ona göre bildirdiğinde diğer meslektaşlarıyla kıyaslama yapmak ve ortak bir adım atmak zorlaşmaktadır. Temelde radyologların amacı, gereksiz biyopsi sayısını en aza indirerek kanseri yakalamaktır. Eğer radyologlar arasındaki iletişim artarsa bu amaca daha çok yaklaşılacaktır. Bunun için ortak bir terminoloji kullanmalı yani aynı dilde ifade edilmelidir. Yıllarca mamografi bulgularını standart bir şekilde inceleyen ortak bir sistem bulunmamaktaydı. Bu nedenle mamografi raporlarındaki kavram karışıklığını kaldırmak, radyologların kendi aralarındaki ve klinisyenlerle olan iletişimini artırmak, raporlardaki bilgileri standart bir halde sunmak ve aralarındaki tecrübelerden faydalanmak amacıyla 1990'lı yılların başında ACR (American College of Radiology)'nin diğer sağlık kuruluşlarıyla ortaklaşa gayretleri sonucunda BI-RADS adı altında standart bir terminoloji geliştirildi (American College of Radiology 1998; D'Orsi 1996). Kurul, literatürdeki yayınları ve tavsiyeleri göz önüne alarak belli aralıklarla bir araya gelip terminolojiyi yeniden gözden geçirmektedir. Terminoloji geliştirilirken durağan olmadığı, belli zaman dilimlerinde yeniden gözden geçirilip değişiklikler yapılabileceği bildirilmiştir (D'Orsi, 1996).

Yapılan pek çok araştırmada BI-RADS terminolojisinin kullanımında radyologlar arası uyumlar incelenmiştir (Berg ve ark. 2000; M.H. Kim ve E. Kim 1999). Bazı araştırmacılar ise BI-RADS terminolojisi içerisinde yer alan mamografik bulguları veya sonuç

kategorilerinin kendi serileri içindeki pozitif öngörü değerlerini incelemişlerdir (Orel ve ark. 1999; Lacquement ve ark. 1990). BI-RADS terminolojisi ile mamografik bulguların sınıflandırılması, histopatolojik sonuçlarla karşılaştırılması ve sonuçların bildirilmesi, terminolojinin saflaştırılması ve mamografi yorumlarındaki pratik değerinin artmasına yol açmıştır.

Çizelge 3.1.'de BI-RADS kriterlerine göre mikrokalsifikasyonların görülme şekilleri, Çizelge 3.2.'de BI-RADS kriterlerine göre mikrokalsifikasyonların dağılımları, Çizelge 3. 3.'de BI-RADS sınıflandırmasına göre mikrokalsifikasyonlara eşlik eden bulgular ve Çizelge 3.4.'de ise BI-RADS sınıflandırmasına göre sonuç kategorileri verilmiştir.

**Çizelge 3.1.** BI-RADS kriterlerine göre mikrokalsifikasyonların şekilleri

| |
|---|
| *1. Tipik benign kalsifikasyonlar* |
| a. Deri kalsifikasyonları<br>b. Vasküler kalsifikasyonlar<br>c. Kaba veya patlamış mısır şeklindeki kalsifikasyonlar<br>d. Kalın çubuk şeklindeki kalsifikasyonlar<br>e. Yuvarlak kalsifikasyonlar<br>f. Lüsent merkezli kalsifikasyonlar<br>g. Yumurta kabuğu veya çevresel kalsifikasyonlar<br>h. Kalsiyum sütü kalsifikasyonları<br>i. Sütür kalsifikasyonları<br>j. Distrofik kalsifikasyonlar<br>k. Punktat kalsifikasyonlar |
| *2. Orta derecede önemli olan kalsifikasyonlar* |
| a. Amorf (şekilsiz) veya belirsiz kalsifikasyonlar |
| *3. Yüksek olasılıkla malign mikrokalsifikasyonlar* |
| a. Pleomorfik veya heterojen (granüler) kalsifikasyonlar<br>b. İnce çizgisel ve/veya çizgisel dallanma gösteren (casting) kalsifikasyonlar |

**Çizelge 3.2.** BI-RADS kriterlerine göre mikrokalsifikasyonların dağılımları

| |
|---|
| 1. Grup veya küme oluşturan |
| 2. Çizgisel (lineer) |
| 3. Segmenter |
| 4. Bölgesel |
| 5. Yaygın (saçılmış) |

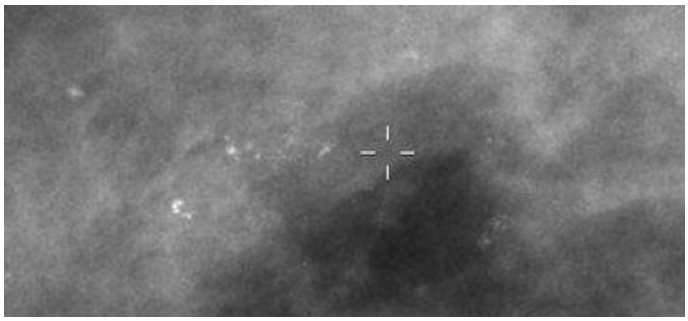
**Çizelge 3.3.** BI-RADS sınıflandırmasına göre mikrokalsifikasyonlara eşlik eden bulgular

| |
|---|
| 1. Deri retraksiyonu |
| 2. Meme başı retraksiyonu |
| 3. Deride kalınlaşma |
| 4. Trabeküler kalınlaşma |
| 5. Deri lezyonu |
| 6. Aksiller lenfadenopati |
| 7. Yapısal distorsiyon |

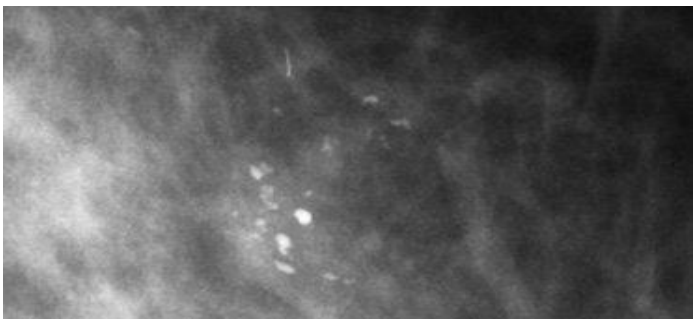
**Çizelge 3.4.** BI-RADS sonuç kategorileri

| *Kategori* | *Tanımlama* |
|---|---|
| 0 | Ek tetkik gerektirenler |
| 1 | Normal mamografi |
| 2 | Benign bulgular |
| 3 | Büyük olasılıkla benign |
| 4 | Şüpheli anormallikler (biyopsi yapılması düşünülmelidir) |
| 5 | Malign olma olasığı çok yüksek lezyonlar (gerekli işlemler yapılmalıdır) |

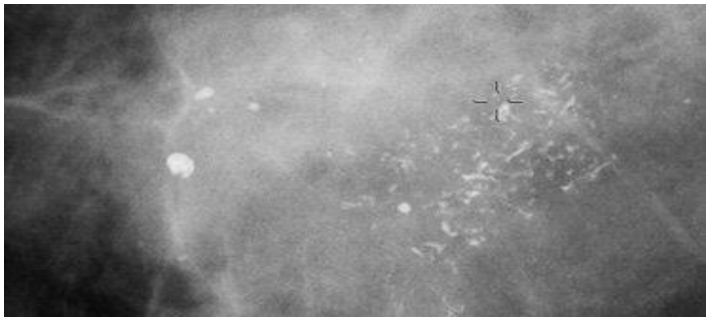
BI-RADS sınıflandırmasına göre çeşitli tip mikrokalsifikasyonlardan yukarda bahsedilmişti. Şekil 3.4. (a)'da belirsiz kalsifikasyonlara (Amorf), Şekil 3.4. (b)'de heterojen (granüler) kalsifikasyonlara, Şekil 3.4. (c)'de dallanma gösteren (casting) kalsifikasyonlara, Şekil 3.4. (d)'de benign kalsifikasyonlara örnek olarak verilmişlerdir.



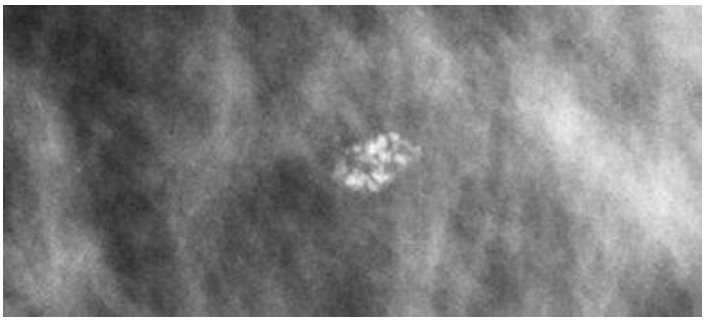
**(a)**



**(b)**



**(c)**



**(d)**

**Şekil 3.4. (a)** Belirsiz (Amorf) kalsifikasyonlar **(b)** Heterojen (granüler) kalsifikasyonlar **(c)** Dallanma gösteren (casting) kalsifikasyonlar **(d)** Benign kalsifikasyonlar

# 4. UYGULANAN YAPAY ZEKA TEKNİKLERİ

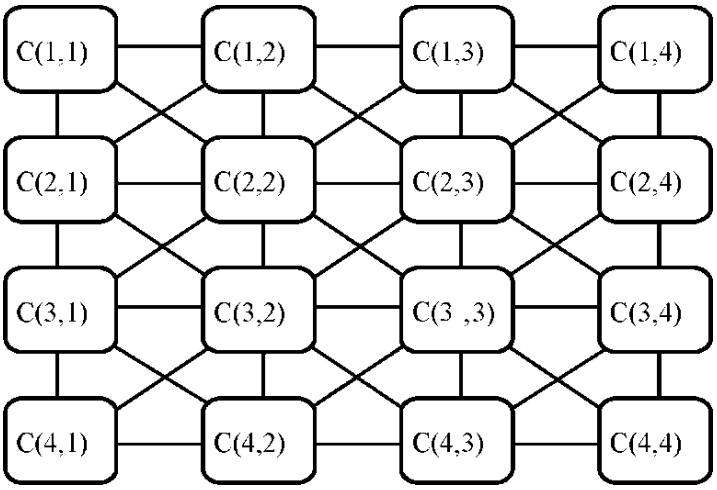
## 4.1. Hücresel Yapay Sinir Ağları (HYSA)

Hücresel Yapay Sinir Ağları (HYSA) ilk olarak 1988 yılında L.Chua ve L.Yang tarafından ortaya atılmıştır (Chua ve Yang 1988a, 1988b). Daha sonra Haykin (1994), Genç ve ark. (1996), Özmen ve ark. (1999-a,b), Güzeliş (1997), Kohonen (1999), Uçan ve ark. (2006) tarafından çalışılmıştır. HYSA, Yapay Sinir Ağlarının özel bir çeşididir ve birbirine bağlı, çoğunlukla iki boyutlu hücrelerden meydana gelmiş olan dinamik bir yapay sinir ağı modelidir. İki boyutlu hücrenin bileşenleri arasındaki ağırlık katsayılarının değişmez olması, HYSA'yı klasik yapay sinir ağlarından daha avantajlı duruma getirmiştir (Bargu, 2004). Temelde yapay sinir ağlarının özelliklerine sahip olmalarının yanında iki boyutlu yapıya sahip olmalarından dolayı da görüntü işleme ve görüntü tanıma konularında oldukça fazla uygulama alanları bulmuşlardır (Chua 1991; Suzuki ve ark. 1992; Sziranyi ve Csapodi 1994).

Görüntü işlemede HYSA kullanılması durumunda, HYSA'nın hücresel yapısı, işlenecek resim üzerinde hareket ettirilerek resmin sürekli taranması sağlanır. Bu sayede resmin ayırt edici özellikleri hücre tarafından öğrenilir. Hücresel yapay sinir ağları paralel çalışma yeteneği ve iki boyutlu yapısından dolayı, bazı ayırt edici özelliklerin çıkarılmasını sağlayan bir ön işleme elemanı olarak kullanılmışlardır. Temelde görüntüdeki her nokta bir nörona karşılık gelir. HYSA'lar, hareket sezme işlemlerinde de kullanılmaktadırlar (Chua ve Yang, 1988-a,b). HYSA'yı diğer dinamik ağlardan farklı kılan bir diğer özellik ise kendine özel bir komşuluk ilişkisi olması ve aktivasyon fonksiyonu olarak "parça parça doğrusal" karakteristiğini kullanmalarıdır (Tander ve Ün, 2001).

### 4.1.1. HYSA mimarisi

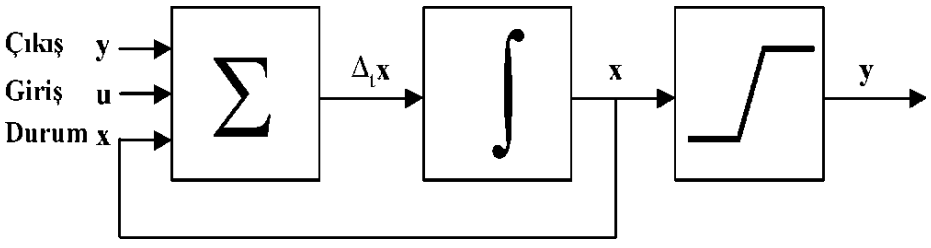
Bir Hücresel Yapay Sinir Ağındaki hücre, komşusu olan hücreler ile belli bir komşuluk ilişkisi içindedir. Şekil 4.1.'de 4x4 boyutunda hücrelerden meydana gelmiş, bir Hücresel Yapay Sinir Ağı gösterilmektedir (Chua ve Yang, 1988-a). $M \times N$ boyutundaki bir HYSA yapısında *i.* satır ve *j.* sütundaki hücreye $(i, j)$ hücresi denir ve $C(i, j)$ ile gösterilir.




**Şekil 4.1.** 4x4 Boyutunda bir hücresel yapay sinir ağı gösterimi (Chua ve Yung, 1988a)

Özellikle görüntü işlemede başarılı sonuçlar veren HYSA'nın amacı, girişe uygulanan görüntüyü istenilen uygun bir çıkış görüntüsüne dönüştürmektir. Elde edilen çıkış görüntüsünün her pikseli -1 veya +1 olacak şekilde sınırlandırılır. Girişe uygulanan görüntü renkli, gri seviyeli veya bit eşlenik resim gibi çeşitli formatlarda olabilir. Sistemin girişine uygulanan görüntü, gerekli başlangıç ve diğer şartların sağlanması halinde her zaman kararlı sabit bir durum noktasına yaklaşır (Ceylan, 2009).

HYSA'da her bir hücre, ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal dinamik bir ara birim ve n parçalı (genellikle üç parçalı) orijine göre simetrik bir çıkış biriminden oluşan dinamik bir devredir (Uçan ve ark., 2006). Şekil 4.2.'de bir hücrenin dinamik yapısı gösterilmiştir.




**Şekil 4.2.** Bir hücrenin dinamik yapısı (Uçan ve Albora, 2003)

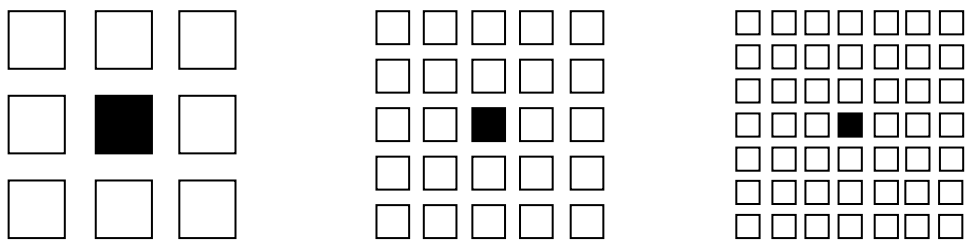
HYSA'nın hücresel yapısı dirençler, kapasiteler, akım ve gerilim kontrollü kaynaklar içeren bir yapıda ifade edilebilir. Hücresel Yapay Sinir Ağları (HYSA) görüntü temelli çalışmalarda iki boyutlu olarak kullanılabildikleri gibi, elde edilen sonuçlar kolaylıkla daha yüksek boyutlu durumlara genelleştirilebilir.

### 4.1.2. Hücresel yapay sinir ağlarında komşuluk ilişkisi

*M* satır ve *N* kolondan oluşan bir *MxN* lik hücresel yapay sinir ağı ele alalım. Böyle bir yapıda *i.* satır ve *j.* kolona *(i,j)* hücresi adını verip *C(i,j)* olarak ifade edilmişti. Burada herhangi bir *C(i,j)* hücresinin r komşuluğu şu şekilde tanımlanır (Chua ve Yang, 1988a).

$$N_r(i,j) = \left\{ C(k,l) \middle| \max(|i-k|,|j-l|) \le r,\ 1 \le i \le M; 1 \le j \le N \right\} \quad (4.1)$$

Burada r, komşuluğu gösteren pozitif bir tamsayıdır ve her bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından doğrudan etkileneceğine işaret eder. Şekil 4.3.'de, r=1 komşuluğunda her bir hücre sadece çevresindeki hücreler tarafından etkilenirken, r=2 ve r=3 komşuluklarında hücreler kendilerinden iki ve üç hücre uzaklıklarındaki hücreler tarafından da etkilenebileceği görülmektedir (Kılıç, 2008).




**Şekil 4.3.** Hücresel yapay sinir ağlarında (HYSA) *r=1, r=2, r=3* komşuluğu için hücre ilişkileri

Yukarıdaki şekillerden de anlaşılacağı üzere; genellikle *r* = 1, *r* = 2 ve *r* = 3 komşuluklarına sırasıyla 3 x 3, 5 x 5 ve 7 x 7 komşulukları da denir. Bir r komşuluğu

içerisinde (2r+1) x (2r+1) tane hücre bulunur. Komşuluk aynı zamanda simetri özelliğine de sahiptir.

$$C(i,j) \in Nr(k,l) \text{ ise} \qquad C(k,l) \in Nr(i,j) \tag{4.2}$$

### 4.1.3. Hücresel yapay sinir ağlarında konvolüsyon ilişkisi

HYSA'da bir hücrenin temel yapısını, çıkış geri beslemenin etkisini belirleyen $A(i,j;k,l)$ parametresi ile girişin kontrol etkisini belirleyen $B(i,j;k,l)$ parametreleri oluşturur. Bu parametrelerden $A(i,j;k,l)$ *Geri Besleme Ağırlık Katsayısı*, $B(i,j;k,l)$ *Giriş Ağırlık Katsayısı* olarak da adlandırılır. 1. dereceden (r=1) komşuluk için A ve B parametrelerinin matris formu aşağıdaki gibi ifade edilebilirler (Kılıç, 2008);

$$A=\begin{pmatrix} A_{-1,-1} & A_{-1,0} & A_{-1,1} \\ A_{0,-1} & A_{0,0} & A_{0,1} \\ A_{1,-1} & A_{1,0} & A_{1,1} \end{pmatrix} \qquad B=\begin{pmatrix} B_{-1,-1} & B_{-1,0} & B_{-1,1} \\ B_{0,-1} & B_{0,0} & B_{0,1} \\ B_{1,-1} & B_{1,0} & B_{1,1} \end{pmatrix} \tag{4.3}$$

Yukardaki matris formundan şu tanımlamalar yapılabilir;

$$A_{-1,-1} = A_{1,1} = a_1,\ A_{-1,0} = A_{1,0} = a_2,\ A_{-1,1} = A_{1,-1} = a_3,\ A_{0,1} = A_{0,-1} = a_4,\ A_{0,0} = a_5 \tag{4.4}$$

$$B_{-1,-1} = B_{1,1} = b_1,\ B_{-1,0} = B_{1,0} = b_2,\ B_{-1,1} = B_{1,-1} = b_3,\ B_{0,1} = B_{0,-1} = b_4,\ B_{0,0} = b_5 \tag{4.5}$$

A ve B matrislerini yeniden düzenlersek:

$$A=\begin{pmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{pmatrix} \qquad B=\begin{pmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{pmatrix} \tag{4.6}$$

**A** matrisi tamamen kararlılık için simetrik seçilirken, **B** matrisi ise hesaplama kolaylığı açısından simetrik seçilmiştir.

Konvolüsyon ilişkisi, çıkış geri beslemenin etkisini belirleyen A ile girişin kontrol etkisini belirleyen B'nin hücrelere yapacağı etkiyi gösterir. Eşitlik (4.5)'de verilen ve ayrık zamanlı hücresel yapay sinir ağını ifade eden formülde **A** ve **y** arasındaki ilişki ile **B** ve **u** arasındaki ilişki aynı olup iki boyutlu bir konvolüsyon ilişkisidir. Burada, konvolüsyon $\otimes$ ile gösterilecektir.

$$x_{ij}(n+1) = \sum_{(k,l)\in N_r(i,j)} A_{i,j;k,l} \cdot y_{k,l}(n) + \sum_{(k,l)\in N_r(i,j)} B_{i,j;k,l} \cdot u_{k,l}(n) + I_{i,j} \tag{4.7}$$

$$x(n+1) = A \otimes y(n) + B \otimes u(n) + I \tag{4.8}$$

Buna göre yeniden düzenleme yaparsak;

$$x_{ij}(n+1) = \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{A}_{i,j} \cdot y_{i-k,j-l}(n) + \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{B}_{i,j} \cdot u_{i-k,j-l}(n) + I \tag{4.9}$$

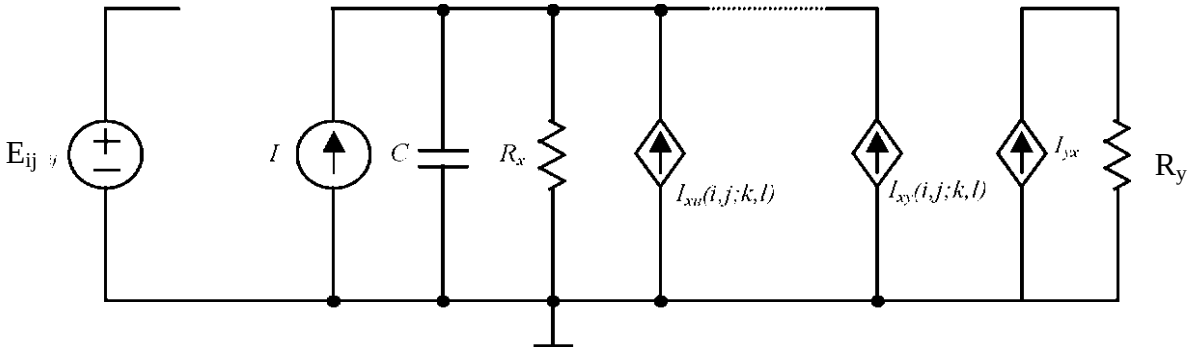
Burada konvolüsyon toplamının yazılabilmesi için; HYSA'nın uygulanacağı görüntülerin sınır değerleri tamamen sıfır olarak seçilmelidir. Ayrıca $\hat{A}$ ve $\hat{B}$ değerlerinin; (4.6)'dekiler ile ilişkisinin $\hat{A}_{i,j} = A_{-i,-j}$ ve $\hat{B}_{i,j} = B_{-i,-j}$ şeklinde olması gereklidir. Buna göre (4.7) yeniden yazılacak olursa:

$$x_{ij}(n+1) = \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{A}_{-i,-j} \cdot y_{i-k,j-l}(n) + \sum_{k\in N_r(i,j)} \sum_{l\in N_r(i,j)} \hat{B}_{-i,-j} \cdot u_{i-k,j-l} + I \tag{4.10}$$

elde edilir.

### 4.1.4. Hücresel yapay sinir ağlarının devresel gösterimi

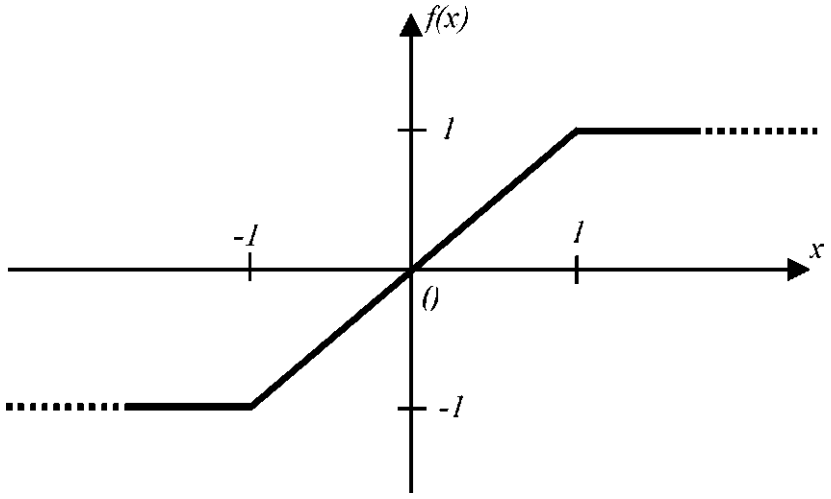
Hücresel yapay sinir ağındaki hücreleri, eşdeğer bir devre ile modelleyebiliriz. Bu yapı Şekil 4.4.'de gösterilmiştir (Chua ve Yang, 1988). Hücresel yapay sinir ağının herhangi bir *C(i,j)* hücresine karşılık gelen bu devrede *u* giriş, x durum ve *y* çıkışa karşılık gelmektedir. Bu *C(i,j)* hücresine ait $v_{xij}$ durum geriliminin başlangıç koşulu ile giriş gerilimi olan $v_{uij}$ 'nin 1 den küçük veya eşit olduğu kabul edilmiştir. $v_{yij}$ ise çıkış gerilimidir (Bargu, 2004).




**Şekil 4.4.** Bir hücre yapısının devresel olarak gösterilmesi

*C(i,j)* hücresi $E_{ij}$ gerilim kaynağı, I akım kaynağı, C kapasite, $R_x$ ve $R_y$ dirençleri, giriş kontrol gerilimi $v_{ukl}$ ile çıkış kontrol gerilimi $v_{ykl}$ tarafından geri besleme olarak kontrol edilen lineer gerilim kontrollü akım kaynaklarından meydana geldiği görülür. Burada $I_{xy}(i,j;k,l)$ ve $I_{xu}(i,j;k,l)$ gerilim kontrollü akım kaynaklarının karakteristikleri $C(k,l) \in N_r(i,j)$ komşuluğu altında $I_{xy}(i,j;k,l)=A(i,j;k,l)v_{ykl}$ ve $I_{xu}(i,j;k,l)=B(i,j;k,l)v_{uki}$ olarak ifade edilirler (Kılıç, 2003).

Her hücre içerisindeki tek lineer olmayan eleman parça-parça doğrusal $I_{yx}=(1/R_y)f(v_{xij})$ karakteristiğine sahip olan gerilim kontrollü akım kaynağıdır. *f(.)* fonksiyonu Şekil 4.5.'de gösterilmiştir.




**Şekil 4.5.** Parça-parça doğrusal çıkış karakteristiği

Kirchoff gerilimler ve akımlar yasası uygulanarak bu hücresel devrenin eşitliği aşağıda gösterildiği gibi kolayca türetilebilir.

Durum eşitliği:

$$C\frac{dv_{xij}(t)}{dt} = -\frac{1}{R_x}v_{xij}(t) + \sum_{C(k,l)\in N_r(i,j)} A(i,j;k,l)v_{ykl}(t) + B(i,j;k,l)v_{ukl}(t) + I \qquad (4.11)$$

Çıkış eşitliği:

$$v_{yij}(t) = \frac{1}{2}\left(\left|v_{xij}(t)+1\right| - \left|v_{xij}(t)-1\right|\right) \quad 1 \le i \le M; 1 \le j \le N \qquad (4.12)$$

Giriş eşitliği:

$$v_{uij}(t) = E_{ij}\ , \qquad 1 \le i \le M; 1 \le j \le N \qquad (4.13)$$

Kısıtlama durumları:

$$\left|v_{xij}(0)\right| \le 1\ , \qquad 1 \le i \le M; 1 \le j \le N \qquad (4.14)$$

$$\left|v_{uij}\right| \le 1 \qquad 1 \le i \le M; 1 \le j \le N \qquad (4.15)$$

Parametrik kabuller:

$$A(i,\ j;k,l) = A(k,l;i,\ j)\,, \qquad 1 \le i \le M; 1 \le j \le N \tag{4.16}$$

$$C > 0,\ R_x > 0. \tag{4.17}$$

Genel olarak şu sonuçları çıkarabiliriz; bir hücresel yapay sinir ağındaki tüm merkezi hücreler aynı devre yapısı ve değerlerine sahiptirler. Bir merkezi hücre, tanımlanan *r* komşuluğunda $(2r+1)^2$ kadar komşu hücreye sahip olan hücredir. Bunun dışında kalan hücreler ise sınır hücreleridir. Bu şekilde tanımlanan hücresel yapay sinir ağ yapıları doğrusal olmayan bir denklem takımı ile karakterize edilirler (Bargu, 2004).

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.

### 4.1.5. Hücresel yapay sinir ağlarında öğrenme

HYSA'da kullanılacak A geri besleme, B kontrol şablonları ile I eşik değerlerinin doğru hesaplanması temel amaçtır. Kullanılacak eğitim algoritması bu bakımdan önemlidir. Öğrenme algoritmalarından birisi de, Güzeliş ve Karamahmut (1994) tarafından geliştirilen dinamik ardışıl algılayıcı öğrenme algoritmasıdır (Recurrent Perceptron Learning Algorithm).

Hücresel yapay sinir ağını karakterize eden denklemler, bu algoritma kullanarak aşağıdaki gibi düzenlenebilir.

$$x_{i,\ j} = -S \cdot x_{i,\ j} + \sum_{(k,l)\in(-1,0,1)} A_{k,l} \cdot y_{(i+k),(j+l)} + \sum_{(k,l)\in(-1,0,1)} B_{k,l} \cdot u_{(i+k),(j+l)} + I \tag{4.18}$$

$$y_{i,\ j}(t) = \frac{1}{2}\left(\left|x_{i,\ j}+1\right| - \left|x_{i,\ j}-1\right|\right) \tag{4.19}$$

### 4.1.6. RPLA öğrenme algoritması

RPLA algoritması burada 3x3 boyutundaki bağlantı ağırlık katsayıları için tanıtılacaktır.

$$A=\begin{pmatrix} A_{-1,-1} & A_{-1,0} & A_{-1,1} \\ A_{0,-1} & A_{0,0} & A_{0,1} \\ A_{1,-1} & A_{1,0} & A_{1,1} \end{pmatrix} \qquad B=\begin{pmatrix} B_{-1,-1} & B_{-1,0} & B_{-1,1} \\ B_{0,-1} & B_{0,0} & B_{0,1} \\ B_{1,-1} & B_{1,0} & B_{1,1} \end{pmatrix} \tag{4.20}$$

Yukardaki matris formundan şu tanımlamalar yapılabilir (Bargu, 2004);

$$A_{-1,-1} = A_{1,1}= a_1,\ A_{-1,0} = A_{1,0} = a_2,\ A_{-1,1} = A_{1,-1} = a_3,\ A_{0,1} = A_{0,-1} = a_4,\ A_{0,0}=a_5 \tag{4.21}$$

$$B_{-1,-1} = B_{1,1} = b_1,\ B_{-1,0} = B_{1,0} = b_2,\ B_{-1,1} = B_{1,-1} = b_3,\ B_{0,1} = B_{0,-1} = b_4,\ B_{0,0}=b_5 \tag{4.22}$$

A ve B matrislerini yeniden düzenlersek:

$$A=\begin{pmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{pmatrix} \qquad B=\begin{pmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{pmatrix} \tag{4.23}$$

Bu öğrenme algoritmasında amaç istenilen görüntü işleme işlevini yerine getirecek bu ağırlık katsayılarını ve $I$ eşik seviyesini elde etmektedir. Bunun için bu değerlerin oluşturduğu bir **w** vektörünü şu şekilde tanımlayalım:

$$w \cong \left[ a^T b^T I \right]^T \cong \left[ a_1 a_2 a_3 a_4 a_5 b_1 b_2 b_3 b_4 b_5 I \right]^T \tag{4.24}$$

Buradaki öğrenme algoritmasında hata fonksiyonunun türevine ihtiyaç yoktur ve giriş iki kısımdan meydana gelmiştir. Bunlar, hücresel yapay sinir ağının girişleri ve başlangıç durum değerleridir. Genelleştirme için bu giriş vektörlerini şu şekilde tanımlayalım. Dış giriş

vektörü $v_u = \left[ ..., u_{i,j}, ... \right]^T \in R^m$ ve başlangıç durum vektörü $v_x = \left[ ..., x_{i,j}(0), ... \right]^T \in R^m$ olmak üzere, sistemin giriş vektörü $v = \left[ v_u{}^T v_x{}^T \right]^T \in R^m$ olarak gösterilsin. Hücresel yapay sinir ağı bu giriş vektöründen **w** ağırlık katsayı değerlerini kullanarak $v_x = \left[ ..., y_{i,j}(t), ... \right]^T \in R^m$ çıkış vektörünü elde eder. Yani giriş vektör uzayıyla çıkış vektör uzayı arasında cebrik dönüşüm tanımlar.

RPLA eğiticili bir öğrenme algoritmasıdır. Buna göre giriş ve istenen çıkış kümelerini bir **d** vektörü olarak şu şekilde tanımlayalım:

$$d = P(v) : \{(v_1, d_1), (v_2, d_2), ....(v_n, d_n)\} \tag{4.25}$$

Burada $v_s$ ve $d_s$ eğitim setlerinden s. örneğe ait giriş ve istenen çıkış çiftlerine karşılık gelmektedir. Hata fonksiyonu $\varepsilon[w]$ ise istenen çıkış ile $y_{i,j}(\infty)$ olarak gösterilen gerçek çıkış (kararlı durum çıkışı) arasındaki farkın ölçüsüdür. Amaç, bu hata fonksiyonunu minimize edecek olan w ağırlık katsayılarının elde edilmesidir. Her bir giriş ve çıkış çifti de göz önünde bulundurularak hata fonksiyonu şu şekilde tanımlanabilir:

$$\varepsilon[w] \cong \sum_{s=1}^{N} \varepsilon^s[w] = \sum_s \sum_{i,l} (y^s{}_{i,l}(\infty) - d^s{}_{i,l})^2 \tag{4.26}$$

Bu aşamadan sonra problem, kısıtlamalı bir optimizasyon problemine dönüşmektedir. Böyle çıkışların sadece +1 ve -1 değerlerinde olması garanti edilmektedir.

$\varepsilon[w]$'daki sabit terimler ihmal edilip yeniden düzenlenirse,

$$\varepsilon[w] \cong \sum_{i,l} (y^s{}_{i,l}(\infty) \cdot (y^s{}_{i,l}(\infty) - d^s{}_{i,l}) = \sum_{(i,j,s) \in D^+} y^s{}_{i,l}(\infty) - \sum_{(i,j,s) \in D^-} y^s{}_{i,l}(\infty) \tag{4.27}$$

eşitliği elde edilir. Bu eşitlik RPLA algoritmasının oluşturulmasını daha anlaşılır kılmaktadır. Bu eşitlikte $D^+ \cong \left\{ (i,j,s) \middle| y^s{}_{i,l}(\infty) = -d^s{}_{i,j} = 1 \right\}$ ve $D^- \cong \left\{ (i,j,s) \middle| y^s{}_{i,l}(\infty) = -d^s{}_{i,j} = -1 \right\}$

şeklindedir. Yani buradaki $D^+$ ve $D^-$ bölgeleri gerçek çıkışlar ile istenen çıkışlar arasındaki uyuşma ölçütünün birer karşılığıdır.

Burada tanımlanan hata fonksiyonunda parça parça doğrusal çıkış fonksiyonunun türevlenebilir bir fonksiyon olmamasından dolayı gradyant yöntemleri bu problem için kullanılamaz. $S \cdot x_{i,j}$ ifadesi eşitliğin sol tarafına alınıp yeniden yazılırsa,

$$S \cdot x_{i,j}(\infty) = w \cong \sum_{(k,l)\in(-1,0,1)} A_{k,l} \cdot y_{(i+k),(j+l)}(\infty) + \sum_{(k,l)\in(-1,0,1)} B_{k,l} \cdot u_{(i+k),(j+l)} + I \qquad (4.28)$$

elde edilir. Burada $Ys_{i,j}C(i,j)$ hücresini süren toplam giriş olarak ifade edilebilir ve şu şekilde gösterilir.

$$Ys_{i,j} = \left[ \left[ y^s{}_{i,j} \right]^T \left[ u^s{}_{i,j} \right]^T I \right]^T \qquad (4.29)$$

A ve B matrislerinin tam simetrik olduklarını da bildiğimizden $y^s{}_{i,j}$ ve $u^s{}_{i,j}$ matrisleri

$$y^s{}_{i,j} \cong \left[ y^s{}_{i-1,j-1}(\infty) + y^s{}_{i+1,j+1}(\infty) y^s{}_{i-1,j}(\infty) + y^s{}_{i+1,j}(\infty) y^s{}_{i-1,j+1}(\infty) + y^s{}_{i+1,j-1}(\infty) y^s{}_{i,j-1}(\infty) + y^s{}_{i,j+1}(\infty) y^s{}_{i,j}(\infty) \right]^T \qquad (4.30)$$

$$u^s{}_{i,j} \cong \left[ u^s{}_{i-1,j-1} + u^s{}_{i+1,j+1} u^s{}_{i-1,j} + u^s{}_{i+1,j} u^s{}_{i-1,j+1} + u^s{}_{i+1,j-1} u^s{}_{i,j-1} + u^s{}_{i,j+1} u^s{}_{i,j} \right] \qquad (4.31)$$

şeklinde tanımlanabilirler.

Burada $Y^s{}_{i,j}$ vektörünün ilk beş teriminin geri besleme ağırlık katsayı matris değerlerinin türevlenebilir bir fonksiyon olmadığına dikkat edilmesi gerekir. Yine burada önemli bir nokta, verilen **w** ağırlık katsayıları vektörü ile girişlere bağlı olarak istenilen işlevi yerine getirecek birden fazla çözümün olabileceğidir. Denklemin denge noktalarındaki bu çözümler seçilen başlangıç durum değerlerine bağlıdır.

Sonuç olarak fark denklemi ile ağırlık katsayı bağlantı vektörü **w** istenilen işlev yerine getirilinceye kadar adım adım uyarlanır. Böylece bu şekildeki fark denklemleriyle verilen ve başlangıç koşullarıyla gerçek çıkışların istenilen çıkışlara ulaşması için ağırlık katsayı

bağlantılarının adım adım uyarlanarak bulunmasını sağlayan bu algoritmaya RPLA algoritması adı verilir.

$$w(n+1) = \left[ w(n) - \varepsilon(n) \cdot \gamma\left[w(n)\right] \right] \tag{4.32}$$

Burada $\gamma\left[w(n)\right]$ vektörü şu şekilde tanımlanır:

$$\gamma\left[w(n)\right] \cong \left( \sum_{(i,j,s)\in D^{+}} Y^{s}{}_{i,j}(n) - \sum_{(i,j,s)\in D^{-}} Y^{s}{}_{i,j}(n) \right) \tag{4.33}$$

$\varepsilon(n)$ öğrenme hızını belirleyen bir parametredir ve zamana bağlı bir fonksiyon seçilebileceği gibi genellikle zamandan bağımsız çok küçük pozitif bir sayı olarak seçilir. RPLA çıkışların +1 ve -1 değerlerine yakınsamalarını garantileyen *a5>S* koşulu altında başlatılır. Her adımda $y^{s}{}_{i,j}(\infty)$ kararlı durum vektörü, diferansiyel denklemler giriş vektörü $v^{s}{}_{u}$ ve uyarlanmış bağlantı ağırlık katsayıları vektörü için seçilen başlangıç durum vektörü $v^{s}{}_{x}$ 'e bağlı olarak çözülür. **[w]+, w** bağlantı ağırlık katsayı vektörünün $A = \left\{ w \in R \middle| a_5 > S \right\}$ kümesinin bir elemanı olduğunu gösterir. Bu da kararlı durum çıkışlarının +1 ve -1 değerlerine gideceklerini garanti eder. $\left[\bullet\right]^{+}$ şu şeklide tanımlanır:

$$w(n) \in A \text{ ise } \left[w(n)\right]^{+} = w(n) \text{ ve } w(n) \notin A \text{ ise } \left[w(n)\right]^{+} = K_n \cdot w(n) \tag{4.34}$$

Burada şeklinde $K_n \cong \mu \cdot \dfrac{A}{a_5(n)}$ tanımlıdır. *u*> 1 olan ve genellikle 1.5 olarak seçilen bir sabittir.

Kısaca, RPLA algoritmasının genel olarak çalışma adımları şu şekilde sıralanabilir:

**1. Adım** Başlangıç koşulları için **w**(0) başlangıç ağırlık vektörüne bir değer atanır.

**2. Adım** Her bir adımda, verilen başlangıç durum **(x)** vektörü ve başlangıç giriş **(u)** vektörü ile o anki bağlantı ağırlık vektörleri **w**(n) için kalıcı durum çıkışları (y) hesaplanır.

**3. Adım** Bir sonraki bağlantı ağırlık vektörleri hesaplanırken $w(n+1)=\left[ w(n)-\varepsilon(n)\cdot\gamma\left[w(n)\right]^{+} \right]$ tanımlaması kabul edilerek bağlantı ağırlık katsayıları güncellenir.

**4. Adım** İstenen çıkış ve elde edilen HYSA çıkışları arasında hesaplanan hata istenen seviyeye gelinceye kadar n'yi 1 arttırarak 2. adımdan sonraki adımlar tekrar edilir.

### 4.1.7. Hücresel yapay sinir ağlarında kararlılık

Hücresel yapay sinir ağlarının halen devam eden araştırma konularından birisi de kararlılık problemidir (Zou ve Nossek 1991; Savacı ve Vanderwalle 1993). Başka bir değişle hücresel yapay sinir ağ çıkışlarının geçici rejimden sonra hangi koşullar altında sabit kararlı çıkış değerlerine ulaşacağıdır. Bu durumu;

$$\lim_{x\to\infty} v_{xij}(t) = sabit\,,\ 1 < i < M;1 < j < N \qquad (4.35)$$

ve ya geçici rejim sonrasında durum görüntüsünün sabit bir değere ulaşması durumunu göz önüne alarak,

$$\lim_{x\to\infty} \frac{dv_{xij}(t)}{dt} = 0\,,\ 1 < \mathrm{i} < \mathrm{M};1 < \mathrm{j} < \mathrm{N} \qquad (4.36)$$

şeklinde de ifade edebiliriz. Bu konuda yapılan çalışmalar göstermiştir ki; A geri besleme ağırlık katsayı matrisinin simetrik olması durumunda aksi ispat edilemediği için devre parametrelerinin $A(i,j;i,j) > \frac{1}{R_x}$ koşulunu sağlaması durumunda,

$$\lim_{x\to\infty} \left| v_{xij}(t) \geq 1 \right|\,,\ 1 < \mathrm{i} < \mathrm{M};1 < \mathrm{j} < \mathrm{N}. \qquad (4.37)$$

veya eşdeğeri

$$\lim_{x\to\infty} v_{yij}(t) = \pm 1,\ 1 < i < M; 1 < j < N. \qquad (4.38)$$

koşulları sağlanmış olur. Bu da hücresel yapay sinir ağı için devrenin osilasyon yapmayacağını veya en azından kaotik bir duruma geçmeyeceğini göstermesi açısından oldukça önem taşımaktadır. Bu durum hücresel sinir ağının çıkışlarının sadece ikili değerlerden oluşacağını garanti etmektedir.

### 4.1.8. Hücresel yapay sinir ağlarının sürekli zaman analizi

Hücresel yapay sinir ağı dinamik bir ağ olduğundan durum ve buna lineer olmayan bir fonksiyonla bağlı olan çıkış sürekli bir değişim içerisindedir. Hücresel yapay sinir ağındaki bu görüntü dönüşümünün nasıl çalıştığını daha rahat anlayabilmek için (4.11) eşitliğini integral formunda aşağıda gösterildiği gibi tekrar yazalım (Bargu, 2004);

$$v_{xij}(t) = v_{xij}(0) + \frac{1}{C}\int_0^t \left[ -\frac{1}{R_x} v_{xij}(\tau) + f_{ij}(\tau) + g_{ij}(u) + I \right] d\tau ,\ 1 < i < M; 1 < j < N \qquad (4.39)$$

$$f_{ij}(t) = \sum_{C(k,l)\in N_r(i,j)} A(i,j;k,l) v_{ykl}(t) \qquad (4.40)$$

$$g_{ij}(u) = \sum_{C(k,l)\in N_r(i,j)} \mathbf{B}(i,j;k,l) v_{ukl}(t) \qquad (4.41)$$

olarak yeniden düzenlenmişlerdir. Burada görülmektedir ki *vxij(t)* görüntünün herhangi bir *t* anındaki durumunu temsil etmektedir. Bu durum başlangıç koşulu olarak verilen görüntü $v_{xij}$ (0) ve hücresel yapay sinir ağının dinamik kurallarına bağlıdır. Böylece buradan da açıkça görülebileceği gibi hücresel yapay sinir ağları, bir başlangıç görüntüsünün herhangi bir *t* anındaki dinamik dönüşümünü elde etmek için kullanılabilir. Özel olarak burada $t \to \infty$ olması durumunda durum değişkeni tam kararlı durumda $v_{xij}$ bir sabite ve çıkış $v_{yij}$ ise +1 ve-1 değerlerinden herhangi birisine gitmektedir. Kararlılık koşullarının sağlanmaması durumunda ise osilasyon ve kaotik durumları ortaya çıkmaktadır.

## 4.2. Genetik Algoritmalar

Genetik algoritmalar evrimsel hesaplama yöntemlerini kullanan sezgisel bir optimizasyon yöntemidir. Bu algoritmalarla ilgili ilk çalışmalar 1950'li yıllarda başlayan biyoloji ve bilgisayar uzmanlarının oluşturdukları bir projeye dayanır. Bu alanda yapılmış ilk yayın 1975 yılında "Doğal ve yapay sistemlerin adaptasyonu" adlı basılmış kitaptır (Holland, 1992). Bu çalışmanın sahibi bilgisayar ve psikoloji uzmanı olarak çalışan John Holland'dır. Holland, Darwin'in "en iyi olan yaşar (survival of the fittest)" prensibinin temel teşkil ettiği, bir popülasyonu oluşturan bireylerin rekabet etmelerini ve rekabet sonucu elenmelerini sağlayan, evrimsel süreci bilgisayarlara öğretmeyi düşündü (Holland, 1975). Fakat pratikte çok fazla bir uygulama alanı bulamaması nedeniyle ciddiye alınmayan genetik algoritmalar (GA), David E. Goldberg'in doktora çalışmasının 1985 yılında National Science Foundation (Ulusal Bilim Kuruluşu) ödülünü almasıyla dikkatleri çekmeyi başardı. Goldberg'in "Genetic Algorithms in Search, Optimization and Machine Learning" adlı kitabında yer alan 83 uygulama ile genetik algoritmaların birçok alana uygulama imkânını gösterdi (Kılınç ve ark., 2006).

Evrimsel hesaplama temeline dayanan bu optimizasyondaki amaç, hayatta kalacak bireylerin yeteneklerini geliştirmektir. Evrimsel hesaplama (EC), bir arama işleminde doğal seçimin benzetimidir. Doğada, organizmalar hayatta kalmak ve çoğalmak için yeteneklerini etkileyen belli karakteristiklere sahiptir. Bu karakteristikler organizmanın kromozomlarında içerilen bilginin uzun stringleri şeklinde temsil edilirler. Eşlenerek çoğaltmadan sonra, yavru kromozomlar her çiften gelen bilginin bir kombinasyonundan oluşur. Umut verici bir biçimde sonuç, her çiftin en iyi karakteristiklerini içeren yavru kromozomlar olacaktır. Doğal seçim işlemi, uygunluk değeri en yüksek bireyin seçilmesini sağlar (Cunkaş, 2006).

Evrim algoritmaları, genetik algoritmalar (GA), genetik programlama (GP), evrimsel programlama (EP), evrimsel strateji (EV) ve benzerlerini içeren alt bölümlere ayrılabilir.

Genetik algoritmalar, biyolojik süreci modelleyerek fonksiyonları optimize eden evrim algoritmalarıdır. GA parametreleri, biyolojideki genleri temsil ederken, parametrelerin toplu kümesi de kromozomu oluşturmaktadır. GA'ların her bir ferdi kromozomlar (bireyler) şeklinde temsil edilen popülasyonlardan oluşur. Popülasyonun uygunluğu, belirli kurallar

dâhilinde maksimize veya minimize edilir. Her yeni nesil, rasgele bilgi değişimi ile oluşturulan diziler içinde hayatta kalanların birleştirilmesi ile elde edilmektedir (Angeline, 1995). GA'ların avantajları aşağıda verilmiştir (Cunkaş, 2006):

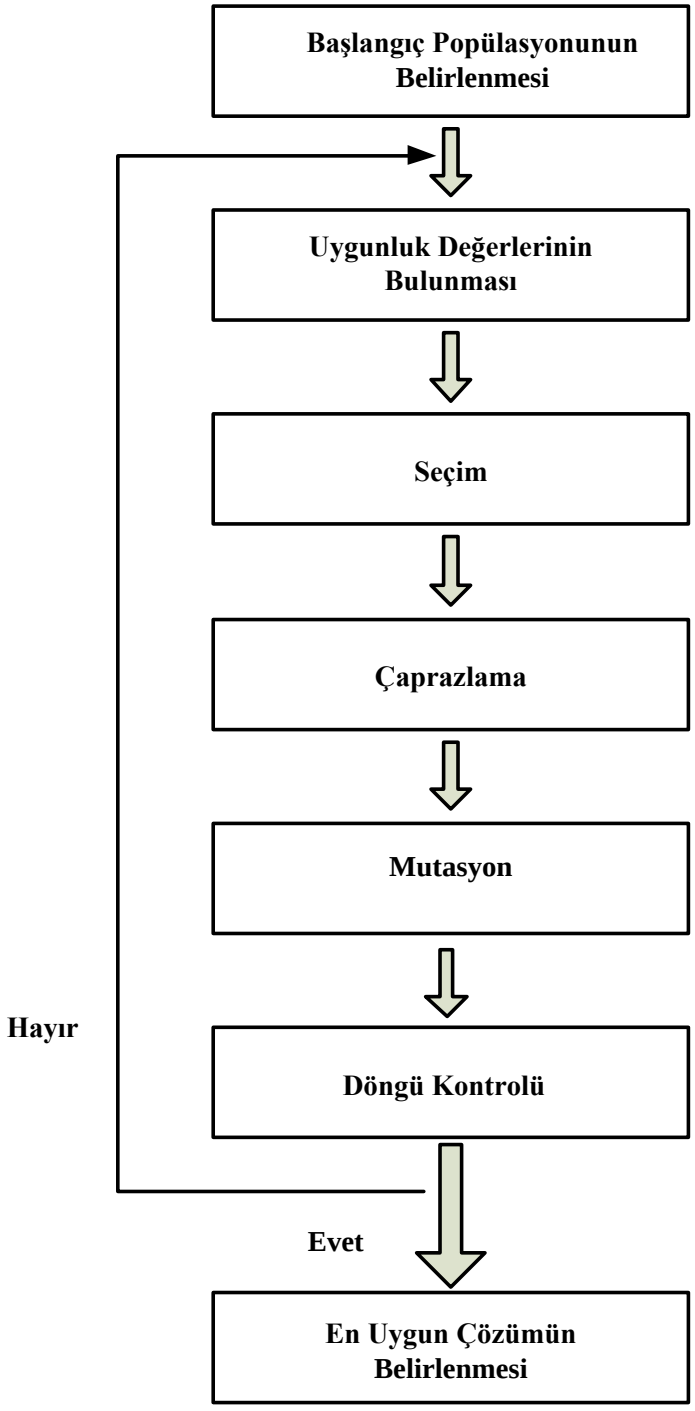
- Sürekli ve ayrık parametreleri optimize etmesi
- Türevsel bilgiler gerektirmemesi
- Amaç fonksiyonunu geniş bir spektrumda araştırması
- Çok sayıda parametrelerle çalışma imkânı olması
- Paralel PC 'ler kullanılarak çalıştırılabilmesi
- Karmaşık amaç fonksiyonu parametrelerini, lokal minimum veya maksimumlara takılmadan optimize edebilmesi
- Sadece tek çözüm değil, birden fazla parametrelerin optimum çözümlerini elde edebilmesi olarak sıralanabilir.

GA' lar arama ve optimizasyon için sezgisel yöntemlerdir. Geniş arama algoritmalarının aksine, genetik algoritmalar en iyiyi seçmek için tüm farklı durumları üretmez. Bundan dolayı, mükemmel çözüme ulaşamayabilir. Fakat zaman kısıtlamalarını hesaba katan en yakın çözümlerden biridir. GA lar şartlara uyum sağlayabilir. Bunun anlamı, önceden hiç bilgisi olmamasına karşın, olayları ve bilgiyi öğrenme ve toplama yeteneğine sahip olmasıdır (Cunkaş, 2006).

Her problemin çözümü için GA kullanmak iyi bir yol değildir. Birkaç parametreli analitik fonksiyonun çözümünde klasik metotlar daha hızlıdır. Böyle durumlarda, nümerik metotlar tercih edilmelidir. Paralel bilgisayarlar kullanılırsa GA daha hızlı sonuç verebilir (Cunkaş, 2006).

Genel olarak genetik algoritmalar seçim, çaprazlama ve mutasyon işlemlerinden oluşurlar. Bu algoritmalarda her çözüm bir dizi olarak kodlanır, bu dizilerin içerisinden bizim belirlediğimiz miktarda tesadüfi olarak bir popülasyon oluşturulur. Seçim operatörü, uygunluk değeri yüksek olan bireyleri çaprazlama işlemine sokar. Seçim operatörü başarının artması için yüksek uygunluk değerine sahip bireyleri belirler. Oluşturulan yeni bireylerden genetik çeşitlilik oluşturabilmek için mutasyon operatörü uygulanır. Bu sayede yeni bir popülasyon

elde edilir. Daha sonra bu bireylerin tekrar uygunluk değerleri hesaplanarak en iyi çözüm belirlenmiş olur. Şekil 4.6.'da GA'ın en temel akış diyagramı görülmektedir (Kılıç, 2008).




**Şekil 4.6.** Genetik algoritma akış diyagramı yapısı (Kılıç, 2008)

Temelde genetik algoritma operatörleri başlangıç popülasyonunun belirlenmesi, uygunluk değerlerinin bulunması, seçim, çaprazlama ve mutasyondur.

### 4.2.1. Başlangıç popülasyonunun belirlenmesi

Popülasyon, çözüm uzayı içerisinde kromozomların oluşturduğu çözüm kümesidir. Başlangıçta popülasyon rastgele seçilen kromozomlardan oluşturulur ve her bir adımda popülasyon yenilenir. Rastgele üretilen popülasyona ait parametreler, amaç fonksiyonunda yerine konularak uygunluk değerleri hesaplanır. Popülasyon küçük seçilirse, sistem optimum sonuca ulaşmayabilir, popülasyon büyük seçilirse de sistem yavaş çalışır. Bu nedenlerden dolayı başlangıç popülasyonunda kromozom sayısının seçimi önemlidir (Cunkaş, 2006).

### 4.2.2. Uygunluk değerlerinin bulunması

Başlangıç popülasyonu içindeki kromozomlarla bir kuşak oluşturduktan sonra, popülasyondaki her bir üyenin uygunluk değerinin hesaplanması sürecine uygunluk değerinin bulunması denir. Her problemin çözümü için bir uygunluk fonksiyonu belirlenir. Bu değer ne kadar yüksekse, yaşama ve çoğalma şansı o kadar fazladır ve sonraki kuşaklarda kullanılma oranı da o kadar yüksektir (Cunkaş, 2006).

### 4.2.3. Seçim

Genetik algoritmadaki temel yapı güçlü ve sağlıklı bireylerin yaşaması, bu bireylerden yeni yavruların elde edilmesidir. Eğer başlangıçta popülasyon fazla ise bazı iteratif adımların uygulanması gerekir. En uygun kromozom hayatta kalmalı diğerleri de yok olmalıdır. Algoritmanın her bir iterasyonunda (jenererasyonunda) doğal seçim uygulanır. Bu adımda ne kadar kromozomun elde tutulacağına karar vermek keyfidir. Genetik algoritmada çeşitli seçim yöntemleri vardır (Cunkaş, 2006).

a) ***Rasgele seçim:*** Kromozomların eşleştirilmesinde rasgele sayı üreteci kullanılır. Kromozomlar 1'den başlayarak N'e kadar sıralanır. N adet sayı üretilerek kromozomlarla eşleştirilir.

***b)*** ***Ağırlıklı seçim:*** Önce amaç fonksiyonunda, kromozomların uygunluk değerleri hesaplanır ve hesaplanan uygunluk değerleri en küçükten en büyüğe doğru sıraya konur. Çizelge 4.1.'de görüldüğü gibi $N_{pop} \leq N_{ipop}$ ise tutulur, geriye kalanlar atılır. Burada $N_{pop}$ değeri $N_{ipop}$'a kadar olabilir. Genelde popülasyonun %50'sinin seçilmesi ($N_{pop}=N_{ipop/2}$) uygun seçenektir. Seçilen $N_{pop}$'un yarısı $N_{iyi}$, yarısı da $N_{kötü}$ olarak ayrılır. $N_{iyi}$ olanlar eşleştirme havuzuna konurken $N_{kötü}$ olanlar eşleştirme havuzundan atılır. Toplam popülasyon sayısı $N_{ipop}=24$'dür. GA'nın her bir iterasyonunda popülasyonun 12'si tutulur ve bu kromozomların altı tanesi eşleştirme havuzuna atılır (Cunkaş, 2006).

**Çizelge 4.1.** Kromozomların uygunluk değerlerine göre sıralanışı (Haupt, 1998)

| Kromozomlar | Uygunluk Değerleri |
|---|---|
| $N_{iyi}$ 00100110011101 | −13778 |
| $N_{iyi}$ 00010100011011 | −13360 |
| $N_{iyi}$ 01010110000100 | −13338 |
| $N_{iyi}$ 00010110000010 | −13225 |
| $N_{iyi}$ 00001101010110 | −13166 |
| $N_{iyi}$ 00010000110101 | −13164 |
| $N_{kötü}$ 01101111000010 | −13079 |
| $N_{kötü}$ 00000000000000 | −13000 |
| $N_{kötü}$ 01111100111100 | −12953 |
| $N_{kötü}$ 01101100110010 | −12927 |
| $N_{kötü}$ 00100001011110 | −12891 |
| $N_{kötü}$ 10100000000011 | −12857 |
| $N_{ipop}$ 10001110111010 | −12759 |
| 10001001011111 | −12756 |
| 01000111010001 | -12700 |
| 01111111101001 | -12560 |
| 11000011001100 | -12452 |
| 11000011001010 | -12347 |
| 10011101110000 | -12335 |
| 10111000111100 | -12320 |
| 01110010101011 | -12220 |
| 11101111001110 | -11890 |
| 11111011010010 | -11800 |
| 11011011101000 | -11797 |

***c)*** ***Ağırlıklı rasgele seçim:*** Bu yöntem, eşleştirme havuzundaki kromozomların, amaç fonksiyonunda hesaplanan uygunluk değerlerine göre seçilme ihtimallerini dikkate alır. En düşük uygunluk değerine sahip kromozom, eşleştirme ihtimali en yüksek kromozom olurken en yüksek uygunluk değerine sahip kromozom eşleştirme ihtimali

en düşük olarak düşünülür. Üretilen rasgele sayı, hangi kromozomun seçileceğini belirler.

***d) Eşik değer seçim:*** Bu teknikte eşik değerden küçük olan kromozomlar yaşamaya devam ederken, eşik değerini aşan kromozomlar ölür. Bu teknikte popülasyonun sıralanmasına gerek yoktur.

***e) Rulet tekerleği seçimi:*** Rulet tekerleği yöntemi en çok kullanılan seçim yöntemlerinden biridir. Bu metodun uygulanması için, önce kromozomların toplam uygunluk değeri hesaplanır. Kromozomlar, toplam uygunluk değerine bölünerek her bir kromozom için 0–1 arasında değişen seçim ihtimalleri bulunur. Daha sonra, kümülatif ihtimaller hesaplanır. Popülasyon sayısı kadar "rasgele" 0-1 arasında sayılar üretilir. Üretilen rasgele sayı, birinci kromozomun kümülatif seçim ihtimalinden küçük ise, birinci kromozom seçilir. Eğer değilse, ikinci kromozomun veya diğerlerinin kümülatif ihtimalleriyle karşılaştırılarak hangisinden küçükse o kromozom seçilir. Böylece Rulet seçim metodu gerçekleştirilmiş olur (Cunkaş, 2006).

***f) Turnuva seçimi:*** Bu yöntemde bir grup k bireyi rasgele olarak seçilir. Bu k bireyleri daha sonra bir turnuvaya katılır ve en iyi uygunluklu birey seçilir. Çaprazlama için iki turnuva tutulur. Bunlardan biri her bir ebeveyni seçmek içindir. Bir kereden daha fazla üretmek için seçilebilecek bir ebeveyn mümkündür. Turnuva seçiminin avantajı, popülasyonun daha kötü bireylerinin seçilmeyecek olması ve bundan dolayı sonraki neslin genetik yapısına katılmayacak olmasıdır. Ayrıca en iyi bireyler tekrar üretim sürecinde baskın olmayacaktır (Cunkaş, 2006).

***g) Seçkinlik(elitism):*** Bu işlem, şu anki nesilden sonraki nesle aktarılan bir grup bireyin seçimini kapsar. Mutasyona uğratılmaksızın, sonraki nesle aktarılan bireylerin sayısı, nesil boşluğu olarak işaret edilir. Eğer nesil boşluğu sıfırsa; yeni nesil, yeni bireylerin girişleriyle oluşur. Pozitif nesil boşlukları bireyleri sonraki nesle aktarılır.

### 4.2.4. Çaprazlama

Yeni nesil elde etmek için kromozomların bulunduğu eşleme havuzundan iki adet kromozom seçilir. Eşleme sürecinde, seçilen kromozomlardan bir ve birden fazla yeni nesil

oluşturma olayına “çaprazlama” denir. En yaygın olarak kullanılan iki kromozomdan iki tane yeni nesil elde edilmesidir. Öncelikle kromozomun ilk biti ile son biti arasında çaprazlama noktası rasgele seçilir. Birinci kromozomun çaprazlama noktasının solundaki bitlerin hepsi ikinci kromozoma geçerken, benzer tarzda ikinci kromozomun çaprazlama noktasının solundaki bitler de birinci kromozoma geçerler. Sonuçta meydana gelen yeni kromozomlar, her iki kromozomun karakterlerini içermektedirler. Çaprazlama oranı, bir popülasyonda ne kadar kromozomun çaprazlamaya tabi tutulacağını belirler (Cunkaş, 2006).

### 4.2.5. Mutasyon

Çaprazlama operatörü mevcut genlerde en iyi çözüme ulaşmayı amaçlar. Fakat, çaprazlama sonucunda yenilenen popülasyon kodlanmış bilginin tamamını içermeyebilir. Bulanık durumda istenilen sonuca ulaşamayabiliriz. Mevcut kromozomları mutasyona uğratarak bitler üzerinde değişiklik yaparak istenilen sonuca ulaşabiliriz. Mutasyon, yeni elde edilecek çözümlerin, önceki çözümü kopyalamasını engellemek ve istenilen sonuca daha hızlı varmak amacıyla yapılan bir genetik algoritma operatörüdür. Basit anlamda mutasyon, çaprazlama sonucunda oluşan yeni bireyin bir bitini rastgele değiştirmektir. Mutasyon operatörü, bir daha elde edilemeyecek sonuçların kaybına karşı koruma sağlamaktır (Goldberg, 1989).

GA operatörlerinin ikincisi olan mutasyon, kromozomdaki bitlerin küçük bir yüzdesini değiştirir. Mutasyon ile kromozomdaki bitler “1” ise “0”, “0” ise “1” yapılır. $N_{pop}xN_{bit}$’lik bir popülasyon matrisinde, mutasyon noktaları rasgele seçilir. Mutasyonun % değeri artırılırsa, algoritma daha geniş parametre uzayını tarama yapar. Son iterasyonda mutasyon meydana gelmez (Cunkaş, 2006).

# 5. MAMOGRAM ÜZERİNDE GÖRÜNTÜ İŞLEME TEKNİKLERİ

Dünya genelinde yaklaşık olarak meme kanserinin %80-85'i mamografi görüntüleme tekniği ile yapılmakta ve tümörlerin %10-25'i radyologlar tarafından gözden kaçırılmaktadır (Younesi ve ark., 2007). Mamogram, üç boyutlu meme yapısının iki boyutlu görüntüye dönüştürülmüş hali olduğundan dolayı bazı hatalar oluşmaktadır. Özellikle dokuların üst üste gelmesinden dolayı bazı belirtiler gözden kaçabilmektedir. Görüntü üzerindeki kontrast problemleri de en sık karşılaşılan durumdur. Yüksek kontrastlı görüntülerde mikrokalsifikasyonların görülmesi, düşük kontrastlı görüntülerde ise lezyonların ve sınırlarının belirlenmesi zorlaşmaktadır. Ayrıca görüntüdeki ayrıntıları yakalamak için yüksek çözünürlüklü çekimler gerekmektedir. Mamogramlar üzerindeki etiketlerler de görüntünün değerlendirilmesinde, özellikle histogram analizlerinde ciddi hatalar oluşturmaktadır.

Mamogram görüntülerini daha hızlı ve hatasız değerlendirmek için bazı görüntü işleme tekniklerinin uygulanması gerekmektedir. Görüntü iyileştirme, süzgeçleme, kenar belirleme, histogram temelli çalışmalar, görüntünün arka planındaki etiket ve istenmeyen bölgelerin çıkarılması, pektoral kas bölgelerin çıkarılması en temel görüntü işleme tekniklerindendir.

## 5.1. Görüntü İyileştirme

Görüntü iyileştirme, çeşitli nedenlerden dolayı kullanışsız olan görüntüyü kullanılabilir bir görüntü haline dönüştürmek amacıyla yapılan işlemlerdir (Arslan, 2011). $f(x,y)$ giriş görüntüsü, $T$ operatör, $g(x,y)$ işlenmiş görüntü olmak üzere görüntü iyileştirme matematiksel olarak eşitlik (5.1)' deki gibi ifade edilebilir (Gonzales ve Woods, 2002).

$$g(x,y) = T\left[ f(x,y) \right] \tag{5.1}$$

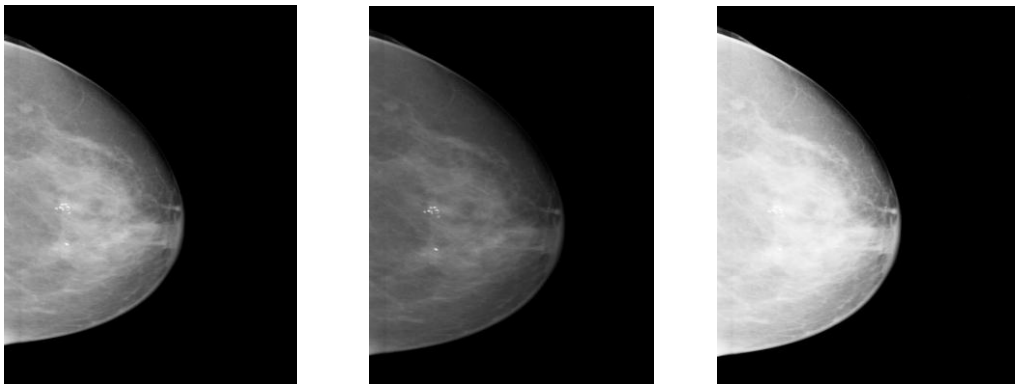
Görüntü iyileştirme yöntemleri genelde ön-işlem aşamasında yapılan çalışmalardır. Görüntü iyileştirme teknikleri seçilirken, verilerin karakterleri göz önünde bulundurularak uygulanmalıdır. Bu nedenle, modern görüntü iyileştirme sistemlerinde işlem sırasında parametrelerin değiştirilmesine imkân sağlayan etkileşimli uygulamalar geliştirilmektedir.

### 5.1.1. Parlaklık

Parlaklık değişimi görüntünün parlaklık değerlerinin belirli bir sayıyla toplanması veya çıkarılması ile gerçekleştirilir. $f(x,y)$ giriş görüntüsü, $g(x,y)$ parlaklık ayarı yapılmış olan görüntü olmak üzere eşitlik (5.2)' deki gibi ifade edilebilir (Gonzales ve Woods, 2002).

$$g(x,y) = f(x,y) + b \tag{5.2}$$

Parlaklığı artırmak için $b > 0$, parlaklığı azaltmak için de $b < 0$ olacak şekilde $b$ değeri seçilir. Şekil 5.1.'de parlaklık ayarları değiştirilen mamogram görüntüsü verilmiştir.



**(a)** **(b)** **(c)**

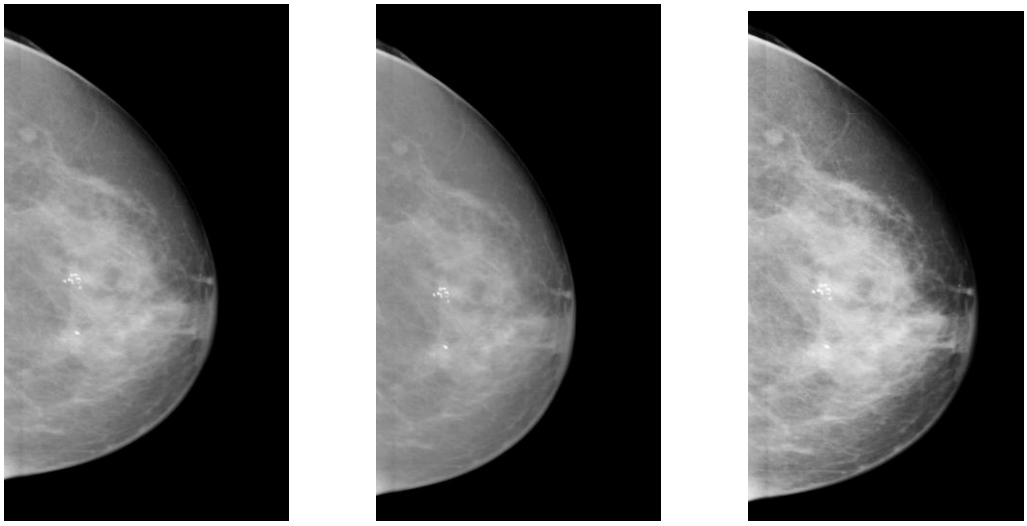
**Şekil 5.1. (a)** Orijinal mamogram görüntüsü **(b)** b=-80 değeri almış mamogram görüntüsü **(c)** b=80 değeri almış mamogram görüntüsü

### 5.1.2. Karşıtlık

Karşıtlık değeri görüntünün parlaklık değerlerinin belirli bir sayıyla çarpılması ile elde edilir.

$$g(x,y) = a \times f(x,y) \tag{5.3}$$

Karşıtlık değerinde eğer $a > 0$ seçilirse contrast artar, $a < 0$ seçilirse contrast azalır. Şekil 5.2.'de karşıtlık ayarları değiştirilen mamogram görüntüsü verilmiştir.



**(a)** **(b)** **(c)**

**Şekil 5.2. (a)** Orijinal mamogram görüntüsü **(b)** a=-45 değeri almış mamogram görüntüsü **(c)** a=95 değeri almış mamogram görüntüsü

### 5.1.3. Eşikleme

Eşikleme tekniği bir görüntüye uygulamadan önce görüntü gri değer verilerini içeren matris formuna dönüştürülür. Bu matriste siyah 0, beyaz 1 ile ifade edilir. Eşikleme işlemi uygulanırken belirlenen değerin altındaki değerler için çıkış 0, üstündeki değerler için ise 1 değeri atanır.

İşlenen görüntünün özelliklerine göre eşik değeri [0, 255] aralığında istenilen bir değer belirlenebilir. Şekil 5.3.'de eşik değerleri 85 ve 190 olarak seçilmiş mamogram görüntüleri verilmiştir.



**(a)** **(b)** **(c)**

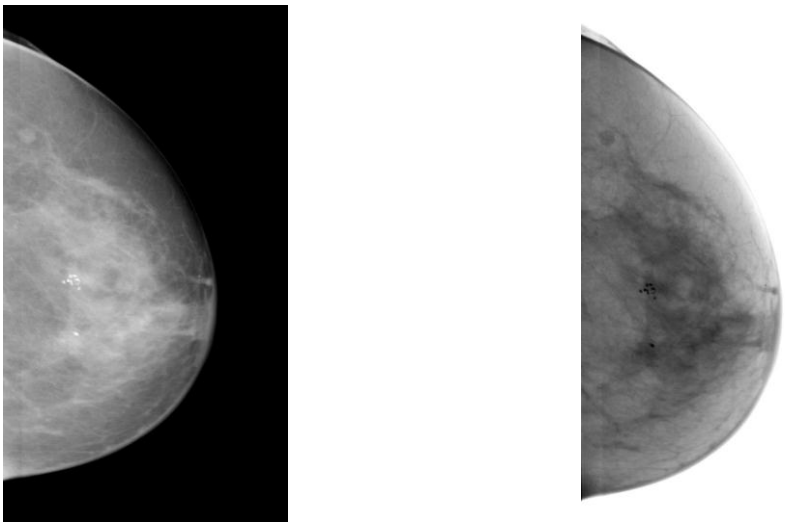
**Şekil 5.3. (a)** Orijinal mamogram görüntüsü **(b)** Eşik değeri =85 belirlenmiş mamogram görüntüsü **(c)** Eşik değeri =190 belirlenmiş mamogram görüntüsü

### 5.1.4. Negatifleştirme

Bir görüntüyü negatifleştirme için, her bir noktan renginin tümleyeni alınır. Yani skala büyüklüğü $L$ ise, rengin değeri $L$ değerinden çıkarılarak her bir noktanın tersi bulunmuş olur. $f(x,y)$ görüntünün kendisini, $g(x,y)$ ise negatifleşmiş görüntüyü ifade ediyor olsun. Bu durumda negatifleştirme işlemi matematiksel olarak eşitlik (5.4)'deki gibi ifade edilebilir (Arslan, 2011).

$$g(x,y) = L - f(x,y) \tag{5.4}$$

Özellikle biyomedikal görüntülerde negatifleştirme oldukça fazla kullanılan bir yöntemdir. Şekil 5.4.'de negatifleştirme işlemine uygulanmış bir mamogram görüntüsü verilmiştir.



**(a)** **(b)**

**Şekil 5.4. (a)** Orijinal mamogram görüntüsü **(b)** Negatifleştirilmiş mamogram görüntüsü

### 5.1.5. Piksel komşuluk işlemleri

Parlaklık, karşıtlık, negatifleştirme gibi görüntü iyileştirme işlemlerinde temelde ilgili pikselin değeri değerlendirilmektedir. Piksel temelli komşuluk işlemlerinde ise ilgili pikselin yeni değeri, komşu piksellerin değerleri de dikkate alınarak hesaplanmaktadır. Hangi komşuların nasıl kullanılacağı seçilen piksel komşuluk işlemine bağlı olarak belirlenir.

Piksel komşuluk işleminde konvolüsyon önemli bir uygulama alanına sahiptir. Konvolüsyon, yumuşatma, keskinleştirme, kenar belirleme gibi görüntü işleme fonksiyonlarını gerçekleştirmede çok sık kullanılmaktadır. Konvolüsyonda bir pikselin yeni değeri kendisinin ve çevresindeki piksellerin ağırlıklı ortalaması ile bulunmaktadır. Piksellerin ağırlıkları konvolüsyon şablonu (kerneli) olarak adlandırılan bir matris ile belirlenir. Konvolüsyon şablonu, uygulamaya göre farklı boyutlarda seçilebilen, genelde 3x3'lük bir matristir. Görüntü üzerinde konvolüsyon işleminin matematiksel ifadesi eşitlik (5.5)'de verilmiştir (Arslan, 2011).

$$g(x,y) = \sum_{j=-n}^{n} \sum_{i=-m}^{m} k(i,j)\, f(x-i, y-j) = k * f \qquad (5.5)$$

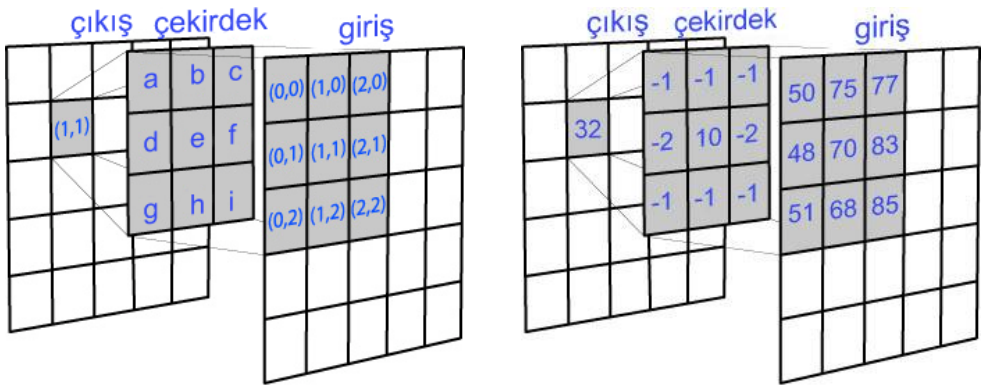
$$m = \frac{(w-1)}{2}, \quad n = \frac{(h-1)}{2}$$

Eşitlik (5.5)'de $k$ konvolüsyon kerneli (çekirdek), $f$ işlenecek görüntü ve $w,h$ görüntü piksel boyutunu ifade etmektedir.

Şekil 5.5.'de görüntü üzerindeki bir piksel için konvolüsyon işlemi görülmektedir. Şablon matris ve matrisin üzerinde bulunduğu görüntü matrisinin konvolüsyonu sonucu elde edilen piksel değeri eşitlik (5.6)'da verilmektedir. Bu işlem görüntü üzerinde tüm piksellere uygulanarak görüntü üzerinde 2 boyutlu konvolüsyon işlemi yapılmış olur.

$$imge = \begin{bmatrix} i(0,0) & i(0,1) & i(0,2) \\ i(1,0) & i(1,1) & i(1,2) \\ i(2,0) & i(2,1) & i(2,2) \end{bmatrix} = \begin{bmatrix} 55 & 75 & 77 \\ 48 & 70 & 83 \\ 51 & 68 & 85 \end{bmatrix} \qquad çekirdek = \begin{bmatrix} -1 & -1 & -1 \\ -2 & 10 & -2 \\ -1 & -1 & -1 \end{bmatrix} \qquad (5.6)$$

$$i(1,1) = (-1x55) + (-1x75) + (-1x77) + (-2x48) + (10x70) + (-2x83) + (-1x51) + (-1x68) + (-1x85) = 32$$




**Şekil 5.5.** Görüntü üzerinde konvolüsyon işlemi

## 5.2. Kenar Bulma

Kenar bulma, bölütleme, sınıflandırma, hedef izleme, nesne tanıma gibi görüntü işleme uygulamalarında önemli bir yer tutmaktadır. Kenar bulma, görüntülerde piksel değerlerindeki değişimlerin gerçekleştiği yerlerin belirlenmesidir (Şenel, 2007). Görüntü içinde belirgin geçişler nesne kenarlarını gösterdiğinden, kenar bulma algoritmaları bu geçişleri bulmayı amaçlamaktadır. Görüntülerdeki kenarları bulmanın temel amacı, görüntü içerisinde istenilen detayları ortaya çıkarmak, istenmeyen detayları ise ortadan kaldırmaktır.

Ayrıca görüntüye kenar belirleme algoritmalarını uygulamak suretiyle görüntüdeki nesneler ya da farklılıklar elde edilmektedir.

Kenar bulma işlemi için çok çeşitli algoritmalar ortaya konmuş ve uygulamaları yapılmıştır (Canny, 1986; Perona ve Malik, 1990; Lu ve Jain, 1992; Mallat ve Zhong, 1992). Başlıca kenar belirleme algoritmaları gradyan tabanlı kenar belirleme algoritmaları, laplacian tabanlı kenar belirleme algoritmaları ve canny kenar belirleme algoritması olarak üç grupta incelenebilir.

### 5.2.1. Gradyan tabanlı kenar belirleme algoritmaları

Kenar tespit işlemi temelde bir görüntüdeki yoğunluk seviyelerindeki önemli yerel değişimlerin tespit edilmesidir. Yoğunluk seviyesindeki değişim, görüntünün gradyanı ile ölçülür. İki boyutlu bir görüntü *f(x,y)* ise bu görüntünün gradyanı aşağıdaki gibi bir vektör olarak tanımlanabilir (Karabiber, 2005).

$$\begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{df}{dx} \\ \frac{df}{dy} \end{bmatrix} \tag{5.7}$$

Gradyanın büyüklüğü eşitlik (5.8)'de tanımlanmıştır.

$$\begin{aligned} G|f(x,y)| &= \sqrt{G_x^{\,2} + G_y^{\,2}} \\ G|f(x,y)| &= |G_x| + |G_y| \\ G|f(x,y)| &= \max\{|G_x|, |G_y|\} \end{aligned} \tag{5.8}$$

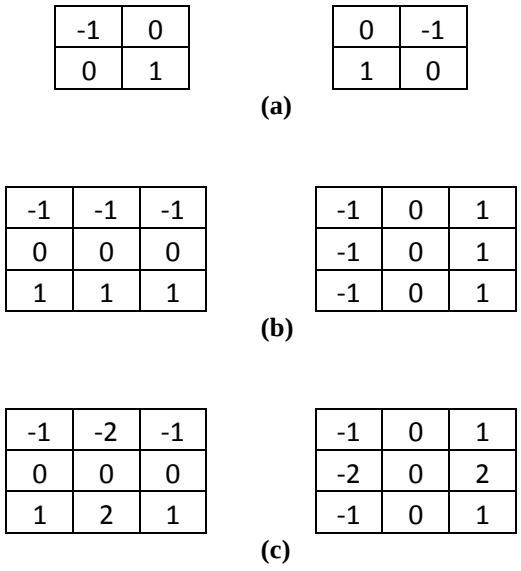
Gradyanın doğrultusu ise aşağıda verilen eşitlik (5.9)'da tanımlanmıştır.

$$\theta(x,y) = \tan^{-1}(G_x / G_y) \tag{5.9}$$

Gradyan operatörleri, biri *x* ve *y* eksenlerindeki gradyanı elde etmek için kullanılan iki maskeye ihtiyaç duyarlar. Bu iki gradyan, büyüklüğü görüntüdeki bir noktadaki kenar gradyanının kuvvetini gösteren ve açısı gradyan açısını gösteren bir vektör büyüklüğünü elde etmek için birleştirilir.

Kenar gradyanlarının hesaplanmasına alternatif bir yaklaşım, görüntünün farklı doğrultularda seçilen 2x2, 3x3… gibi küçük boyutlu matrisler ile konvolüsyona sokulmasını içerir. Her şablon belirli bir yöndeki kenarların bulunmasını sağlar.

Kenar Belirleme Robert, Prewitt ve Sobel en sık kullanılan gradyan tabanlı operatörlerdir. Roberts 2x2'lik bir maske kullanmaktadır ve Şekil 5.6. (a)'da gösterilmiştir. Prewitt operatörü Şekil 5.6. (b)'de gösterilmiştir. Sobel operatörü de 3x3 boyutunda, Şekil 5.6. (c)'de gösterilen bir maskedir.




**Şekil 5.6**. Gradyan tabanlı kenar belirleme operatörleri **(a)** Roberts operatörleri **(b)** Prewitt operatörleri **(c)** Sobel operatörleri

Kenar belirleme için kullanılan operatörlerden biri kullanılarak görüntünün gradyanı hesaplandıktan sonra eşikleme ile kenarlar tespit edilmeye çalışılır. Görüntüdeki her bir nokta için gradyanın büyüklüğü ile bir eşik değeri karşılaştırılır. Karşılaştırılan noktanın değeri seçilen eşik değerinden büyükse bu noktada bir kenar noktasının var olduğu, aksi halde kenar

noktasının olmadığı tespit edilir. Eşik değerinin seçilmesi kenarların iyi bir şekilde elde edilmesi için son derece önemlidir. Eğer seçilen eşik değeri büyükse, doğru kenar noktalarının tespit edilememe olasılığı vardır. Benzer şekilde seçilen eşik değeri küçükse, pek çok gürültülü noktanın yanlışlıkla kenar noktası olarak tespit edilmesi mümkündür. Bu nedenle eşik değerinin optimum olacak şekilde seçilmesi ideal bir kenar belirleyici için son derece önemlidir.

### 5.2.2. Laplacian tabanlı kenar belirleme algoritmaları

Laplacian filtreler görüntüdeki belirgin geçişleri bulmak için kullanılan ikinci türev tabanlı filtrelerdir. İki boyutlu bir $f(x,y)$ fonksiyonunun ikinci derece türevi aşağıdaki eşitlikte gösterildiği gibi tanımlanır (Karabiber, 2005):

$$L(x,y) = \nabla^2 f(x,y) = \frac{\partial^2 f(x,y)}{\partial x^2} + \frac{\partial^2 f(x,y)}{\partial y^2} \qquad (5.10)$$

Laplacian'i bir konvolüsyon filtresi kullanılarak da bulunabilir. Bu değere erişmek için kullanılan konvolüsyon maskesi Şekil 5.7.'de verildiği gibidir.

| | | |
|---|---|---|
| 0 | -1 | 0 |
| -1 | 4 | -1 |
| 0 | -1 | 0 |

| | | |
|---|---|---|
| -1 | -1 | -1 |
| -1 | 8 | -1 |
| -1 | -1 | -1 |

**Şekil 5.7.** Laplacian maskeleri

Bu maskelerden biri kullanılarak, standart konvolüsyon metotları kullanılarak görüntü fonksiyonunun laplacian'ını hesaplamak mümkündür. Bu maskeler görüntünün ikinci türev değerine yaklaştığı için gürültüye oldukça duyarlıdır. Gürültüyü azaltmak için genellikle görüntü laplacian filtresinden önce Gaussian filtresi gibi bir filtreden geçirilerek görüntüdeki yüksek frekanslı gürültü bileşenleri azaltılarak yumuşatılır. Önce Gaussian daha sonra Laplacian filtrelerinden geçirilerek iki aşama sonucu elde edilen filtreleme işlemine LoG

(Laplacian of Gaussian) filtreleme metodu denilmektedir. Sıfır merkezli olmak üzere iki boyutlu (2-D) bir LoG fonksiyonu aşağıdaki gibi tanımlanır (Arslan, 2011):

$$LoG(x,y) = -\frac{1}{\pi\sigma^4}\left[1-\frac{x^2+y^2}{2\sigma^2}\right]e^{-\frac{x^2+y^2}{2\sigma^2}} \tag{5.11}$$

Burada $\sigma$ Gaussian standart sapması'dır. Aynı şekilde maske kullanılarak da bu işlem gerçekleştirilebilir. Konvolüsyon işleminde kullanılabilen farklı LoG maskeleri Şekil 5.8.'de görülmektedir

| | | |
|---|---|---|
| 0 | -1 | 0 |
| -1 | 5 | -1 |
| 0 | -1 | 0 |

| | | |
|---|---|---|
| -1 | -1 | -1 |
| -1 | 8 | -1 |
| -1 | -1 | -1 |

**Şekil 5.8**. LoG maskeleri (Arslan, 2011)

### 5.2.3. Canny kenar belirleme algoritması

Hata oranı en az ve iyi sonuç veren kenar bulma algoritmalardan biri olarak Canny algoritması, en iyi kenar belirleme filtrelerinden biri olarak kabul görmektedir (Arslan, 2011).

Bu algoritma yumuşatma, gradyanın hesaplanması, maksimum olmayan noktaların bastırılması ve eşikleme olmak üzere 4 adımda uygulanır.

#### 1. Yumuşatma

Görüntüye bir Gaussian filtresi yardımıyla yumuşatma işlemi yapılır. $I[i,j]$ orijinal görüntü, $G[i,j,\sigma]$ Gaussian yumuşatıcı filtre ve $\sigma$ Gaussian filtresinin standart sapması (yumuşatma derecesi) olmak üzere, orijinal $I[i,j]$ görüntüsü ve $G[i,j,\sigma]$ filtresinin konvolüsyonu sonucu elde edilen yumuşatılmış görüntü $S[i,j]$ ile ifade edilmektedir (Arslan, 2011).

$$S[i,j] = G[i,j,\sigma] * I[i,j] \tag{5.12}$$

**2. Gradyanın hesaplanması**

Kısmi türevler için sonlu-fark yaklaşımları kullanılarak gradyan büyüklüğü ve yönü hesaplanır. İlk olarak eşitlik 5.12'de verilen $S[i,j]$'nin kısmi türevleri elde edilir (Arslan, 2011). Bunlar:

$$\begin{aligned} P[i,j] &\approx (S[i,j+1] - S[i,j] + S[i+1,j+1] - S[i+1,j])/2 \\ Q[i,j] &\approx (S[i,j] - S[i+1,j] + S[i,j+1] - S[i+1,j+1])/2 \end{aligned} \tag{5.13}$$

şeklindedir. x ve y kısmi türevleri 2x2'lik kare matris üzerindeki sonlu farkların ortalaması alınarak hesaplanır. Buna göre gradyanın büyüklük değeri:

$$M(i,j) = \sqrt{P[i,j]^2 + Q[i,j]^2} \tag{5.14}$$

ve açısı:

$$Q[i,j] = \arctan(Q[i,j], P[i,j]) \tag{5.15}$$

olur.

**3. Maksimum olmayan noktaların bastırılması**

Görüntünün büyüklük değerinde maksimum olmayan noktaların bastırılması işlemi uygulanır. Gradyan algoritmasında, giriş görüntüsünün büyüklük değerinin gradyanı alınarak kenar pikselleri belirlemek mümkündü. Fakat Canny metodu karmaşık bir yaklaşıma sahiptir. Bu yaklaşıma göre bir kenar noktası, şiddeti gradyan vektörü yönünde lokal olarak maksimum olan bir nokta olarak düşünülebilir. Bu durum oldukça kısıtlayıcı bir durumdur ve eşikleme

yöntemiyle bulunan kenar piksellerinden oluşan çizgileri inceltmek için kullanılan bu işleme Maksimum Olmayan Noktaların Bastırılması adı verilir. Bu işlemden sonra elde edilen $N[i, j]$ görüntüsü aşağıdaki gibidir (Arslan, 2011):

$$N[i, j] = nms(M[i, j], \xi[i, j]) \tag{5.16}$$

Yerel maksimum noktaları olarak kabul edilen noktalarda bu değer sıfırdır.

**4. Eşikleme**

Kenar pikselleri bulmak için çift eşikleme algoritması kullanılır. Canny kenar belirleme algoritması işaret gürültü oranını optimize edecek şekilde tasarlanmıştır. İlk adımda yumuşatma işlemi gerçekleştirilmesine rağmen, maksimum olmayan noktaları bastırılmış olan $N[i, j]$ görüntüsünde, gürültüler nedeniyle bazı hatalı kenar noktaların oluşması olasıdır. Bu hatalı kenar noktaların etkisi çok fazla değildir. Maksimum olmayan noktaları bastırılmış bu görüntüdeki hatalı kenar noktaları azaltmak gerekmektedir. Bunları azaltmanın yöntemi $N[i, j]$'ye bir eşik değeri uygulayarak eşik değerinin altındaki bütün noktaları sıfır yapmaktır.

Maksimum olmayan noktaları bastırılmış görüntüye eşikleme işlemi uyguladıktan sonra elde edilen görüntü yani $E(i, j)$ kenarları belirginleşmiş bir görüntü haline gelmiştir. Ancak bu metotta uygun eşik değerini bulmak zordur, deneme yoluyla bulmak gerekmektedir. Eğer eşik değerini çok küçük seçersek, $E(i, j)$ görüntüsünde karşılaşılan yanlış kenarlar fazla olur, eşik değerini çok büyük seçersek de bazı kenarlar kaybolabilir (Arslan, 2011).

## 5.3. Süzgeçleme İşlemleri

### 5.3.1. Ortanca süzgeçleme

Görüntü ve sinyal işleme konularında, gürültü temizlemek için kullanılan yöntemlerden birisidir. Amaç belirli bir pencere aralığındaki sayıların ortancasını alarak aşırı büyük atlamaları kaldırmaktır. Ortanca süzgeçlemede, bir pikselin değeri, o piksele komşu

alanlardaki gri seviyelerin ortanca değeri ile değiştirilir. Ortanca süzgeçleme oldukça popülerlerdir, çünkü belli bazı rastgele gürültü için bunlar mükemmel gürültü azaltma kabiliyeti gösterirler ve benzer boyuttaki lineer düzeltme filtrelerine göre çok daha az bulanıklığa neden olurlar. Ortanca süzgeçleme imaj üzerinde beyaz ve siyah noktalar halinde görünen ve tuz ve biber gürültüsü olarak da adlandırılan özellikle darbe gürültüsünün mevcut olduğu haller de etkilidirler.

Bir $f(x,y)$ görüntüsü üzerine $(m,n)$ boyutunda bir T matrisi ile ortanca süzgeç uygulandığında elde edilen görüntü $g(x,y)$ ise (Özşen, 2002):

$$g(x,y) = or\tan ca\{ f(x-m,y-n) \mid (m,n) \in T \} \qquad (5.17)$$

şeklinde ifade edilir.

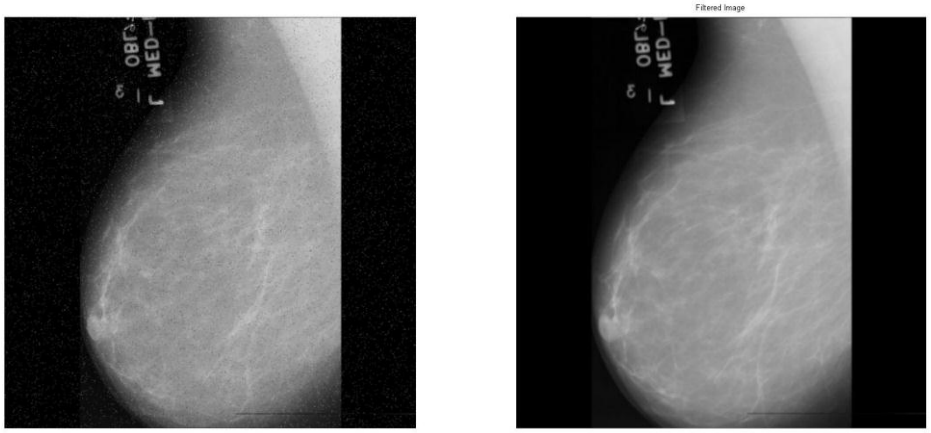
3*x*3 'lük bir matris kullanarak ortanca süzgeç yönteminin bir uygulamasını yapacak olursak, önce matris içinde elemanlar küçükten büyüğe doğru sıralanır ve ortanca eleman bulunur. Bulunan bu değer 3*x*3 'lük matrisin ortadaki elemanıyla değiştirilir (Özşen, 2002).

| | | |
|---|---|---|
| 20 | 43 | 21 |
| 12 | 30 | 50 |
| 40 | 17 | 28 |

12 17 20 1 28 30 40 43 50 sıralamasında ortanca değer 28'dir. Ortadaki 30 değeri 28 değeri ile değiştirilerek aşağıdaki matris oluşturulur.

| | | |
|---|---|---|
| 20 | 43 | 21 |
| 12 | 28 | 50 |
| 40 | 17 | 28 |

Ortanca süzgeçleme ile mamogram görüntüleri üzerinde gürültü filtrelemede iyi sonuçlar elde edilmekte, fakat görüntünün kenarlarındaki bazı piksellerde kayıplar olmaktadır (Bovik ve ark., 1978). Şekil 5.9.'da bir mamogram görüntüsü ve bu görüntüye ortanca süzgeç uygulandıktan sonraki hali görünmektedir.




**(a)** **(b)**

**Şekil 5.9.(a)** Orijinal mamogram görüntüsü **(b)** Ortanca süzgeçleme uygulanmış mamogram görüntüsü

### 5.3.2. Gauss bulanıklık algoritması

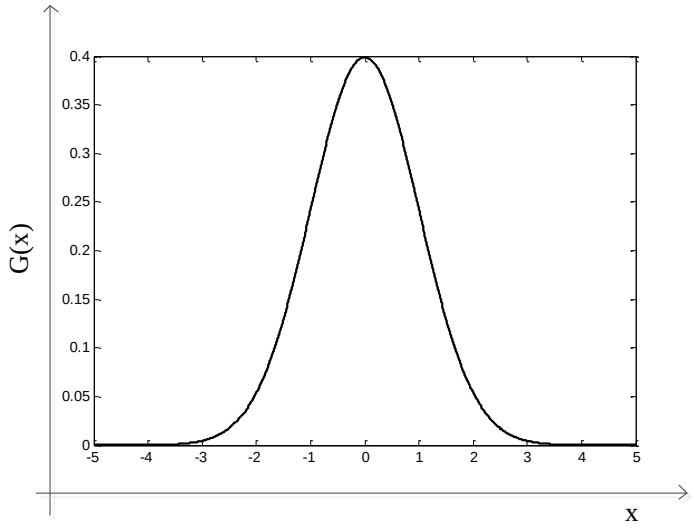
Gauss Bulanıklık Algoritması gelişmiş komşuluk ve piksel temeline dayanan bir filtredir. Görüntü işleme alanında yaygın bir şekilde ön-işlem aşamasında kullanılmaktadır. Gauss Bulanıklık Algoritması dönüşüm işleminde gauss fonksiyonunu kullanır. Bu durum birçok harmonik yapısının ortaya çıkmasına neden olur. Her bir pikselin değeri, komşularının ağırlıklarının ortalama değerine dönüştürülür. Matematikte, görüntü fonksiyonu $f(x)$'in konvolüsyonu olan bulanık fonksiyon $g(x)$'in ifadesi aşağıdaki eşitlik (5.18a)'deki gibidir.

$$g(x) : (f * g)(x) = \int f(s)g(x-s) \qquad (5.18a)$$

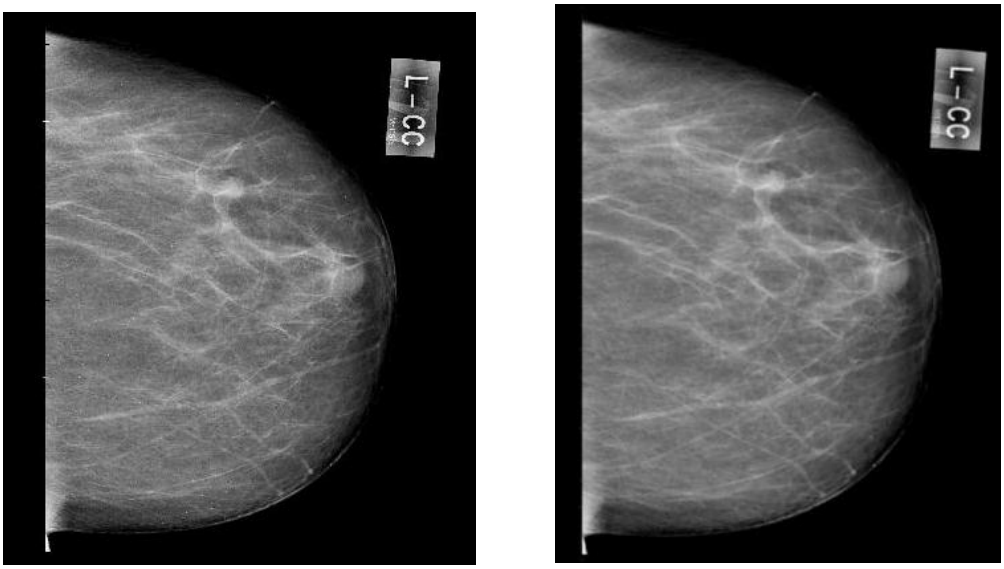
Gauss bulanıklık fonksiyonunun denklemi eşitlik (5.18b)'deki gibidir. Denklemde $\mu$ beklenen değer, $\sigma$ ise standart sapmadır. Şekil 5.11.'de bir mamogram görüntüsü ve bu görüntüye Gauss Bulanıklık Algoritması uygulandıktan sonraki hali görünmektedir.

$$g_{\mu,\sigma}(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \qquad (5.18b)$$

Şekil 5.10.'da $\sigma = 1$ için gauss fonksiyonu verilmiştir.




**Şekil 5.10.** $\sigma = 1$ için gauss fonksiyonu




**(a)** **(b)**

**Şekil 5.11. (a)** Orijinal mamogram görüntüsü **(b)** Gauss bulanıklık algoritması uygulanmış mamogram görüntüsü

## 5.4. Histogram

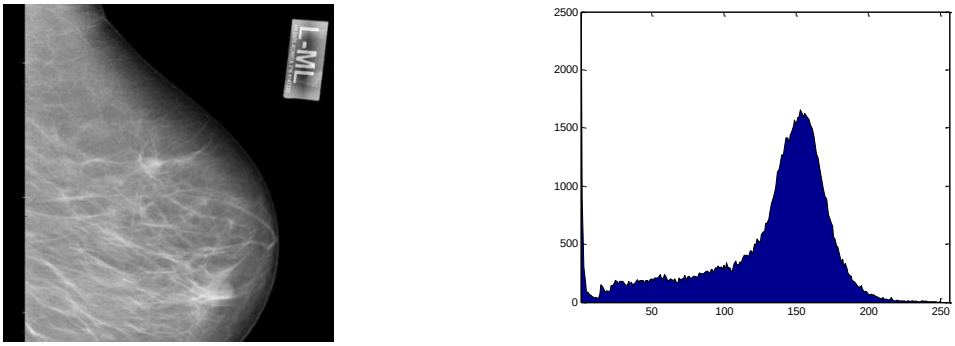
Histogram, bir görüntüdeki piksellerin gri seviyelerinin piksel sayısına göre grafiği olarak isimlendirilebilir. Histogram, bir görüntünün parlaklığı ve şiddet dağılımı hakkında bilgi sağlar. Histogramın formülü eşitlik (5.19)'de ifade edildiği gibidir (Demirel, 2008).

$$p(r_k) = n_k \tag{5.19}$$

Denklemde $r_k$ $k$. gri düzeyi, $n_k$ ise görüntüdeki $r_k$ gri düzeyine sahip piksellerin sayısını ifade eder. Burada $k = 0,1,2...(L-1)$ olmak üzere, $[0,(L-1)]$ aralığında değişen bir dijital görüntünün histogramı, görüntüdeki toplam piksel sayısı $n$'e bölünerek normalize edilebilir ve eşitlik (5.20)'da verilmiştir. Bu denklemde $p(r_k)$, $r_k$'nın meydana gelme olasılığını ifade eder ve normalize edilmiş bir histogramda bütün elemanların toplamı 1 olur (Gonzalez ve Woods, 1992).

$$p(r_k) = n_k / n \tag{5.20}$$

Şekil 5.12.'de bir mamogram görüntüsü ve bu görüntünün histogramı verilmiştir. Histogram grafiğini basitçe, piksel değerlerinin çubuk tipi grafikle ifadesi gibi görebiliriz. Piksel değerlerini x ekseni, piksel değerlerinin ortaya çıkma sıklığını da y ekseni ifade eder. İdeal görüntülerde piksel dağılımı homojen olanlardır. Eğer görüntü kontrası koyu ise piksel dağılımı histogramın sol tarafına doğru, açık ise piksel dağılımı histogramın sağ tarafına doğru oluşmaktadır.




**(a)** **(b)**

**Şekil 5.12. (**a) Orijinal mamogram görüntüsü **(b)** Mamogram görüntüsünün histogramı

**Histogram eşitleme:**

Histogram eşitleme, histogram üzerinde eşit dağılımlı bir yapı elde etmeye yönelik çalışmadır. Histogram üzerindeki bu yayma işlemi istenirse sadece seçilen bölgeler için de uygulanabilir. Görüntü iyileştirme işlemlerinde histogram eşitleme önemli bir yer tutmaktadır.

Histogram eşitleme işleminin denklemi aşağıdadır (Gonzalez ve Woods, 1992; Jain, 1989).

$$s_k = \sum_{j=0}^{k} p(r_j) = \sum_{j=0}^{k} \frac{n_j}{n} \qquad k = 0,1,2...(L-1) \qquad (5.21)$$

Denklemden, $r_k$ gri seviyesine sahip bir görüntü, çıkışta $s_k$ gri seviyesine sahip olacaktır.

## 5.5. Mamogram Görüntülerinin Güçlendirilmesi

Meme kanseri belirlemede radyologlara yardımcı olma amaçlı yapılan pek çok bilgisayar destekli çalışmalarda, görüntü güçlendirme adımı, görüntü işlemenin en önemli aşamalarından biridir. Görüntü güçlendirme gürültü azaltma, arka plan görüntüsünde istenmeyen bölgelerin uzaklaştırılması, keskinleştirme, contrast ayarlama gibi işlemleri içermektedir. Mamogram görüntülerinde güçlendirme işleminin en önemli amaçlarından birisi, şekil ve arka plan arasındaki parlaklığı ayarlamak ve görüntünün sınırlarını belirginleştirmektir (Quintanilla-Dominguez ve ark., 2010).

Mamogram görüntülerini güçlendirme üzerine pek çok çalışmalar yapılmıştır. Mamogram görüntülerini güçlendirme üzerine fotografik keskinleştirilmiş maskeleme (Morrow ve ark., 1992; Chen ve ark., 2006), sayısal keskinleştirilmiş maskeleme (Panetta ve ark., 2008), spatial bandpass filtreleme (Smathers ve ark., 1986) gibi çalışmalar yapılmıştır. Chen ve ark. (2006) optimize edilmiş görüntülerin parlaklığını güçlendirme üzerine bir metot

geliştirmişlerdir. Kosheleva ve ark. görüntü güçlendirmede, seçici ortalama filtreleme yöntemini kullanmışlardır (Kosheleva ve ark., 1998).

Görüntü güçlendirme üzerine histogram temelli önemli çalışmalar yapılmış, çeşitli güçlendirme algoritmaları geliştirilmiştir. Pizer (1987), adaptif histogram temelli CLAHE (Contrast Limited Adaptive Histogram Equalization) güçlendirme metodunu geliştirmiştir. Görüntü güçlendirmede HE (Histogram Equalization), US (Unsharp Mask), LHE (Local Histogram Equalization) ve AHE (Adaptive Histogram Equalization) gibi model temelli olmayan güçlendirme algoritmaları kullanılmıştır.

### 5.5.1. CLAHE (Contrast Limited Adaptive Histogram Equalization)

İlgilenilen bölge sabitlendiğinde, bir pikselin yerel histogramı pencerelenen bölgenin merkezindeki pikselle aynıdır. Sadece yerel alan içindeki pikseller değerlendirilirken, diğer pikseller göz ardı edilir. Fakat insan görme sisteminin karakteristik özelliklerine göre görsel sistem, ilgilenilen bölgeye göre değişirken aynı zamanda çevresindeki yapıdan da etkilenir.

Bu problemi çözmek için Pizer (1987), Contrast Limited Adaptive Histogram Equalization (CLAHE) olarak adlandırılan bir yöntem geliştirmiştir. CLAHE metodu seçilen bölgeye HE (Histogram Equalization) uygular. Orijinal görüntüdeki her bir pikselini merkez alan bir ilgilenilen bölge oluşturulur. Orijinal histogram kırpılır ve kırpılan pikseller tüm gri seviyelere dağıtılır. Yeni oluşturulan histogram, olağan histogramlardan farklıdır, çünkü her bir pikselin yoğunluğu kullanıcı tarafından belirlenebilen bir maksimum değerle sınırlandırılmıştır. Dolayısıyla CLAHE gürültünün güçlendirilmesini de sınırlar (Pizer, 1987).

CLAHE metodu aşağıdaki adımlarla açıklanabilir (Zhiyuan ve ark., 2009):

1. Adım: Orijinal görüntü çakışmayan ve sürekli çalışma bölgelerine bölünmelidir. Her bir çalışma bölgesinin boyutu MxN dir.
2. Adım: Çalışma bölgelerinin histogramları hesaplanır.
3. Adım: Histogramlar kırpılır.

Çalışma bölgesindeki pikseller, gri değere karşı gelecek şekilde dağıtılırlar. Daha sonra her biri gri değere eşitlenmiş piksellerin ortalama değeri aşağıda verilen denklem ile hesaplanır (Zhiyuan ve ark., 2009):

$$N_{aver} = \frac{N_{CR-Xp} \times N_{CR-Yp}}{N_{gray}} \tag{5.22}$$

Burada:

$N_{aver}$ piksellerin sayısının ortalaması,

$N_{gray}$ çalışma bölgesindeki gri seviyelerin sayısı,

$N_{CR-Xp}$ çalışma bölgesinin x eksenindeki piksellerin sayısı,

$N_{CR-Yp}$ çalışma bölgesinin y eksenindeki piksellerin sayısıdır.

Eşitlik (5.22) temelinde $N_{CL}$ aşağıdaki gibi yazılabilir:

$$N_{CL} = N_{clip} \times N_{aver} \tag{5.23}$$

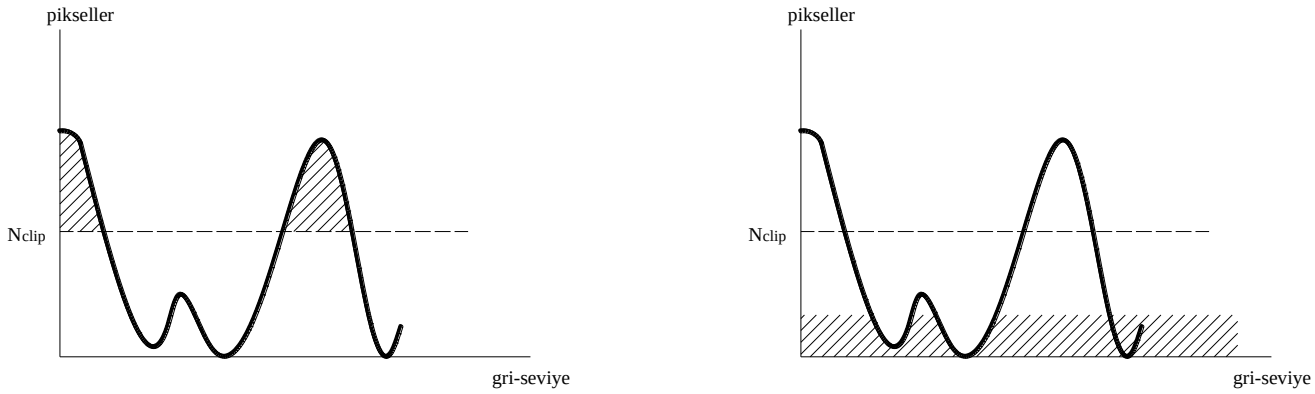
Burada:

$N_{CL}$ kırpma sınırı,

$N_{clip}$ çalışma bölgesinin her bir gri seviyedeki ortalama piksellerin maksimumudur.

Orijinal ve kırpılmış histogram Şekil 5.13.'de görülmektedir (Zhiyuan ve ark., 2009). Şekil 5.13.(a)'da görüldüğü gibi eğer piksellerin sayısı $N_{clip}$'den büyükse, pikseller kırpılacaktır. Kırpılmış piksellerin toplam sayısı $N_{\sum clip}$ olarak gösterilmiştir ve her bir gri-seviyeye dağıtılmış piksellerin sayısı aşağıdaki eşitlikle tanımlanmıştır:

$$N_{acp} = \frac{N_{\sum clip}}{N_{gray}} \tag{5.24}$$




**(a)** **(b)**

**Şekil 5.13. (a)** Orijinal histogram **(b)** Kırpılmış histogram

$H_{CR}(i)$ çalışma bölgesinin her bir gri seviyedeki piksellerinin sayısı, $i$ gri seviyenin sayısıdır.

Eşitlik (5.24) baz alınarak, aşağıda tanımlanan kurallarla çalışma bölgesinin sınırlandırılmış histogram contrast değeri hesaplanabilir.

$$\begin{aligned} &If \quad H_{CR}(i) > N_{CL} \ , \quad H_{NCR}(i) = N_{CL} \ ; \\ &\text{Else if} \quad H_{CR}(i) + N_{acp} \geq N_{CL} \ , \quad H_{NCR}(i) = N_{CL} \ ; \\ &\text{Else} \quad H_{NCR}(i) = H_{CR}(i) + N_{acp} \ ; \end{aligned} \tag{5.25}$$

Dağılımdan sonra kırpılmış piksellerin sayısı $N_{LP}$ olarak ifade edilir ve dağıtılmış piksel adımı aşağıdaki eşitlikte verilmiştir:

$$S = \frac{N_{gray}}{N_{LP}} \tag{5.26}$$

Program minimumdan maksimum gri seviyeye göre aramaya başlar. Eğer gri seviyedeki piksellerin sayısı $N_{CL}$ 'den az ise program her bir pikseli gri seviyeye dağıtacaktır. Eğer piksellerin tamamı dağıtılmamışsa program eşitlik (5.26)'e göre yeni adımı hesaplayacaktır. Elde edilen yeni histogram Şekil 5.13. (b)' de gösterilmiştir.

**4.** Adım: Her bir çalışma bölgesindeki gri-skala histogramı, histogram eşitleme tarafından işlenir.

**5.** Adım: Çalışma bölgesinin merkezindeki noktalar örnekleme noktaları olarak ifade edilir.

**6.** Adım: Herhangi bir pikselin sonuç değeri (haritası), etrafını saran 4 örnek çerçeve pikselinin değerleri ile uyumlu hale getirilir. (x,y) noktasındaki ilgili piksel uygunluk değeri $i$, $m_{+-}$, $m_{++}$, $m_{-+}$, $m_{--}$ sırasıyla üst-sağ piksel, alt-sağ piksel, alt-sol piksel ve üst-sol pikseldir. Eğri uydurma formülü aşağıdaki gibidir:

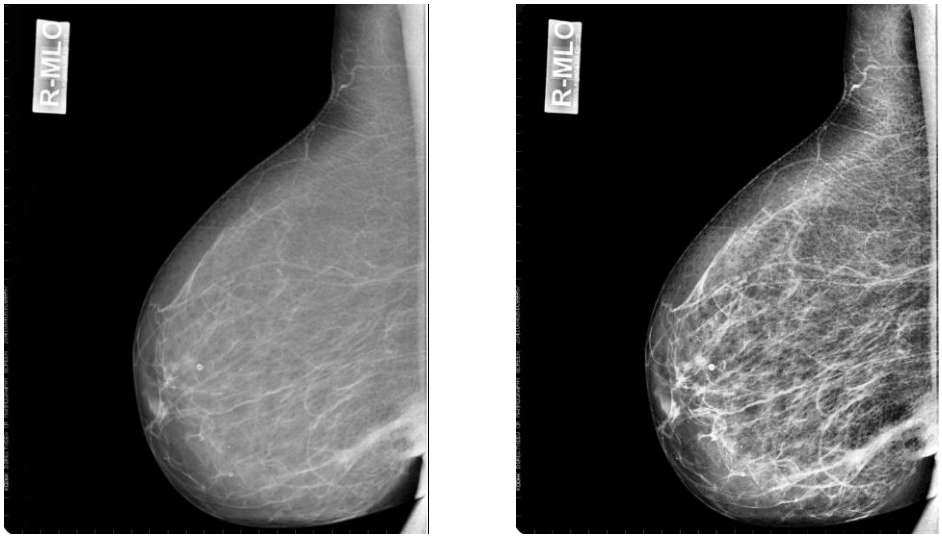
$$m(i) = a\left[bm_{--}(i) + (1-b)m_{+-}(i)\right] + \left[1-a\right]\left[bm_{-+}(i) + (1-b)m_{++}(i)\right] \qquad (5.27)$$

Burada,

$$a = \frac{y - y_-}{y_+ - y_-} \quad , \quad b = \frac{x - x_-}{x_+ - x_-}$$

ifade etmektedir.

Şekil 5.14. (a)'da Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Bölümü'nden alınan H6.4_BR5 nolu ham görüntü ve (b)'de bu görüntünün CLAHE algoritması ile güçlendirilmiş hali görülmektedir.




**(a)** **(b)**

**Şekil 5.14. (a)** H6.4_BR5 nolu ham görüntü **(b)** CLAHE algoritması ile güçlendirilmiş H6.4_BR5 nolu görüntü

### 5.5.2. HE (Histogram Equalization)

Gri değer seviyesi $[0, L-1]$ aralığında değişen sayısal bir görüntünün Olasılık Dağılım Fonksiyonu aşağıdaki denklemle hesaplanabilir (Yeganeh ve ark., 2008) :

$$P(r_k) = \frac{n_k}{N} \qquad \text{k=0,...,L-1} \tag{5.28}$$

Burada $r_k$ $k.$gri seviye, $n_k$ görüntüdeki $r_k$ gri seviyeli piksellerin sayısıdır. Kümülatif dağılım fonksiyonu aşağıda gösterilen denklemle hesaplanır:

$$C(r_k) = \sum_{i=0}^{i=k} P(r_i) \qquad k = 0,...,L-1 \quad 0 \le C(r_k) \le 1 \tag{5.29}$$

HE (Histogram Equalization), giriş görüntüsünün $r_k$ gri seviyesi denklem (5.29) kullanılarak $S_k$ gri seviye değeri bulunur:

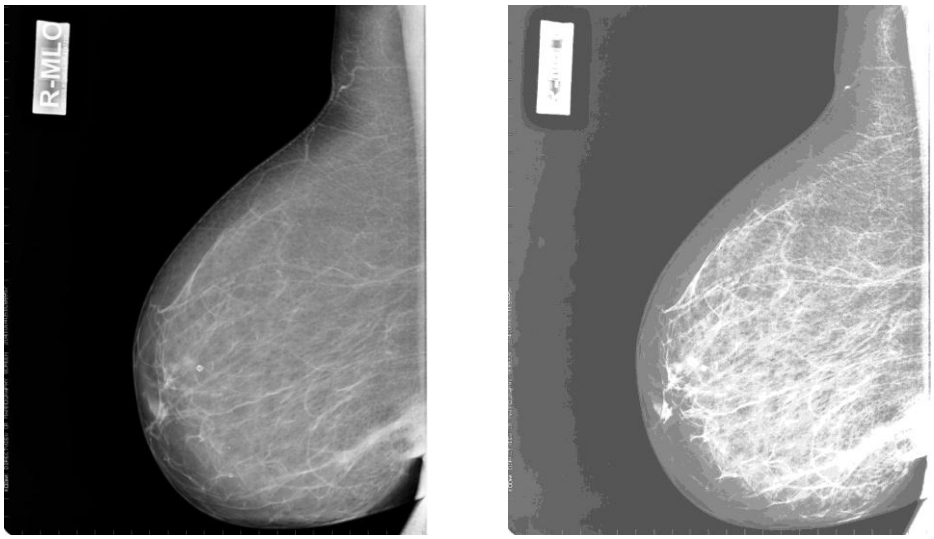
$$S_k = (L-1) \times C(r_k) \tag{5.30}$$

$S_k$ 'nın gri seviye değişimi aşağıdaki gibi hesaplanır:

$$\Delta S_k = (L-1) \times P(r_k) \tag{5.31}$$

$S_k$ ve $S_k + 1$ arasındaki mesafe, $r_k$ gri seviyesindeki giriş görüntüsünün olasılık dağılım fonksiyonu ile doğrudan ilişkilidir.

Şekil 5.15. (a)'da Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Bölümü'nden alınan H6.4_BR5 nolu ham görüntü ve (b)'de bu görüntünün HE algoritması ile güçlendirilmiş hali görülmektedir.



**(a)** **(b)**

**Şekil 5.15. (a)** H6.4_BR5 nolu ham görüntü **(b)** HE algoritması ile güçlendirilmiş H6.4_BR5 nolu görüntü

### 5.5.3. US (Unsharp Mask)

Giriş görüntüsü $f(m,n)$'den güçlendirilmiş çıkış görüntüsü $g(m,n)$, lineer unsharp maks algoritmasından aşağıdaki eşitlikte gösterildiği gibi elde edilir (Xiao ve Zhang, 2010):

$$g(m,n) = f(m,n) + \lambda f_H(m,n) \tag{5.32}$$

Burada $f_H(m,n)$, bir lineer yüksek geçirgen filtrenin çıkışı olarak hesaplanmış düzeltme sinyali $\lambda$, çıkışta ulaşılacak kontrast güçlendirme seviyesini kontrol edecek pozitif bir ölçekleme faktörüdür.

$f_H(m,n)$ giriş görüntüsünün iki boyutlu laplası en yaygın olarak seçilmektedir.

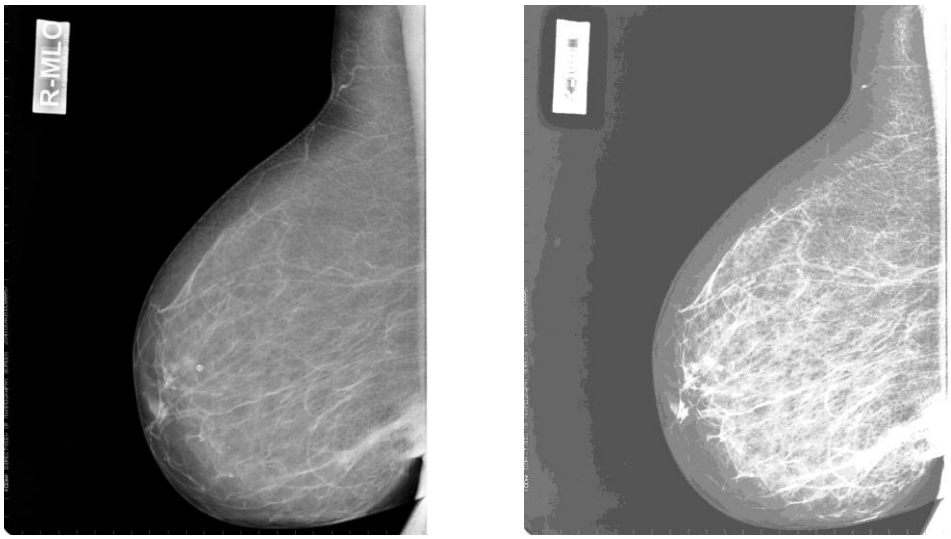
$$f_H(m,n) = 4f(m,n) - f(m-1,n) - f(m+1,n) - f(m,n-1) - f(m,n+1) \tag{5.33}$$

Bu seçim birçok uygulamada iyi çalışıyor olsa da, iki ana dezavantajı vardır:

1. Lineer yüksek-geçiren filtrenin varlığı sistemi gürültülere karşı son derece duyarlı yapmaktadır. Bu sonuç özellikle zayıf gürültülerin bile hissedilebilir ve istenmeyen bozulmalara yol açtığı görülmektedir.

2. Bu yapı, yüksek kontrastlı alanları görüntüye göre daha fazla güçlendirir. Sonuç olarak, çıkış görüntüsünde bazı istenmeyen gürültüler görünebilir.

Şekil 5.16. (a)'da Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Bölümü'nden alınan H6.4_BR5 nolu ham görüntü ve (b)'de bu görüntünün US algoritması ile güçlendirilmiş hali görülmektedir.




**(a)** **(b)**

**Şekil 5.16. (a)** H6.4_BR5 nolu ham görüntü **(b)** US algoritması ile güçlendirilmiş H6.4_BR5 nolu görüntü

# 6. MAMOGRAM GÖRÜNTÜLERİ İÇİN GELİŞTİRİLEN KARAR DESTEK SİSTEMİ

Meme kanseri dünya genelinde (Stewart ve ark., 2004) ve Türkiye'de kadınlarda en sık rastlanan kanser tipi olarak kabul edilmektedir (Tuncer, 2007). Dünya genelinde olduğu gibi ülkemizde de meme kanseri en önemli sağlık problemlerinden birisidir. Bu problemin çözümünde, erken teşhis ve doğru tanı koymak binlerce hayatı kurtarmak açısından oldukça önemlidir.

Meme kanserinde, küçük kalsiyum tanecikleri olan mikrokalsifikasyonların belirlenmesi, benign (iyi huylu) ve malign (kötü huylu) nodüllerin ayırt edilmesi oldukça önemlidir. Bu amaçla manyetik rezonans görüntüleme, tomografi, ultrasonografi ve mamografi gibi çeşitli görüntüleme teknikleri kullanılmaktadır. Bu teknikler içinde maliyetinin düşüklüğü sebebiyle en yaygın olarak mamografi görüntüleme tekniği uygulanmaktadır. Dünya genelinde yaklaşık olarak meme kanserinin %80-85'i mamografi görüntüleme tekniği ile yapılmaktadır (Karabulut, 2009).

Tez çalışmasında, radyologların mamogram görüntüleri üzerindeki meme kanserini belirlemelerine ve kesin tanı koymalarına yardımcı olmak için yeni akıllı bir karar destek sistemi (KDS) geliştirilmiştir. Bu sistem mamogram görüntülerini inceleyen radyologlara, kitlelerin benign (iyi huylu) veya malign (kötü huylu) olup olmadığına karar vermede yardımcı olacaktır. Ayrıca yeni geliştirilen güçlendirme algoritması ile meme kanserinin en önemli belirtilerinden birisi olan ve glandular meme dokularında görülmesi zor olan mikrokalsifikasyonların daha net görülmesi amaçlanmıştır. Dünya genelinde tümörlerin %10-25'i radyologlar tarafından gözden kaçırıldığı (Karabulut, 2009) düşünüldüğünde, önerilen akıllı karar destek sisteminin gerekliliği ortaya çıkmaktadır.

## 6.1. Tez Çalışmasında Kullanılan Veri Setleri

Tez çalışmasında, karar destek sisteminde kullanılmak üzere iki mamogram veri seti kullanılmıştır. Kullanılan ilk veri seti MIAS (The Mammography Image Analysis Society), 322 görüntüden oluşan sayısal hale getirilmiş (digitized) bir veri setidir (MIAS Database, 2010). Diğer kullanılan veri seti ise, Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi[1] Radyoloji Bölümünden, toplam 84 hastadan alınan 286 adet sayısal (digital) mamogram görüntüdür.

### 6.1.1. MIAS veri seti

MIAS veri tabanındaki tüm görüntüler 1024 x 1024 piksel çözünürlüğünde ve 8 bit gri yapıdadır. Bu veri seti 161 hastanın sağ ve sol meme görüntülerini içeren 322 görüntüden oluşmaktadır. Verilen görüntüler 208 normal, 63 benign (iyi huylu), 51 malign (kötü huylu) görüntü içermektedir. Görüntüler deneyimli radyologlar tarafından değerlendirilmiş, normal olmayan lezyonlar etiketlenmiştir. Etiketleme işleminde memelerin doku yapısı, normal olmayan lezyonların sınıflandırılması, lezyonların koordinatlarının belirlenmesi ve normal olmayan yapıların yaklaşık yarıçapları verilmiştir. Uzmanların tanımlamalarına göre, MIAS veri tabanındaki normal olmayan lezyonlar, yapısal bozukluklar (architectural distortions), stellate lezyonlar (stellate lesions), sınırlı kitleler (circumscribed mass) ve kalsifikasyonlar (calcifications) olarak adlandırılan dört çeşit yapıdan oluşmaktadır.

MIAS veri tabanı yedi sütundan oluşan bir yapıda verilmiştir. 1.sütünda görüntülere mdbxxx olarak bir referans numarası verilmiştir. Burada xxx, hasta numarasını göstermektedir. 2.sütünda meme dokusunun yapısı verilmiştir. Bu yapı:

- **F** Yağlı (Fatty)
- **G** Yağlı-glandular (Fatty-glandular)
- **D** Yoğun-glandular (Dense-glandular)

olarak gösterilmiştir. 3.sütünda normal olmayan kitlelerin sınıflandırılması yapılmıştır. Bu sınıflandırma aşağıdaki gibi yapılmıştır.

[1] Etik Kurul İzni alındığı tarihte Selçuk Üniversitesi Meram Tıp Fakültesi olarak hizmet vermekteydi.

**CALC** Kalsifikasyon (calcification)
**CIRC** İyi tanımlanmış / sınırlı kitleler (well-defined/circumscribed masses)
**SPIC** Spiculated kitleler (spiculated masses)
**MISC** Kötü tanımlanmış kitleler (ill-defined masses)
**ARCH** Yapısal bozulma (architectural distortion)
**ASYM** Asimetri (Asymmetry)
**NORM** Normal (Normal)

4.sütünda normal olmayan kitlelerin iyi huylu veya kötü huylu olma durumu verilmiştir.

**B** İyi huylu (benign)
**M** Kötü huylu (malign)

5.sütünda kitlenin x ekseni, 6.sütünda y ekseni olmak üzere piksel olarak koordinatları verilmiştir. Koordinat sisteminin başlangıç noktası sol alt köşe seçilmiştir. 7.sütünda ise normal olmayan kitlelerin piksel olarak yarıçapı verilmiştir. MIAS veri tabanı yapısı Çizelge 6.1.'de verilmiştir.

**Çizelge 6.1.** MIAS veri tabanı

```
mdb001 G CIRC B 535 425 197
mdb002 G CIRC B 522 280 69
mdb003 D NORM
mdb004 D NORM
mdb005 F CIRC B 477 133 30
mdb005 F CIRC B 500 168 26
mdb006 F NORM
mdb007 G NORM
mdb008 G NORM
mdb009 F NORM
mdb010 F CIRC B 525 425 33
mdb011 F NORM
mdb012 F CIRC B 471 458 40
mdb013 G MISC B 667 365 31
mdb014 G NORM
mdb015 G CIRC B 595 864 68
mdb016 G NORM
mdb017 G CIRC B 547 573 48

.
.
.
mdb322 D NORM
```

### 6.1.2. Hastaneden alınan veri seti

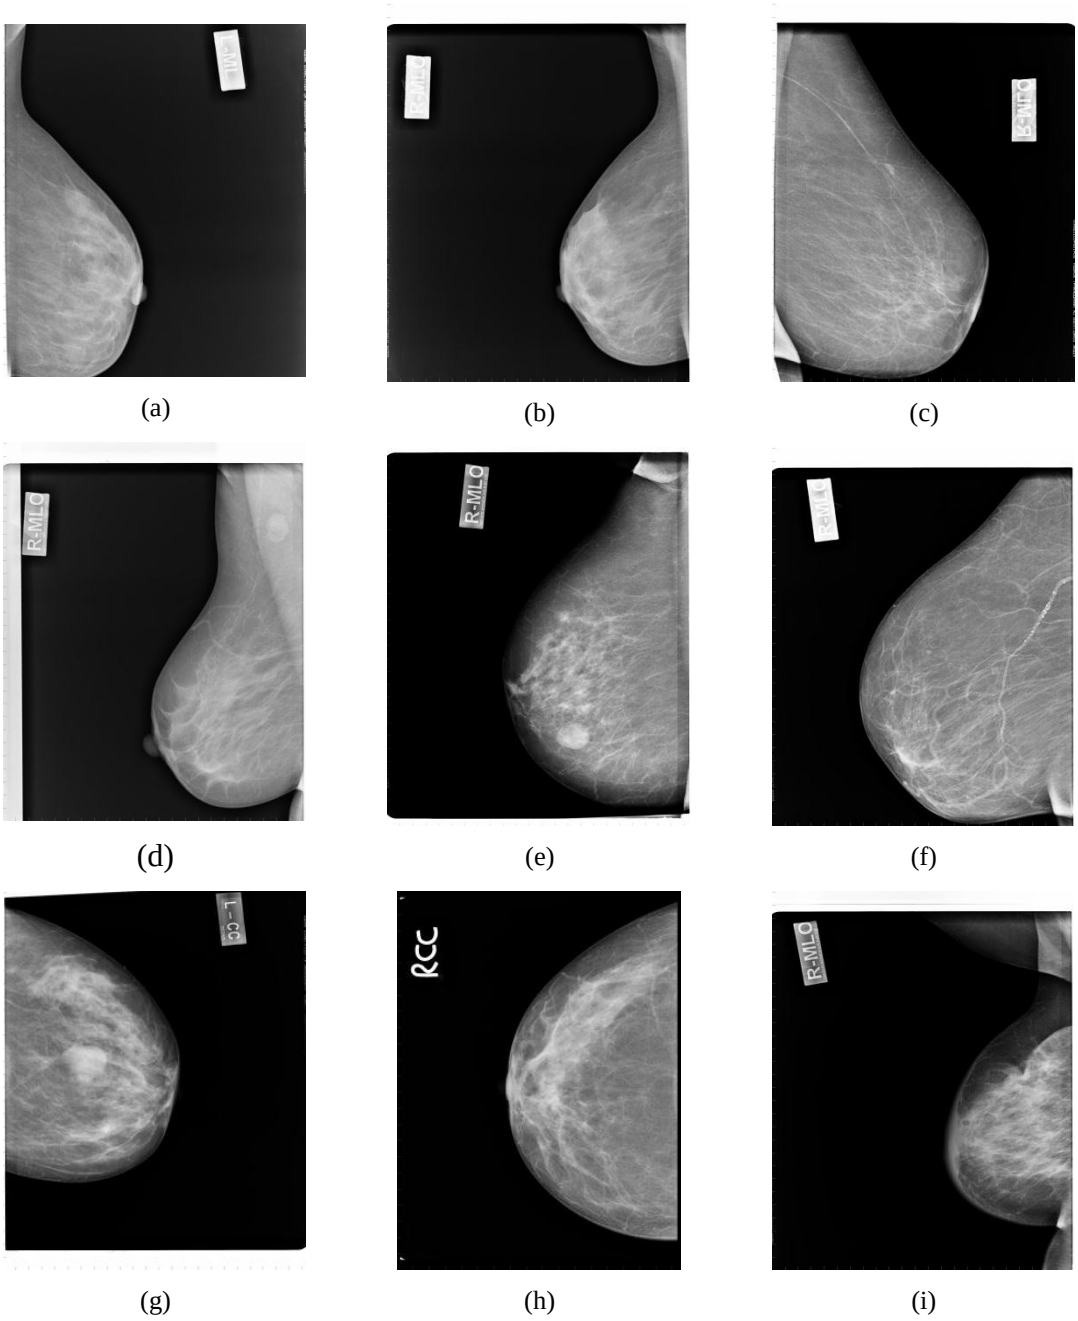
Hastaneden alınan veri seti, Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesi Radyoloji Bölümü'nde hekim ve teknisyen kontrolünde alınmıştır. Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi, Girişimsel Olmayan Klinik Araştırmalar Değerlendirme Komisyonu tarafından 26.05.2010 tarih ve 2010/048 karar sayısı ile bu tez çalışmasına normal/hasta bireylerden kayıt izni verilmiştir (EK-1).

Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Radyoloji Bölümünden alınan sayısal görüntüler, 2400 x 3000 piksel çözünürlüğünde ve 8 bit RGB (Red Green Blue) yapıdadır. Veri seti radyologlar tarafından BI-RADS (Breast Imaging Reporting and Data System) standardında etiketlenmiş ve BR1, BR2, BR3, BR4 ve BR5 gruplandırması yapılarak sınıflandırılmıştır. Veri seti 84 hastadan alınan toplam 286 görüntüden oluşmaktadır. Bu görüntülerin 93'ü BR1 70'i, BR2, 40'ı BR3, 61'i BR4, 22'si BR5 tipindedir. BI-RADS sınıflandırması Çizelge 6.2.'de verildiği gibidir.

**Çizelge 6.2.** Mamogram görüntülerindeki BI-RADS sınıflandırması

| ***Kategori*** | ***Tanımlama*** |
|---|---|
| BR1 | Normal mamografi |
| BR2 | Benign bulgular |
| BR3 | Büyük olasılıkla benign |
| BR4 | Şüpheli anormallikler (biyopsi yapılması düşünülmelidir) |
| BR5 | Malign olma olasılığı çok yüksek lezyonlar (gerekli işlemler yapılmalıdır) |

Bu tez çalışmasında hastaneden alınan görüntülerin isimleri değiştirilerek, kodlama yapılarak görüntülerin isimleri yeniden düzenlenmiştir. Yapılan çalışmada görüntüler **H**a.b**_BR**c yapısında kodlanmıştır. Burada H hasta, a hasta numarasını, b hastanın kaçıncı görüntüsü olduğunu, c ise hangi BR kategorisinde olduğunu ifade etmektedir. Örneğin H8.1_BR4; 8. hastanın BR4 kategorisinde etiketlenmiş 1. görüntüsünü ifade etmektedir. Şekil 6.1.'de hastane veri tabanından rastgele seçilmiş ve BI-RADS sınıflandırması yapılmış bazı mamogram görüntüleri görülmektedir.




(a) (b) (c)

(d) (e) (f)

(g) (h) (i)

**Şekil 6.1.** Hastane **v**eri tabanından seçilen BI-RADS sınıflandırması yapılmış bazı mamogram görüntüleri (a) H1.1_BR1 indeksli görüntü (b) H1.4_BR1 indeksli görüntü (c) H13.2_BR2 indeksli görüntü (d) H4.4_BR3 indeksli görüntü (e) H9.2_BR3 indeksli görüntü (f) H19.3_BR4 indeksli görüntü (g) H17.2_BR4 indeksli görüntü (h) H3.3_BR5 indeksli görüntü (i) H5.2_BR5 indeksli görüntü

Şekil 6.1. (a)'da verilen H1.1_BR1 indeksli görüntü, normal mamografi ve 1.hastaya ait 1. görüntüsüdür. (b)'de verilen H1.4_BR1 indeksli görüntü, normal mamografi ve 1.hastaya ait 4. görüntüsüdür. (c)'de verilen H13.2_BR2 indeksli görüntü, benign bulgular içeren ve 13.hastaya ait 2. görüntüsüdür. (d)'de verilen H4.4_BR3 indeksli görüntü, büyük olasılıkla benign bulgular içeren ve 4.hastaya ait 4. görüntüsüdür. (e)'de verilen H9.2_BR3 indeksli görüntü, büyük olasılıkla benign bulgular içeren ve 9.hastaya ait 2. görüntüsüdür. (f)'de verilen H19.3_BR4 indeksli görüntü, şüpheli anormallikler içeren ve 19.hastaya ait 3. görüntüsüdür. (g)'de verilen H17.2_BR4 indeksli görüntü, şüpheli anormallikler içeren ve 17.hastaya ait 2. görüntüsüdür. (h)'da verilen H3.3_BR5 indeksli görüntü, malign olma olasılığı çok yüksek lezyonlar içeren ve 3.hastaya ait 3. görüntüsüdür. (i)'de verilen H5.2_BR5 indeksli görüntü, malign olma olasılığı çok yüksek lezyonlar içeren ve 5.hastaya ait 2. görüntüsüdür.

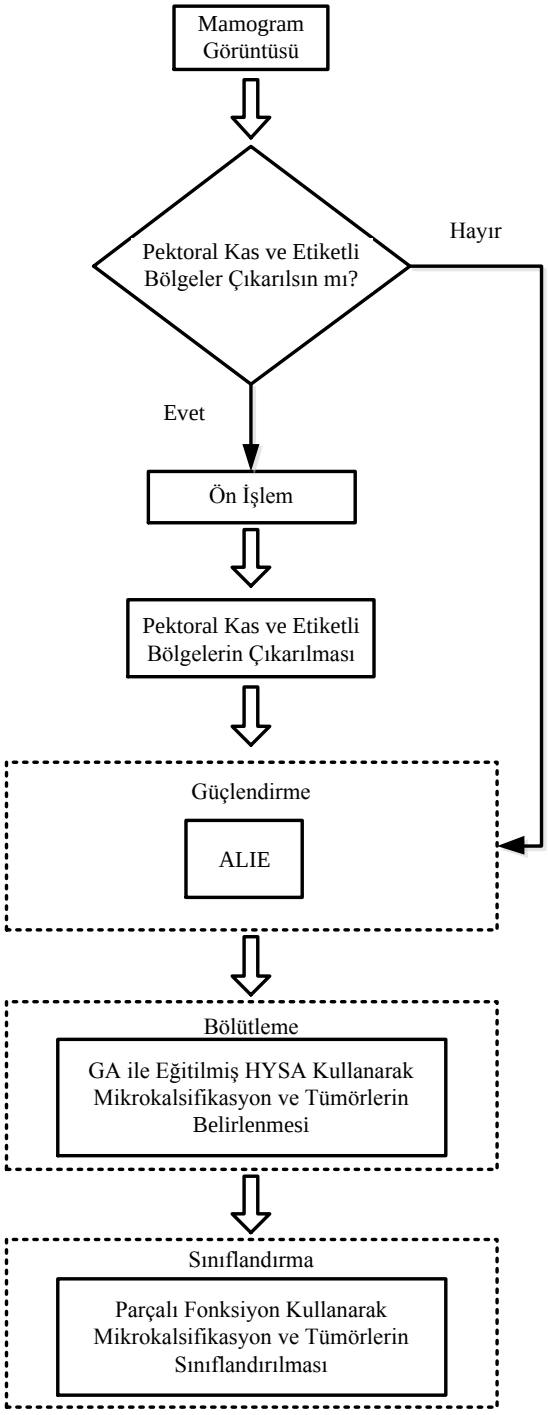
## 6.2. Mamogram Görüntüleri İçin Geliştirilen Karar Destek Sistemin Yapısı

Geliştirilen Karar Destek Sisteminin (KDS) blok şeması Şekil 6.2.'de verilmiştir. Bu yapı ön işlem, güçlendirme, bölütleme ve sınıflandırma aşamalarından oluşmaktadır. Ön işlem adımında sayısal (digital) veya sayısallaştırılmış (digitized) mamogram görüntüleri üzerinde görüntü boyutunun ayarlanması işlemi yapılmıştır. MIAS veri tabanındaki 1024 x 1024 piksel çözünürlüğündeki görüntüler ve hastaneden alınan 2400 x 3000 piksel çözünürlüğündeki görüntüler pektoral kas ve etiketli bölgelerin çıkarılması işlemi için 512 x 512 piksel çözünürlüğüne düşürülmüştür. Daha sonra görüntü üzerinde gri formata dönüştürme, görüntü netleştirme gibi işlemler uygulanmıştır.

Güçlendirme aşamasında, mamogram görüntüleri için yeni geliştirilen ALIE algoritması uygulanmıştır. Bu algoritma histogram temelli ve otomatik olarak kitle yoğunluğunun güçlendirilmesi üzerine geliştirilen bir algoritmadır. ALIE algoritması mamogram görüntüleri üzerinde bulunan etiketli bölgeleri çıkarmakta, isteğe bağlı olarak da mamogram görüntülerinden pektoral kas bölgeleri çıkartılarak güçlendirme yapılmıştır.

Bölütleme adımında, genetik algoritma ile eğitilmiş HYSA kullanılarak mikrokalsifikasyon ve tümörler belirlenmiştir. HSYA'nın parametrelerini belirlemede kullanılan genetik algoritmanın uygunluk fonksiyonu olarak korelasyon fonksiyonu kullanılmıştır.

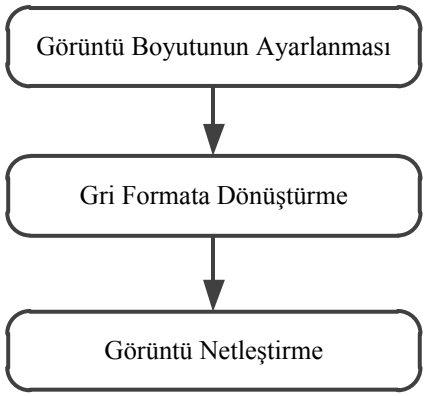
Sınıflandırma aşamasında, kitleleri ve mikrokalsifikasyonları belirlemek için görüntüler üzerinde şekil analizi kullanılarak sınıflandırma yapılmıştır. Mikrokalsifikasyon taneciklerinin ve kitlelerin mamogram görüntüleri üzerinde belirlenmesi amacıyla parçalı bir sınıflandırma fonksiyonu oluşturulmuştur. Şekil analizi için uzama, yoğunluk, eğim, yönelim gibi parametreler hesaplanarak sınıflandırma işlemi gerçekleştirilmiştir.




**Şekil 6.2.** Mamogram görüntüleri için geliştirilen Karar Destek Sisteminin (KDS) blok şeması

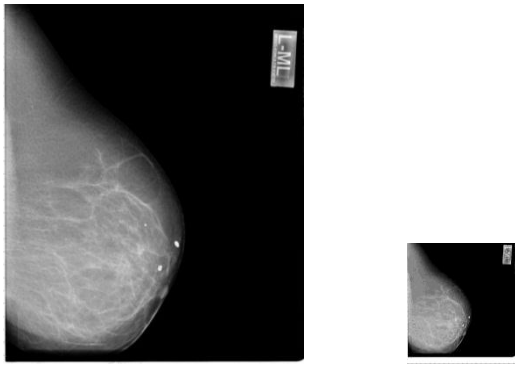
### 6.2.1. Ön işlem aşaması

MIAS veri tabanı 1024 x 1024 piksel çözünürlüğünde ve 8 bit gri, Meram Tıp Fakültesi'nden alınan görüntüler de 2400 x 3000 piksel çözünürlüğünde ve 8 bit RGB yapıdaki verilerden oluşmaktadır. Farklı özellikteki bu veri yapılarından elde edilen görüntülere 3 aşamadan oluşan ön işlem uygulanmıştır. Öncelikle 1024 x 1024 piksel boyutunda ve 2400 x 3000 piksel boyutundaki iki farklı formattaki görüntülerin boyutları 512 x 512 piksel çözünürlüğüne ayarlanmış, daha sonra görüntüler RGB'den gri yapıya dönüştürülmüştür. Son aşamada görüntü netleştirme işlemi yapılmıştır. Görüntü netleştirme, görüntü üzerine blur ve keskinleştirmenin uygulanmasını içermektedir. Ön işlem aşamasının blok diyagramı Şekil 6.3.'de verilmiştir.




**Şekil 6.3.** Ön işlem aşamasının blok diyagramı

Şekil 6.4.'de hastane veri tabanından alınan 2400 x 3000 piksel çözünürlüğündeki H3.1_BR4 indeksli ham görüntünün, 512 x 512 piksel çözünürlüğüne düşürülme ve netleştirme işleminin uygulanması görülmektedir.



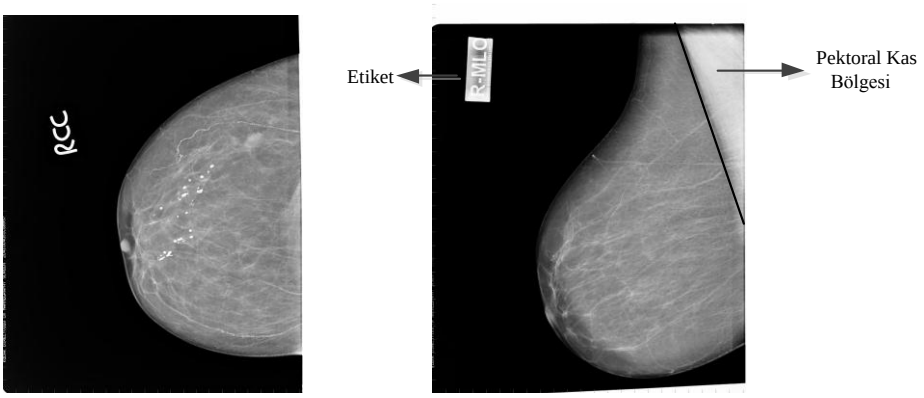
**(a)** **(b)**

**Şekil 6.4. (a)** 2400 x 3000 piksel çözünürlüğünde H3.1_BR4 indeksli ham görüntü **(b)** 512 x 512 piksel çözünürlüğüne düşürülmüş, gri formatlı ve netleştirilme işlemi uygulanmış H3.1_BR4 indeksli görüntü

### 6.2.2. Pektoral kas ve etiketli bölgelerin çıkarılması

Ön işlemden geçirilmiş görüntülerin bölütleme ve sınıflandırma işlemlerinde daha yüksek bir performans elde etmesi amacıyla yeni bir güçlendirme algoritması geliştirilmiştir. Bu algoritma, histogram-temelli bir güçlendirme algoritmasıdır. ALIE (Automated Lesion Intensity Enhancer) adı verilen algoritma, mamogram görüntülerinin yoğunluk seviyesini düşürürken, şüpheli bölgelerin yoğunluk seviyesini güçlendirmekte, bu sayede kitle ve mikrokalsifikasyon gibi anormal yapılar daha net olarak ortaya çıkarılmaktadır. ALIE histogram-temelli bir algoritma olduğundan dolayı, yüksek kontrastlı pektoral kas içeren mamogram görüntülerinde bu alanın ve istenmeyen etiketlerin çıkarılması gerekmektedir.

Pektoral kas, göğüs ön duvarı üst kısmında yer alan kalın bir kastır. Pars clavicularis, pars sternocostalis ve pars abdominalis olmak üzere üç ayrı bölgeden oluşur. Pars clavicularis, kola iç rotasyon (dönme) ve addüksiyon (kolu vücuda yaklaştırma) yaptırırken diğer bölümler inspirasyona (nefes alma) ve kolun yukarıya kaldırılmasına yardım ederler (Cankur, 2013). Pektoral kas, mamogramın üst köşesinde parlak, üçgen şeklinde görülen ve memeyi tutan kastır (Thangavel ve Karnan 2005). Pektoral kas bölgesi bazı mamogram görüntülerinde görülmediği halde bazı mamogram görüntülerinde geniş bir alanı kapsamaktadır. Mamogram görüntüleri üzerinde, genelde sağ üst veya sol üst bölgeye görüntü hakkında bilgi amaçlı yazılan veriler görülmektedir. Bu yazılara etiketli alan denilmektedir. Şekil 6.5.'de pektoral kas bölgesine sahip, etiketli ve pektoral kas bölgesine sahip olmayan, etiketli iki görüntü verilmiştir.

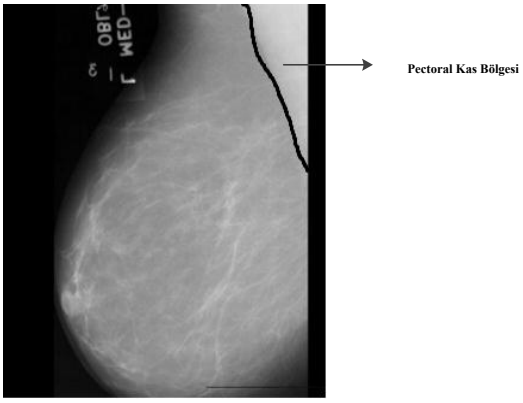



**(a)** **(b)**

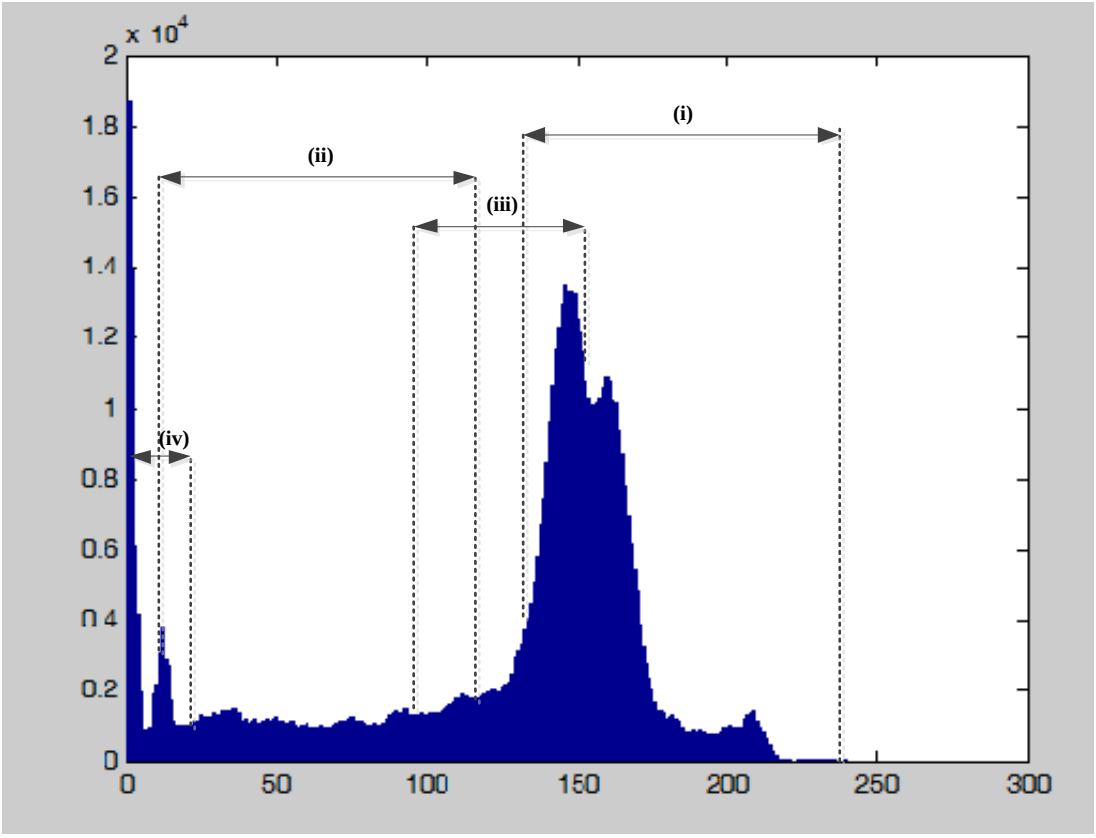
**Şekil 6.5. (a)** 2400 x 3000 piksel çözünürlüğünde pektoral kas bölgesine sahip olmayan, etiketli H2.8_BR2 indeksli görüntü **(b)** 2400 x 3000 piksel çözünürlüğünde pektoral kas bölgesine sahip, etiketli H17.2_BR1 indeksli görüntü

ALIE güçlendirme algoritması görüntünün tamamını analiz ederek elde ettiği sayısal değerlere göre güçlendirme yapmaktadır. Pektoral kas bölgesinin görüntüde fazla oranda yer alması veya aşırı parlak olması durumunda algoritmanın kullandığı katsayıların doğru hesaplanmasına negatif etki etmektedir. Bu nedenden dolayı pektoral kas bölgesinin çıkarılması gerekmektedir. Bazı durumlarda ise pektoral kas bölgesinin çıkartılması katsayıların hesaplanmasında hatalara neden olmakta, bu durum özellikle küçük kümecikler olan mikrokalsifikasyonların gözden kaçmasına sebep olabilmektedir. Dolayısıyla pektoral kas bölgesinin çıkarılması her zaman başarılı sonuçlar vermez. Bu bölgenin çıkartılıp çıkartılmayacağı tercihi algoritmayı kullanan uzmanın kararına bırakılmıştır.

Görüntü analizi temelde nitelik çıkarma, bölütleme ve sınıflandırmadan oluşur (Jain, 1989). Nitelik çıkarma işleminde piksel ve kontrast temelli çalışmalar oldukça önemlidir (Rosenfeld ve Kak, 1982). Gri-skalalı görüntülerde sınır belirleme işlemi gri-seviye yoğunluğuna bağlıdır. Mamogramdaki görüntü sınırları genelde yön-duyarlılığı operatörü, sobel operatörü gibi maske temelli operatör ve gauss yumuşatma operatörünü kullanan sınır belirleme operatörleri kullanılarak belirlenir (Nalwa, 1993). Görüntü üzerindeki gri seviye temelli nitelik çıkarma, bölütleme ve sınıflandırma işlemlerinin hassas olması görüntü üzerindeki istenmeyen etiket, pektoral kas gibi bölgelerin doğru bir şekilde uzaklaştırılmasına bağlıdır. Mamogram görüntülerinde, pektoral kas bölgesi sınırının belirlenmesi ve çıkarılması temel bölütleme işlemlerinden biridir. Şekil 6.6. ’da MIAS veri kaynağından alınmış mdb231 nolu mamogram görüntüsü ve bu görüntünün histogramı görülmektedir.




**(a)**




**(b)**

**Şekil 6.6. (a)** MIAS mdb231 nolu orijinal mamogram görüntüsü **(b)** MIAS mdb231 nolu orijinal mamogram görüntüsünün histogramı

Mamogrom görüntüsünün histogram yapısı incelendiğinde, histogram doku yapısına göre dört farklı bölgeye ayrıldığı görülür (Polakowski ve ark. 1997). Şekil 6.6. (a)'da MIAS (Mammographic Image Analisis Society) veri kaynağından alınmış mdb231 nolu mamogram görüntüsü ve Şekil 6.6. (b)'de bu görüntünün histogramı verilmiştir. Histogram doku yapısına göre dört farklı bölgeye ayrılmıştır. Şekilde *(i)* pektoral kas, *(ii)* yağ dokusu, *(iii)* süt bezi dokusu ve *(iv)* görüntünün arka plan ve etiketli bölgesi olarak belirlenmiştir.

Bu tez çalışmasında, pektoral kas bölgesinin ve görüntü üzerinde istenmeyen etiketlerin uzaklaştırılmasında Hücresel Yapay Sinir Ağları (HYSA) temelli bir çalışma yapılmıştır. Öncelikle görüntü üzerindeki memenin tüm hatlarıyla belirlenmesi için back propagation algoritmasıyla (Güzeliş ve Karamahmut, 1994) HYSA eğitilmiş, daha sonra da belirlenen bölge ikili sistemde bir maskeye dönüştürülerek, diğer alanların değeri sıfır değerine atanmıştır. Böylece etiketli bölgeler görüntüden çıkarılmıştır. Pektoral kas yapısını görüntüden ayırmada, back propagation algoritmasıyla eğitilmiş ikinci bir HYSA yapısı kullanılmıştır. Bu yapı meme dokusu ile pektoral kas dokusu arasındaki bağlantıyı birbirinden ayırarak pektoral kas bölgesini görüntüden çıkarmıştır. Çıkarma işlemini yapan bu HYSA yapısının çıkışına bulanıklık filtresi uygulanmıştır. Bulanıklık filtresi her iterasyon adımında HYSA'nın çıkışını yumuşatma işlemini yapmıştır.

Etiketli bölgelerin çıkarılmasında kullanılan HYSA'nın eğitimi back propagation algoritması ile yapılmıştır. Yapılan eğitim sonrası elde edilen HYSA'nın A, B ve I parametreleri belirlenmiştir. Aşağıda ilk adımda elde HYSA'nın A, B ve I parametreleri verilmiştir:

$$A = \begin{bmatrix} 0.8574 & 1.3370 & 0.9301 \\ 1.7550 & -1.6794 & 1.7550 \\ 0.9301 & 1.3370 & 0.8574 \end{bmatrix} \quad B = \begin{bmatrix} -1.7855 & -0.4677 & 1.6051 \\ -0.4438 & 0.4286 & -0.4438 \\ 1.6051 & -0.4677 & -1.7855 \end{bmatrix}$$

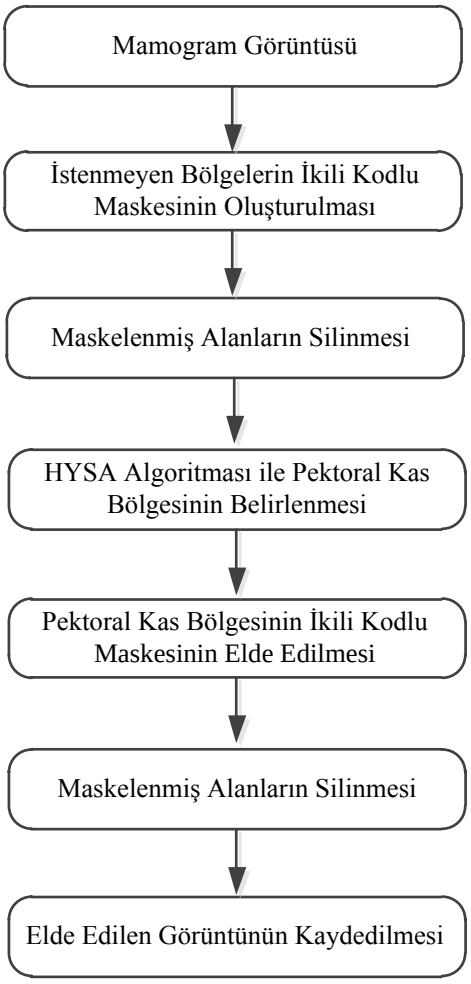
$$I = \begin{bmatrix} 0.8016 \end{bmatrix} \qquad (6.1)$$

Mamogram görüntülerinden istenmeyen etiketlerin çıkarılmasından sonra pektoral kas bölgesinin de uzaklaştırılması için kullanılan Hücresel Yapay Sinir Ağları'nın A, B ve I parametreleri aşağıda verilmiştir:

$$A=\begin{bmatrix}1.3372 & 1.8066 & 0.0406\\ 0.8926 & -0.8811 & 0.8926\\ 0.0406 & 1.8066 & 1.3372\end{bmatrix} \quad B=\begin{bmatrix}1.4478 & -0.2689 & -1.4972\\ -1.0045 & -0.2501 & -1.0045\\ -1.4972 & -0.2689 & 1.4478\end{bmatrix}$$

$$I=\begin{bmatrix}-2.1454\end{bmatrix} \tag{6.2}$$

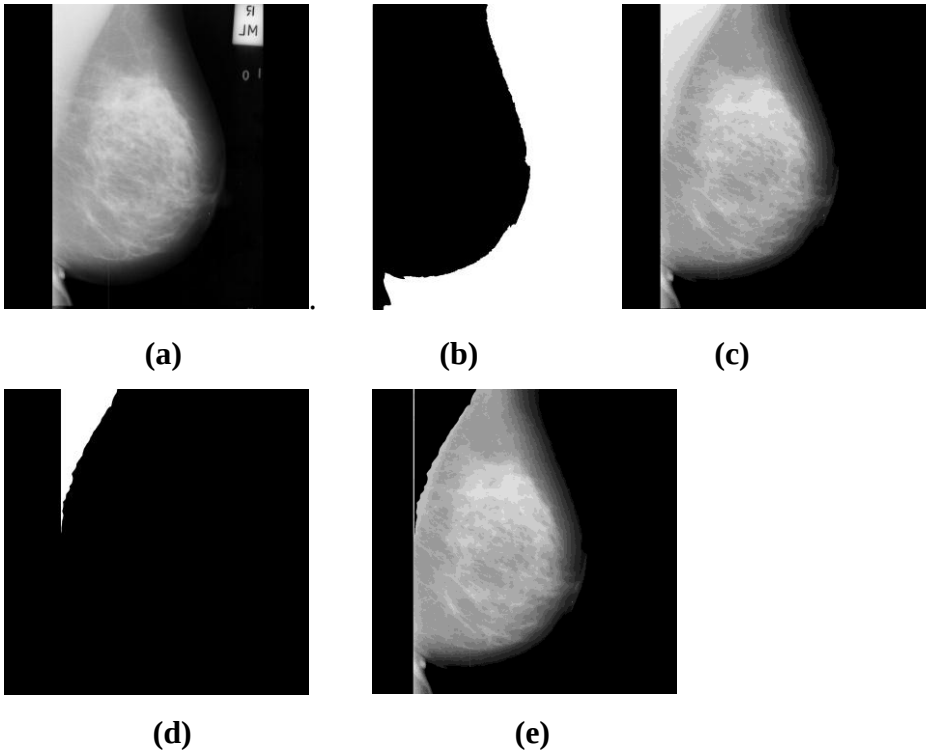
Etiketli bölgelerin ve pektoral kas bölgesinin çıkartılmasını gösteren akış şeması Şekil 6.7.'de verilmiştir.




**Şekil 6.7.** Pektoral kas ve istenmeyen etiketli bölgelerin mamogram görüntüsünden çıkarılmasının akış şeması

Mamogram görüntüsü öncelikle 512 x 512 piksel boyutuna düşürülmektedir. Bunun iki önemli nedeni vardır: HYSA temelli çalışmalarda genellikle kare görüntülerle çalışılmaktadır ve giriş görüntüleri üzerindeki pektoral kas ve etiketli bölgelerin uzaklaştırılması şablon temelli yapıldığından, hızlı işlem için düşük boyutta çalışılması gerekmektedir. Etiket ve pektoral kas bölgelerinin çıkarılmasında sadece meme bölgesinin ikili kodda maskesi elde edilir. Elde edilen bu maske orijinal görüntüde meme bölgesinin bölütlenmesinde kullanılır. Bu amaçla boyutu 512 x 512 olan bu maske görüntüsü orijinal resim boyutuna getirilir. Orijinal boyuttaki maske kullanılarak sadece incelenecek olan meme bölgesi elde edilir.

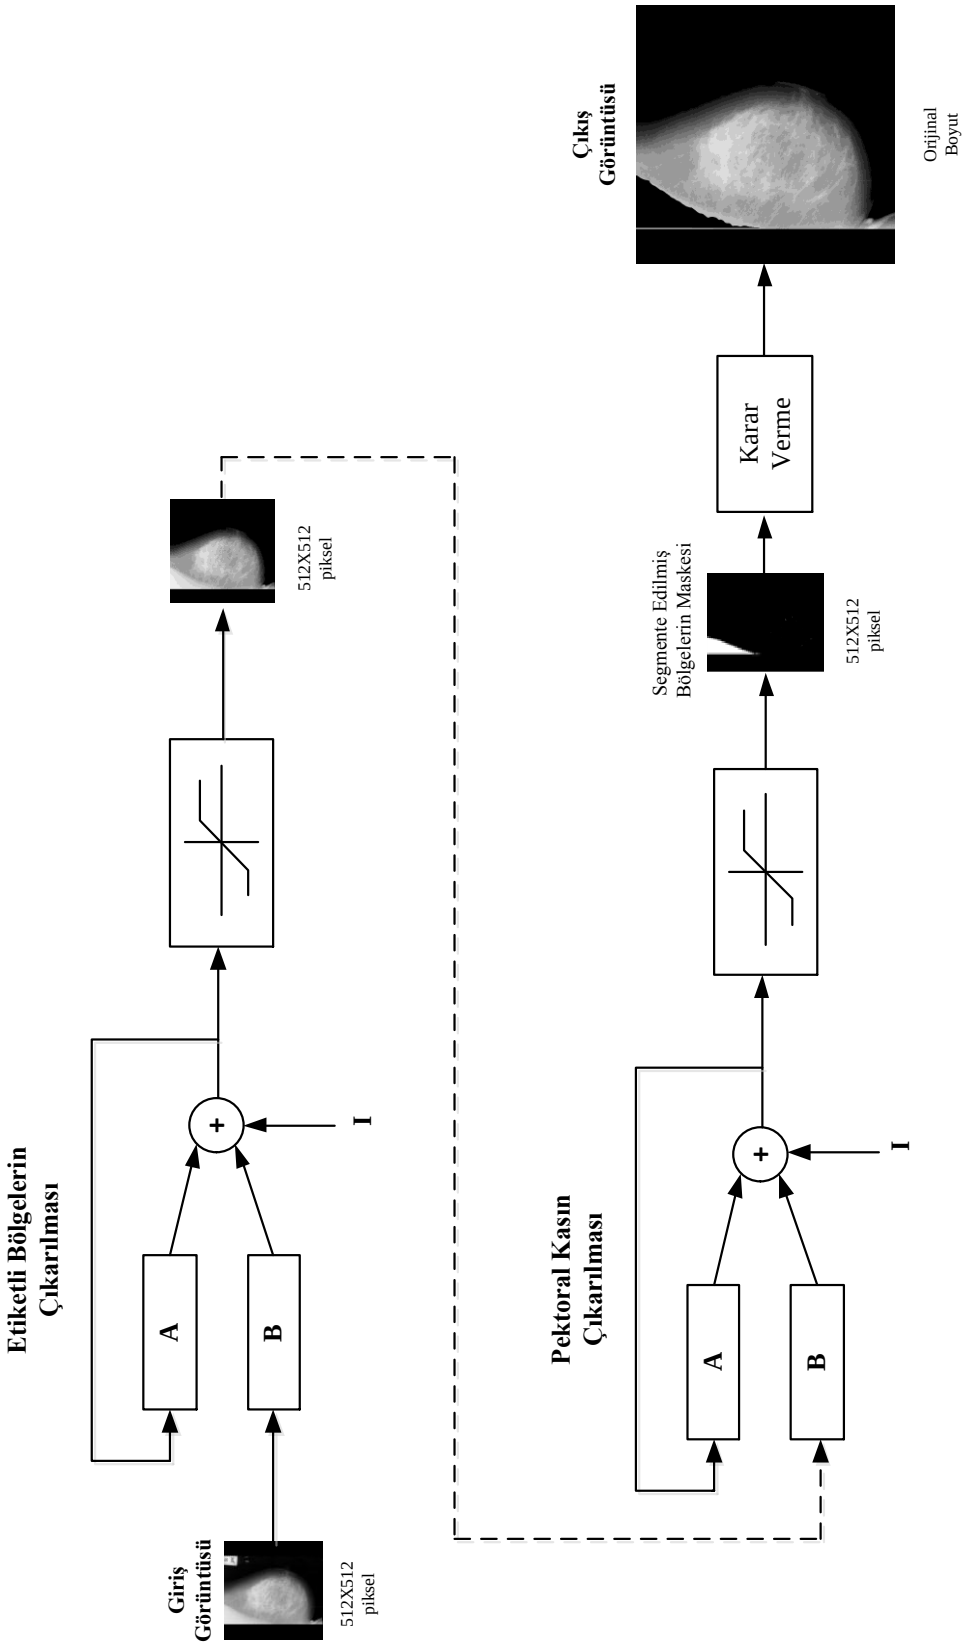
Şekil 6.8.'de MIAS (Mammographic Image Analysis Society) veri kaynağından alınmış (a) mdb210 nolu mamogram görüntüsü, (b) etiketli bölgeleri çıkarmak için oluşturulan maske, (c) etiketli bölgeleri çıkarılmış mdb210 nolu mamogram görüntüsü, (d) pektoral kas bölgesinin ikili kodlu maskesi, (e) etiketli bölgeleri ve pektoral kas bölgesi çıkarılmış mdb210 nolu mamogram görüntüsü verilmiştir.




**Şekil 6.8. (a)** mdb210 nolu mamogram görüntüsü **(b)** Etiketli bölgeleri çıkarmak için oluşturulan maske **(c)** Etiketli bölgeleri çıkarılmış mdb210 nolu mamogram görüntüsü **(d)** Pektoral kas bölgesinin ikili kodlu maskesi **(e)** Etiketli bölgeleri ve pektoral kas bölgesi çıkarılmış mdb210 nolu mamogram görüntüsü

Şekil 6.9.'da mamogram görüntülerinden etiketli bölgelerin ve pektoral kas bölgesinin çıkarılma işleminin blok yapısı verilmiştir. Tasarlanan yapı temelde iki alt bloktan oluşmaktadır. I. blokta etiketli bölgeler, II. blokta pektoral kas bölgeleri çıkarılmıştır. Girişe, 512 x 512 piksel çözünürlüğe ön işlem aşamasında düşürülmüş görüntüler uygulanmıştır. I. HYSA çıkışında mamogram görüntülerinden etiketli bölgeler çıkarılmış, bu görüntüler II. HYSA'nın giriş görüntüleri olmuştur. II. blokta pektoral kas bölgelerinin çıkarılması işlemi yapılmıştır. Karar verme yapısı, bölütlenmiş görüntülerdeki pektoral kas bölgesini belirlemek için kullanılmıştır. Görüntü içinde sağ veya sol üst köşede bulunan üçgene benzeyen alan tespit edilip, bu alan pektoral kas bölgesi olarak sınıflandırılarak, görüntüden çıkarılmıştır.

Şekil 6.9.'da öncelikle etiketli bölgelerin çıkarımı yapılmaktadır. Pektoral kas bölgesi çıkarımı opsiyonel olarak uzmana bırakılmaktadır. Bu işlem için geliştirilen ara-yüz programda (bölüm 6.4.2.'de anlatılmıştır), pektoral kas bölgesi çıkarımı ve etiketli bölgelerin çıkarımı seçenekleri programı kullanan kişiye bırakılmıştır.




**Şekil 6.9.** Mamogram görüntülerinden HYSA algoritması kullanılarak etiketli bölgelerin ve pektoral kas bölgesinin çıkarılma işleminin blok yapısı

### 6.2.3. Mamogram görüntülerinde mikrokalsifikasyon ve kitlelerin bölütlenmesi

Tez çalışmasında, mamogram görüntüleri üzerindeki mikrokalsifikasyon kümeciklerini ve kitleleri belirlemede HYSA temelli bir algoritma geliştirilmiştir. Hücresel yapay sinir ağları temelli birçok görüntü işleme uygulamaları vardır (Chua ve Yang, 1988, Roska ve Chua, 1990).

HYSA'daki en önemli yapı, çözülecek probleme göre en uygun parametreleri belirleyebilmektir. Yani HYSA temelli algoritmalarda en başarılı sonucu veren $\{A, B, I\}$ parametrelerini belirlemek oldukça önemlidir. Probleme göre en uygun parametreleri belirleyebilmek için de en uygun algoritmayı seçmek gerekmektedir. Klasik sinir ağlarında buna öğrenme algoritmaları denilmektedir. Mamogram görüntülerindeki mikrokalsifikasyon ve kitlelerin bölütlenmesinde, $\{A, B, I\}$ parametreleri genetik algoritma yapısı kullanılarak belirlenmiştir.

HYSA parametrelerinin eğitilmesinde genetik algoritma kullanılmasının üç temel sebebi vardır (Jiang ve Butler 1995);

1. Eğer nispeten bağımsız parametreler daha az seçilir ve bağımlı değişkenler daha fazla seçilirse (çıkış piksel değerleri) genetik algoritma iyi sonuçlar verir.
2. HYSA yapısı içinde görüntüleri tanıma açısından analitik bir metotla çalışmak oldukça zordur.
3. Genetik algoritma istenilen çıkışlara göre parametreleri belirlemede oldukça başarılıdır.

Genetik algoritma kullanarak mamogram görüntüleri üzerindeki mikrokalsifikasyon ve kitle gibi anormal yapıların belirlenmesi ve sınıflandırmasında bazı temel kurallar vardır. Genetik algoritmada en temel yapı, popülasyon, uygunluk fonksiyonu, çaprazlama ve mutasyon gibi genetik operatörleri doğru bir şekilde belirlemektir (Jiang ve Butler 1995).

HYSA parametrelerinin eğitimi için kullanılan genetik algoritmanın işlem basamakları popülasyonun oluşturulması, kromozomların oluşturulması, uygunluk fonksiyonunun belirlenmesi, çaprazlama ve mutasyondur.

a. *Popülasyonun Oluşturulması:* Başlangıç popülasyonu 11 kromozomlu 20 bireyden oluşan bir matris seçilmiştir.

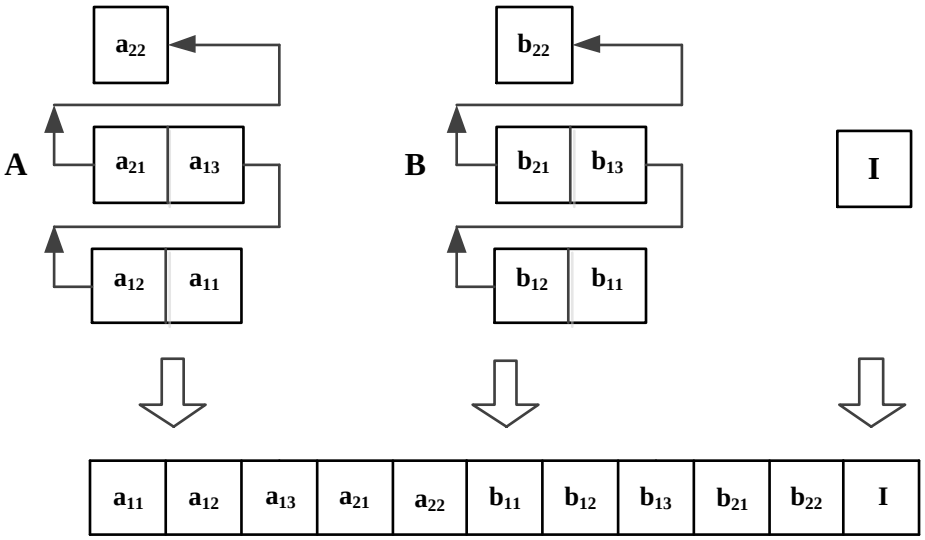
b. *Kromozomların Oluşturulması:* Genetik algoritmalarda, genel optimal çözümlerin türetilmesi kromozomların evriminde önemli bir rol oynar. HYSA'nın $\{A, B, I\}$ parametrelerini belirlemede 11 adet kromozom kullanılmıştır. Kromozomlar, $[-3, +3]$ aralığından seçilen tam sayılarla kodlanarak oluşturulmuştur.

Mikrokalsifikasyonlar çok küçük boyutlara sahip olduğu için HYSA parametrelerinin boyutları da küçük tutulmuş ve 3 x 3 boyutunda matrisler seçilmiştir. HYSA'nın kararlı olarak çalışması için parametreler için kullanılan matrislerin simetrik olması uygundur. Böylece bir matris 5 elemanla ifade edilebilir. Bias değeri de bir eleman olarak seçildiğinde HYSA'nın parametrelerini belirlemede 11 adet kromozom seçilmiştir.

HYSA parametreleri için komşuluk derecesi 1 olarak seçildiğinde A, B ve I parametreleri 3x3'lük bir matris oluşturur.

$$A=\begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{21} \\ a_{13} & a_{12} & a_{11} \end{pmatrix} \qquad B=\begin{pmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{21} \\ b_{13} & b_{12} & b_{11} \end{pmatrix} \tag{6.3}$$

Şekil 6.10.'da HYSA parametrelerin kromozom yapısı vektör formunda gösterilmiştir.




**Şekil 6.10.** HYSA parametrelerinin kromozom yapısının vektör formunda gösterimi

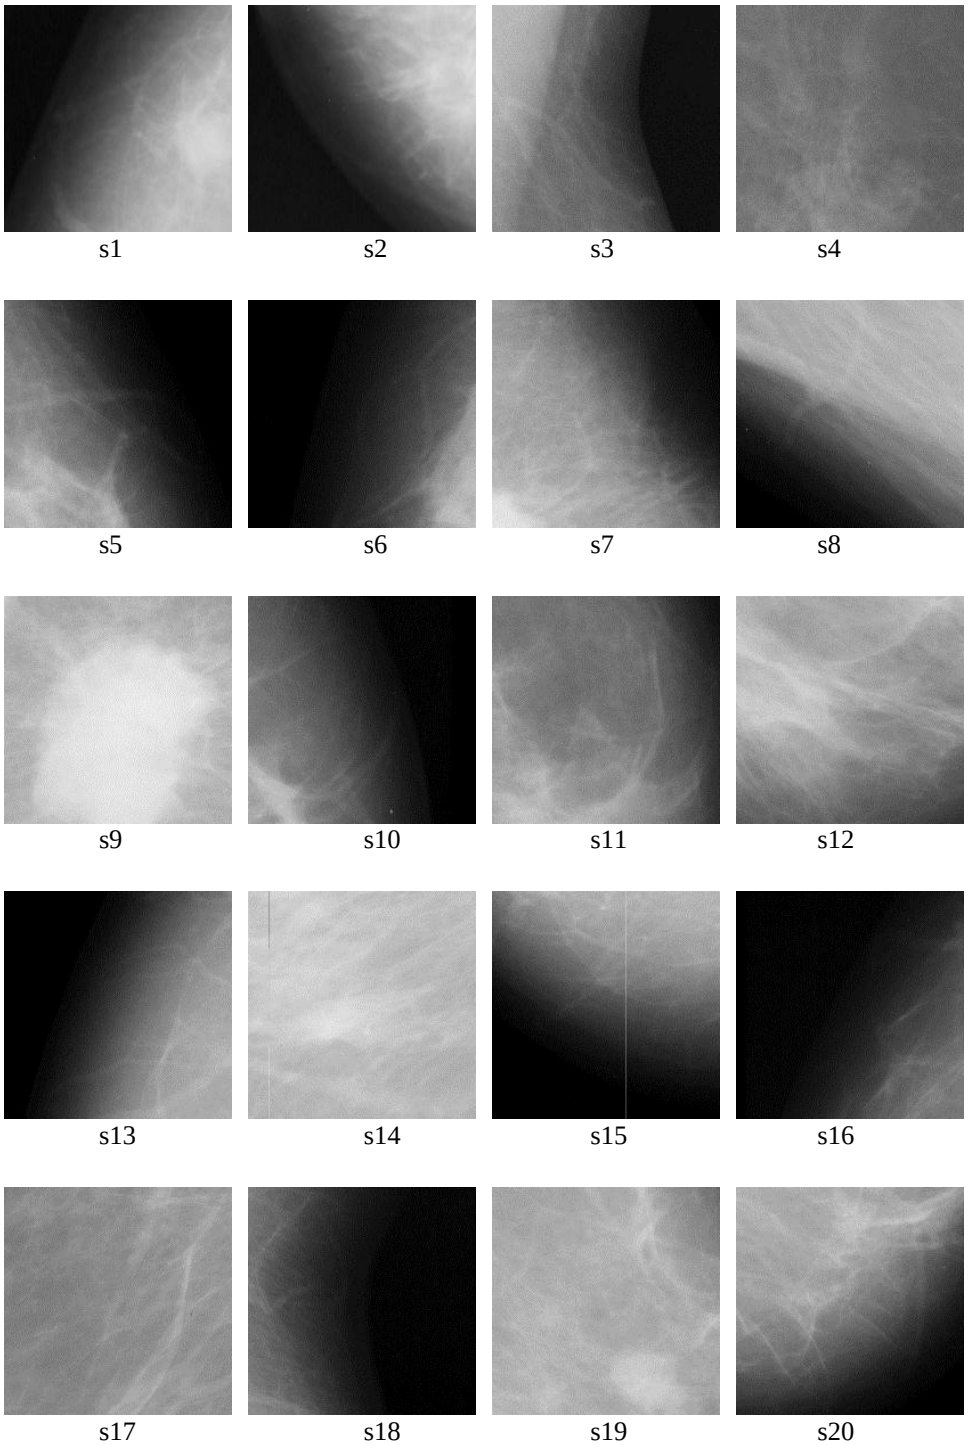
c. *Uygunluk Fonksiyonunun Belirlenmesi*: HYSA parametrelerin belirlenmesi için kullanılan uygunluk fonksiyonu olarak korelasyon formülü kullanılmıştır. HYSA algoritması görüntünün geneline etki ettiği için, çıkış görüntüleri ile hedef görüntüleri arasındaki korelasyon bize eğitimin başarısı hakkında net bilgi vermektedir. Bu fonksiyon eşitlik (6.4)'de verilmiştir.

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{\left(\sum_m \sum_n (A_{mn} - \bar{A})^2\right)\left(\sum_m \sum_n (B_{mn} - \bar{B})^2\right)}} \tag{6.4}$$

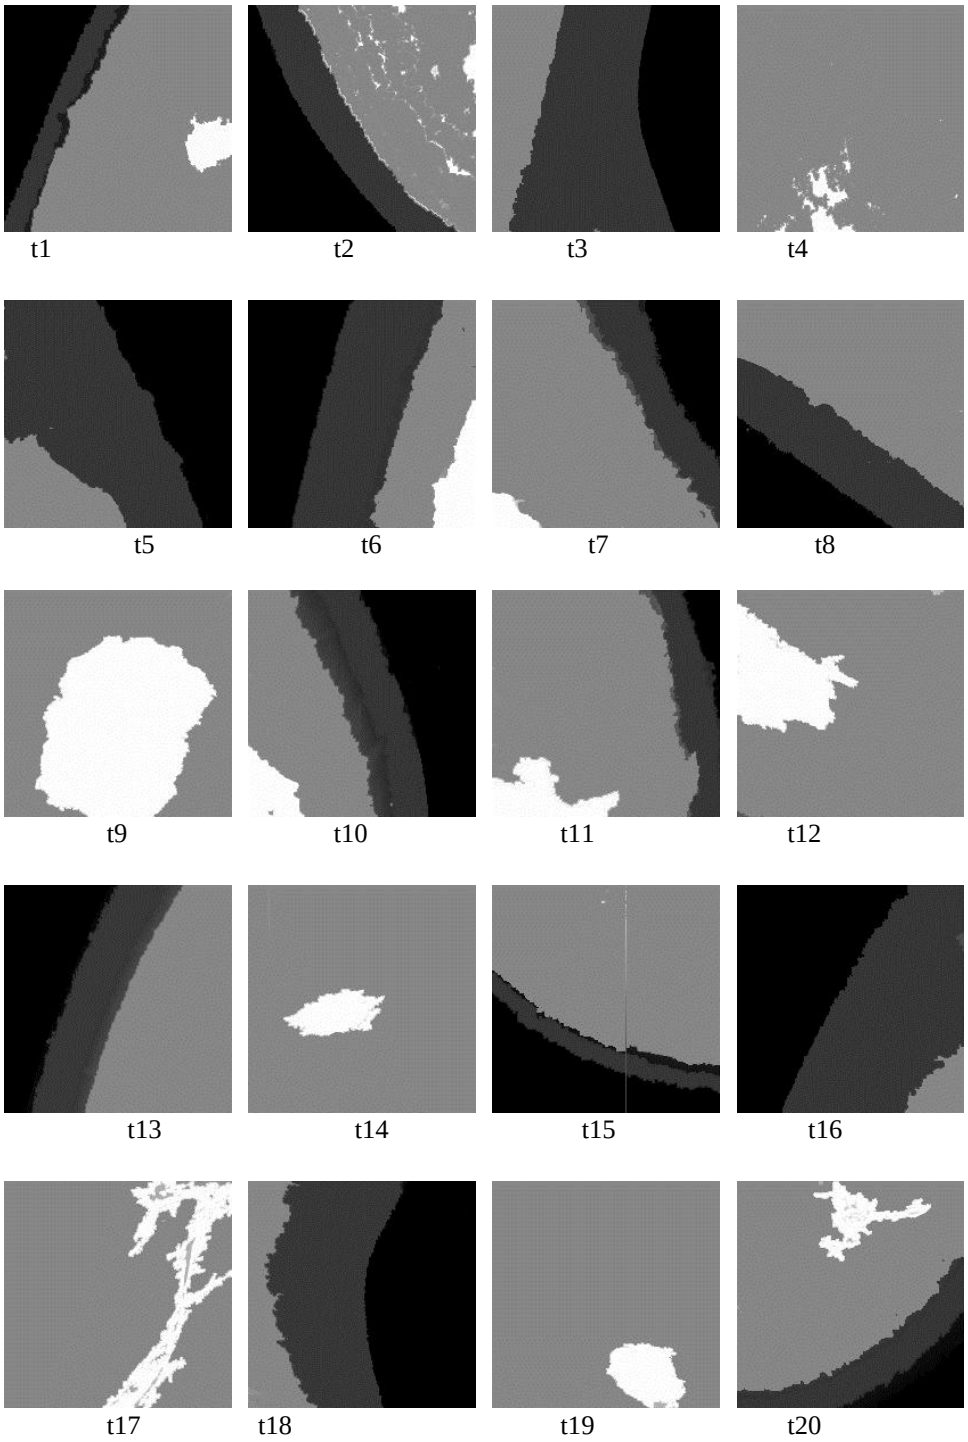
Denklemde $A$ çıkış görüntüsü, $\bar{A}$ çıkış görüntüsünün ortalama değeri, $B$ hedef görüntü ve $\bar{B}$ hedef görüntünün ortalama değeridir.

Eğitimde kullanmak üzere, hastaneden alınan 20 adet mamogram görüntüsü üzerinden 200 x 200 çözünürlüğünde ve jpeg formatında sınıflandırmaya uygun bölgeler belirlenerek seçilmiştir. Özellikle mamogram görüntülerinin üst, alt ve orta bölümleri incelenerek bir veri kümesi oluşturulmaya dikkat edilmiştir. Böylece HYSA'nın aranan nesnelerin örüntüsü öğretilmiştir. Sınıflandırma sonunda HYSA'nın arka plan, dış çeper, iç kısım ve şüpheli alan olmak üzere dört ayrı sınıf oluşturması sağlanmıştır.

Giriş görüntü seti olarak (s1, s2, s3,…s20) belirlenmiş, bu giriş görüntüleri için 20 adet de çıkış görüntü seti (t1, t2, t3,…t20) oluşturulmuştur. Çıkış görüntüleri de 200 x 200 çözünürlüğünde ve jpeg formatında oluşturulmuştur. Şekil 6.11.'de eğitim için kullanılan giriş görüntü seti, Şekil 6.12.'de eğitim için kullanılan çıkış görüntü seti ve Şekil 6.13.'de de HYSA parametrelerinin eğitilmesi için kullanılan genetik algoritmanın akış diyagramı verilmiştir.

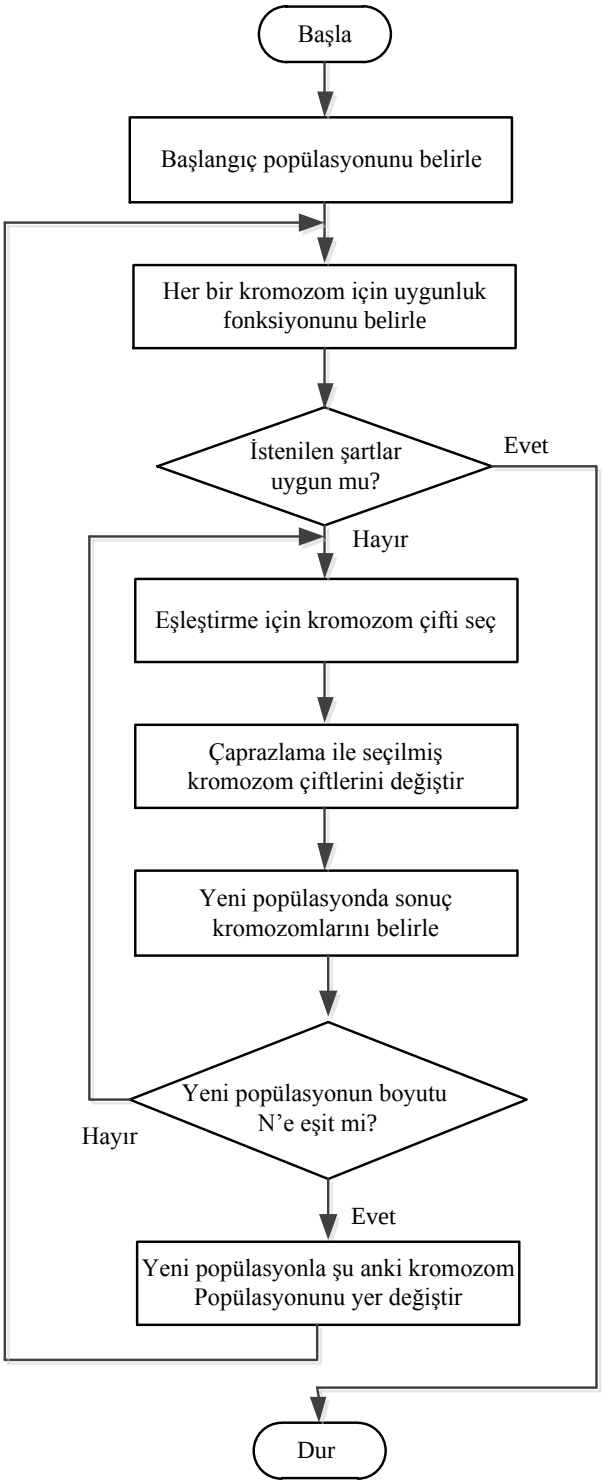



**Şekil 6.11.** Eğitim için kullanılan giriş görüntü seti




**Şekil 6.12.** Eğitim için kullanılan çıkış görüntü seti

*d. Çaprazlama ve Mutasyon:* Çaprazlama ve mutasyon ile yeni bir kuşak oluşmaktadır. Belirlenen durdurma şartları sağlandığında en iyi $\{A, B, I\}$ parametreleri elde edilmiş olur. Durdurma şartı; şu anki iterasyondaki korelasyon değeri ile bir önceki iterasyondaki korelasyon değeri arasındaki farkın $1.10^{-6}$ değerinin altına düşmesi veya iterasyonun sonlanması olarak belirlenmiştir.



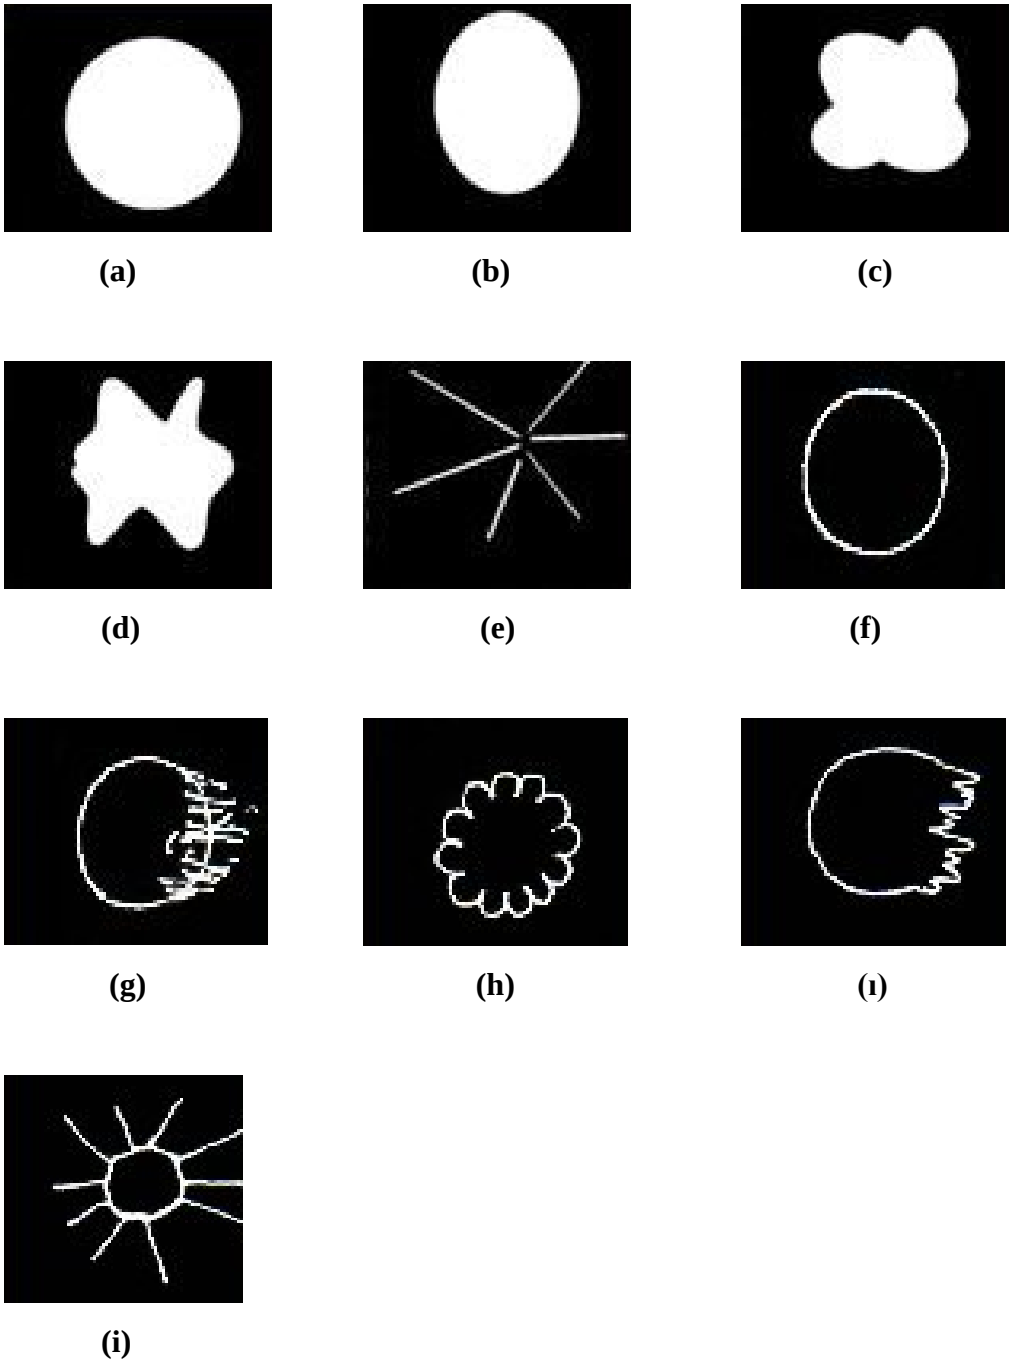

**Şekil 6.13.** HYSA parametrelerinin eğitilmesi için kullanılan genetik algoritmanın akış diyagramı

### 6.2.4. Mamogram görüntülerinde mikrokalsifikasyon ve kitlelerin sınıflandırılması

Mamogram görüntüleri incelendiği zaman birçok yapılardan oluştuğu görülür. Görüntü arka planı, damarlar, yağ dokusu, süt bezi dokusu, kaslar gibi çok çeşitli yapılar vardır. Bu yapılar tek boyutlu mamogram görüntülerinde gri tonlama yapılarak gösterilmesi mamogram görüntüleri üzerindeki mikrokalsifikasyon ve kitlelerin belirlenmesini zorlaştırmakdadır. İlgili alanların belirlenmesinde piksellerin aldığı değerler, pikseller arasındaki komşuluk değerleri kitleleri belirlemede yeterli olmamaktadır. Bu nedenle mikrokalsifikasyon ve kitleleri sınıflandırmada, görüntüler üzerinde şekil analizi yaparak çeşitli parametreler elde edilmeye çalışılmıştır. Belirlenen kitleler üzerinde en-boy oranı, uzama, yoğunluk, gibi özellikler çıkartılarak şekil analizi yapılmıştır. Yine bu kitleler üzerinde şekil analizi parametreleri olan eğim, yönelim, yönelim büyüklüğü ve yönelim oranı değerleri bulunmuştur (Jiang ve ark., 2006).

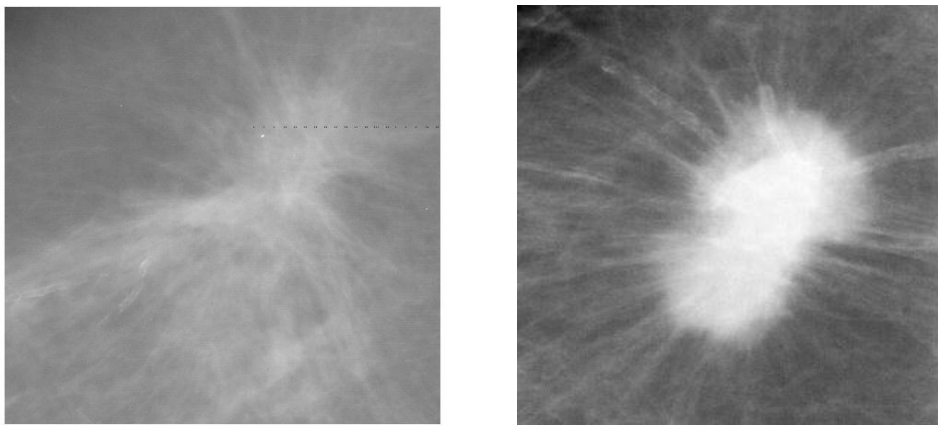
Mamogram görüntüleri üzerinde rastlanan çeşitli tümör tipleri vardır. Bu tümör tipleri yuvarlak (round), oval (oval), bölümlü (lobulated), düzensiz (irregular), yapısal bozulma (architectural distortion), sınırlandırılmış (circumscribed), gizlenmiş (obscured), mikro bölümlü (micro-lobulated), tanımlanmış (defined) ve spiculated olarak sınıflandırılmıştır (Karabulut, 2009). Bu tümörler şekil olarak analiz edildiğinde, tanımlanmış (defined) ve spiculated olanları kötü huylu (malign), yuvarlak (round) ve oval (oval) olanlar iyi huylu (benign) olarak değerlendirilebilir. Diğer tipteki tümörlerin de patolojik olarak değerlendirilmesi gerekmektedir.

Şekil 6.14.'de memede rastlanan tümör çeşitleri modelleri olan round, oval, lobulated, irregular, architectural distortion, circumscribed, obscured, micro-lobulated, ill-defined ve spiculated tiplerinin geometrik modelleri verilmiştir (Karabulut, 2009).




**Şekil 6.14.** Memede rastlanan tümör çeşitlerinin modelleri (a) Round (b) Oval (c) Lobulated (d) Irregular (e) Architectural Distortion (f) Circumscribed (g) Obscured (h) Micro-lobulated (ı) ill-defined (i) Spiculated (Karabulut, 2009)

Şekil 6.15.'de mamogram üzerinden alınan spiculated tipi tümör ve architectural distortion tipi tümör tipleri görülmektedir (Heath ve ark., 2000).



**(a)** **(b)**

**Şekil 6.15.** (a) Spiculated tipi tümör (b) Architectural Distortion tipi tümör (Heath ve ark., 2000)

Algoritma sonunda elde edilen şüpheli bölgelerin inceleme ve sınıflandırılmasında çeşitli yöntemler kullanılabilir. Bunlar yapay zeka teknikleri, sezgisel teknikler, stokastik teknikler ya da önceden elde edilmiş temel bilgilere dayalı teknikler olabilir. Bu tez çalışmasında; mamogram görüntülerinde şüpheli bölgelerden bazı özellikler elde edilerek sınıflandırma fonksiyonu yardımıyla sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma fonksiyonu önceden elde edilmiş bilgilere dayalı bir fonksiyondur. Elde edilen özellikler nesnenin şekil ve doku özelliklerini karakterize edecek şekilde seçilmiştir. Bu özelliklerin çıkarılması için izlenen yol aşağıda verilmiştir.

Şekil 6.16.'da görüldüğü gibi kitlenin ilgili bölgesini analiz etmek için şeklin eksenleri üzerinde bir elips oluşturulmuştur. En-Boy Oranı, Uzama ve Yoğunluk adı verilen üç adet parametre belirlenmiştir. Bu parametrelerin tanımı aşağıdaki gibidir (Jiang ve ark., 2006).

$$EnBoyOranı = \frac{Küçük}{Büyük} \tag{6.5}$$

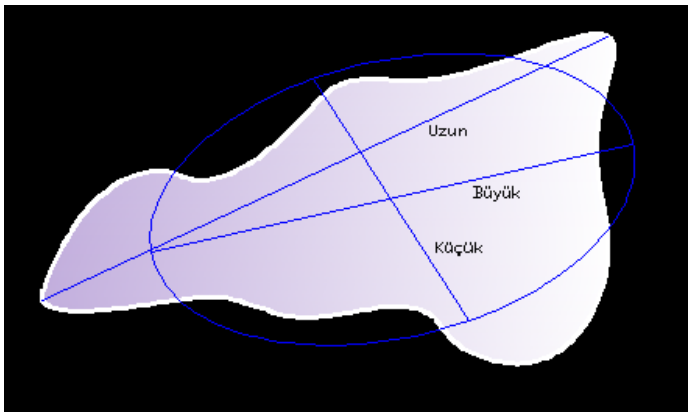
Burada büyük ve küçük parametreleri oluşan elipsin en küçük ve en büyük değerleridir.

$$Uzama = \frac{Büyük}{Uzun} \tag{6.6}$$

Burada uzun parametresi ilgili bölgenin en uzak iki noktası arasındaki mesafedir.

$$Yoğunluk = \frac{L_B^{\,2}}{A} \tag{6.7}$$

Burada $L_B$ ilgili bölgenin çevresi, $A$ ise ilgili bölgenin alanıdır.




**Şekil 6.16.** Kitlenin şekil analizi açısından örneklenmesi

İlgili bölgenin doku yapısını tanımlamak için, yatay ve dikey eksenler (x ekseni, y ekseni) boyunca şekil parametrelerinin eğim (gradient) değerleri hesap edilmiştir. Bu değerler yönelim (orientation), yönelim_büyüklüğü (orientation magnitude) ve yönelim_oranı (gradient radio) olarak ifade edilmiştir ve değerleri aşağıdaki gibidir (Jiang ve ark., 2006):

$$\{ yönelim_x , yönelim_y \} = \frac{1}{L_B} \left\{ \sum_{(i,j)\in B} Eğim_x(i,j), \sum_{(i,j)\in B} Eğim_y(i,j) \right\} \quad (6.8)$$

$$\{ yönelim_büyüklüğü_x , yönelim_büyüklüğü_y \} = \frac{1}{L_B} \left\{ \sum_{(i,j)\in B} |Eğim_x(i,j)|, \sum_{(i,j)\in B} |Eğim_y(i,j)| \right\} \quad (6.9)$$

$$\{ yönelim_oranı_x , yönelim_oranı_y \} = \left\{ \left| \frac{yönelim_x}{yönelim_büyüklüğü_x} \right|, \left| \frac{yönelim_y}{yönelim_büyüklüğü_y} \right| \right\} \quad (6.10)$$

Burada $Eğim_x(i,j) = O(x,y)A$ ve $Eğim_y(i,j) = O(x,y)B$; ($O(x,y)$ incelenen nesnenin görüntüde kapladığı bölgeyi ifade etmektedir) $A$ ve $B$ matrisleri ise aşağıdaki gibi tanımlanmıştır:

$$A = \begin{pmatrix} -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \end{pmatrix} \qquad B = \begin{pmatrix} -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{pmatrix}$$

Hesaplama işleminde hızı arttırmak için x ve y eksenlerindeki parametrelerin maksimum olanları kullanılmıştır. Böylece altı parametre yerine üç parametre kullanılmış oldu.

$$MakYönelim = mak\{ yönelim_x, yönelim_y \} \quad (6.11)$$

$$MakBüyüklük = mak\{ yönelim_büyüklüğü_x, yönelim_büyüklüğü_y \} \quad (6.12)$$

$$MakOran = mak\{ yönelim_oranı_x, yönelim_y, yönelim_oranı_y \} \quad (6.13)$$

Mikrokalsifikasyon ve kitleleri belirlemede görüntüler üzerinde şekil analizi ile sınıflandırma yapılması amacıyla bir parçalı sınıflandırma fonksiyonu oluşturulmuştur.

Sınıflandırma fonksiyonu, şekil analizi için kullanılan en-boy oranı, uzama, yoğunluk, eğim, yönelim, yönelim büyüklüğü, yönelim oranı parametrelerini kullanarak oluşturulmuştur.

Sınıflandırma fonksiyonu belirlenirken aşağıdaki kurallar göz önünde bulundurulmuştur (Jiang ve ark., 2006):

1. *EnBoyOranı* parametresinin büyük olması
2. *Yoğunluk* parametresinin küçük olması
3. *Uzama* parametresinin 1'e yaklaşması

Sınıflandırmada mikrokalsifikasyonlar, kitlelere göre daha küçük şekillerden oluşması nedeniyle hassasiyeti artırmak için parçalı bir fonksiyon seçilmiştir. Kullanılan parçalı fonksiyonun tasarımını kolaylaştırmak ve doğruluğu arttırmak için ilgili bölge, alanlarına göre küçük, orta, geniş ve çok geniş olarak dört parçaya bölünmüştür. Özellikle mikrokalsifikasyonların bulunduğu alanlar çok küçük bölgeler olduğu için belirtilen bu dört parçayı belirlemede çok hassas olunmalıdır. Bu nedenle aşağıdaki kriterler tanımlanmıştır (Jiang ve ark., 2006).

| | |
|---|---|
| Küçük: | Alan < *T1* |
| Orta: | *T1*≤ Alan <*T2* |
| Geniş*:* | *T2*≤ Alan <*T3* |
| Çok geniş: | Alan ≥*T3* |

Burada *T1 – T3* arasındaki üç eşik değeri ampirik olarak belirlenmiş ve algoritmada *T1*=30 piksel, *T2*=300 piksel, *T3*=2000 piksel seçilmiştir. Seçilen ampirik temelli yapıda, sınıflandırma fonksiyonu değerleri aşağıdaki gibi tanımlanmıştır:

1. Alan < $T_1$ için:

$$\textit{Sınıflandırma}\ \text{Fonksiyonu} = \begin{Bmatrix} \text{Sınıf.Fonk.} - 0.03 & * \\ \text{Sınıf.Fonk.} + f_1(\text{MakBüyüklük}) & ** \end{Bmatrix}$$

* = Eğer (EnBoyOranı>5) veya (Yoğunluk>7) veya (MakYönelim>100)
**=Değilse

(6.14)

Burada $f_1(x)$ aşağıdaki gibi tanımlanmıştır:

$$f_1(x) = \begin{cases} 0.2 & x > 120 \\ -0.03 & x < 100 \\ 0.01x - 1 & 100 < x < 120 \end{cases} \quad (6.15)$$

2. $T_1 \leq \text{Alan} < T_2$ için:

$$\textit{Sınıflandırma}\ \text{Fonksiyonu} = \left\{ \begin{array}{cc} \text{Sınıf.Fonk.} - 0.4 & * \\ \text{Sınıf.Fonk.} - 0.05 & ** \\ \text{Sınıf.Fonk.} + f_2(\text{MakBüyüklük,MakOran}) & *** \end{array} \right\}$$

* = *Eğer* (Uzama < 0.7)
**=*Eğer* (MakBüyüklük>100) ve (MakYönelim>100) (6.16)
***=*Eğer* (Uzama ≥ 0.7) ve (MakYönelim>100) ve (MakYönelim < 100)

Burada $f_2(x)$ aşağıdaki gibi tanımlanmıştır:

$$f_2(x, y) = \begin{cases} 1 & x > 120 \text{ ve y < 0.3} \\ 0.8 & x > 120 \text{ ve y < 0.8} \\ 0.04x - 4 & 100 < \text{x} \leq 120 \text{ ve y <0.8} \\ -0.05 & \text{diğer şartlarda} \end{cases} \quad (6.17)$$

3. $T_2 \leq \text{Alan} < T_3$ için:

$$\textit{Sınıflandırma}\ \text{Fonksiyonu} = \text{Sınıf.Fonk.} + f_3(\textit{MakOran}) \quad (6.18)$$

Burada $f_3(x)$ aşağıda tanımlanmıştır:

$$f_3(x) = \begin{cases} 0.8 & x < 0.2 \\ -x + 0.8 & 0.2 \leq x < 0.6 \\ -0.1 & x \geq 0.6 \end{cases} \quad (6.19)$$

4. $Alan \geq T_3$ için:

$$Sınıflandırma \text{ Fonksiyonu} = \text{Sınıf.Fonk.} - 1 - \frac{\text{Alan}}{1000} \qquad (6.20)$$

Çizelge 6.3.'de hastane veri tabanındaki bazı görüntülerden elde edilen şekil ve doku analizi parametrelerine ait değerler, Çizelge 6.4.'de ise MIAS veri tabanındaki bazı görüntülerden elde edilen şekil ve doku analizi parametrelerine ait değerler piksel cinsinden verilmiştir.

**Çizelge 6.3.** Hastane veri tabanındaki bazı görüntülerden elde edilen şekil ve doku analizi parametrelerine ait değerler (piksel cinsinden)

| **Manign kitleler için** | | | | | | | |
|---|---|---|---|---|---|---|---|
| **Alan** | **Büyük** | **Küçük** | **Uzun** | **Çevre** | **EnBoyOranı** | **Uzama** | **Yoğunluk** |
| 41 | 16.532 | 4.951 | 16.125 | 36.385 | 0.299 | 1.025 | 32.289 |
| 21 | 9.804 | 3.654 | 10.77 | 21.314 | 0.373 | 0.91 | 21.632 |
| 14 | 9.097 | 2.618 | 9.487 | 18.485 | 0.288 | 0.959 | 24.408 |
| 33 | 9.991 | 7.208 | 12.806 | 37.556 | 0.721 | 0.78 | 42.742 |
| 15 | 10.146 | 2.414 | 8.944 | 17.657 | 0.238 | 1.134 | 20.784 |
| | | | | | | | |
| **Benign kitleler için** | | | | | | | |
| **Alan** | **Büyük** | **Küçük** | **Uzun** | **Çevre** | **EnBoyOranı** | **Uzama** | **Yoğunluk** |
| 464 | 59.701 | 14.685 | 67.424 | 212.693 | 0.246 | 0.885 | 97.497 |
| 132 | 25.696 | 8.869 | 29.411 | 78.426 | 0.345 | 0.874 | 46.596 |
| 90 | 18.759 | 7.23 | 19.313 | 56.87 | 0.385 | 0.971 | 35.936 |
| 62 | 9.715 | 8.829 | 14.142 | 35.213 | 0.909 | 0.687 | 20 |
| 97 | 23.513 | 5.756 | 25.807 | 55.598 | 0.245 | 0.911 | 31.867 |
| | | | | | | | |
| **Mikrokalsifikasyonlar için** | | | | | | | |
| **Alan** | **Büyük** | **Küçük** | **Uzun** | **Çevre** | **EnBoyOranı** | **Uzama** | **Yoğunluk** |
| 6 | 5.292 | 1.886 | 5.385 | 8.828 | 0.356 | 0.983 | 12.99 |
| 5 | 5.774 | 1.155 | 5.099 | 8 | 0.2 | 1.132 | 12.8 |
| 2 | 2.309 | 1.155 | 2.236 | 2 | 0.5 | 1.033 | 2 |
| 6 | 5.292 | 1.886 | 5.385 | 8.828 | 0.356 | 0.983 | 12.99 |
| 8 | 4.619 | 2.309 | 4.472 | 8 | 0.5 | 1.033 | 8 |

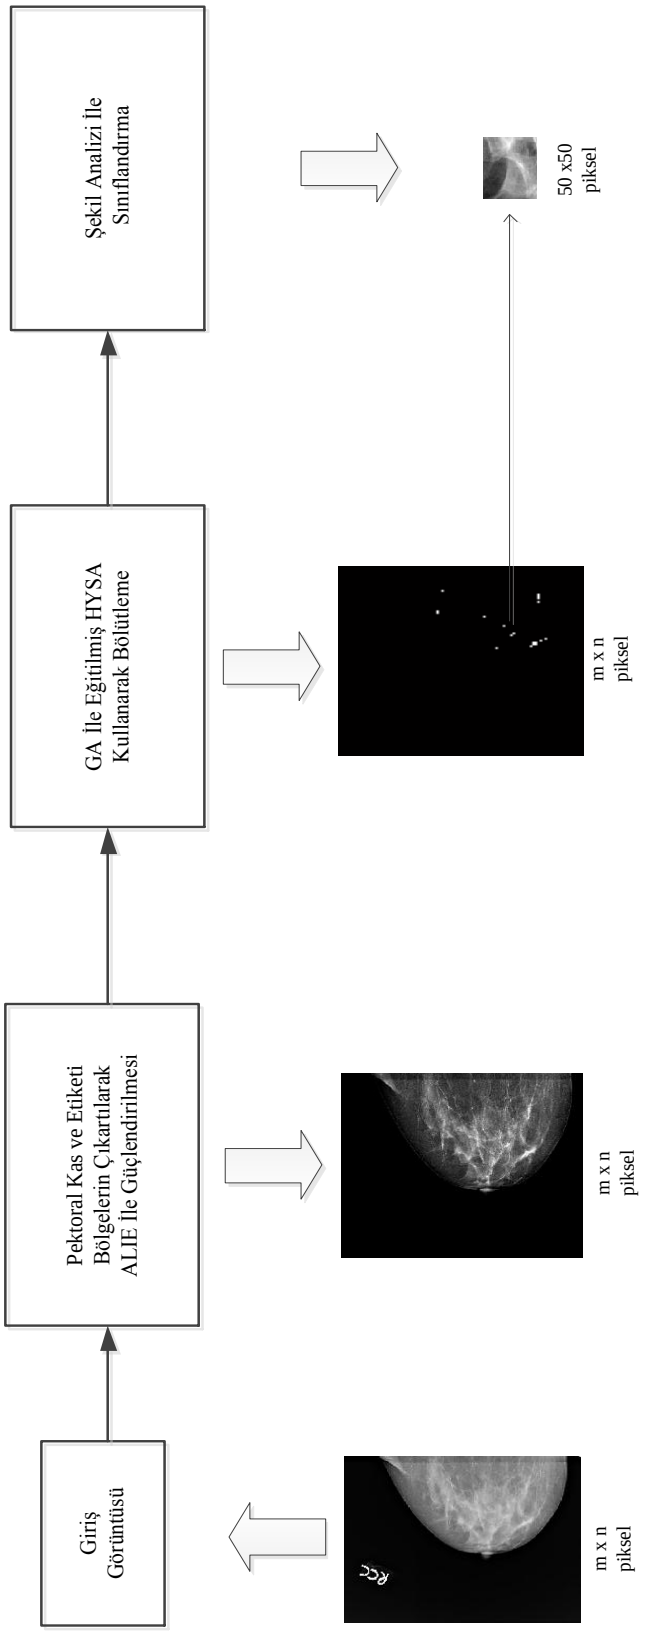
Hastane veri tabanındaki 286 adet mamogram görüntüsünde manign kitleler için elde edilen şekil ve doku analizi parametrelerine ait ortalama değerler: Alan 27.2, Büyük 10.3, Küçük 6.55, Uzun 12.3, Çevre 24.1, EnBoyOranı 0.39, Uzama 0.94 ve Yoğunluk 28.7 şeklinde elde edilmiştir. Benign kitleler için ortalama değerler: Alan 180, Büyük 24.5, Küçük 6.55, Uzun 33.7, Çevre 90.2, EnBoyOranı 0.45, Uzama 0.87 ve Yoğunluk 46.4 şeklinde elde edilmiştir. Mikrokalsifikasyonlar için ortalama değerler: Alan 5.4, Büyük 4.8, Küçük 1.7, Uzun 5.8, Çevre 7.8, EnBoyOranı 0.38, Uzama 1.03 ve Yoğunluk 9.8 olarak elde edilmiştir.

**Çizelge 6.4.** MIAS veri tabanındaki bazı görüntülerden elde edilen şekil ve doku analizi parametrelerine ait değerler (piksel cinsinden)

| **Manign kitleler için** | | | | | | | |
|---|---|---|---|---|---|---|---|
| **Alan** | **Büyük** | **Küçük** | **Uzun** | **Çevre** | **EnBoyOranı** | **Uzama** | **Yoğunluk** |
| 135 | 19.709 | 11.461 | 21.932 | 69.698 | 0.582 | 0.899 | 35.984 |
| 9 | 7.5 | 2.211 | 7.616 | 13.657 | 0.295 | 0.985 | 20.723 |
| 135 | 19.709 | 11.461 | 21.932 | 69.698 | 0.582 | 0.899 | 35.984 |
| 117 | 20.373 | 9.066 | 24.083 | 57.113 | 0.445 | 0.846 | 27.879 |
| 80 | 15.606 | 9.223 | 19.105 | 51.698 | 0.591 | 0.817 | 33.409 |
| | | | | | | | |
| **Benign kitleler için** | | | | | | | |
| **Alan** | **Büyük** | **Küçük** | **Uzun** | **Çevre** | **EnBoyOranı** | **Uzama** | **Yoğunluk** |
| 61 | 10.837 | 7.492 | 13.601 | 31.556 | 0.691 | 0.797 | 16.325 |
| 174 | 24.56 | 9.884 | 27.785 | 68.77 | 0.402 | 0.884 | 27.18 |
| 174 | 24.56 | 9.884 | 27.785 | 68.77 | 0.402 | 0.884 | 27.18 |
| 81 | 12.377 | 8.817 | 15.556 | 39.213 | 0.712 | 0.796 | 18.984 |
| 104 | 21.388 | 7.339 | 22.804 | 65.598 | 0.343 | 0.938 | 41.376 |
| | | | | | | | |
| **Mikrokalsifikasyonlar için** | | | | | | | |
| **Alan** | **Büyük** | **Küçük** | **Uzun** | **Çevre** | **EnBoyOranı** | **Uzama** | **Yoğunluk** |
| 12 | 6.023 | 2.858 | 6.708 | 12.243 | 0.474 | 0.898 | 12.49 |
| 5 | 5.774 | 1.155 | 5.099 | 8 | 0.2 | 1.132 | 12.8 |
| 8 | 4.441 | 2.991 | 5 | 9.657 | 0.674 | 0.888 | 11.657 |
| 12 | 5.178 | 3.426 | 6.403 | 11.899 | 0.662 | 0.809 | 11.8 |
| 10 | 5.259 | 2.907 | 5.657 | 11.071 | 0.553 | 0.93 | 12.257 |

MIAS veri tabanındaki 100 adet mamogram görüntüsünde manign kitleler için elde edilen şekil ve doku analizi parametrelerine ait ortalama değerler: Alan 95.3, Büyük 17.2, Küçük 9.7, Uzun 19.2, Çevre 55.7, EnBoyOranı 0.49, Uzama 0.88 ve Yoğunluk 31.8 şeklinde elde edilmiştir. Benign kitleler için ortalama değerler: Alan 120, Büyük 19.4, Küçük 9.7, Uzun 22.1, Çevre 55.8, EnBoyOranı 0.51, Uzama 0.89 ve Yoğunluk 26.4 şeklinde elde edilmiştir. Mikrokalsifikasyonlar için ortalama değerler: Alan 9.5, Büyük 5.9, Küçük 2.3, Uzun 5.7, Çevre 10.8, EnBoyOranı 0.61, Uzama 0.94 ve Yoğunluk 12.3 olarak elde edilmiştir.

Şekil 6.17.'de bir mamogram görüntüsünün güçlendirme, bölütleme ve sınıflandırma işleminin blok yapısı verilmiştir. Giriş görüntüsü m x n piksel boyutundadır. Bu boyut MIAS veri tabanından alınan görüntülerde 1024 x 1024 piksel, hastane kayıtlarından alınan görüntülerde ise 2400 x 3000 pikseldir. Pektoral kas ve etiketli bölgelerin çıkartılıp ALIE algoritması ile güçlendirilme aşamasından sonra genetik algoritma ile eğitilmiş HYSA yapısıyla bölütlenmiş görüntünün boyutu 50 x 50 piksel olarak elde edilmiştir. Bu bölütlenmiş görüntüde ilgili alanlar elde edilmiştir. Bu alanlar tek tek şekil analizinden geçirilerek sınıflandırma yapılmıştır.




**Şekil 6.17.** Bir mamogram görüntünün güçlendirme, bölütleme ve sınıflandırma işleminin blok yapısı

## 6.3. Sınıflandırma Performanslarının Değerlendirilmesi

Biyomedikal görüntülerin sınıflandırılmasında aşağıda verilen ölçümler kullanılarak değerlendirmeler yapılabilir (Kohavi ve Provost, 1998):

*Doğru Pozitif (DP):* Uzman tarafından hasta (malign) olarak etiketlenmiş bir verinin sınıflandırıcı tarafından hasta (malign) olarak sınıflandırılması.

*Doğru Negatif (DN)*: Uzman tarafından sağlıklı (benign) olarak etiketlenmiş bir verinin sınıflandırıcı tarafından sağlıklı (benign) olarak sınıflandırılması.

*Yanlış Pozitif (YP):* Uzman tarafından sağlıklı (benign) olarak etiketlenmiş bir verinin sınıflandırıcı tarafından hasta (malign) olarak sınıflandırılması.

*Yanlış Negatif (YN):* Uzman tarafından hasta (malign) olarak etiketlenmiş bir verinin sınıflandırıcı tarafından sağlıklı (benign) olarak sınıflandırılması.

Yukardaki ölçümlerden faydalanılarak sınıflayıcı sonuçları ve verilerin etiketlerine uygun olarak gerçek sınıflarının yer aldığı genel gösterim *karmaşıklık matrisi* (Kohavi ve Provost 1998) olarak ifade edilir. Karmaşıklık matrisi gösterimi Çizelge 6.5.'de verilmiştir (Ceylan, 2009):

**Çizelge 6.5.** Sınıflayıcılar için karmaşıklık matrisi

| Verilerin Gerçek Sınıfı | Sınıflayıcının Sonucu | |
|---|---|---|
| | Pozitif (Malign) | Negatif (Belign) |
| Pozitif (Malign) Etiketli Veri | DP | YP |
| Negatif (Belign) Etiketli Veri | YN | DN |

Sınıflayıcıların, sınıflama performansları DP, DN, YP ve YN kriterlerini kullanarak duyarlılık, belirlilik, doğruluk değerleri bulunur ve bu değerlerle değerlendirilirler (Şengür, 2006). Bu kavramlar:

*Duyarlılık: Sınıflayıcının* hastalığı belirleyebilme oranıdır.

$$Duyarlılık = \frac{DP}{DP + YN} \tag{6.21}$$

*Belirlilik: Sınıflayıcının* sağlıklıyı belirleyebilme oranıdır.

$$Belirlilik = \frac{DN}{DN + YP} \tag{6.22}$$

*Doğruluk: Testin* hasta ve sağlıklıyı toplam belirleme oranıdır.

$$Doğruluk = \frac{DP + DN}{DP + YP + YN + DN} \tag{6.23}$$

Mikrokalsifikasyonların belirlenmesi ve kitlelerin iyi huylu mu, kötü huylu mu olduklarının sınıflandırması işleminde Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesinden alınan etiketli 286 adet görüntü kullanılmıştır. 286 adet görüntü üzerinde iki grupta çalışılmıştır. İlkinde 25 adet görüntü üzerinde mikrokalsifikasyonları belirleme ve kitleleri sınıflandırma işlemi uzman bir Radyolog ve geliştirilen KDS tarafından yapılarak performans karşılaştırılmasına gidilmiştir. İkincisinde, 261 görüntü üzerinde KDS yapısı kullanılarak mikrokalsifikasyonları belirleme ve kitleleri sınıflandırma işlemi yapılarak performans karşılaştırılması yapılmıştır.

Çizelge 6.6.'da, geliştirilen KDS yapısı ile konusunda uzman bir radyoloğun hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması verilmiştir. Görüntülerin sınıflandırma işlemi, konusunda yaklaşık 15 yıllık deneyimi olan uzman bir Radyolog hekim tarafından yapılmıştır. Radyolog, çizelgenin değerlendirmesini, görüntülerin önceden yapılmış mikrokalsifikasyon ve kitle tanımı etiketlemesini bilmeden yapmıştır.

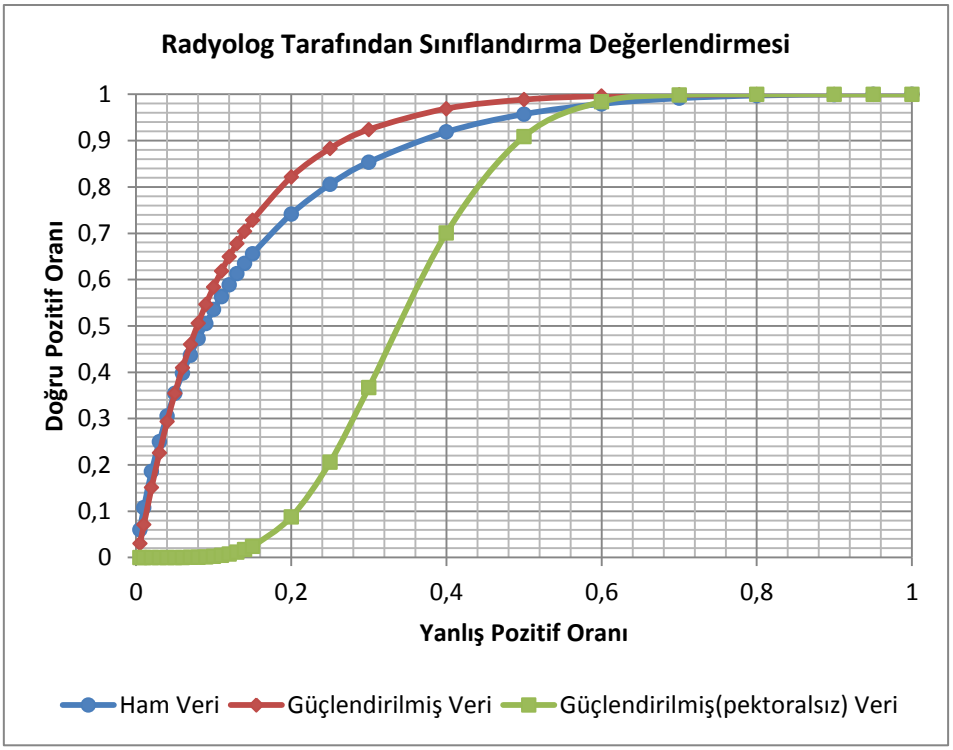
Radyolog ham görüntüleri değerlendirmede %84.0 oranında doğruluk, %88.2 oranında duyarlılık ve %75.0 oranında belirlilik değerlerine ulaşmıştır. Güçlendirilmiş görüntülerde ise %88.0 oranında doğruluk, %92.4 oranında duyarlılık ve %75.0 oranında belirlilik değerlerine ulaşmıştır. Pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırılmasında ise %80.0 oranında doğruluk, %88.2 oranında duyarlılık ve %62.5 oranında belirlilik değerlerine ulaşmıştır. Uzman radyoloğun ALIE algoritması ile güçlendirilmiş görüntüleri,

ham görüntülere göre daha yüksek bir başarıyla değerlendirdiği görülmektedir. Uzman radyoloğun pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırılmasındaki başarısı, ham görüntüleri sınıflamasındaki başarısından daha yüksek, ALIE algoritması ile güçlendirilmiş görüntüleri sınıflandırılmasındaki başarısından daha düşük olduğu görülmektedir. Pektoral kasın, görüntüdeki pektoral kas alanı oranın fazla olması veya yüksek kontrasa sahip olma durumunda çıkarılması daha başarılı sonuçlar vermektedir. Fakat Çizelge 6.6.'da pektoral kas çıkarımı, seçim yapmaksızın bütün görüntülere uygulandığından dolayı bu düşük değerlendirme oranı görülmektedir.

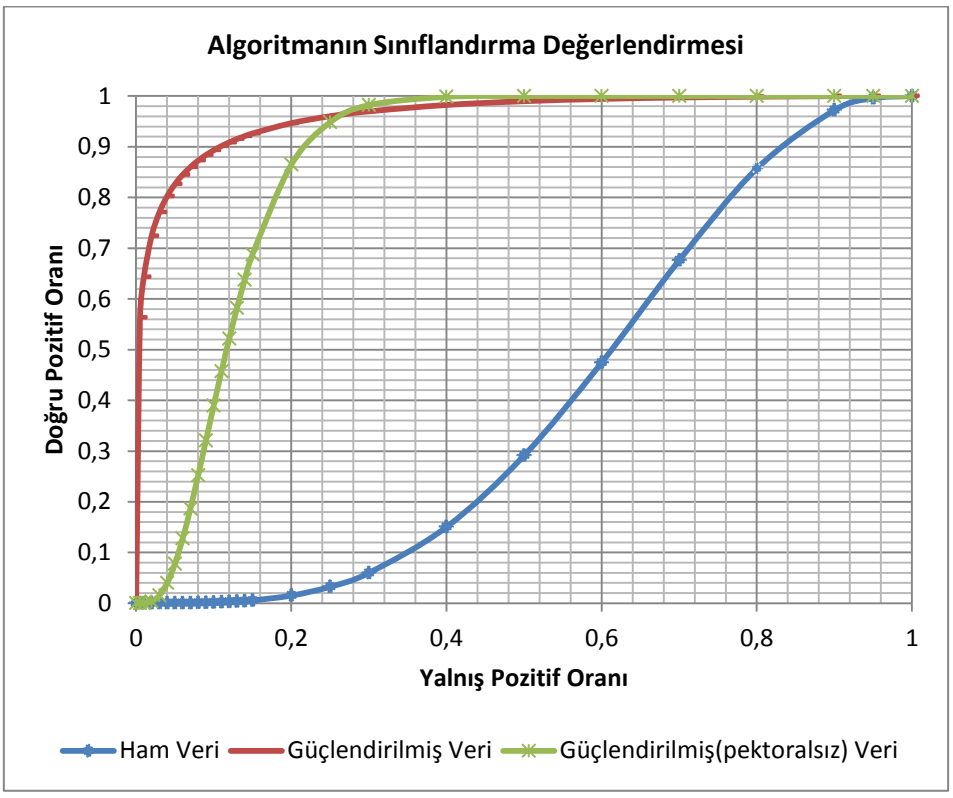
Geliştirilen KDS yapısı ham görüntüleri değerlendirmede %68.0 oranında doğruluk, %88.2 oranında duyarlılık ve %25.0 oranında belirlilik değerlerine ulaşmıştır. Güçlendirilmiş görüntülerde ise %92.0 oranında doğruluk, %95.2 oranında duyarlılık ve %75.0 oranında belirlilik değerlerine ulaşmıştır. Pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırılmasında ise %84.0 oranında doğruluk, %85.0 oranında duyarlılık ve %80.0 oranında belirlilik değerlerine ulaşmıştır. Geliştirilen KDS yapısı, ALIE güçlendirme algoritması ile oldukça iyi bir başarı elde etmiştir. Pektoral kas bölgesi çıkarılarak ALIE ile güçlendirilmiş algoritmanın başarısı, Pektoral kas bölgesi çıkartılmadan ALIE ile güçlendirilmiş algoritmanın başarısından daha düşük olduğu görülmektedir. Yukarıda da bahsedildiği gibi bütün görüntülere pektoral kas çıkarımının uygulanması, değerlendirme oranını düşürmektedir.

**Çizelge 6.6.** Geliştirilen KDS yapısı ile uzman bir Radyoloğun hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması

| | **Radyolog** | | | **Geliştirilen KDS** | | |
|---|---|---|---|---|---|---|
| | **Ham Görüntü** | **Güçlendirilmiş Görüntü** | **Pektoral Kas Çıkartılarak Güçlendirilmiş Görüntü** | **Ham Görüntü** | **Güçlendirilmiş Görüntü** | **Pektoral Kas Çıkartılarak Güçlendirilmiş Görüntü** |
| Görüntü Sayısı | 25 | 25 | 25 | 25 | 25 | 25 |
| Doğru Sayısı | 21 | 22 | 20 | 17 | 23 | 21 |
| Kayıp Sayısı | 4 | 3 | 5 | 8 | 2 | 4 |
| Doğruluk | %84.0 | %88.0 | %80.0 | %68.0 | %92.0 | %84.0 |
| Duyarlılık | %88.2 | %92.4 | %88.2 | %88.2 | %95.2 | %85.0 |
| Belirlilik | %75.0 | %75.0 | %62.5 | %25.0 | %75.0 | %80.0 |
| ROC Alanı | 0.856 | 0.885 | 0.655 | 0.4 | 0.962 | 0.872 |
| Ampirik ROC Alanı | 0.827 | 0.864 | 0.961 | 0.474 | 0.935 | 0.8 |




**Şekil 6.18**. Hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin radyolog tarafından sınıflandırılması




**Şekil 6.19**. Hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin geliştirilen KDS yapısı ile sınıflandırılması

Şekil 6.18.'de hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin Radyolog tarafından sınıflandırılması ROC eğrisi ile verilmiştir. Şekil 6.19.'da hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin geliştirilen KDS ile sınıflandırılması ROC eğrisi ile verilmiştir. Şekil 6.18.'de uzman radyoloğun güçlendirilmiş görüntüleri değerlendirmedeki başarısının, ham görüntülerdeki değerlendirme başarısından daha yüksek olduğu görülmektedir. Şekil 6.19.'da KDS'nin hem güçlendirilmiş görüntülerde hem de pektoralsız güçlendirilmiş görüntülerdeki değerlendirme başarısının, güçlendirme uygulanmamış görüntülerden daha yüksek olduğu görülmektedir. Bu sonuçlardan, ALIE güçlendirme algoritmasının başarılı bir algoritma olduğu görülmektedir.

Çizelge 6.7.'de, geliştirilen KDS yapısının hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması verilmiştir. Necmettin Erbakan Üniversitesi, Meram Tıp Fakültesinden alınan etiketli toplam 261 mamogram görüntüsü üzerinde çalışılmıştır.

Geliştirilen KDS yapısı ham görüntüleri değerlendirmede %67.0 oranında doğruluk, %85.0 oranında duyarlılık ve %24.0 oranında belirlilik değerlerine ulaşmıştır. Güçlendirilmiş görüntülerde ise %91.3 oranında doğruluk, %93.1 oranında duyarlılık ve %70.0 oranında belirlilik değerlerine ulaşmıştır. Pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırılmasında da ise %81.0 oranında doğruluk, %82.5 oranında duyarlılık ve %77.2 oranında belirlilik değerlerine ulaşmıştır. Geliştirilen KDS yapısı, ALIE güçlendirme algoritması ile oldukça iyi bir başarı elde etmiştir. Bu değerlendirme işleminde yine ALIE algoritması ile güçlendirilmiş görüntülerdeki başarının en iyi sonuçları verdiği görülmektedir.

**Çizelge 6.7.** Geliştirilen KDS yapısının hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntüleri sınıflandırmadaki performans karşılaştırılması

| | **Geliştirilen KDS** | | |
|---|---|---|---|
| | **Ham Görüntü** | **Güçlendirilmiş Görüntü** | **Pektoral Kas Çıkartılarak Güçlendirilmiş Görüntü** |
| Görüntü Sayısı | 261 | 261 | 261 |
| Doğru Sayısı | 175 | 238 | 214 |
| Kayıp Sayısı | 86 | 23 | 47 |
| Doğruluk | %67.0 | %91.3 | %81.0 |
| Duyarlılık | %85.0 | %93.1 | %82.5 |
| Belirlilik | %24.0 | %70.0 | %77.2 |
| ROC Alanı | 0.35 | 0.951 | 0.812 |
| Ampirik ROC Alanı | 0.42 | 0.922 | 0.74 |

Çizelge 6.8.'de, geliştirilen KDS yapısının MIAS veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması verilmiştir.

Geliştirilen KDS yapısı ham görüntüleri değerlendirmede %60.0 oranında doğruluk, %84.2 oranında duyarlılık ve %17.0 oranında belirlilik değerlerine ulaşmıştır. Güçlendirilmiş görüntülerde ise %82.0 oranında doğruluk, %91.0 oranında duyarlılık ve %52.0 oranında belirlilik değerlerine ulaşmıştır. Pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntülerin sınıflandırılmasında da ise %74.8 oranında doğruluk, %81.0 oranında duyarlılık ve %55.0 oranında belirlilik değerlerine ulaşmıştır.

Geliştirilen KDS'nın hastane veri tabanındaki görüntüleri sınıflandırmadaki başarısının, MIAS veri tabanındaki görüntüleri sınıflandırmadaki başarısından daha fazla olduğu görülmektedir.

**Çizelge 6.8.** Geliştirilen KDS yapısının MIAS veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkarılarak güçlendirilmiş görüntüleri sınıflandırmadaki performans karşılaştırılması

| | **Geliştirilen KDS** | | |
|---|---|---|---|
| | **Ham Görüntü** | **Güçlendirilmiş Görüntü** | **Pektoral Kas Çıkartılarak Güçlendirilmiş Görüntü** |
| Görüntü Sayısı | 100 | 100 | 100 |
| Doğru Sayısı | 61 | 82 | 75 |
| Kayıp Sayısı | 39 | 18 | 25 |
| Doğruluk | %60.0 | %82.0 | %74.8 |
| Duyarlılık | %84.2 | %91.0 | %81.0 |
| Belirlilik | %17.0 | %52.0 | %55.0 |
| ROC Alanı | 0.31 | 0.85 | 0.721 |
| Ampirik ROC Alanı | 0.33 | 0.84 | 0.70 |

## 6.4. Karar Destek Sistemi İçin Geliştirilen Programlar

Karar destek sistemi (KDS) için iki ara-yüz program geliştirilmiştir. Bu programlardan ilki genetik algoritma eğitimi ile HYSA parametrelerinin belirlenmesi için geliştirilen program, ikincisi ise ham görüntüleri ALIE algoritmasıyla güçlendiren, mikrokalsifikasyonları ve kitleleri belirleyen, görüntü üzerinde seçilen kitlelere ait sınıflandırma parametrelerinin değerlerini belirleyen programdır.

İlk program HYSA'nın en iyi sonuç veren $\{A, B, I\}$ parametrelerini belirlemek amacıyla geliştirilen bir eğitim programıdır. İkinci program ise geliştirilen Karar Destek Sistemini içeren, yani seçilen mamogram görüntüsüne ön işlem uygulama, ALIE algoritması ile güçlendirme yapma, kitle ve mikrokalsifikasyonları belirliyerek sınıflandırma işlemlerini yapan programdır.

### 6.4.1. HYSA parametrelerinin belirlenmesi için geliştirilen program

HYSA parametrelerinin belirlenmesi için Matlab tabanlı bir genetik algoritma programı oluşturulmuştur. Programın kodları yazılırken genetik algoritma kullanılarak optimum HYSA parametreleri belirlenmiştir. Aşağıda bu yapının kodları verilmiştir:

```
Başlangıç popülasyonlarını oluştur,

      for R = 1:numpop (seçilen popülasyon sayısı)
          for R1 = 1:13
       if R1>=1 && R1 <=11
         pop(R,R1)=(rand * -4)+2;
             else
         pop(R,R1)=rand;
       end
       end
     end


Seçim işlemi yap,

sayac=1;

if dur==0
while sayac<=iter
x=ones(5);
y=ones(8);

for R = 1:numpop
    x=pop(R,1:5);
    y=pop(R,6:13);

    pop(R,14)=cnnfonk(x,y);
end

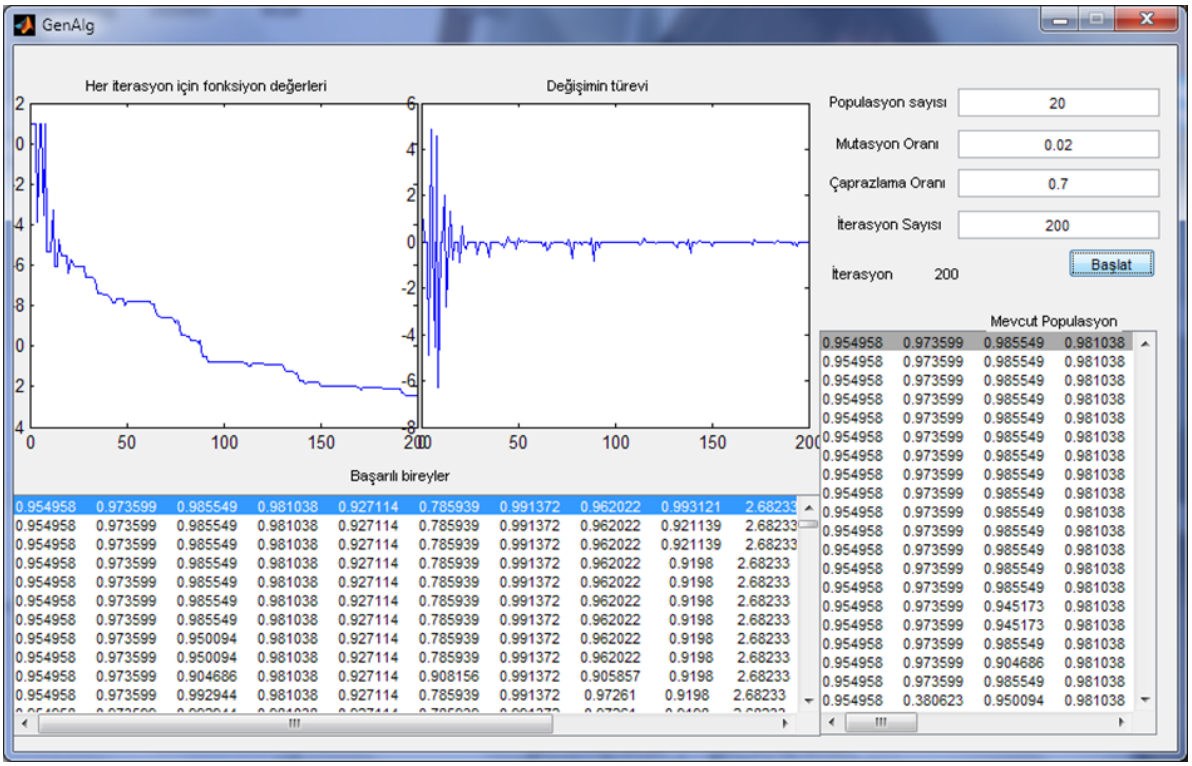

Turnuva fonksiyonunu çalıştır

Çaprazlama fonksiyonunu çalıştır

Mutasyon fonksiyonunu çalıştır

Yeni popülasyonu belirle
```

HYSA parametrelerinin belirlenmesi için geliştirilen programın ekran görüntüsü Şekil 6.20.'de gösterilmiştir.




**Şekil 6.20.** HYSA parametrelerinin belirlenmesi için geliştirilen programın ara yüzü

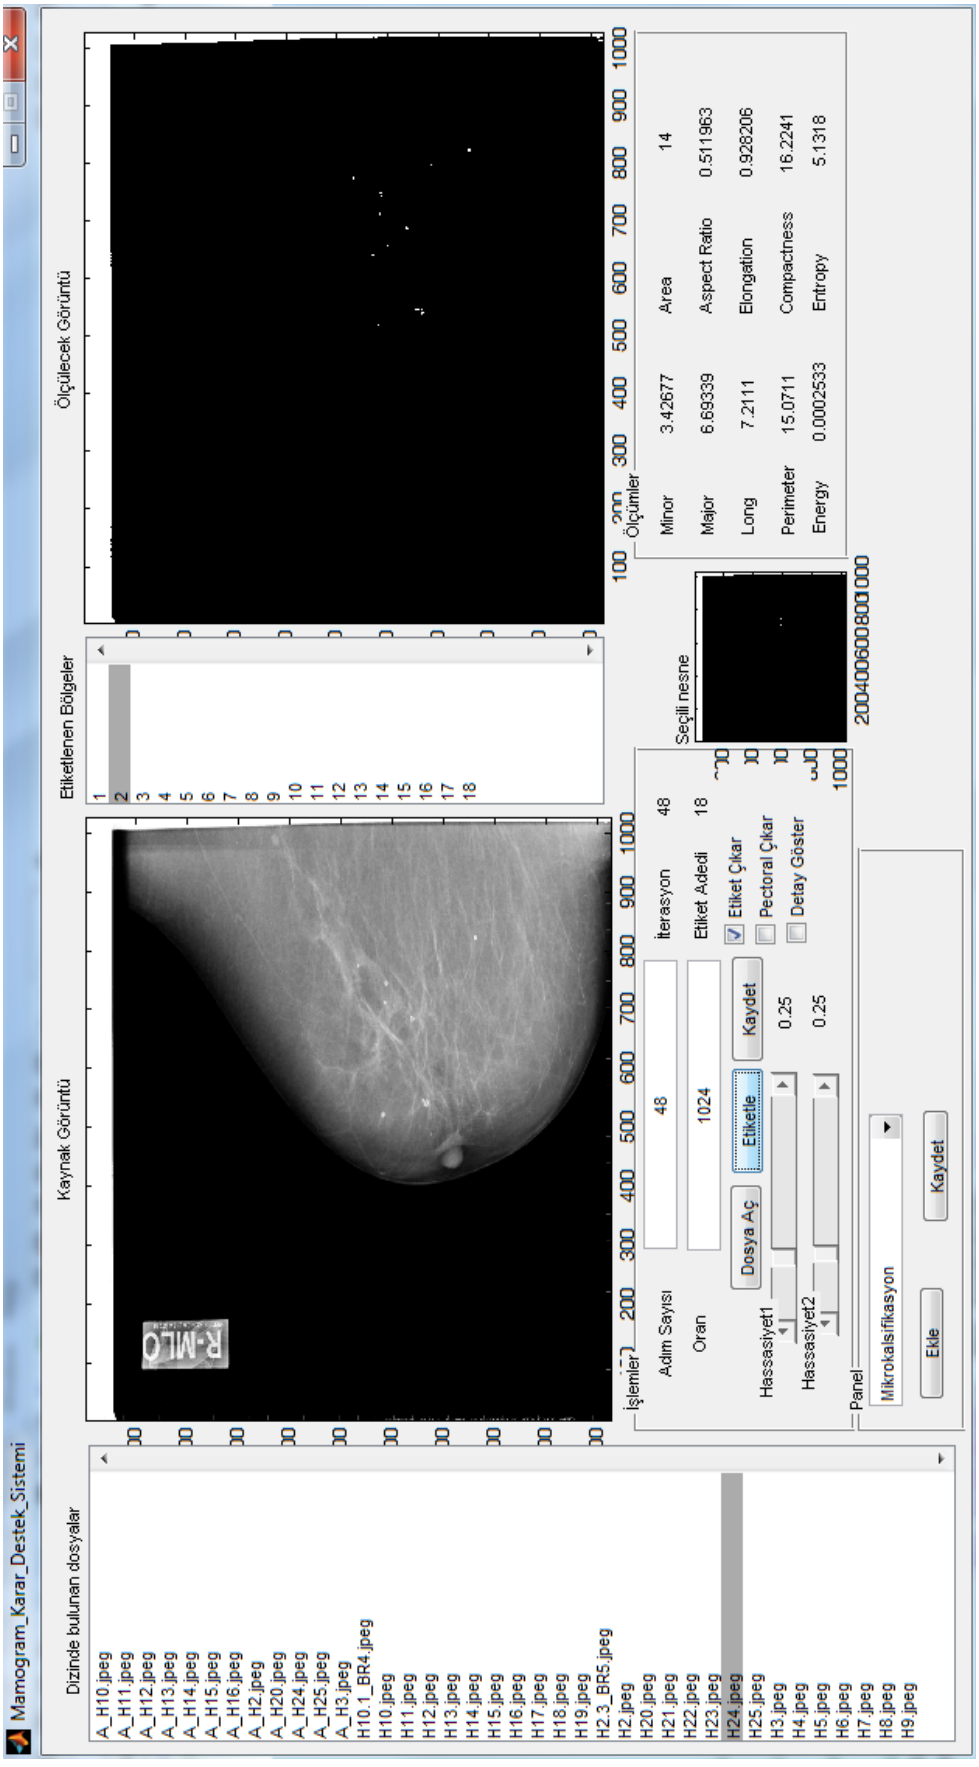
Yukarıda ara-yüz görüntüsü verilen programda popülasyon sayısı, mutasyon oranı, çaprazlama oranı ve iterasyon sayısı için gerekli değerler girildikten sonra başla butonuna basılarak program başlatılır. Popülasyon değeri 20 ile 50 arasında, iterasyon değeri de 100 ile 1000 arasında hassasiyet ve kullanılan bilgisayarın bileşenleri göz önünde tutularak seçilir. Çalışmada mutasyon oranı 0.02, çaprazlama oranı 0.7 seçilmiştir. Mevcut popülasyon alanında da popülasyon sayısı ne seçilmiş ise, bu bireyler sıralı olarak gösterilmektedir. Başarılı bireyler alanında, her iterasyondan sonra en başarılı bireyler gösterilmektedir. Her iterasyon için fonksiyon değeri alanında, her iterasyon sonu en başarılı bireyin uygunluk fonksiyonu, değişimin türevi alanında da bir önceki bireyle şimdiki bireyin uygunluk fonksiyonlarının arasındaki değişim farkının grafiği verilmektedir.

### 6.4.2. Lezyonları belirlemek ve sınıflandırmak için geliştirilen program

Geliştirilen ikinci programda sayısal veya sayısallaştırılmış görüntülere önce ALIE algoritması uygulanmakta, mikrokalsifikasyonlar ve kitleler belirlenmekte ve görüntü üzerinde seçilen kitlelere ait sınıflandırma parametrelerinin değerleri belirlenmektedir. Tasarlanan programın ekran görüntüsü Şekil 6.21.'de gösterilmiştir.

Program çalıştırıldığında aktif dizinde bulunan görüntü dosyaları listelenmektedir. Hangi dosya seçilmiş ise o dosyanın ön görüntüsü kaynak görüntü alanında görünmektedir. Adım sayısı alanında HYSA için iterasyon sayısı, oran alanında ise görüntüyü küçültme oranı belirlenmektedir. Etiketle butonuna basıp programı çalıştırmadan önce etiket çıkar seçeneği ile görüntü üzerindeki etiket ve istenmeyen gürültülerin çıkarılmasını, pektoral çıkar ile pektoral kas bölgesinin çıkarılmasını ve detay göster ile de seçili nesnenin detayının ön izlemesi sağlanmıştır. Hassasiyet1 seçeneği güçlendirme için, hassasiyet2 seçeneği sınıflandırma için seçilen thresholding değerini ayarlamaktadır. Etiketle butonuna basılıp program çalıştırıldıktan sonra ölçülecek görüntü alanında sistemin belirlediği tüm şüpheli kitleler görülmekte ve bu kitlelerin indeks numaraları da etiketlenen bölgeler alanında verilmektedir.

Şüpheli kitle seçildiğinde, bu kitlenin yeri görüntü üzerinde belirlenip, diğer şüpheli alanlar ise bastırılmaktadır. Bu kitleye ait sınıflandırma işleminde kullanılacak küçük (minor), büyük (major), uzun (long), çevre (perimeter), en-boy oranı (aspect ratio), uzama (elongation), yoğunluk (compactness) ve entropy değerleri hesaplanarak ekrana verilmektedir. Kaydet butonuna basarak bulunan bu değerler excel formatında otomatik olarak bir dosya içine kaydedilmektedir.




**Şekil 6.21.** Lezyonları belirlemek ve sınıflandırmak için geliştirilen programın ara yüzü

# 7. MAMOGRAM GÖRÜNTÜLERİNİN GÜÇLENDİRİLMESİ

Görüntü işleme üzerine yapılan pek çok çalışmalarda olduğu gibi, biyomedikal görüntüleri üzerine yapılan çalışmalarda da güçlendirme işlemi önemli aşamalardandır (Zhiyuan ve ark., 2009) . Özellikle bölütleme ve sınıflandırma öncesi yapılan görüntü üzerindeki güçlendirme, bölütleme ve sınıflandırmadaki başarıyı artırmaktadır.

Geliştirilen Karar Destek Sisteminin (KDS) verimli ve daha başarılı sonuçlara ulaşması için yeni bir güçlendirme algoritması olan ALIE (Automated Lesion Intensity Enhancer) geliştirilmiştir. Tez çalışmasında, mamogram görüntüleri üzerindeki lezyonları belirlemede, özellikle mikrokalsifikasyonları belirlemede, histogram temelli güçlendirme algoritması kullanılmıştır. Bu algoritma, kitlelere göre belirlenmesi daha zor olan mikrokalsifikasyonları ortaya çıkarmada başarılı olmuştur.

## 7.1. Görüntü Güçlendirme

Çeşitli kaynaklardan değişik formatlarda sayısal görüntüler elde edilmekte ve bu verilerle çalışılmaktadır. Fakat her elde edilen sayısal görüntü aynı piksel değerinde, çözünürlükte ve parlaklık değerinde değildir. Görüntü güçlendirme, doğru bir görüntü analizi kullanarak parlaklık vb. görüntü özelliklerini iyileştirmektir (Wu ve ark., 2008). İyi bir güçlendirme algoritması, görüntünün kalitesini artırırken, görüntü üzerinde bilgi kaybı oluşturmaması gerekir.

Pek çok görüntü güçlendirme algoritmaları geliştirilmiş ve halen geliştirilmektedir (Petrick ve ark., 1996, Panetta ve ark., 2008, Xiao ve Zhang, 1010). Bu algoritmalar temelde iki kategoride sınıflandırılabilirler: uzaysal yöntemler (spatiel domain methods) ve dönüşüm yöntemleri (transform domain methods) (Wu ve ark., 2008). Uzaysal yöntemler sınıfındaki güçlendirme algoritmaları, görüntünün bütünü üzerinde veya görüntü üzerinde seçilen belirli bir bölgede işlemleri gerçekleştirirler. Bu güçlendirme algoritmalarına histogram eşitleme (histogram equalization), görüntü ortalama (image averaging), sınır veya kontur gibi nitelikleri keskinleştirme (sharpening of important features such as edges or contours) ve doğrusal olmayan filtreleme (nonlinear filtering) yöntemleri örnek olarak verilebilir.

Dönüşüm yöntemleri grubundaki görüntü güçlendirme algoritmaları ise, Fourier ve dalgacık dönüşümlerini kullanarak görüntüleri güçlendirir. Bu alanlarda belirli katsayılar arttırılır ve görüntü bileşenleri uzaysal alana dönüştürülür.

### 7.1.1. Uzaysal yöntemler

Bu metotta yoğunluk bölgesi $[0, L]$ aralığında tanımlanan gri-seviyeli görüntüler, görüntü dönüşüm operatörü $T$, görüntü haritası $I$ ve yeni görüntü $g$ olmak üzere aşağıdaki denkleme göre görüntü dönüşümü gerçeklenir (Wu ve ark., 2008):

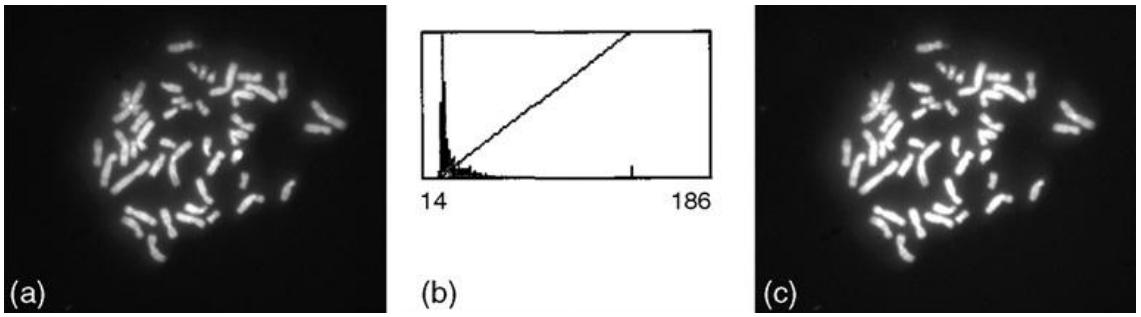
$$g = T(I) \tag{7.1}$$

Kontrast ayarlama, kırpma ve eşikleme, görüntü çıkarma ve ortalama, histogram eşitleme, kontrast ayarlı histogram eşitleme yöntemleri bu metotta örnek olarak verilebilir.

Kontrast ayarlama yöntemine göre, ilgili bölgenin yoğunluğu $I_1$ ve $I_2$ olmak üzere, yeni görüntü $g$ aşağıdaki gibi tanımlanabilir (Wu ve ark., 2008):

$$g = \frac{(I - I_1)}{(I_2 - I_1)}(\mathrm{I_{max}} - \mathrm{I_{min}}) + \mathrm{I_{min}} \tag{7.2}$$

Şekil 7.1.'de kontrast ayarlama yöntemi kullanarak görüntü güçlendirme işlemi yapılmıştır. (a) orjinal görüntü (b) tanımlanan haritalama (c) güçlendirilmiş görüntüdür.




**Şekil 7.1.** Kontrast ayarlama yöntemi kullanarak görüntü güçlendirme (a) Orjinal görüntü (b) Tanımlanan haritalama (c) Güçlendirilmiş görüntü (Wu ve ark., 2008).

Görüntü kırpma ve eşikleme özellikle gürültü bastırmada kullanılan, kontrast ayarlamanın özel bir durumudur. Giriş görüntüsü $f$, $[0,L]$ aralığında olmak üzere, dönüşüm aşağıdaki denklemde verildiği gibi tanımlanmıştır (Wu ve ark., 2008):

$$g=\begin{Bmatrix} 0 & 0\le f<a \\ \alpha I & a\le f<b \\ L & f\ge b \end{Bmatrix} \qquad (7.3)$$

$a$ ve $b$ görüntünün histogramından elde edilmiş katsayılardır ve eğer $a=b$ olursa dönüşüm *eşikleme* (thresholding) olarak isimlendirilir ve çıkış görüntüsü binary görüntüdür.

Uzaysal yöntemler sınıfına giren metotlardan bir diğeri de görüntü çıkarma ve ortalama (image subtraction and averaging) metodudur. Sabit bir nesnenin $N$ adet görüntüsü mevcut olduğunda, $\sqrt{N}$ çarpanı ile sinyal-gürültü oranının azaltılmasını temel alan bir yoldur. Aynı görüntü farklı şartlar altında elde edilebilirse görüntü çıkarma işlemi yapılabilir (Agart ve ark., 1989). Görüntü çıkarma işleminde iki görüntü arasındaki farklılıklar vurgulanır.

### 7.1.2. Dönüşüm yöntemleri

Fourier ve dalgacık dönüşüm algoritmaları en temel dönüşüm yöntemlerindendir. Birçok durumda frekans domeni filtreleme, görüntülerden gürültüleri ayırmada daha başarılıdır. Görüntü frekans domenine dönüştüğünde, görüntüdeki geniş yapılar ve yumuşak bölgeler alçak-frekans bileşenlerine; görüntü nitelikleri orta-frekans bileşenlerine ve baskın gürültüler yüksek-frekans bileşenlerine karşılık gelir. Bu nedenle filtre tasarlanırken frekans bileşenleri bilgisi göz önünde bulundurulur (Beghdadi ve Negrate, 1991). Örneğin bir gürültü-bastırma güçlendirme filtresi, orta-frekans bileşenlerinin genliğini yükseltmeye, yüksek-frekans bileşenlerini de düşürmeye çalışır.

Fourier dönüşüm yöntemlerine; Wiener filtreleme (Wiener filtering), en küçük kareler yaklaşımı kullanarak dekonvolüsyon (deconvolution using a least-squares approach), frekans domeninde alçak-geçiren filtreleme (low-pass filtering in the Fourier domain) ve frekans domeninde yüksek-geçiren filtreleme (high-pass filtering in the fourier domain) örnek olarak verilebilir.

Dalgacık dönüşümleri çoklu görüntü yapılarının analizi için geliştirilmiştir (Knutsson ve ark., 1983). Fourier dönüşümü gibi geleneksel dönüşüm metotlarının tersine, dalgacık-temelli dönüşüm metotları sadece sinyallerin frekans bileşenlerini analiz etmez, aynı zamanda farklı skaladaki frekans bileşenlerinin de analizini mümkün kılar. Dalgacık-temelli dönüşüm metotları görüntü verilerini sıkıştırma, gürültü bastırma ve sınır belirleme gibi uygulamalar için oldukça uygundur.

Dalgacık dönüşüm yöntemlerine; dalgacık eşikleme (wavelet thresholding) ve diferansiyel dalgacık dönüşümü (differential wavelet transform) örnek verilebilir.

## 7.2. Mamogram Görüntülerinde Kitle Yoğunluğunun Otomatik Olarak Güçlendirilmesi

Kitleler ve özellikle mikrokalsifikasyonların belirlenmesi, meme kanserinin erken teşhisinde son derece önemlidir. Meme kanseri olgularının %30-40'ında mikrokalsifikasyon görülmesi, erken tanıda mikrokalsifikasyonların önemini ortaya koymaktadır (Heywang-Köbrunner ve ark., 1997). Mikrokalsifikasyonların büyüklüğü genellikle 0.1 mm – 2 mm aralığında, 1cm$^2$ alandan daha küçük parlak noktacıklar olarak görülürler (Hernández-Cisneros ve Yerashima-Marin, 2006) .

Mamogram görüntüleri küçük sinyalli işretlerdir (Vilariño ve ark. 2003). Arka plan gürültüleri ve düşük kontrast seviyeleri de diğer önemli problemlerdir. Geleneksel güçlendirme algoritmaları, özellikle yoğun (dense) memelerde kontrast değerini artırırlar. Bu yoğun doku üzerindeki kalsifikasyonlar, düşük kontrastları nedeniyle belirlenmeleri zorlaşır (Morrow ve ark., 1992). Pek çok histogram temelli metotlarda da genelde görüntünün kontrast değeri artırılırken, görüntü üzerinde arzu edilmeyen etkiler oluşur (Yeganeh ve ark., 2008).

Mikrokalsifikasyon kümeciklerini başarılı bir şekilde belirlemede, kontrast seviyelerini güçlendirmeye ve gürültüleri uzaklaştırmaya ihtiyaç vardır. İşte bu problemleri ortadan kaldırmak için uzaysal yöntemler sınıfına giren histogram-temelli yapıda bir güçlendirme algoritması, ALIE (Automated Lesion Intensity Enhancer) geliştirilmiştir. Algoritma temelde mamogram görüntülerindeki arka planın yoğunluk seviyesini düşürürken, anormal bölgelerin yoğunluk seviyesini güçlendirmektedir. Önce görüntünün gri-ölçekleme histogramı oluştulup, histogramdan tam siyah bölgelerin histogramı çıkarılarak yeni bir histogram elde edilmiştir. Koyu ve açık bölgelerin ortalama değer histogramları hesaplanarak, çok hassas bir şekilde ilgili alanlar güçlendirilerek oldukça başarılı sonuçlar elde edilmiştir.

Bu algoritma 8 bit tam sayılı, 0-255 arasında ölçeklenmiş gri-ölçekli görüntüler için tasarlanmıştır. Algoritma görüntünün tamamına uygulanmakta, görüntüyü koyulaştırırken, mikrokalsifikasyon gibi lezyonların gri değerini korumaktadır. Algoritma başlangıçta bütün görüntünün histogramından indeks değerleri ve katsayılar üretmekte ve bu değerler kullanılarak iki yeni destekleyici görüntü oluşturulmaktadır. Oluşturulan görüntülerden ilki, orijinal görüntüden koyu indeks değerinin çıkarılması ile ikinci görüntü ise, orijinal görüntüye açık indeks değerinin ilave edilmesiyle elde edilmektedir. Bu görüntüler elde edildikten sonra,

algoritma doğrusal birleştirme tekniklerini kullanarak bu üç görüntüden güçlendirilmiş görüntüyü elde eder. Algoritmada medyan ve ortalama filtreleri de kullanılmıştır. İlk bakışta bu filtreler normalde mikrokalsifikasyon gibi küçük lezyonlar için tehlikeli ve kullanışsız gibi görülse de, algoritmanın son adımında orijinal görüntü ile üretilen görüntü arasında doğrusal birleştirme tekrar yapılarak küçük lezyonlardaki kayıplar tamamen önlenmiştir. 22 adımdan oluşan bu algoritmanın pseuedo kodları aşağıda, akış şeması ise Şekil 7.2.'de verilmiştir.

**ALIE (Source_Image //** Mamogram Görüntüsünü Oku**){**

Sharpened=unsharp(Source_image); // Görüntüye Keskinleştirme Maskesini Uygula

H=histogram(Sharpened); // Görüntünün Gri-Ölçekleme Histogramını Oluştur

H_W =H(5:255); // Histogramdan Tam Siyah Bölgeleri Çıkar

DH= H_W(1:125); // Histogramın Koyu Bölgelerini Belirle

LH=H_W(126:255); // Histogramın Açık Bölgelerini Belirle

DM=median(DH); // Koyu Bölgelerin Ortalama Değer Histogramını Bul

LM=median(LH); // Açık Bölgelerin Ortalama Değer Histogramını Bul

D_I= find (DM); // Koyu Indeks Değerinin Bulunması

L_I= find (LM); // Açık Indeks Değerinin Bulunması

D_image= Source_image – D_I; // Kaynak Görüntüden Zayıflatılmış Görüntüyü Çıkar

L_image= Source_image + L_I; // Kaynak Görüntüyle Güçlendirilmiş Görüntüyü Topla

TR_Image1= linearcombinate(D_image, Source_image); // Kaynak Görüntü ve Zayıflatılmış Görüntünün Doğrusal Birleştirilmesiyle Üretilmiş Geçici ilk Görüntü

TR_Image2= linearcombinate(L_image, Source_image); // Kaynak Görüntü ve Güçlendirilmiş Görüntünün Doğrusal Birleştirilmesiyle Üretilmiş Geçici İkinci Görüntü

TR_Image3= linearcombinate(TR_image1, - TR_image2); // İlk Geçici Görüntü ve İlk Geçici Görüntünün negatifi ile Doğrusal Birleştirilmesiyle Üretilmiş Geçici Üçüncü Görüntü

TR_image4= linearcombinate(TR_image3, Source_image); // Üçüncü Geçici Görüntü ve Kaynak Görüntünün Doğrusal Birleştirilmesiyle Üretilmiş Geçici Dördüncü Görüntü

TR_image5= TR_image4 - D_I; // Dördüncü Geçici Görüntüden Koyu Indeksin Çıkarılmasıyla Üretilmiş Geçici Beşinci Görüntü

M_image= median_2d(TR_image5); // Geçici Beşinci Görüntü Üzerine İki Boyutlu Medyan Filtresi Uygulamak Suretiyle Üretilmiş Medyan Filtrelenmiş Görüntü

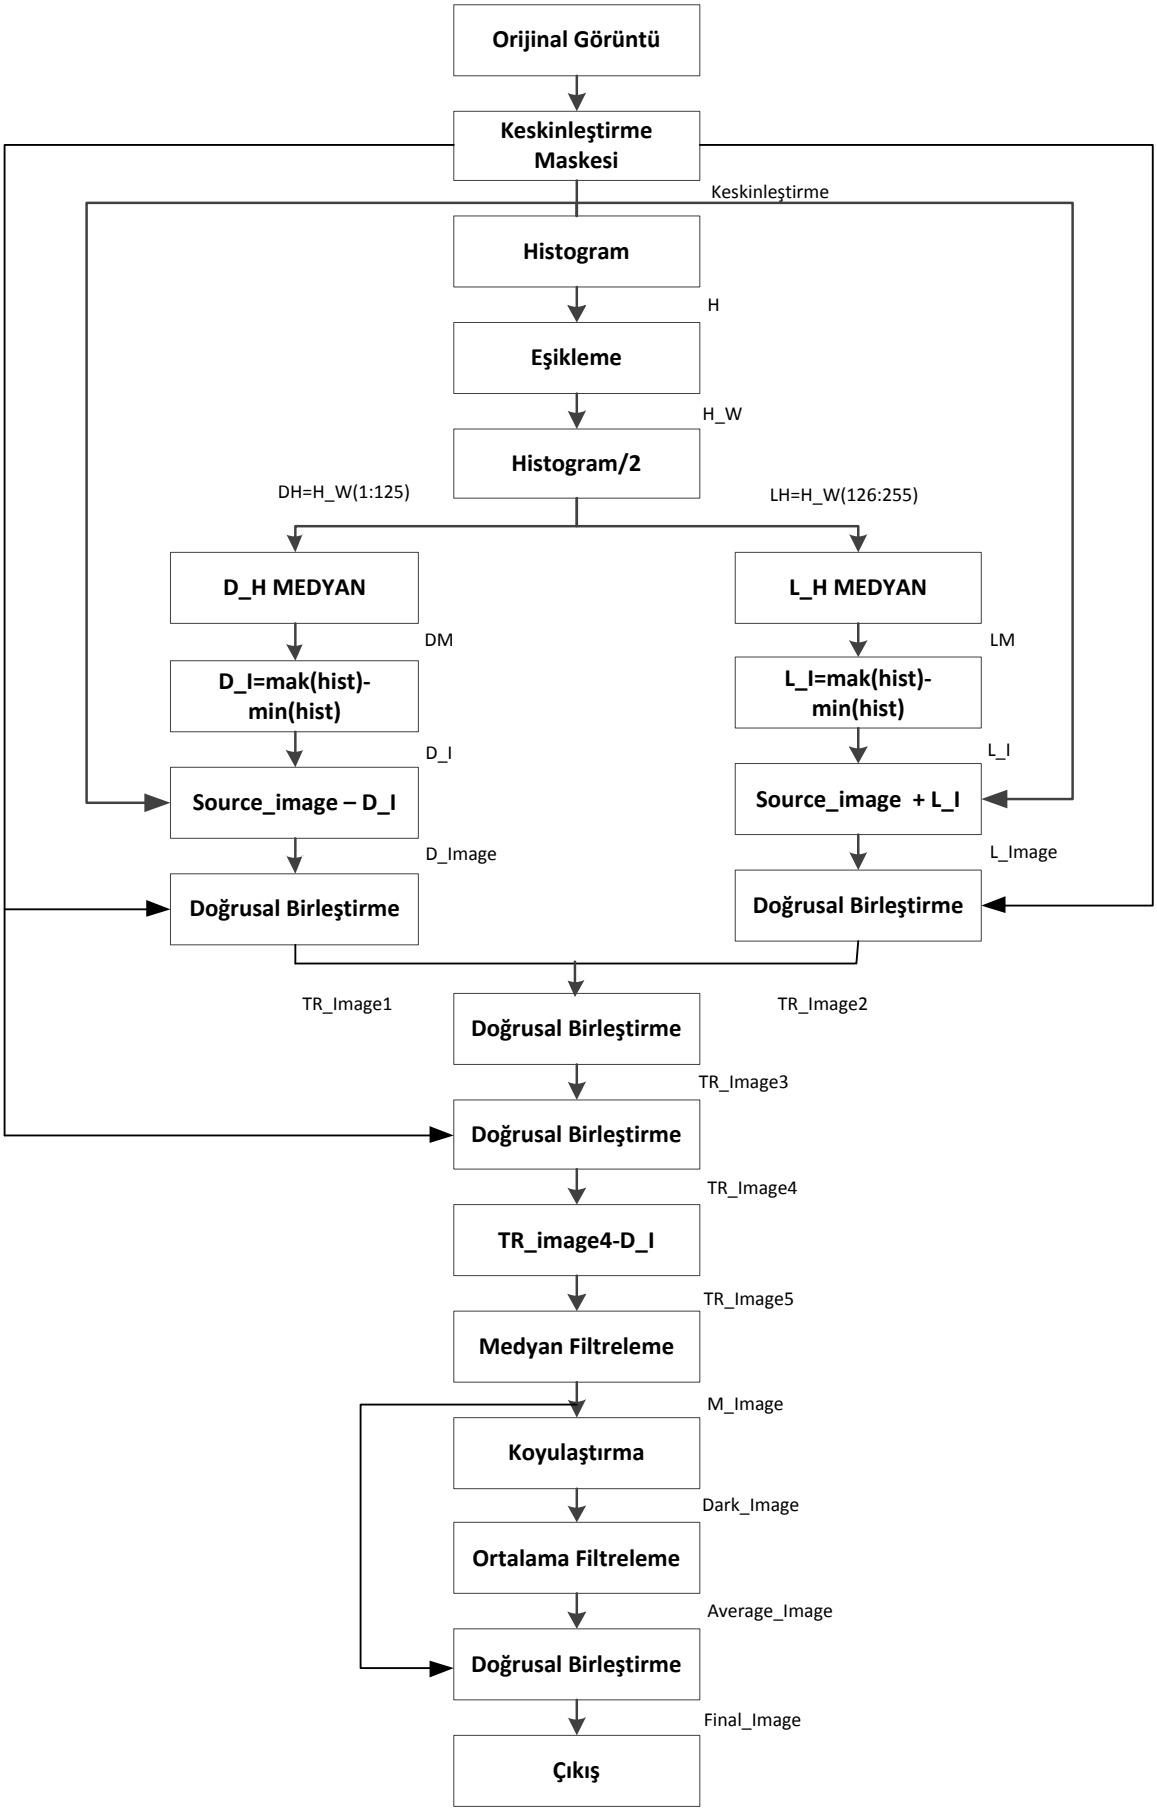
Cbright= |L_I – D_I|; // Aydınlatma Katsayısının Hesaplanması

Cdark=Cbright-1; // Koyulaştırma Katsayısının Hesaplanması

Dark_image=darken(M_image,Cdark); // Koyulaştırma Katsayısı Kullanılarak Koyulaştırılmış Medyan Filtreli Görüntü

AvDark_image = average_filter(Dark_image); // Ortalama Filtrelenmiş Koyu Görüntü

Final_image= linearcombinate (AvDark_image, M_image); //Koyulaştırılmış Görüntü ve Medyan Filtrelenmiş Görüntünün Doğrusal Birleştirilmesiyle Üretilmiş Son Görüntü **}**



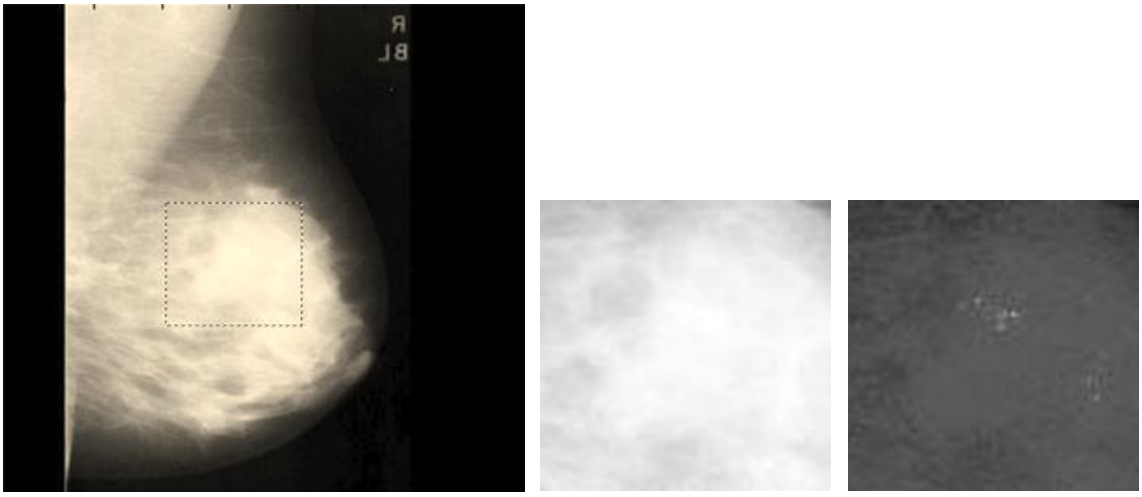

**Şekil 7.2.** ALIE güçlendirme algoritmasının akış şeması

Geliştirilen ALIE güçlendirme algoritmasının adım adım açıklaması yapılacak olursa, öncelikle okunan görüntülerin boyutları ele alınmıştır. Görüntünün boyutu belirlenen bir boyuta göre normalize edilerek yeniden boyutlandırılma işlemi yapılmıştır. Daha sonra görüntünün formatına bakılıp gri yapıya sahip olup olmadığına bakılmış, eğer gri yapıda değilse bu yapıya dönüştürülme işlemi yapılmıştır. Bu aşamaların Matlab kodları aşağıda verilmiştir:

```
incele=imread(resim);              %Resmi oku
boyut=size(incele);                %En - Boy Değerleri
oran=b/boyut(1);                   %b'ye oranı
incele2=imresize(incele,oran);     %Orana göre yeniden boyutlandır
chk_rgb=isrgb(hedef);              % RGB kontrolü
if chk_rgb
hedef=rgb2gray(hedef);             % Değil ise RGB'ye çevirme işlemi
```

Boyutlandırma ve görüntü formatının belirlenmesinden sonraki aşama, görüntünün keskinleştirilmesi ve gri ölçekli histogramının bulunmasıdır. Bulunan bu histogramdan önce tam siyah bölgeler çıkarılmıştır. Daha sonra histogramın koyu ve açık bölgeleri belirlenmiş, koyu ve açık bölgelerin ortalama değer histogramları bulunmuş, koyu ve açık olarak iki eşik değeri belirlenmiştir. Kaynak görüntüden zayıflatılmış görüntü çıkarılarak D_image= Source_image – D_I, kaynak görüntüden güçlendirilmiş görüntü toplanarak L_image= Source_image + L_I elde edilmiştir. Kaynak görüntü ve zayıflatılmış görüntünün doğrusal birleştirilmesiyle geçici ilk görüntü, kaynak görüntü ve güçlendirilmiş görüntünün doğrusal birleştirilmesiyle geçici ikinci görüntü elde edilmiştir. Üçüncü görüntü ilk geçici görüntü ve ilk geçici görüntünün negatifi ile doğrusal birleştirilmesiyle üretilmiştir. Dördüncü görüntü üçüncü geçici görüntü ve kaynak görüntünün doğrusal birleştirilmesiyle üretilmiştir. Beşinci görüntü dördüncü geçici görüntüden koyu eşik değerinin çıkarılmasıyla üretilmiştir. Daha sonra geçici beşinci görüntü üzerine iki boyutlu medyan filtresi uygulanarak medyan filtrelenmiş görüntü elde edilmiştir. Aydınlatma ve koyulaştırma katsayıları hesaplanmış, koyulaştırma katsayısı kullanılarak koyulaştırılmış medyan filtreli görüntü ve filtrelenmiş koyu görüntü ortalama bulunmuştur. Son olarak koyulaştırılmış görüntü ve medyan filtrelenmiş görüntünün doğrusal birleştirilmesiyle güçlendirilmiş çıkış görüntüsü elde edilmiştir.

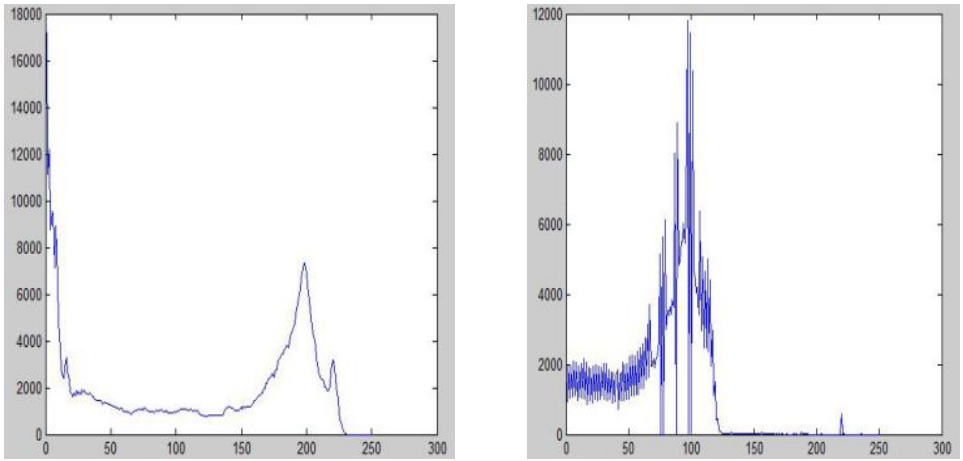
ALIE algoritmasının MIAS veri tabanındaki 1024 x 1024 çözünürlüğündeki mdb222 numaralı görüntüye uygulanmasıyla elde edilen sonuçlar Şekil 7.3.'de gösterilmiştir. Şekil 7.3.(a) mdb222 nolu orijinal görüntüyü, Şekil 7.3.(b) mikrokalsifikasyonlu bölgenin 145 x 145 çözünürlüğünde seçilmiş görüntüsünü, Şekil 7.3.(c) ise algoritma sonucu güçlendirilen 145 x 145 çözünürlüğündeki mikrokalsifikasyonlu bölgeyi göstermektedir.



**(a)** **(b)** **(c)**

**Şekil 7.3.** (a) Original mdb222 nolu mamogram görüntüsü (b) Mikrokalsifikasyonlu bölgenin görüntüsü (c) Algoritma sonucu elde edilen mikrokalsifikasyonlu bölgenin görüntüsü

Aşağıdaki Şekil 7.4.'da orijinal mdb222 numaralı görüntünün ve ALIE ile güçlendirilmiş görüntünün histogramları verilmiştir.




**(a)** **(b)**

**Şekil 7.4.** (a) Kaynak görüntünün histogramı (b) ALIE güçlendirme algoritması uygulandıktan sonra elde edilen görüntünün histogramı

Görüntü güçlendirmeleri değerlendirmede yaygın olarak kullanılan Enhancement Measure (EME), Absolute Mean Brightness Error (AMBE) ve Universal Image Quality Index (UIQI) gibi değerlendirme metotları vardır. Bu değerlendirme metotları aşağıdaki gibi formülüze edilirler (Wang ve Bovik 2002, Grgic ve ark. 2004, Sundaram ve ark. 2011).

Enhancement Measure (EME):

$$EME(\hat{f}) = EME_{\Phi}(\hat{f}) = \frac{1}{k^2}\sum_{m=1}^{k}\sum_{n=1}^{k} 20\log_2 \frac{\max(\hat{f}[m,l])}{\min(\hat{f}[m,l])} \tag{7.4}$$

Absolute Mean Brightness Error (AMBE):

$$AMBE = \left|E(X) - E(Y)\right| \tag{7.5}$$

Universal Image Quality Index (UIQI):

$$x = \left\{x_i \middle| i = 1,2,...,N\right\} \quad \text{ve} \quad y = \left\{y_i \middle| i = 1,2,...,N\right\} \tag{7.6}$$

$$Q = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma^2{}_x + \sigma^2{}_y)\left[(\bar{x})^2 + (\bar{y})^2\right]} \tag{7.7}$$

$$\bar{x} = \frac{1}{N}\sum_{i=1}^{N} x_i \qquad , \bar{y} = \frac{1}{N}\sum_{i=1}^{N} y_i \tag{7.8}$$

$$\sigma^2{}_x = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})^2 , \sigma^2{}_y = \frac{1}{N-1}\sum_{i=1}^{N}(y_i - \bar{y})^2 \tag{7.9}$$

$$\sigma^2{}_{xy} = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})(y_i - \bar{y}) \tag{7.10}$$

MIAS veri tabanından rastgele alınan 22 tane anormal (mikrokalsifikasyon veya kitle içeren) görüntüye dört farklı güçlendirme algoritması uygulanmıştır. Bu algoritmalar Contrast Limited Adaptive Histogram Equalization (CLAHE), Histogram Equalization (HE), Unsharp Mask (US) ve tez kapsamında geliştirilen Automated Lesion Intensity Enhancer (ALIE)'dir. CLAHE, HE ve US algoritmaları aşağıdaki denklemlerle ifade edilirler.

Contrast Limited Adaptive Histogram Equalization (CLAHE):

$$g = \left[ g_{\max} - g_{\min} \right] p(f) + g_{\min} \tag{7.11}$$

Burada

$g_{\max}$ = maksimumu piksel değeri

$g_{\min}$ = minimum piksel değeri

$g$ = hesaplanmış piksel değeri

$p(f)$ = kümülatif olasılık dağılım fonksiyonu

Histogram Equalization (HE):

$$p_n = \frac{piksel\ yoğunluk\ sayısı}{toplam\ piksel\ sayısı} \qquad \text{n = 0, 1, ..., L − 1.}$$

(7.12)

$$g_{i,j} = floor((L-1) \sum_{n=0}^{f_{i,j}} p_n \tag{7.13}$$

Unsharp Mask (US):

$$f(\alpha) = \frac{1}{\alpha+1} \begin{bmatrix} -\alpha & \alpha-1 & -\alpha \\ \alpha-1 & \alpha+5 & \alpha-1 \\ -\alpha & \alpha-1 & -\alpha \end{bmatrix} \tag{7.14}$$

Çizelge 7.1.'de Geliştirilen ALIE algoritmasının CLAHE, HE ve US güçlendirme algoritmaları ile karşılaştırması verilmiştir. CLAHE ve HE güçlendirme algoritmaları, ALIE gibi histogram temelli, US algoritması da contrast güçlendirme temelli bir algoritmadır.

MIAS veri tabanından rastgele seçilen 22 görüntü kullanılarak, geliştirilen ALIE algoritması ve CLAHE, HE ve US güçlendirme algoritmaları ile güçlendirme işlemine tabi tutulmuşlardır. Bu güçlendirme algoritmaların performanslarının değerlendirilmesi için EME, AMBE ve UIQI performans kriterleri ALIE, CLAHE, HE ve US güçlendirme algoritmaları için ayrı ayrı hesaplanarak Çizelge 7.1.'de verilmiştir.

**Çizelge 7.1.** Geliştirilen ALIE algoritmasının CLAHE, HE ve US algoritmaları ile EME, AMBE ve UIQI performans değerlendirme kriterleri açısından karşılaştırması

| **MIAS Görüntüsü** | **Doku Yapısı** | **EME** | | | | **AMBE** | | | | **UIQI** | | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| | | *CLAHE* | *HE* | *US* | *ALIE* | *CLAHE* | *HE* | *US* | *ALIE* | *CLAHE* | *HE* | *US* | *ALIE* |
| mdb209 | G | 6.854 | 1.125 | 3.023 | **4.881** | 4.306 | 92.983 | 0.234 | **42.102** | 0.325 | 0.261 | 0.769 | **0.430** |
| mdb211 | G | 4.250 | 0.489 | 2.372 | **3.865** | 0.862 | 102.792 | 0.186 | **38.069** | 0.296 | 0.259 | 0.825 | **0.571** |
| mdb212 | G | 3.838 | 0.470 | 2.250 | **3.306** | 0.391 | 107.396 | 0.171 | **35.181** | 0.285 | 0.229 | 0.819 | **0.556** |
| mdb213 | G | 4.107 | 0.374 | 3.411 | **2.837** | 2.002 | 127.884 | 0.125 | **28.353** | 0.256 | 0.151 | 0.849 | **0.635** |
| mdb214 | G | 3.676 | 0.334 | 2.305 | **2.668** | 3.663 | 134.764 | 0.133 | **27.536** | 0.240 | 0.139 | 0.856 | **0.640** |
| mdb218 | G | 6.597 | 1.539 | 7.531 | **2.968** | 2.034 | 78.500 | 0.094 | **37.910** | 0.387 | 0.274 | 0.752 | **0.454** |
| mdb219 | G | 5.027 | 1.053 | 3.038 | **5.418** | 0.982 | 65.623 | 0.213 | **54.459** | 0.383 | 0.376 | 0.800 | **0.483** |
| mdb222 | D | 4.395 | 0.515 | 3.544 | **2.671** | 3.375 | 104.654 | 0.129 | **31.267** | 0.303 | 0.223 | 0.824 | **0.591** |
| mdb223 | D | 3.911 | 0.418 | 4.093 | **2.103** | 3.903 | 131.994 | 0.159 | **25.515** | 0.251 | 0.167 | 0.850 | **0.662** |
| mdb226 | D | 5.138 | 0.625 | 2.538 | **2.535** | 3.763 | 122.189 | 0.178 | **29.288** | 0.252 | 0.160 | 0.811 | **0.532** |
| mdb227 | G | 3.118 | 0.323 | 1.995 | **3.387** | 0.181 | 128.263 | 0.148 | **33.732** | 0.255 | 0.210 | 0.874 | **0.674** |
| mdb231 | F | 6.291 | 1.626 | 3.172 | **8.226** | 4.311 | 69.342 | 0.250 | **59.924** | 0.378 | 0.326 | 0.766 | **0.408** |
| mdb236 | D | 6.482 | 1.684 | 7.789 | **2.652** | 1.049 | 73.506 | 0.153 | **40.325** | 0.385 | 0.288 | 0.757 | **0.469** |
| mdb238 | F | 4.137 | 0.708 | 6.028 | **3.625** | 3.561 | 105.771 | 0.146 | **37.781** | 0.332 | 0.235 | 0.799 | **0.534** |
| mdb239 | D | 6.305 | 1.270 | 3.576 | **2.920** | 1.237 | 60.312 | 0.226 | **42.575** | 0.379 | 0.308 | 0.771 | **0.479** |
| mdb240 | D | 5.635 | 1.113 | 3.473 | **3.573** | 0.739 | 59.85 | 0.141 | **37.481** | 0.364 | 0.296 | 0.772 | **0.431** |
| mdb241 | D | 3.695 | 0.461 | 3.447 | **1.947** | 1.446 | 121.984 | 0.154 | **25.653** | 0.254 | 0.183 | 0.853 | **0.677** |
| mdb248 | F | 7.073 | 1.499 | 3.600 | **4.183** | 3.313 | 82.277 | 0.186 | **42.683** | 0.340 | 0.255 | 0.754 | **0.415** |
| mdb249 | D | 4.910 | 0.682 | 2.773 | **3.879** | 0.125 | 95.422 | 0.185 | **38.681** | 0.321 | 0.264 | 0.817 | **0.547** |
| mdb252 | F | 4.809 | 0.772 | 3.574 | **4.232** | 2.893 | 105.329 | 0.158 | **39.793** | 0.307 | 0.245 | 0.811 | **0.546** |
| mdb253 | D | 5.887 | 1.497 | 6.785 | **2.969** | 1.301 | 65.899 | 0.196 | **43.206** | 0.403 | 0.277 | 0.761 | **0.477** |
| mdb256 | F | 5.062 | 1.281 | 3.025 | **3.923** | 3.034 | 74.236 | 0.173 | **48.344** | 0.345 | 0.226 | 0.759 | **0.435** |
| **Ortalama** | | **5.054** | **0.903** | **3.788** | **3.580** | **2.203** | **95.95** | **0.170** | **38.175** | **0.320** | **0.243** | **0.802** | **0.529** |

Enhancement Measure (EME), Absolute Mean Brightness Error (AMBE) ve Universal Image Quality Index (UIQI) metotları güçlendirilmiş görüntülere uygulandıktan sonra alınan sonuçların değerlendirilmesi yapılırken bazı kriterlere bakılmaktadır. EME değerinin yüksek olması aşırı güçlendirmeyi gösterir ve bu durumda yerel bilgi kayıplarını oluşturabilir. EME değerinin düşük olması güçlendirmenin yeterince yapılamadığını gösterir. AMBE'nin çok düşük veya çok yüksek değerleri güçlendirmenin yetersiz olduğunun göstergesidir. UIQI değeri [0,1] aralığında bir değer alır. Bu değer 1'e doğru yaklaştıkça başarılı güçlendirmeden uzaklaşıldığı, 0'a doğru yaklaştıkça da bilgi kayıplarının arttığı anlaşılır (Sundaram ve ark.,

2011). MIAS görüntüleri EME kriterine göre değerlendirecek olursa, HE güçlendirme algoritmasında güçlendirmenin zayıf olduğu görülür. CLAHE algoritmasında ise aşırı güçlendirme görülmektedir. ALIE algoritması diğer algoritmalara göre daha ideal değerlerdedir ve güçlendirme açısından daha iyi görülmektedir. AMBE kriterine göre CLAHE ve US algoritmaları düşük değerlerde, HE algoritması yüksek değerlerdedir ki bu da güçlendirmenin yetersiz olduğunu gösterir. ALIE algoritması AMBE kriterine göre, diğer algoritmalardan daha iyidir. UIQI kriterine göre değerlendirildiğinde; CLAHE ve HE algoritmalarında bilgi kayıplarının fazla olduğu, ALIE algoritmasında orta düzeyde bir başarı elde edildiği, US algoritmasının ise bu algoritmalar içinde UIQI kriterine göre en başarılı sonuçlara ulaştığı görülmektedir. Çizelge 7.1.'deki veriler değerlendirildiğinde geliştirilen güçlendirme algoritması ALIE'nin başarılı bir algoritma olduğu söylenebilir.

Çizelge 7.1.'in 2.sütünda meme dokusunun yapısı verilmiştir. Burda, F: Yağlı (Fatty), G: Yağlı-glandular (Fatty-glandular), D: Yoğun-glandular (Dense-glandular) dokuları göstermektedir. Dokulara göre görüntülerin ortalama EME, AMBE ve UIQI değeri ile bütün görüntülerin ortalama EME, AMBE ve UIQI değeri Çizelge 7.2.'de verilmiştir.

**Çizelge 7.2.** ALIE algoritmasının EME, AMBE ve UIQI performans kriterleri açısından doku yapısına göre karşılaştırılması

| | **ALIE Algoritması** | | |
|---|---|---|---|
| | **EME (Ortalama)** | **AMBE (Ortalama)** | **UIQI (Ortalama)** |
| **Yoğun-glandular** | 2.806 | 34.888 | 0.540 |
| **Yağlı-glandular** | 3.666 | 37.168 | 0.555 |
| **Yağlı** | 4.838 | 45.705 | 0.468 |
| **Ortalama** | 3.580 | 38.175 | 0.529 |

Çizelgede verilen ortalama değer, Çizelge 7.1.'deki 22 MIAS görüntüsünün ortalama değeridir. Bu ortalama değer referans alındığında ALIE güçlendirme algoritması, EME ve AMBE açısından yağlı-glandular dokularda en başarılı sonuca ulaştığı görülmektedir. Yoğun-glandular dokularda da başarı sağlanmıştır. Yağlı dokularda elde edilen başarı oranı diğer dokulara göre düşük kalmıştır. UIQI açısından değerlendirildiğinde, bütün dokularda başarı oranının yüksek olduğu görülmektedir.

Çizelge 7.3.'de MIAS veri tabanından rastgele seçilen 22 adet etiketlenmiş görüntü kullanılarak güçlendirme algoritmalarının HYSA temelli sınıflandırma açısından genel bir performans karşılaştırması yapılmıştır. ALIE ile güçlendirilmiş ve hiç güçlendirme uygulanmamış MIAS görüntülerinin Radyolog1 ve Radyolog2 tarafından ayrı ayrı değerlendirmesi verilmiştir. Kullanılan 22 görüntü için MIAS veri tabanında verilen koordinatlardan anomali olan bölgeler çıkartılmış, böylece 22 görüntüden 100 adet anomali içeren bölge test için kullanılmıştır.

Çizelge 7.3.'de tanımlanan ALIE+HYSA, ALIE algoritması ile güçlendirilmiş görüntülerin HYSA temelli sınıflandırılması; ALIE+CLAHE, CLAHE algoritması ile güçlendirilmiş görüntülerin HYSA temelli sınıflandırılması; ALIE+HE, HE algoritması ile güçlendirilmiş görüntülerin HYSA temelli sınıflandırılması; ALIE+US, US algoritması ile güçlendirilmiş görüntülerin HYSA temelli sınıflandırılmasını göstermektedir. ALIE+ Radyolog1, ALIE algoritması ile güçlendirilmiş görüntülerin Radyolog1 tarafından sınıflandırılmasını; ALIE+ Radyolog2, ALIE algoritması ile güçlendirilmiş görüntülerin Radyolog2 tarafından sınıflandırılmasını ifade etmektedir. Görüntülerin sınıflandırma işlemini yapan Radyolog1, konusunda yaklaşık 15 yıllık deneyimi olan uzman bir hekim, Radyolog2 ise konusunda yaklaşık 4 yıllık deneyimi olan uzman bir hekimdir.

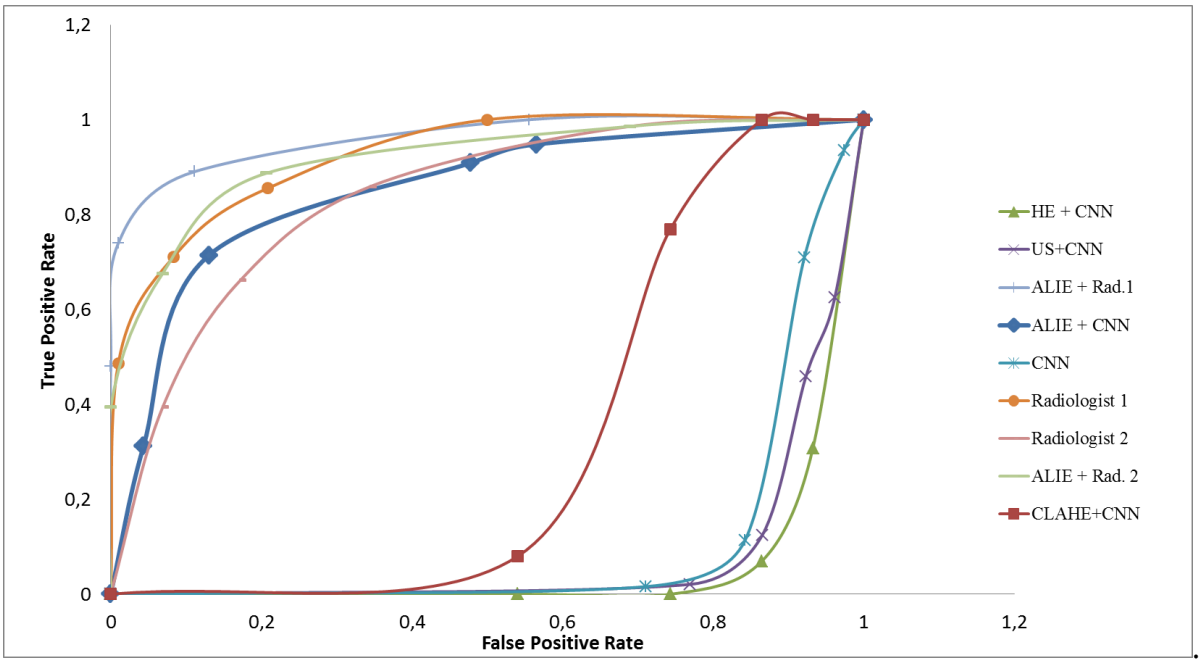
ALIE algoritması uygulanmış görüntülerin HYSA ile sınıflandırılmasında 82%'lik doğruluk değeri ile en başarılı algoritma olmuştur. CLAHE algoritması uygulanmış görüntülerin HYSA ile sınıflandırılmasında %36'lık doğruluk değeri, HE algoritması uygulanmış görüntülerin HYSA ile sınıflandırılmasında %10'luk doğruluk değeri ve US algoritması uygulanmış görüntülerin HYSA ile sınıflandırılmasında %26'lık doğruluk değerine ulaştığı görülmektedir.

Herhangi bir güçlendirme algoritması uygulanmamış görüntülerin değerlendirilmesinde Radyolog1 %84'lük doğruluk değerine, Radyolog2 ise %80'lik doğruluk değerine ulaşmıştır. ALIE ile güçlendirilmiş görüntülerin değerlendirilmesinde Radyolog1 %89, Radyolog2 ise %86'lık bir doğruluk değerine ulaşmıştır. Bu sonuçlardan, yeni geliştirilen ALIE güçlendirme algoritmasının radyologların mamogram görüntülerini değerlendirmesindeki başarısını artırdığı görülmektedir.

**Çizelge 7.3.** Güçlendirme algoritmaları ile Radyologların, mikrokalsifikasyon ve kitleleri sınıflandırma performans karşılaştırması

| | **ALIE + HYSA** | **CLAHE + HYSA** | **HE + HYSA** | **US + HYSA** | **HYSA** | **Rad. 1** | **Rad. 2** | **ALIE + Rad. 1** | **ALIE + Rad. 2** |
|---|---|---|---|---|---|---|---|---|---|
| Örnek Sayısı | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 |
| Doğru Sayısı | 82 | 36 | 10 | 26 | 47 | 84 | 80 | 89 | 86 |
| Kayıp Sayısı | 18 | 64 | 90 | 74 | 53 | 16 | 20 | 11 | 14 |
| Doğruluk | %82.0 | %36.0 | %10.0 | %26.0 | %47.0 | %84.0 | %80.0 | %89.0 | %86.0 |
| Duyarlılık | %90.9 | %100.0 | %0.0 | %45.8 | %71.0 | %85.5 | %85.9 | %89.0 | %88.7 |
| Belirlilik | %52.2 | %13.5 | %13.5 | %7.7 | %7.9 | %79.2 | %65.5 | %88.9 | %79.3 |
| ROC Alanı | 0.853 | Tanımsız | Tanımsız | 0.073 | 0.102 | 0.93 | 0.839 | 0.969 | 0.92 |
| Ampirik ROC Alanı | 0.838 | 0.321 | 0.055 | 0.084 | 0.115 | 0.918 | 0.826 | 0.955 | 0.905 |

Şekil 7.5.'de ALIE güçlendirme algoritması ile CLAHE, HE ve US güçlendirme algoritmalarının performans karşılaştırılması ile radyologların her hangi bir güçlendirme algoritması uygulanmadan ve ALIE güçlendirme algoritması uygulanarak mamogram görüntülerini değerlendirme performans karşılaştırılması verilmiştir.




**Şekil 7.5.** ALIE, CLAHE, HE ve US güçlendirme algoritmalarının arasındaki ve Radyologların ALIE güçlendirme algoritması ile güçlendirilen MIAS görüntülerini değerlendirmedeki performanslarının ROC eğrileri

# 8. SONUÇLAR ve ÖNERİLER

## 8.1. Sonuçlar

Meme kanseri dünya genelinde (Stewart ve ark. 2004) ve Türkiye'de (Türkiye'de Kanser Kontrolü 2007) kadınlar arasında en sık rastlanan kanser tipi olduğu göz önünde tutulduğunda, meme kanserinin erken teşhisi, hastanın hayatta kalması açısından oldukça önemlidir. Meme kanserinin mamogram ve diğer biyomedikal görüntüler üzerinde tanımlama işleminde kitlelerin iyi huylu (benign) veya kötü huylu (malign) olup olmadığına ve görüntüler üzerinde belirlenmesi zor olan mikrokalsifikasyon olarak adlandırılan küçük kalsiyum taneciklerinin varlığına bakılmaktadır. Mamografi görüntüleri, üç boyutlu konumdan iki boyutlu görüntülere dönüştürüldüğünden dolayı farklı dokular üst üste gelmekte, şüpheli bölgelerin değerlendirilmesi zorlaşmaktadır. Bu problemleri ortadan kaldırmak ve hekimlere yardımcı olmak amacıyla bir Karar Destek Sistemi (KDS) geliştirilmiştir.

Hekimler mamogram görüntülerini değerlendirmede, görüntüler üzerinde çeşitli görüntü netleştirme işlemlerini manuel olarak yaptıkları farklı programlar kullanmaktadırlar. Bu programların başarısı hekimin tecrübesine bağlıdır. Tez çalışmasında, yeni geliştirilen bir güçlendirme algoritması sayesinde başarılı bir bölütleme işlemi yapılarak akıllı bir sistem tasarlanmıştır. Hekimlerin bu geliştirilen sistemi rahat kullanabilmeleri için de kullanıcı uyumlu ara yüz içeren bir program yazılmıştır.

Tez çalışması temelde iki ana yapı üzerine kurulmuştur. Birincisi, histogram temelli yeni bir güçlendirme algoritması geliştirilmiştir. İkincisi, mamogram görüntüleri üzerindeki mikrokalsifikasyon ve kitleleri belirlemede, HYSA temelli bir yapıyla bölütleme yapılıp, şekil analizi ile sınıflandırma yapılmıştır.

Mamogram görüntülerinde kitle yoğunluğunun otomatik olarak güçlendirmesi amacıyla geliştirilen ALIE (Automated Lesion Intensity Enhancer) algoritmasının, literatürde mevcut olan CLAHE, HE ve US güçlendirme algoritmaları ile karşılaştırması Çizelge 7.1.'de verilmiştir. MIAS veri tabanından rastgele seçilen 22 görüntüye CLAHE, HE, US ve

geliştirilen ALIE algoritması ayrı ayrı uygulanarak güçlendirme yapılmış ve güçlendirilen bütün görüntüler için EME, AMBE ve UIQI performans kriterleri hesaplanmıştır.

EME kriterine göre, HE ve US güçlendirme algoritmalarında güçlendirmenin zayıf olduğu, CLAHE algoritmasında aşırı güçlendirme olduğu görülmektedir. ALIE algoritması ise diğer algoritmalara göre daha ideal değerlere ulaştığı görülmektedir. UIQI kriterine göre değerlendirildiğinde, CLAHE ve HE algoritmalarında bilgi kayıplarının fazla olduğu, ALIE algoritmasında orta düzeyde bir başarı elde edildiği, US algoritmasının bu algoritmalar içinde UIQI kriterine göre en başarılı sonuçlara ulaştığı görülmektedir. AMBE kriterine göre, CLAHE ve US algoritmaları düşük değerlere, HE algoritması yüksek değerlere çıkmıştır. ALIE algoritması AMBE kriterine göre, diğer algoritmalara göre daha başarılı değerlere sahip olduğu görülmüştür. Çizelge 7.1.'deki veriler değerlendirildiğinde geliştirilen güçlendirme algoritması ALIE'nin başarılı bir algoritma olduğu söylenebilir.

Çizelge 7.2.'de ALIE algoritmasının doku yapısına göre performans karşılaştırılması yapılmıştır. ALIE güçlendirme algoritması, EME ve AMBE açısından yağlı-glandular dokularda en başarılı sonuca ulaştığı, yağlı dokularda elde edilen başarı oranının diğer dokulara göre düşük kaldığı görülmüştür. UIQI açısından değerlendirildiğinde, bütün dokularda başarı oranının yüksek olduğu görülmüştür.

Çizelge 7.3.'de ALIE, CLAHE, HE ve US algoritmalarının MIAS veri tabanındaki görüntülerin HYSA ile sınıflandırılmalarının sonuçları görülmektedir. Çizelge 7.3.'de aynı zamanda iki ayrı radyolog hekimin (Radyolog1 ve Radyolog2) görüntüleri, ham ve güçlendirme algoritması uygulandıktan sonra değerlendirmesi de verilmiştir.

Çizelge 7.3'de geliştirilen ALIE güçlendirme algoritmasının diğer algoritmalara göre %82'lik bir doğruluk elde ederek en başarılı algoritma olduğu görülmektedir. Radyolog1 ham verilerde %84, ALIE ile güçlendirilmiş verilerde %89'luk doğruluğa erişerek %5'lik bir performans artışı yakalamış, Radyolog2 ise ham verilerde %80, ALIE ile güçlendirilmiş verilerde %86'lık doğruluğa erişerek %6'lık bir performans artışı yakalamıştır. Bu sonuçlardan ALIE güçlendirme algoritmasının görüntüler üzerinde karar vermede başarıyı artırdığı görülmektedir.

Mikrokalsifikasyon ve kitlelerin sınıflandırılmasında alan, büyük, küçük, uzun, çevre, EnBoyOranı, Uzama ve yoğunluk parametreleri elde edilerek şekil ve doku analizi yapılmıştır. Hastane veri tabanındaki 286 adet mamogram görüntülerinde manign kitleler, benign kitleler ve mikrokalsifikasyonlar için elde edilen şekil ve doku analizi parametrelerine ait piksel cinsinden ortalama değerler Çizelge 8.1.'de verilmiştir. MIAS veri tabanındaki 100 adet mamogram görüntülerinde manign kitleler, benign kitleler ve mikrokalsifikasyonlar için elde edilen şekil ve doku analizi parametrelerine ait piksel cinsinden ortalama değerler Çizelge 8.2.'de verilmiştir.

**Çizelge 8.1.** Hastane veri tabanındaki görüntülerden elde edilen şekil ve doku analizi parametrelerine ait ortalama değerler

| **Manign kitleler için (ortalama değerler)** | | | | | | | |
|---|---|---|---|---|---|---|---|
| Alan | Büyük | Küçük | Uzun | Çevre | EnBoyOranı | Uzama | Yoğunluk |
| 27.5 | 10.3 | 6.55 | 12.30 | 24.1 | 0.39 | 0.94 | 28.7 |
| | | | | | | | |
| **Benign kitleler için (ortalama değerler)** | | | | | | | |
| Alan | Büyük | Küçük | Uzun | Çevre | EnBoyOranı | Uzama | Yoğunluk |
| 180 | 24.5 | 6.55 | 33.7 | 90.2 | 0.45 | 0.87 | 46.4 |
| | | | | | | | |
| **Mikrokalsifikasyonlar için (ortalama değerler)** | | | | | | | |
| Alan | Büyük | Küçük | Uzun | Çevre | EnBoyOranı | Uzama | Yoğunluk |
| 5.4 | 4.8 | 1.7 | 5.8 | 7.8 | 0.38 | 1.03 | 9.8 |

**Çizelge 8.2.** MIAS veri tabanındaki görüntülerden elde edilen şekil ve doku analizi parametrelerine ait ortalama değerler

| **Manign kitleler için (ortalama değerler)** | | | | | | | |
|---|---|---|---|---|---|---|---|
| Alan | Büyük | Küçük | Uzun | Çevre | EnBoyOranı | Uzama | Yoğunluk |
| 95.3 | 17.2 | 9.7 | 19.2 | 55.7 | 0.49 | 0.88 | 31.8 |
| | | | | | | | |
| **Benign kitleler için (ortalama değerler)** | | | | | | | |
| Alan | Büyük | Küçük | Uzun | Çevre | EnBoyOranı | Uzama | Yoğunluk |
| 120 | 19.4 | 9.7 | 22.1 | 55.8 | 0.51 | 0.89 | 26.4 |
| | | | | | | | |
| **Mikrokalsifikasyonlar için (ortalama değerler)** | | | | | | | |
| Alan | Büyük | Küçük | Uzun | Çevre | EnBoyOranı | Uzama | Yoğunluk |
| 9.5 | 5.9 | 2.3 | 5.7 | 10.8 | 0.61 | 0.94 | 12.3 |

Çizelge 6.6.'da Necmettin Erbakan Üniversitesi Meram Tıp Fakültesinden alınan 2400 x 3000 çözünürlüğündeki verilerin Radyolog ve geliştirilen KDS tarafından ham veri, güçlendirilmiş veri ve pektoral kas bölgesi çıkarılarak güçlendirilmiş veriler olarak sınıflandırılmalarının sonuçları verilmiştir.

Radyolog ham verilerin sınıflandırılmasında %84'lük, güçlendirilmiş verilerin sınıflandırılmasında %88'lik, pektoral kas bölgesi çıkarılarak güçlendirilmiş verilerin sınıflandırılmasında %80'lik bir başarı elde etmiştir. Geliştirilen Karar Destek Sistemi (KDS) ham verilerin sınıflandırılmasında %68'lik, güçlendirilmiş verilerin sınıflandırılmasında %92'lik, pektoral kas bölgesi çıkarılarak güçlendirilmiş verilerin sınıflandırılmasında %84'lük bir başarı elde etmiştir. Geliştirilen KDS en iyi başarıyı güçlendirilmiş verilerin sınıflandırılmasında göstermiş, ham verilerin sınıflandırılmasında başarı oldukça düşmüştür. Dolayısıyla geliştirilen ALIE güçlendirme algoritması sınıflandırma başarısını artırmada ciddi bir performans sağlamıştır.

Çizelge 6.7.'de, geliştirilen KDS yapısının hastane veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması verilmiş, Çizelge 6.8.'de ise, geliştirilen KDS yapısının MIAS veri tabanındaki ham görüntü, güçlendirilmiş görüntü ve pektoral kas bölgesi çıkartılarak güçlendirilmiş görüntülerin sınıflandırmasının performans karşılaştırılması verilmiştir. Geliştirilen KDS hastane veri tabanındaki güçlendirilmiş görüntülerin sınıflandırmasında %91.3'lük, MIAS veri tabanındaki güçlendirilmiş görüntülerin sınıflandırmasında %82.0'lik bir başarı göstermiştir. Hastane verileri sayısal ve MIAS verilerine göre daha yüksek çözünürlükte veriler olduğundan dolayı bu performans farkı ortaya çıkmıştır.

Bazı mamogram görüntülerinde, pektoral kas bölgesinin görüntüde fazla oranda yer alması veya aşırı parlak olması, histogram temelli ALIE güçlendirme algoritmasının başarısını düşürmektedir. Fakat her mamogram görüntüden pektoral kas bölgesinin çıkartılması, özellikle pektoral kas bölgesinde olması muhtemel mikrokalsifikasyon ve kitlelerin kayıplarına neden olmaktadır. Dolayısıyla pektoral kas bölgesinin çıkarılması her zaman başarılı sonuçlar vermez. Bu bölgenin çıkartılıp çıkartılmayacağı tercihi algoritmayı kullanan uzmanın kararına bırakılmıştır.

## 8.2. Öneriler

Tez çalışmasında, mamogram görüntülerindeki kitle ve mikrokalsifikasyonların belirlenmesi ve sınıflandırılması için yeni bir Karar Destek Sistemi (KDS) önerilmiştir. Çalışma kapsamında ortaya çıkarılan bu KDS, HYSA yapısı kullanılarak geliştirilmiştir. İleride yapılabilecek çalışmalarda bu yapıyı geliştirmek amacı ile farklı yapay-zeka metotlarıyla işlem yapabilecek şekilde tasarlanabilir. HYSA'nın A, B ve I parametrelerini belirlemede kullanılan Genetik Algoritma yerine farklı optimizasyon algoritmaları kullanılarak elde edilecek HYSA yapısının bölütlemedeki başarısı üzerinde etkilerinin incelenmesi de faydalı bir çalışma olacaktır.

Tez çalışmasında, kitle ve mikrokalsifikasyonların sınıflandırılmasındaki başarıyı artırmak için yeni histogram temelli bir güçlendirme algoritma olan ALIE geliştirilmiştir. Farklı biyomedikal görüntüler üzerinde yapılacak çalışmalarda ALIE algoritması kullanılarak görüntü zenginleştirmesinde kullanılabilme için geliştirmeler yapılabilir.

Meme kanseri tüm dünya genelinde ve ülkemizde kadınlar arasında en sık rastlanan kanser tipi olduğundan dolayı, Sağlık Bakanlığı 2006 yılından itibaren ülke genelinde yaygın bir şekilde meme kanseri tarama işlemini başlatmış ve bu amaçla mamogram tarama birimleri (KETEM) açmıştır. İşte bu bağlamda geliştirilen KDS bu birimlere adapte edilerek radyologların mamogram görüntülerini okuma başarılarının ve hızlarının artırılması için çalışmalar yapılabilir. Bu sayede, KDS geniş bir veri tabanı üzerinde uygulanması ve radyologlardan gelecek geri bildirimlere bağlı olarak iyileştirilmesi sağlanabilir.

## 9. KAYNAKLAR


Ackerman, L.V. and Gose, E., 1972, Breast lesion classification by computer and xeroradiograph, Cancer, 30: 1025–1035.

Agard, D.A., Hiraoka, Y., Shaw, P., Sedat, J. W., 1989, Fluorescence Microscopy in Three Dimensions, 30: 353–377.

American College of Radiology (ACR), 1998, Illustratedbreast imaging reporting and datasystem (BI-RADStm), Third Edition. Reston [VA]: American College of Radilogy.

Ammari, H., 2008, An Introduction To Mathematics Of Emerging Biomedical Imaging, *Mathématiques et Applications,* Volume 62, Springer-Verlag, Berlin.

Angeline, P.J., 1995, Evolution Revolution: An Introduction to the Special Track on Genetic and Evolutionary Programming, *IEEE Expert Intelligent Systems and Their Applications*, 6-10.

Arslan, E., 2011, Hücresel Sinir Ağ Sistemleri Kullanarak Hareketli Nesnelerin Görüntü İşleme Uygulamaları, *İ.Ü. Fen Bilimleri Doktora Tezi*, İstanbul.

Bargu, H., 2004, Hücresel Yapay Sinir Ağ – Markov Rastgele Alan (HYSA-MRA) Yöntemi ve Yerbilimlerine Uygulamaları, *İ.Ü.Fen Bilimleri Ens., Yüksek Lisans Tezi*, İstanbul.

Beghdadi, A. and Negrate, A.L., 1989, Contrast Enhancement Technique Based on Local Detection of Edges, Computer Vision and Graphical Image Processing, 46: 162–174.

Berg, W.A., Campassi, C., Langenberg, P., Sexton, M.J., 2000, Breast imaging reporting and data system: inter and intraobserver variability in feature analysis and final assessment. AJR 2000; 174: 1769-1770.

Bovik, A.C., Huang, T.S., Munson, D.C., 1978, The Effect of Median Filtering on Edge Estimation and Detection, *IEEE IEEE Transactions on Pattern Analysis and Machine Intelligence* 9: 181-194.

Bovis, K., Singh, S., 2000, Detection of Masses in Mammograms Using Texture Features, *Pattern Recognition, 2000. Proceedings. 15th International Conference,* 2: 267-270.

Brzakovic, D., Luo, X. M., Brzakovic, P., 1990, An approach to automated detection of tumors in mammograms, *IEEE Trans. Med. Imag.*, 9(3): 233–241.

Cankur, N.Ş., 2013, İnternet kaynağından alıntı, http://anatomi.uludag.edu.tr/thorax.htm [Ziyaret Tarihi: 9 Eylül 2013].

Canny, J. F., 1986, A Computational Approach to Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6): 679-698.

Ceylan, M., 2009, Bilgisayar Tomografili Akciğer Görüntülerinin Değerlendirilmesinde Kompleks Değerli Yeni Bir Akıllı Sistem Tasarımı, *S.Ü. Fen Bilimleri Ens., Doktora Tezi*, Konya.

Chen, Y., Levine, S., Rao, M., 2006, Variable Exponent, Linear Growth Functionals in Image Restoration, *SIAM J. Appl. Math*., 66(4), 1383–1406.

Chen, Z.Y., Abidi, B.R., David, L., Abidi, M.A., 2006, Gray-level grouping (GLG): an automatic method for optimized image contrast enhancement - part II: the variations, *Image Processing, IEEE Transactions*, 15(8): 2303 - 2314.

Chua, L.O., Yang, L., 1988a, Cellular Neural Networks: Theory, IEEE Transactions on Circuits and Systems, 35 (10): 1257 - 1272.

Chua, L.O., Yang, L.,1988b, Cellular Neural Networks: Applications, IEEE Transactions on Circuits and Systems, 35 (10): 1273 - 1290.

Chua, L.O., 1991, An Analitic Method for Designing Simple Cellular Neural Networks, *IEEE Transactions on Circuits and Systems*, 38(11): 1332-1341.

Colbassani, H.J., Feller, W.F., Cigtay, O.S., Chun, B., 1982, Mammography and pathologic correlation of microcalcification in disease of the breast, Surg Gynecol Obstet, 155: 689-696.

Cunkaş, M., 2006, Genetik Algoritmalar ve Uygulamaları*, Ders Notları, Selçuk Üniversitesi*, Konya.

Demirel, B., 2008, Meme Kanseri Tedavi Yöntemlerinin Veri Madenciliği ile Belirlenmesi, *S.D.Ü. Fen Bilimleri Ens., Yüksek Lisans Tezi*, İsparta.

Demirel, B., 2008, İnternet kaynağından alıntı, http://www.biyolojiegitim.yyu.edu.tr/k/lenftkstm/pages/lenfatikler_jpg.htm [Ziyaret Tarihi: 10 Mayıs 2013].

Demirkazık, F.B., 1997, Mamografi ve Meme Görüntülemenin Temel İlkeleri, Hacettepe Tıp Dergisi, 28(1): 73-83.

Dheeba, J., Selvi, S.T., 2011, Classification of malignant and benign microcalcification using SVM classifier, *Emerging Trends in Electrical and Computer Technology (ICETECT), 2011 International Conference*, 686–690.

D'Orsi, C.J., 1996, The American College of Radiologymammography lexicon: an initial attemptto standardize terminology. *AJR1996*; 166: 779-80.

Erkul, Z. K., Erkuş, M., Taşkın, F., Meteoğlu, İ., 2005, Meme Biyopsisinde Liesegang Ring Kalsifikasyon: Olgu Sunumu, Meme Sağlığı Dergisi, 1(1): 22-24.

Eroğlu, C., Eryılmaz, M.A., Civcik, S., Gürbüz, Z., 2010, Meme Kanseri Risk Değerlendirmesi: 5000 Olgu, *International Journal of Hematology and Oncology*, 20(1): 027-033.

Fam, B. W., Olson, S. L., Winter, P. F., Scholz, F. J., 1988, Algorithm for the detection of fine clustered calcifications on film mammograms, 169(2): 333–337.

Fisher, B., 1994, Malignancies of the Breast. In: Cameron RB (edls), Pratical Oncology. Appleton & Lange, Connecticut, 417-434.

Geetha, K., Thanushkodi, K., Kumar, A. K., 2008, New Particle Swarm Optimization for Feature Selection and Classification of Microcalcifications in Mammograms, *Signal Processing, Communications and Networking, 2008. ICSCN '08. International Conference*, 458–463.

Genc, I., Guzelis, C., Goknar, I.C., 1996, Classification of Acoustical Alarm Signals with CNN Using Wavelet Transformation, *Cellular Neural Networks and their Applications, 1996. CNNA-96. Proceedings.*, 375 – 379.

Giger, M. L., Yin, F. F., Doi, K., Metz, C. E., Schmidt, R. A., Vyborny, C. J., 1990, Investigation of methods for the computerized detection and analysis of mammographic masses, *SPIE Medical Imaging IV: Image Processing*, 1233: 183–184.

Goldberg, D.E., 1989, Genetic Algorithm in Search, Optimization and Machine Learning, Addison-Wesley Publishing, USA.

Gonzalez, R. C., Woods, R. E., 1992, Digital Image Processing, MA: Addison-Wesley.

Gonzales, C., Woods, R.E., 2002, Digital Image Processing, Prentice Hall, New Jersey.

Grgic, S., Grgic, M., Mrak, M., 2004, Reliability of objective Picture Quality Mesures, *Journal of Electrical Engineering* , 55(1-2): 3-10.

Güzeliş, C., Karamahmut, S., 1994, Recurrent Perceptron Learning Algorithm for Completely Stable Cellular Neural Networks, *In Proc. ThirdIEEE Int. Workshop on Cellular Neural Network and Applications*, 177-182.

Güzeliş, C., 1997, *Yapay Sinir Ağları Ders Notu*, İTÜ, İstanbul.

Hand, W., Semmlow, J. L., Ackerman, L. V., Alcorn, F. S., 1979, Computer screening of xeromammograms: A technique for defining suspicious areas of the breast, *Comput. Biomed. Res*., (12): 445–460.

Haykin, S., 1994, Neural Networks, A Comprehensive Foundation, Second Edition, Prentice-Hall Inc., New Jersey.

Hanmandlu, M., Vineel, D., Madasu, V. K., Vasikarla, S.,2008, Computer Aided Detection of Suspicious Masses and Micro-Calcifications, *Information Technology: New Generations, 2008. ITNG 2008. Fifth International Conference* , 789–794.

Haupt, R. L., Haupt, S. E., 1998, Practical Genetic Algorithms, A Willey-Interscience Publication, USA.

Heath, M., Bowyer, K. W., Kopans, D. Moore, R. and Kegelmeyer, P., 2000, The Digital Database for Screening Mammography, *presented at 5th International Workshop on Digital Mammography*, Toronto, Canada.

Hernández-Cisneros, R.R., Yerashima-Marin, H., 2006, Feature Selection for the Classification of Both Individual and Clustered Microcalcifications in Digital Mammograms Using Genetic Algorithms, *A Recombination of the 15th International Conference Genetic Algorithms (ICGA) and the 11th Genetic Programming Conference (GP).* 2006.Seattle, WA, USA.

Heywang-Köbrunner, S.H., Schreer, I., Dershaw, D.D., 1997, Diagnostic Breast Imaging, Thieme.

Holland, J.H., 1975, Adaption in Natural and Artifical Systems, MIT Press, Cambridge, MA.

Holland, J.H., 1992, Adaptation in Natural and Artificial Systems, MIT press, MA, USA.

Homer, M.J., Safaii, H., Smith, T.J., Marchant, D.J., 1989, The relationship of mammographic microcalcification to histologic malignancy: radiologic-pathologic correlation, (153): 1187-1189.

İşgör, A., 2013, http://www.adnanisgor.com/meme3genelbilgikonu.html [Ziyaret Tarihi: 10 Mayıs 2013].

Jain, A. K., 1989, Fundamentals of digital image processing, Prentice-Hall. Endewood Cliffs, NJ. USA. 1989'1. Information and Svstem.

Jiang, J., Butler, D., 1995, Vector quantization with genetic learning algorithm. *In: IEE proceedings of GALESIA'95: international conference on engineering application of genetic algorithms*, Sheffield, ISBN 0-85296-650-4: 331–6.

Jiang, J., Yao, B., Wason, A.M., 2006, A genetic algorithm design for microcalcification detection and classification in digital mammograms, *Computerized Medical Imaging and Graphics*, 31(1): 49-61.

Kalaycı, G., Acarlı, K., Demirkol, K., Ertekin, C., 2002, Meme Anatomisi ve Gelişmesi, Genel cerrahi cilt 1, Türkiye, İstanbul, Nobel, 537-542.

Kaleli, F., 2007, Computer Aided Diagnosis of Breast Canser, *Yüksek Lisans Tezi, Bahçeşehir Üniversitesi, FBE.*,İstanbul.

Kandaswamy, A., Malar, E., Ahilaa, T.D., 2010, Indrani, R., Adaptive algorithms for detection of microcalcification in mammograms with the aid of Graphical programming language, a CAD system, *Computing Communication and Networking Technologies (ICCCNT), 2010 International Conference*, 1-5.

Karabiber, F., 2009, Analog Hücresel Sinir Ağı İşlemcisi Kullanarak Gerçek Zamanlı Görüntü İşleme Uygulamaları, *İ.Ü. Fen Bilimleri Ens., Doktora Tezi*, İstanbul.

Karabulut, E., 2009, Mamografi Görüntülerinin Değerlendirilmesinde Örüntü Tanıma Temelli Bir Karar Destek Sistemi, *Yüksek Lisans Tezi, Fırat Üniversitesi, FBE.,* Elazığ.

Kegelmeyer, W. P., 1993, Evaluation of stellate lesion detection in a standard mammogram data set, *Int. J. Pattern Recog. Artificial Intell*., 7: 1477–1493.

Kim, M.H., Kim, E., 1999, Nonpalpable mammographic clustered microcalcification: interobserver agreement and the positive predictive value of Acr Bi-rads lexicon and final assessment categories. *RSNA 1999*; 213:200.

Kılıç, N., Uçan, O.N. ve Osman, O., 2003, Biyomedikal İşaretlerin Markov Rastgele Alanları Kullanılarak İşlenmesi, *İ.Ü. Fen Bilimleri Ens., Yüksek Lisans Tezi*, İstanbul.

Kılıç, N., Uçan, O.N. ve Osman, O., 2008, Bilgisayarlı Tomografi Görüntülerinde Üç Boyutlu Şablonlar Kullanılarak Kolonik Polip Tespiti, , *İ.Ü. Fen Bilimleri Ens., Doktora Tezi*, İstanbul.

Kılıç, N., Osman, O. ve Uçan, O.N., 2006, Kolonik Polip Tespiti İçin Yeni Bir Bölütleme Yöntemi: Genetik-Hücresel Yapay Sinir Ağları, *Biyomedikal Mühendisliği Ulusal Toplantısı*, İstanbul.

Knutsson, H., Wilson, R., Granlund, G.H., 1983, Anisotropic Non-Stationary Image Estimation and Its Applications, Part I, Restoration of Noisy Images, *IEEE Transactions on Communications*, 31(3): 388–397.

Kohavi, R., Provost, F., 1998, Glossary of Terms, Editorial for the Special Issue on Applications of Machine Learning and the Knowledge Discovery Process, 30(2/3).

Kohonen, T., 1999, Self-Organization and Associative Memory, Second Edition, Springer Verlag.

Kosheleva, O., Arenas, J., Aguirre, M., Mendoza, C., Cabrera, S.D., 1998, Compression degradation metrics for analysis of consistency in microcalcification detection, *Image Analysis and Interpretation, 1998 IEEE Southwest Symposium*, 35 – 40.

Lacquement, M.A., Mitchell, D., Hollingsworth, A.B.. 1990, Positive predictive value of the breast imaging reporting and data system. J Am Coll Surg1990, 189:34-40.

Lai, S. M., Li, X. B., Bischof, W. F., 1989, On techniques for detecting circumscribed masses in mammograms, *IEEE Trans. Med. Imag*., 8(4): 377–386.

Lau, T. K., Bischof, W. F., 1991, Automated detection of breast tumors using the asymmetry approach, *Comput. Biomed. Res*., 24: 273–295.

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.

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 Trans. Med. Imag.*, 14(3): 565–576.

Liberman, L., Evans, H.P., Dershaw, D.D., Hann, L.E., Deutch, B.M., 1994, Radiography of microcalcifications in stereotaxic mammary core biopsy specimens, Radiology; 190: 223-225.

Lo, J.Y., Land, W.H., Morrison, C.T.,1999, Application of Evolutionary Programming and Probabilistic Neural Networks to breast cancer diagnosis, *IEEE Conference*,.5: 3712 – 3716.

Lu, Y., Jain, R. C., 1992, Reasoning About Edges in Scale Space, *IEEE Transactions On Pattern An. and Mach. Intel*.. 14(4): 337 – 356.

Mallat, S., Zhong, S., 1992, Characterization of Signals from Multiscale Edges, *IEEE Transactions on PAMI*, 14(7): 710 – 732.

Meme Sağlığı Dergisi, 2007, Meme Kanserinde Tanı, 3(2): 100-106.

Mini, M.G., Tessamma, T., 2003, A Neural Network Method for Mammogram Analysis Based on Statistical Features, *Conference on Convergent Technologies for Asia-Pacific Region*, 4: 1489- 1492.

MIAS Database, http://peipa.essex.ac.uk/info/mias.html [Ziyaret Tarihi: 10 Şubat 2010].

Morrow, W.M., Paranjape, R.B., Rangayyan, R.M., Desautels, J.E.L., 1992, Region-based contrast enhancement of mammograms, Medical Imaging, *IEEE Transactions*, 11(3): 392 - 406 .

Nalwa, V. S., 1993, A guided tour of computer vision, Addison-Wesley Reading, MA, USA.

Norman, L., 2013, http://lakenormanbreastcancersupportgroup.wordpress.com/ [Ziyaret Tarihi: 23 Şubat 2013].

Orel, S.G., Kay, N., Reynolds, C.,1999, Sullivan DC. BI-RADS categorization as a predictor of malignancy. *Radiology 1999*, 211: 845-850.

Oya,r O., 2008, Magnetik Rezonans Görüntüleme (Mrg)'nin Klinik Uygulamaları ve Endikasyonları, *Harran Üniversitesi Tıp Fakültesi Dergisi*;5(2): 31-40.

Özmen, A., Albora, A.M., Uçan, O.N., 1999a, Hücresel Yapay Sinir Ağları (HYSA) Kullanarak Sivas Bölgesi Gürün ilçesi Kötüyurttepe mevkiinin modellenmesi, *11.MühendislikHaftası Yerbilimleri Sempozyumu-ISPARTA*, 373-381.

Özmen, A., Uçan,, O.N., Albora, A.M., 1999b, Arkeolojik Sahalarda Ölçülen Cisimlerin Hücresel Yapay Sinir Ağları Kullanılarak Görüntülenmesi, *TMMOB Jeofizik Mühendisleri Odası İzmir Şubesi-İZMİR*, 24.

Özşen, Ö., 2002, Matematiksel Morfoloji Kullanarak Göğüs Kanserinin Erken Teşhisi, *A.Ü. . Fen Bilimleri Ens., Yüksek Lisans Tezi*, Eskişehir.

Öztürk, E., Demirkazık, F. B., 2007, Meme Ultrasonografisi (Teknik, Raporlama, Tanı Kriterleri), *Turkiye Klinikleri J Int Med Sci*, 3(44): 25-38.

Panetta, K.A., Wharton, E.J., Agaian, S.S., 2008, Human Visual System-Based Image Enhancement and Logarithmic Contrast Measure, *IEEE Transactions on* 38(1): 174 – 188.

Parkin, DM, Bray, F, Ferlay, J, Pisani, P., 2002, Global cancer statistics, CA Cancer J Clin, 5(2):74-108.

Park, J.M., Choi, H.K., Bae, S.J., Lee, M.S., Ahn, S.H., Gong, G., 2000, Clustering of breast microcalcifications, . Clin Radiol; 55: 114-118.

Parr, T., Astley, S., Boggis, C., 1994, The detection of stellate lesions in digital mammograms, *in Proc. 2nd Int. Workshop on Digital Mammography*, York, England, July 10–12, 231–240.

Perona, P., Malik, J., 1990, Scale-Space and Edge Detection Using Anisotropic Diffusion, *IEEE Trans. On PAMI*, l2(6),: 629-639.

Petrick, N., Chan, H.P., Sahiner, B., Wei, D., 1996, An Adaptive Density-Weighted Contrast Enhancement Filter for Mammographic Breast Mass Detection, *IEEE Trans. Medical Imaging*, 15(1): 59-67.

Petrosian, A., Chan, H. P., Helvie, M. A., Goodsitt, M. M., and Adler, D. D., 1994, Computer-aided diagnosis in mammography: Classification of mass and normal tissue by texture analysis, *Phys. Med. Biol.*, 39: 2273–2288.

Pizer, S. M., 1987, Adaptive Histogram Equalization and Its Variations Computer Vision, Graphics and Images Processing, 335-368.

Pohlman, S. K., Powell, K. A., Obuchowski, N., Chilcote, W., and Grundfest, B. S., 1995, Classification of breast lesions based on quantitative measures of tumor morphology, *in Proc. IEEE Engineering in Medicineand Biology Society 17th Annu. Int. Conf.*, Montreal, Canada, 2 - 4.

Polakowski, W. E., Cournoyer, D. A., Rogers, S. K., 1997, Computer-Aided Breast Cancer Detection and Diagnosis of Masses Using Difference of Gaussians and Derivative-Based Feature Saliency, *IEEE Transactions on Medical Imaging*, 16(6): 811–819.

Priebe, C. E., Lorey, R. A., Marchette, D. J., Solka, J. L., Rogers, G. W., 1994, Nonparametric spatio-temporal change point analysis for early detection in mammography, *in Proc. 2nd Int. Workshop on Digital Mammography*, York, England, 111–120.

Prince, J.L., Links, J.M., 2006, Medical Imaging Signals and Systems, *Pearson Prentice Hall Bioengineering*, New Jersey, USA, 3-13.

Quintanilla-Dominguez, J., Cortina-Januchs, M. G., Ojeda-magaña, B., Jevtić, A., Vega-Corona, A., Andina, D., 2010, Microcalcification detection applying artificial neural

networks and mathematical morphology in digital mammograms, SpainWorld Automation Congress (WAC), 1-6.

Rosenfeld, A., Kak, A.C., 1982, Digital picture processing, Academic Press, New York, 2nd edn.

Roska, T. and Chua, L. 0., 1990, Cellular neural networks with nonlinear and delay-type template elements, *in Proc. IEEE Int. Workshop on Cellular Neural Neworks and Their Applications*, 12-25.

Sahiner, B., Petrick, N., Heang-Ping, C., Hadjiiski, L.M., 2001, Computer-Aided Characterization of Mammographic Masses: Accuracy of Mass Segmentation and Its Effects on Characterization, , *IEEE Transactions On Medical Imaging*, 20(12): 1275-1284.

Savacı, F.A., Vanderwalle, J., 1993, On the Stability of Cellular Neural Networks, IEEE Transactions on Circuits and Systems, 40 (3), 213-215.

Sayman, H. B., 2006, Meme Kanseri Tanısında Pozitron Emisyon Tomografisi (PET), *Meme Kanseri Sempozyum Dizisi,* Türkiye, İstanbul, 54: 31 – 34.

Semmlow, J. L., Shadagopappan, A., Ackerman, L. V., Hand, W., Alcorn, F. S., 1980, A fully automated system for screening xeromammograms, *Comput. Biomed. Res*., 13: 350–362.

Smathers, R.L., Bush, E., Drace, J., Stevens, M., Sommer, F.G., Brown, B.W., Kanas, B., 1986, Mammographic microcalcifications: Detection with xerography, screen-film and digitized film display, Radiology, 159(3) 673-677.

Spiesberger, W., 1979, Mammogram inspection by computer, *IEEE Trans. Biomed. Eng*., 26: 213–219.

Spratt, J. S., Tabin, G.R., 1995, Gross anatomy of the breast, In: Donegan WL, Spratt JS, eds. Cancer of the breast, *4th edition, Philedelphia,* London: W.B.Saunders, 22-42.

Stewart, SL., King, JB., Thompson, TD., et al., 2004, Cancer mortality surveillance United States, 1990-2000. MMWR Surveill Summ 53: 1-108.

Sundaram, M., Ramar, K., Arumugam, N., Prabin, G., 2011, Histogram Modified Local Contrast Enhancement for mammogram images, *Applied Soft Computing,* In Press.

Suziki, H., Matsimoto, T., Chua, L.O., 1992, A CNN Handwritten Character Recognizer, *International Journal of Circuit Theory and Applications*, 20: 601-612.

Sziranyi, T., Csapodi, M., 1994, Texture Classification and Segmentation by Cellular Neural Networks using Genetic Learning, Research Report, *Computer and Automation Institute Hungarian Academy of Sciences*.

Şenel, H.G., 2007, Topological Gradient Operators for Edge Detection, *ICIP 2007. IEEE International Conference on Image Processing.*

Şengür, A., 2006, Endoskopik Görüntülerin Değerlendirilmesinde Görüntü İşleme Temelli Akıllı Karar Destek Sistemi, *Doktora Tezi, Fırat Üniversitesi, FBE.* Elazığ.

Tander, B. ve Ün, M., 2001, Hücresel yapay sinir ağları için gerilim kaynaklı hücre modelleri, *Istanbul University Journal of Electrical Electronics Engineering*, 1(2): 209-221.

Thangavel, K., Karnan, M., 2005, Computer Aided Diagnosis in Digital Mammograms: Detection of Microcalcifications by Meta-Heuristic Algorithms, *GVIP Journal*, 5(7): 41-55.

Tuncer, A. M., 2007, Türkiye'de Kanser Kontrolü, *T.C. Sağlık Bakanlığı Kanserle Savaş Dairesi*, Ankara.

Tuncer, A. M., 2009, Türkiye'de Kanser Kontrolü, *T.C. Sağlık Bakanlığı Kanserle Savaş Dairesi*, Ankara.

Uçan, O.N. ve Albora, A.M., 2003, İşaret ve görüntü işlemede yeni yaklaşımlar, *İ.Ü. Mühendislik Fakültesi Yayınları*, , 975-404-686-7, İstanbul.

Uçan, O.N., O. Osman., Albora, A.M., 2006, Görüntü İşleme Teknikleri ve Mühendislik Uygulamaları, Nobel Yayınları.

Verma, B., Zakos, J., 2001, A computer-aided diagnosis system for digital mammograms based on fuzzy-neural and feature extraction techniques, *IEEE Transactions On Information Technology in Biomedicine*, 5: 46-54.

Vilariño, D. L., Cabello, D., Pardo, X. M. and Brea, V. M., 10 February 2003, Cellular neural networks and active contours: a tool for image segmentation. *Original Research Article Image and Vision Computing*, 21(2): 189-204.

Wang, T.C., Karayiannis, N.B., 1998, Detection of Microcalcifications in Digital Mammograms Using Wavelets, *IEEE Transactions On Medical Imaging*, 17(4): 498-509.

Wang, Z., Bovik, A.C., 2002, A universal image quality index. Signal Processing Letters, IEEE, 9(3): 81 – 84.

Winsbeg, F., Elkin, M., Macy, J. J., Bordaz, V., Weymouth, W., 1967, Detection of radiographic abnormalities in mammograms by means of optical scanning and computer analysis, Radiol, 89: 211–215.

Wirth, M., Fraschini, M., Lyon, J., 2004, Contrast enhancement of micro calcifications in mammograms using morphological enhancement and non-flat structuring elements, *17th IEEE Symposium on Computer-Based Medical Systems, CBMS 2004*. Bethesda, MD, USA, 134-139.

Woods, K. S., Bowyer, K. W., 1994 , Computer detection of stellate lesions, *in Proc. 2nd Int. Workshop on Digital Mammography*, York, England, 221–230.

Wu, Q., Merchant, F.A., Castleman, K.R., 2008, Microscope Image Processing, ISBN: 978-0-12-372578-3.

Wu, Y., He, J., Man, Y., Arribas, J. I., 2004, Neural Network Fusion Strategies for Identifying Breast Masses, *IEEE International Joint Conference*, 3: 2437-2442.

Xiao X., Zhang X., 2010, An Improved Unsharp Masking Method for Borehole Image Enhancement, *2nd International Conference on Industrial Mechatronics and Automation.* 2: 349-353.

Yabashi , S., Hata, M., Kubo, K., Ishikawa, T., 1989, Image processing for recognition of tumor on mammography, *in Proc. 1989 Int. Symp. Noise and Clutter Rejection in Radars and Imaging Sensors*, 182–185.

Yeganeh, H., Ziaei, A., Rezaie, A., 2008, A novel approach for contrast enhancement based on Histogram Equalization, *A Computer and Communication Engineering*, 2008. *ICCCE 2008. International Conference on Digital Object*, 256 – 260.

Yin, F. F., Giger M. L., Doi K., Vyborny, C. J. , Schmidt, R. A., Metz, C. E., 1990, Computer-vision for the detection and characterization of masses for use in mammographic screening programs, *in SPIE Applications of Optical Engineering:* Proc. OE/Midwest'90, 1396: 2–4.

Younesi, F., Alam, N.R., Zoroofi, R.A., Ahmadian, A. and Guiti, M., 2007, Computer-Aided Mass Detection on Digitized Mammograms Using Adaptive Thresholding and Fuzzy Entropy, *Engineering in Medicine and Biology Society, 29th Annual International Conference of the IEEE*, 5638 - 5640.

Yu, S., Guan, L., 2000, A CAD System for the Automatic Detection of Clustered Microcalcifications in Digitized Mammogram Films, *IEEE Transactions On Medical Imaging*, 19: 15-126.

Zhang, P., Verma, B., Kumar, K., 2004, A neural-genetic algorithm for feature selection and breast abnormality classification in digital mammography , *IEEE International Joint Conference*, 3: 2303-2308.

Zhao, H., Li, L., Xu, W., Zhang, J., 2010, A Novel Clustering Method based on K-Means with Region Growing for Microcalcifications, 1-4.

Zhiyuan, X., Xiaoming, L., 2009, Fog Removal from Video Sequences Using Contrast Limited Adaptive Histogram Equalization, *Computational Intelligence and Software Engineering, CiSE 2009 International Conference on Digital Object*, 1-4.

Zou, F., Nossek, J.A., 1991, Stability of Cellular Neural Networks with Opposite- Sign Templates, *IEEE Transactions on Circuits and Systems*, 38 (6): 675-677.

**EKLER**

**EK 1: Selçuk Üniversitesi Meram Tıp Fakültesi Dekanlığından Alınan Etik Kurul Raporu**

T.C.
SELÇUK ÜNİVERSİTESİ MERAM
TIP FAKÜLTESİ DEKANLIĞI
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR DEĞERLENDİRME KOMİSYON KARARI

**Toplantı Sayısı: 03** **Toplantı Tarihi: 26.05.2010**

**Karar Sayısı:2010/048:** S.Ü. Mühendislik Mimarlık Fakültesi Elektrik-Elektronik Müh. Bölümü Öğretim Üyesi Doç. Dr. Yüksel ÖZBAY'ın **"Yapay Zeka Yöntemleri İle Meme Kanseri Teşhisi"** başlıklı doktora tez çalışması ile ilgili 24.05.2010 tarihli dilekçesi ve ekleri görüşüldü, doktora tez çalışmasının S.Ü. Mühendislik Mimarlık Fakültesi Elektrik-Elektronik Müh. Bölümü Öğretim Üyesi Doç. Dr. Yüksel ÖZBAY'ın sorumluluğunda yürütülmesinin uygun olduğuna oybirliği ile karar verilmiştir

ASLIGİBİDİR
26.05.2010

# ÖZGEÇMİŞ

## KİŞİSEL BİLGİLER

**Adı Soyadı** : Levent CİVCİK
**Uyruğu** : T.C.
**Doğum Yeri ve Tarihi** : Erzurum, 29.08.1968
**Telefon** : 0332.3232364
**Faks** :
**e-mail** : lcivcik@selcuk.edu.tr

## EĞİTİM

| Derece | | Adı, İlçe, İl | Bitirme Yılı |
|---|---|---|---|
| Lise | : | Konya Gazi Lisesi | 1985 |
| Üniversite | : | Yıldız Üniversitesi | 1991 |
| Yüksek Lisans | : | Selçuk Üniversitesi | 1998 |
| Doktora | : | | |

## İŞ DENEYİMLERİ

| Yıl | Kurum | Görevi |
|---|---|---|
| 1990-1992 | BİLTAM A.Ş. | Sistem Müh. |
| 1992-devam ed. | Selçuk Üniversitesi | Öğr.Gör. |

## UZMANLIK ALANI

Biyomedikal, Görüntü İşleme

## YABANCI DİLLER

İngilizce

## YAYINLAR

L. Civcik, B. Yılmaz, Y. Özbay, G. D. Emlik, “Detection of Microcalcification in Digitized Mammograms with Multistable Cellular Neural Networks Using a New Image Enhancement Method: Automated Lesion Intensity Enhancer (ALIE)”, Available on line 01 June 2013, PDF Last modified on 08 July 2013 06:43:24, DOI: 10.3906/elk-1303-139. (Doktora tezinden yapılmıştır).