



**MAMOGRAFİ GÖRÜNTÜLERİNDE MİKROKALSİFİKASYONLARIN  
GÖRÜNÜRLÜĞÜNÜN İYİLEŞTİRİLMESİ ve SINIFLANDIRILMASI İÇİN  
YENİ YAKLAŞIMLAR**

**AYŞE AYDIN YURDUSEV**

**DOKTORA TEZİ**

**MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI  
DOÇ. DR. MAHMUT HEKİM  
İKİNCİ DANIŞMAN: DR. ÖGR. ÜYESİ CANAN ORAL  
Aralık – 2019**

**Her hakkı saklıdır**

T.C.  
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

DOKTORA TEZİ

MAMOGRAFİ GÖRÜNTÜLERİNDE MİKROKALSİFİKASYONLARIN  
GÖRÜNÜRLÜĞÜNÜN İYİLEŞTİRİLMESİ VE SINIFLANDIRILMASI İÇİN YENİ  
YAKLAŞIMLAR

AYŞE AYDIN YURDUSEV

TOKAT

Aralık - 2019

Her hakkı saklıdır

Ayşe AYDIN YURDUSEV tarafından hazırlanan “Mamografi Görüntülerinde Mikrokalsifikasyonların Görünürlüğünün İyileştirilmesi ve Sınıflandırılması için Yeni Yaklaşımlar” adlı tez çalışmasının savunma sınavı 5 Aralık 2019 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman  
Doç. Dr. Mahmut HEKİM



Üye  
Dr. Öğretim Üyesi Cem EMEKSİZ  
Tokat Gaziosmanpaşa Üniversitesi



Üye  
Dr. Öğretim Üyesi İsmail İŞERİ  
Ondokuz Mayıs Üniversitesi



Üye  
Dr. Öğretim Üyesi Bülent TURAN  
Tokat Gaziosmanpaşa Üniversitesi



Dr. Öğretim Üyesi Erhan BERGİL  
Amasya Üniversitesi



ONAY

  
Prof. Dr. Çetin ÇEKİÇ  
Fen Bilimleri Enstitüsü Müdürü



## TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdığı yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

**Ayşe AYDIN YURDUSEV**

05 Aralık 2019



## ÖZET

### DOKTORA TEZİ

#### MAMOGRAFİ GÖRÜNTÜLERİNDE MİKROKALSİFİKASYONLARIN GÖRÜNÜRLÜĞÜNÜN İYİLEŞTİRİLMESİ VE SINIFLANDIRILMASI İÇİN YENİ YAKLAŞIMLAR

AYŞE AYDIN YURDUSEV

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

MEKATRONİK MÜHENDİSİĞİ ANABİLİM DALI

TEZ DANIŞMANI: DOÇ. DR. MAHMUT HEKİM  
İKİNCİ DANIŞMAN: DR. ÖĞR. ÜYESİ CANAN ORAL

Bu tez çalışmasında, mamogramlardaki mikrokalsifikasyonların görünürliğini arttırmak için yeni bir piksel atama temelli uzamsal filtreye sahip bir bilgisayar destekli teşhis (CAD) sistemi önerilmektedir. CAD sisteminin bir parçası olarak kullanılan uzamsal filtre, önce ilgilenilen merkez piksel ile 8 komşusu arasındaki farkların mutlak değerlerini toplamakta ve bu toplam değeri ilgilenilen merkez pikseline atamaktadır. Bu işlemler görüntünün her pikseli için tekrarlanmaktadır. Önerilen filtrenin CAD sistemine katkısının karşılaştırılmasında adilliği sağlamak için filtrelenmiş görüntülere kontrast germe uygulanmıştır. Yaygın olarak kullanılan ortalama, standart sapma, entropi, enerji, çarpıklık ve kurtos temel istatistiksel parametreleri kullanılarak filtreli kontrast-germeli bu görüntülerden özellik vektörleri elde edilmiştir. Elde edilen bu özellik vektörleri hem mikrokalsifikasyon içeren mamogramları tespit etmek ve hem de mikrokalsifikasyonları sınıflandırmak için destek vektör makineleri, çok katmanlı algılayıcı sinir ağı ve lineer diskriminant analizi temelli sınıflandırıcı modellere giriş olarak kullanılmıştır. Önerilen filtrenin mikrokalsifikasyonların tespit edilmesinde ve tespit edilen mikrokalsifikasyonların sınıflandırılmasında CAD sistemine olan etkisini değerlendirmek için literatürde temel olarak kullanılan Laplace, Gabor, Top-hat ve Gauss yüksek geçiren filtreleri ile karşılaştırılmıştır. Gerçekleştirilen sınıflandırma çalışmalarında, önerilen filtre mikrokalsifikasyon içeren mamogramların tespitinde ve mikrokalsifikasyonların sınıflandırılmasında diğer filtrelerden daha yüksek başarı oranlarına ulaşmıştır. Dolayısıyla, bu karşılaştırma, önerilen filtrenin mamogramlardaki mikrokalsifikasyonların görünürliğini arttırdığını göstermiştir. Sonuç olarak, önerilen uzamsal filtre mamografilerdeki mikrokalsifikasyonların görünürliğünün belirginleştirilmesinde ve bu filtreye sahip CAD sistem tanısal karar destek mekanizması olarak meme kanserinin analizinde kullanılabilir.

2019, 90 SAYFA

**ANAHTAR KELİMELER:** Mamografi, Mikrokalsifikasyon, Bilgisayar Destekli Teşhis, Uzamsal Filtre, Sınıflandırma, Meme Kanseri

## **ABSTRACT**

### **DOCTORATE THESIS**

#### **THE NEW APPROACHES FOR THE CLASSIFICATION OF MICROCALCIFICATIONS IN THE VISIBILITY-ENHANCED MAMMOGRAM IMAGES**

**AYŞE AYDIN YURDUSEV**

**TOKAT GAZIOSMANPASA UNIVERSITY  
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

**DEPARTMENT OF MECHATRONICS ENGINEERING**

**SUPERVISOR: ASSOC. PROF. DR. MAHMUT HEKİM  
CO-SUPERVISOR: ASST. PROF. DR. CANAN ORAL**

In this thesis, we proposed a new computer aided diagnosis (CAD) system which has the pixel assignment-based spatial filter to enhance the visibility of microcalcifications in mammograms. The proposed filter used as a part of the CAD system, first sums the absolute values of the differences between the center pixel of interest and its 8-neighbors, and then assigns this summed value to that center pixel of interest. This process was repeated for each pixel of the image. Then, the contrast stretching was applied to the filtered-images in order to ensure the fairness in the comparison of the contribution of the proposed filter to the CAD system. The feature vectors were extracted from the filtered-contrast stretched-images by using the widely used and well-known statistical parameters which are mean, standard deviation, entropy, energy, skewness and kurtosis. The extracted feature vectors were applied to the inputs of support vector machines, linear discriminant analysis and multilayer perceptron neural network classifiers in order to detect the mammograms with microcalcifications as absent/present and to classify the detected microcalcifications as benign and malignant. In order to evaluate the effect of the proposed filter on the success of detection and classification, it was compared to widely used Laplace, Gabor, Top-hat and Gaussian high pass filters. In the implemented experiments, the comparison showed that this filter provided higher contribution to the success of detection and classification than the others, and hence enhanced the visibility of microcalcifications in mammograms. Finally, it can be concluded that the proposed filter can contribute to the development of the state-of-art methodologies and can be used with a CAD system as a diagnostic decision support mechanism in the analysis of mammograms.

2019, 90 PAGE

**KEYWORDS:** Mammography, Microcalcification, Computer Aided Diagnosis, Spatial Filter, Classification, Breast Cancer

## ÖNSÖZ

Doktora tezim boyunca hem aldığım derslerde hem de tezimin şekillenmesinde bana yol gösteren, kılavuzum olan, hiçbir zaman yardımlarını esirgemeyen danışmanım Sayın Doç. Dr. Mahmut HEKİM ve ikinci danışmanım Sayın Dr. Öğr. Üyesi Canan ORAL'a teşekkür ederim. Ayrıca, tez izleme komitesi üyelerinden fikirleriyle ve bilgileriyle bana yardımcı olan Sayın Dr. Öğr. Üyesi Cem EMEKSİZ'e ve Sayın Dr. Öğr. Üyesi İsmail İŞERİ'ye teşekkürlerimi sunarım. Doktora çalışması boyunca her konuda yardımlarını esirgemeyen Mekatronik Mühendisliği Bölümünün tüm öğretim elemanlarına sonsuz teşekkürlerimi sunarım. Amasya Üniversitesi bünyesinde çalışma şansına eriştiğim hem iş hayatımda hem de doktora çalışmamda desteklerini her zaman hissettiğim çalışma arkadaşlarıma ve idari amirlerimize teşekkür ederim.

Bu süreçte beni destekleyen, daima yardımcı olan sevgili eşime, varlığıyla bana desteklerin en büyüğünü veren canım oğluma ve tüm eğitim hayatım boyunca emeği ve çabası ile yanımda olan kıymetli anne ve babama sonsuz sevgi ve minnetle teşekkür ederim.

**Ayşe AYDIN YURDUSEV**

**ARALIK, 2019**

## İÇİNDEKİLER

Sayfa

ÖZET .....	i
ABSTRACT.....	ii
ÖNSÖZ .....	iii
İÇİNDEKİLER .....	iv
SİMGELER ve KISALTMALAR.....	vi
ŞEKİL LİSTESİ.....	x
ÇİZELGE LİSTESİ.....	xii
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER .....	4
2.1. Meme Kanseri.....	4
2.2. Görüntüleme Teknikleri .....	4
2.2.1. Mamografi.....	7
2.3. Meme Yapısındaki Anomaliler.....	10
2.3.1. Mikrokalsifikasyonlar .....	13
2.4. Bilgisayar Destekli Teşhis .....	17
2.5. Literatür Özeti .....	18
3. MATERYAL ve YÖNTEM .....	23
3.1. Veri Tabanı .....	24
3.2. Önişleme .....	28
3.3. Görüntü İyileştirme.....	32
3.3.1. Uzamsal filtreleme .....	34
3.3.2. Frekans bölgesinde filtreleme.....	38
3.3.3. Morfolojik görüntü işleme .....	44
3.3.4. Önerilen filtre.....	48



3.4.	Özellik Çıkarımı .....	54
3.5.	Sınıflandırma .....	55
3.5.1.	Destek vektör makineleri .....	56
3.5.1.	Çok katmanlı algılayıcı sinir ağı.....	58
3.5.2.	Doğrusal diskriminant analizi .....	60
3.5.3.	Sınıflandırma başarısının ölçülmesi.....	61
4.	BULGULAR.....	65
4.1.	Mikrokalsifikasyonların Tespiti için CAD Sistemi.....	71
4.2.	Mikrokalsifikasyonların Sınıflandırılması için CAD Sistemi.....	76
5.	TARTIŞMA ve SONUÇ .....	81
6.	KAYNAKLAR.....	83
7.	ÖZGEÇMİŞ .....	89

## SİMGELER ve KISALTMALAR

<b>Simgeler</b>	<b>Açıklama</b>
$\gamma$	Uzamsal En-Boy Oranı
$\Theta$	Gauss Dağılımı Açısı
$\lambda$	Dalga Boyu
$\mu$	Tüm Sınıfların Ortalama Değeri
$\mu_i$	Sınıfın ortalama değeri
$\sigma$	Standart Sapma
$A \oplus B$	Morfolojik Genişletme
$A \ominus B$	Morfolojik Aşındırma
$A \circ B$	Morfolojik Açma
$A \bullet B$	Morfolojik Kapama
$c$	LDA Toplam Sınıf Sayısı
$D_0$	Kesim Frekansı
$E$	Hata Oranı
$f(t)$	Sürekli Zamanlı Fonksiyon
$F(u,v)$	Ayrık Zamanlı Fourier Dönüşümü Çıktısı
$f(x,y)$	Gri-Seviye Görüntü
$F(\mu)$	Fourier Dönüşümü Çıktısı
$f$	Aktivasyon Fonksiyonu
$f_{SVM}(x)$	SVM Fonksiyonu
$g(x,y)$	Uzamsal Filtre Çıktısı
$H(u,v)$	GHP Filtre Çıktısı
$h_i$	Gri-Seviye Histogramı
$j$	ANN'de Nöron
$K(x,y)$	Önerilen Filtre Çıktısı
$K(x,s_k)$	Çekirdek Fonksiyonu
$L$	Gri-Seviye Değeri
$m$	Ortalama
$N$	Görüntüdeki Toplam Piksel Sayısı
$N_i$	Sınıftaki Örnek Sayısı

$p_i$	Normalizeli ve Kümelemeli Histogram Deęeri
$S_b$	LDA Sınıflar Arası Saçılma
$S_w$	LDA Sınıf İçi Saçılma
$w(x,y)$	Uzamsal Maske
$w(x,y) \star f(x,y)$	Uzamsal İlinti
$w(x,y) \star f(x,y)$	Uzamsal Konvolüsyon
$w_{ij}$	Nöron Ağırlık katsayısı
$x_i$	Özellik Kümesi
$x_n$	Normalizeli Özellik Kümesi
$y_j$	Nöron Çıktısı
$y_{dj}$	ANN Nöron Hedef Çıktı Deęeri

#### **Kısaltmalar**

#### **Açıklama**

2D DFT	2 Boyutlu Ayırık Fourier Dönüşümü (2D Discrete Fourier Transform)
2D IDFT	2 Boyutlu Ters Ayırık Zamanlı Fourier Dönüşümü (2D Inverse Discrete Fourier Transform)
AHE	Adaptif Histogram Eşitleme (Adaptive Histogram Equation)
ANN	Yapay Sinir Ağı (Artificial Neural Network)
BI-RADS	Meme Görüntüleme, Raporlandırma ve Veri Sistemi (Breast Imaging-Reporting and Data System)
CAD	Bilgisayar Destekli Teşhis (Computer Aided Diagnosis)
CADe	Bilgisayar Destekli Tespit (Computer Aided Detection)
CADx	Bilgisayar Destekli Teşhis (Computer Aided Diagnosis)
CC	Kranio Kaudal (Cranio Caudal)
CNN	Konvolusyonel Sinir Ağı (Convolutional Neural Network)
CNR	Kontrast Gürültü Oranı (Contrast-to-Noise Ratio)
DDSM	Mamografi Görüntüleme Sayısal Veritabanı (Digital Database of Screening Mammography)
DICOM	Tıpta Sayısal Görüntüleme ve İletişim (Digital Imaging and Communications in Medicine )
DoG	Gaussların farkı (Difference-of-Gaussian)

FN	Yanlış Negatif (False Negative)
FP	FP (False Positive)
GHP	Gauss Yüksek Geçiren (Gaussian High Pass)
HMF	Hibrit Medyan Filtre (Hybrid Median Filter)
HOF	Yüksek Mertebe Filtresi (Higher Order Filter)
IQI	Kalite Endeksi (the Institutional Quality Index)
kNN	k-En Yakın Komşu (k-Nearest Neighbor)
LDA	Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
LM	Levenberg – Marquardt
LMMSE	Doğrusal Minimum Ortalama Kare Hata (Linear Minimum Mean Square Error)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAF	Harektli Ortalama Filtre (Moving Average Filter)
MD	Maksimum Fark (Maximum Difference)
MIAS	Mamografik Görüntü Analiz Derneği Sayısal Mamogram Veri Tabanı (Mammographic Image Analysis Society Digital Mammogram Database)
MLO	Mediolateral Oblik (Medio Lateral Oblique)
MLPNN	Çok Katmanlı Algılayıcı Sinir Ağı (Multilayer Perceptron Neural Network)
MSE	Ortalama Kare Hata (Mean Square Error)
MSSIM	Ortalama Yapı Benzerlik İndeksi (Mean Structural Similarity Index)
NAE	Normleştirilmiş Mutlak Hata (Absolute Error)
NLM	Yerel Olmayan Araçlar (Non-Local Mean)
ORNRAD	Yönlendirilmiş Rician Gürültü Azaltma Anizotropik Difüzyon (Oriented Rician Noise Reduction Anisotropic Diffusion)
PSNR	Tepe-Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ration)
RGB	Renk Uzayı/Kırmızı-Yeşil-Mavi (Red-Green-Blue)
ROC	Alıcı İşlem Karakteristiği (Receiver Operating Characteristic)
ROI	İlgi Bölgesi (Region of Interest)
SC	Yapısal İçerik (Structural Content)

SVM	Destek Vektör Makineleri (Support Vector Machine)
TCC	Toplam Sınıflandırma Doğruluđu (Total Correct Classification)
TN	Dođru Negatif (True Negative)
TP	Dođru Pozitif (True Positive)



## ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 2.1. Memenin anatomik yapısı ve lenf nodülleri .....	5
Şekil 2.2. Sayısal mamografi cihazı yapısı .....	7
Şekil 2.3. MLO ve CC tekniği ile mamografi çekiminin gösterimi .....	8
Şekil 2.4. MLO ve CC mamografi görüntüleri .....	9
Şekil 2.5. Bir komedo tipi mikrokalsifikasyon kümesinin mamogram görüntüsü. ....	16
Şekil 2.6. Dört yıl arayla çekilmiş yumurta kabuğu mikrokalsifikasyonun mamogramı	16
Şekil 2.7. Bilgisayar destekli tespit ve teşhis algoritması.....	18
Şekil 3.1. Tasarlanan sistemin öbek gösterimi .....	23
Şekil 3.2. MIAS veri tabanı bilgi satırı .....	24
Şekil 3.3. Örnek MIAS mamogramları.....	25
Şekil 3.4. Örnek DDSM mamografi görüntüleri .....	26
Şekil 3.5. Zincir kod koordinatları.....	27
Şekil 3.6. Örnek zincir kod uygulaması.....	27
Şekil 3.7. (a) Orijinal mamogram (b) Gürültü eklenmiş mamogram .....	29
Şekil 3.8 Mamografi imgelerindeki gürültülerin gösterimi .....	31
Şekil 3.9. Örnek pektoral kas ve gürültü temizlenmiş mamogram.....	32
Şekil 3.10. 3×3 piksellik bir görüntünün koordinat bilgileri. ....	32
Şekil 3.11. 8-bit derinliğinde bir gri-seviye görüntü .....	33
Şekil 3.12. Sayısal görüntüyü filtreleme işlemi .....	34
Şekil 3.13. Laplace filtre çıktıları .....	38
Şekil 3.14. Frekans düzleminde süzme işlemi .....	39
Şekil 3.15. ROI'ye GHP filtre uygulaması .....	42
Şekil 3.16. Mikrokalsifikasyon kesitine Gabor filtre uygulaması .....	44
Şekil 3.17. Mikrokalsifikasyon kesitine morfolojik işlemlerin uygulanması.....	46
Şekil 3.18. Mikrokalsifikasyon kesitine Top-hat ve Bottom-hat uygulaması .....	48
Şekil 3.19. Farklı mamografilere ait mikrokalsifikasyon görüntüleri .....	49
Şekil 3.20. Tek mikrokalsifikasyon görüntüsünden kesit alınması ve yeğinlik değerleri .....	50
Şekil 3.21. ROI'ye önerilen filtre uygulaması ve histogram değerleri.....	52

Şekil 3.22. Kontrast germeli orijinal ROI ve önerilen filtreli-kontrast germeli ROI karşılaştırılması .....	53
Şekil 3.23. SVM Hiper-Düzlemi .....	57
Şekil 3.24. Bir MLPNN yapısı örneği .....	59
Şekil 3.25. MLPNN’de nöron yapısı .....	59
Şekil 3.26. Örnek bir ROC eğrisi gösterimi.....	63
Şekil 4.1. A_1201_SAĞ_MLO’dan alınan mikrokalsifikasyonlu ROI örneği ve bu görüntüden elde edilen filtreli-kontrast germeli ROI’ler .....	66
Şekil 4.2. A_1496_SOL_MLO’dan alınan mikrokalsifikasyonlu ROI örneği ve bu görüntüden elde edilen filtreli-kontrast germeli ROI’ler .....	67
Şekil 4.3. D_4528_SAĞ_MLO’dan alınan mikrokalsifikasyonsuz ROI örneği ve bu görüntüden elde edilen filtreli-kontrast germeli ROI’ler .....	68
Şekil 4.4. Sınıflandırma aşamaları .....	70
Şekil 4.5. Mikrokalsifikasyonların varlığını saptamaya yönelik CAD sonuçlarının ROC analizi .....	73
Şekil 4.6. Mikrokalsifikasyonların varlığını tespit için tekrarlı sınıflandırma doğruluk sonuçları .....	75
Şekil 4.7. Mikrokalsifikasyonların türlerinin tespitine yönelik CAD sonuçlarının ROC analizi .....	77
Şekil 4.8. Mikrokalsifikasyonların türlerini tespit için tekrarlı sınıflandırma doğruluk sonuçları .....	78

## ÇİZELGE LİSTESİ

<b><u>Çizelge</u></b>	<b><u>Sayfa</u></b>
Çizelge 2.1. Memede görülen kitlelerin şekil yapısı olarak sınıflandırılması ve mimari distorsiyon .....	10
Çizelge 2.2. Memede görülen kitlelerin sınır yapısı .....	11
Çizelge 2.3. BI-RADS sınıfları .....	12
Çizelge 2.4. Kalsifikasyon Şekilleri BI-RADS sınıflandırması .....	14
Çizelge 2.5. Mikrokalsifikasyonların dağılım türleri.....	15
Çizelge 3.1. MIAS veri tabanı mamografi dağılımı .....	25
Çizelge 3.2. Sayısal görüntü dizin uzantıları .....	33
Çizelge 3.3. Karışıklık matrisi .....	62
Çizelge 4.1. Mikrokalsifikasyon varlığı tespiti için eğitim ve test verilerinin dağılımı .	70
Çizelge 4.2. Mikrokalsifikasyon türlerinin tespiti için eğitim ve test veri setlerinin dağılımı .....	71
Çizelge 4.3. Mikrokalsifikasyon varlığını saptamaya yönelik sınıflandırma sonuçları .	74
Çizelge 4.4. Mikrokalsifikasyonların türlerine göre sınıflandırılmasına ilişkin sınıflandırma sonuçları.....	76
Çizelge 4.5. Uygulanan filtrelerin başarı özeti .....	79



## 1. GİRİŞ

Meme kanseri kadınlar üzerinde en etkili olan ölümcül kanser türüdür (Avdan Aslan, 2013). Halk Sağlığı Birimi'ne ait 2014 yılı verilerine göre Türkiye'de ve dünya genelinde kadınlarda görülen en yaygın kanser türü %24.9 oranıyla meme kanseridir (Hacıkamiloğlu ve ark., 2017). Bu da her 4 kanserli kadından birinin meme kanseri olduğunu göstermektedir. Meme kanserinin bu kadar yaygın ve ölümcül olmasındaki sebep memenin fiziksel yapısı olarak gösterilebilir. Meme yapısında onlarca süt bezesi, süt lobulları, süt kanalları ve yağ dokusu, glandüler doku bulunmaktadır. Dolayısıyla meme yapısal olarak içi pütürlü bir yapıdadır ve kitle gibi iyi huylu veya tümör gibi kötü huylu yapılar meme içerisinde fark edilmekte zorlanılmaktadır. Hatta meme içerisindeki anomalinin elle tespit edildiği zaman tümör çapının büyük olmasından dolayı kanser evresinin ilerlemiş olduğu ve lenf nodüllerinde tutulma yaptığı dolayısıyla sağ kalım oranlarının azaldığı bilinmektedir (Avdan Aslan, 2013).

Meme kanserinin en etkili tedavi yöntemi erken teşhis ile mümkün olmaktadır. Ülkemizde de kanser erken teşhis tarama ve eğitim merkezleri (KETEM) tarafından kanser taramaları yapılarak henüz ortada bir şikâyet bile yokken erken teşhis ile kanserin tedavisi planlanmaktadır (Sağlık Bakanlığı, 2017). Erken teşhisin ilk ve en önemli biri göstergelerinden mikrokalsifikasyonlardır (Yu ve Guan, 2000). Mikrokalsifikasyonlar meme içerisinde bulunan çok küçük kalsiyum birikintileridir. Boyutları 0.5mm-1cm'den küçük olduğu için tespitlerinde görüntüleme teknikleri kullanılmaktadır (Memiş, 2002; Abubaker, 2015). En yaygın mikrokalsifikasyon görüntüleme tekniği olan mamografi meme kanserini erken teşhis etmede oldukça etkilidir (Yu ve Guan, 2000; Redman ve ark., 2015).

Mamografi ile çekilen görüntülerde mikrokalsifikasyonların tespitinin doğruluğu okuyan uzman hekimin deneyimine, hasta yoğunluğuna, dikkat durumuna ve benzeri insani faktörlere bağlıdır (Malich ve ark., 2006). Bu bağlılığı en aza indirmek için bazı sağlık kuruluşlarında aynı mamografinin iki farklı hekim tarafından okunması sağlanmaktadır. Fakat bu durum ekonomik ve hızlı bir çözüm değildir (Petrick ve ark., 2002; Malich ve ark., 2006). Bu sebeple günümüz modern teknolojisinin de yardımıyla bilgisayar destekli

teşhis/tespit (CAD) sistemleri kullanılmaktadır. Bu sistemler bir bilgisayar programı tarafından bir mamografinin okunarak hangi anomalileri taşıdığı, anomalinin türü, koordinatları ve benzeri bilgileri sağlayabilir. Literatürde mamografi okumaya yönelik birçok CAD sistemi bulunmaktadır (Shen ve ark., 1994; Sahiner ve ark., 1996; Kim ve ark., 1997; Yu ve Guan, 2000; Soltanian-Zadeh ve ark., 2004; Fu ve ark., 2005; Hupse ve Karssemeijer, 2009; Mencattini ve ark., 2010; Andreadis ve ark., 2015; Bria ve ark., 2018; Elmoufidi ve ark., 2018). Literatürdeki CAD sistemleri meme dokusundaki farklı anomalilere odaklanabilir örneğin bazı CAD sistemler meme içerisindeki tümörlere odaklanırken bazıları ise kalsifikasyonlara odaklanmaktadır.

Bu tezde, meme kanserinin ilk belirtilerinden kabul edilen mikrokalsifikasyonların tespiti için görünürlüğünü iyileştirmek amacıyla piksel tabanlı uzamsal bir filtre tasarlanmış ve mikrokalsifikasyonların tespitine yönelik bu filtreyi kullanan bir CAD sistemi tasarlanmıştır. Mikrokalsifikasyonlar hem çok küçük oldukları için hem de mamografilerde bulunan gürültülere benzedikleri için tespitleri oldukça güçtür. Ayrıca her vakadaki meme yapısı kişiye özgü olduğu için mikrokalsifikasyonların tespiti zorlanmaktadır. Dolayısıyla mikrokalsifikasyon tespitine yönelik çalışma yapma ihtiyacı zorunludur.

Bu çalışmada amaç mikrokalsifikasyonların görünürlüğünü ortaya çıkartmak için yeni bir filtre geliştirmektir. Bu filtre arka plandaki gürültüleri bastırmalı ve mikrokalsifikasyon görüntüsünden arka plandaki görüntüleri ayırt etmeli, böylece mikrokalsifikasyonların daha belirgin hale gelmesini sağlamalıdır. Bu yüzden mikrokalsifikasyonların yapısı incelenmiş ve piksel komşuluklarını temel alan bir uzamsal filtre tasarımı gerçekleştirilmiştir. Önerilen filtre, merkezdeki ilgili pikselin alt, üst, sağ, sol ve çaprazlardan kesişimi bulunan 8 komşusu ile merkez pikselin yeğlilik değerlerinin arasındaki farkın mutlak değerlerini hesaplayarak merkez piksel için yeni bir değer oluşturur. Böylelikle bir pikselin değeri sadece komşuları ile fark değerlerine bağlı hale gelir.

Çalışmamızda önerilen süzgecin sınıflandırma üzerindeki başarısını göstermek için bir CAD sistemi tasarlanmıştır. Bu sistemde mamografi kesitleri önerilen filtre ile işleme

alınmış ve 3 farklı sınıflandırıcı tarafından sınıflandırılmıştır. Önerilen filtrenin sınıflandırma başarısını değerlendirmek amacıyla önerilen filtre literatürde var olan, aynı amaç için kullanılan, temel filtrelerle karşılaştırılmıştır. Bu çalışmada geliştirilen filtrenin mamografideki mikrokalsifikasyon görünürlüğünü geliştirerek sınıflandırma sonuçlarının başarısını artırdığı görülmektedir.

Bu çalışmanın “KURAMSAL TEMELLER” bölümünde meme yapısı, meme kanseri, mamografi gibi meme kanseri ile ilgili genel kavramlardan bahsedilmektedir. Daha önce yapılmış olan çalışmalara değinilerek CAD sistemleri hakkında genel bir bilgi verilmektedir.

Çalışmada üçüncü bölüm olan “MATERYAL ve YÖNTEM” bölümünde çalışmamızı gerçekleştirmek için kullandığımız teknikler açıklanarak, önerilen süzgecin yapısına ve çalışmasına ait detaylar verilerek tasarlanan CAD sistemi ve aşamaları hakkında bilgi verilmektedir.

Dördüncü bölüm “BULGULAR” bölümünde tasarladığımız CAD sistemine ait sınıflandırma başarıları hem önerilen filtre için hem de karşılaştırılan filtreler için sayısal verilere dayanılarak sunulmaktadır.

Son bölüm olan “TARTIŞMA ve SONUÇ” bölümünde ise tasarladığımız sisteme ait sonuçlar yorumlanarak gelecek çalışmalar hakkında düşünceler iletilmektedir.

## **2. KURAMSAL TEMELLER**

### **2.1. Meme Kanseri**

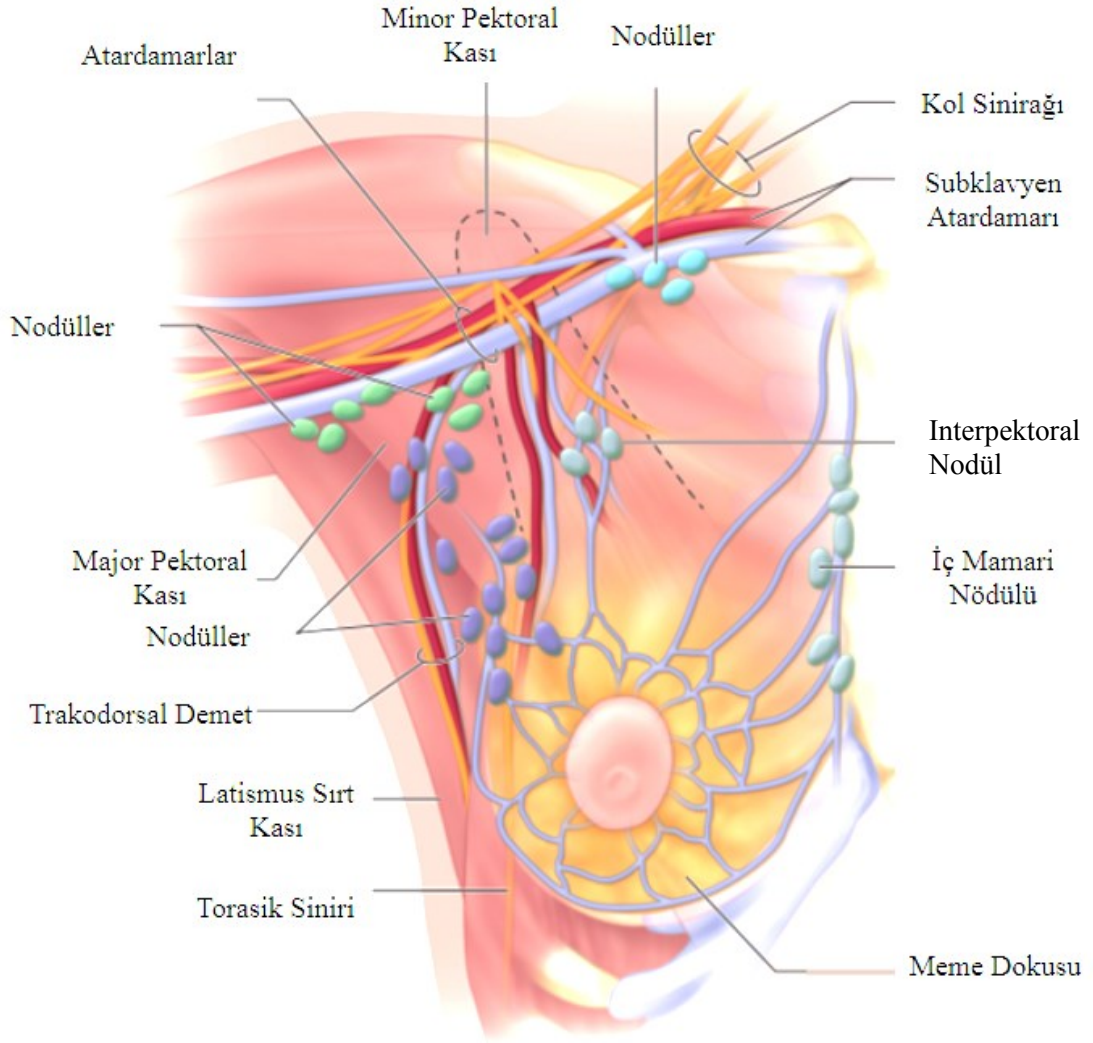
Meme kanseri kadınlarda en çok ölümlle sonuçlanan, kadın ve erkeklerde, akciğer kanserinden sonra ikinci en çok ölümlle sonuçlanan kanser türüdür (Gülsün ve ark., 2002; Avdan Aslan, 2013). Dünya çapında her yıl yaklaşık 170 bin kadında meme kanseri görülmektedir ve kanserden dolayı ölümlerin %17'sinin sebebi meme kanseridir (Özşen, 2004). Meme kanseri kadınlara kıyasla 1/100 oranında erkeklerde de görülmektedir (Avdan Aslan, 2013).

Şekil 2.1'de meme yapısında birçok nodül ve kanal vardır (Murthy ve ark., 2016). Meme kanserinin belirtilerinden olan anomaliler memede bulunan süt kanallarında, süt lobullarında veya meme yağ dokusunun içerisinde oluşabilir (Türkiye Meme Vakfı, 2007).

Memedeki büyük kütleler hiçbir muayene olmaksızın fark edilebilirken, orta ve büyük boyuttaki kütleler kişinin kendini muayene etmesi veya doktor muayenesi ile bulunabilir. Küçük boyuttaki kütleler ise dokunulmayla fark edilmezler ve mamografi, ultrasonografi, galaktografi gibi bir görüntüleme tekniği ile tespit edilir (Yılmaz, 2006). Mikron ölçülerinde oluşan mikrokalsifikasyonlar ise mamografi ile ultrasona nazaran daha belirgin görülebilir (Yılmaz, 2006; Avdan Aslan, 2013).

### **2.2. Görüntüleme Teknikleri**

Meme kanserinin en önemli belirtisi olan memede kitlenin varlığıdır. Memedeki kitle ortalama 2.1 cm çapa ulaştığında kişinin kendi kendine yaptığı elle muayeneyle fark edilebilir. Eğer kişi kendini bilinçli olarak muayene etmiyorsa bu kitlenin boyutu yaklaşık 3.6 cm olduğunda kazara hissedilebilir (Ricks, 2005). Olası 3 cm'lik bir tümör ise diğer dokulara yayılıp hastalığın seyrini kötü yönde değiştirebilir. Bu sebeple memedeki kistler, kitleler mümkün olan en küçük boyutta iken tespit edilmelidir. Elle muayenede 2 cm'den



Şekil 2.1. Memenin anatomik yapısı ve lenf nodülleri

daha küçük yapılar hissedilemez. Bu nedenle meme kanserini teşhis etmek ve takibini yapmak için meme dokusunun içinin görüntülenmesi şarttır. Bu görüntüleme teknikleriyle bulunan bulgulara göre biyopsi gibi ileri tetkiklerle meme kanserinin kesin teşhisi yapılabilir. Meme dokusu görüntülemek için başlıca aşağıdaki yöntemler kullanılır

- i. Mamografi meme dokusunun röntgeninin çekilmesidir. X-ışını kullanılarak meme iki tarafından sıkıştırılarak görüntüsü alınır. Böylece meme içinde yağ dokusu, süt kanalları, süt lobülleri, lif beze dokusu ve varsa anormal dokular görüntülenir (Ricks, 2005; Redman ve ark., 2015).

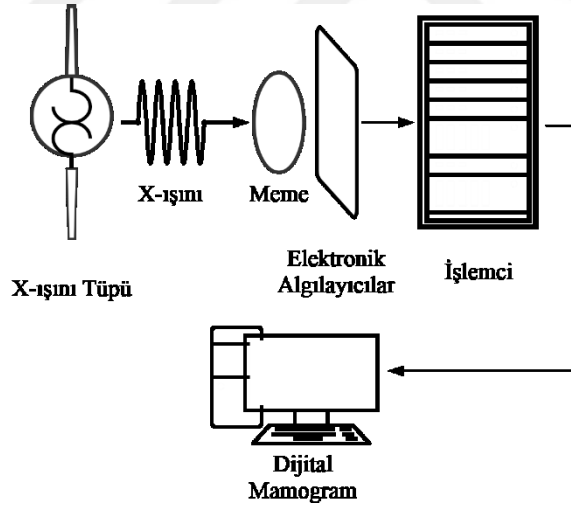
- ii. Galaktografi ya da duktografi ise memeye kontrast-sıvı enjekte edilerek süt kanallarının daha görünür hale gelmesiyle, sadece sıvı verilmiş alanın mamografisinin çekilmesidir (Ricks, 2005; Redman ve ark., 2015).
- iii. Meme tomografisi memenin birçok açıdan mamografisini oluşturarak, bunları tek bir görüntüde birleştirir. Böylece mamografide görülemeyen alanlar görülebilir. Memenin 3 boyutlu bir benzetimi yapılabilir (Redman ve ark., 2015).
- iv. Meme ultrasonu yüksek frekanslı ses dalgaları yardımıyla meme içinin görüntüleri elde edilir. Memede belli bir noktada bulunan lezyonların şeklini ve yapısını incelemek için kullanılabilir. Genellikle yoğun yapılı memeler için tercih edilebilir. Ultrason memedeki kitlelerin iç yapısında sıvı-doluluğun olup olmadığını tespit edebilir ki bu da iyi huylu kistlerin bir kısmını teşhis edebilir. Ultrason aynı zamanda meme yapısında pektoral kasa çok yakın bölgelerdeki anomalilikleri de görüntüleyebilir (Ricks, 2005; Redman ve ark., 2015).
- v. Manyetik rezonans görüntüleme (MRI) manyetik alan ve radyo dalgaları ile meme iç yapısı görüntülenir, X-ışını kullanılmaz. Çekilen MRI boyutuna bağlı olarak, genelde, her iki meme için tüm memenin tek boyutlu bir görüntüsü elde edilir. Genç kadınlarda ve implant içeren bir memenin görüntülenmesinde iyi sonuç vermektedir. En büyük dezavantajı maliyetinin çok yüksek olmasıdır (Ricks, 2005; Redman ve ark., 2015).

Görüntüleme teknikleri arasında mamografi, veya diğer adıyla mamogram, tarama ve teşhis için bilinen en kullanışlı yöntemdir (Memiş, 2002; Avdan Aslan, 2013; Akbay, 2015; Redman ve ark., 2015).

### 2.2.1. Mamografi

Mamografi meme iç yapısını, yumuşak dokuları ve kireçlenmeleri, süt kanallarını gösteren bir görüntüleme tekniğidir (Memiş, 2002; Avdan Aslan, 2013; Redman ve ark., 2015). Mamografi ile ortalama 1.5 cm boyutundaki kitleler ilk muayenede tespit edilebilir. Bu da genel olarak kendi kendine muayeneden 2 yıl önce hastalığın teşhisi demektir (Ricks, 2005). Bu sebeple mamografi erken teşhis için en yaygın olarak kullanılan görüntüleme tekniğidir.

Mamografide meme dokusunu görüntülemeye yetecek mümkün olan en düşük seviyede X-ışını kullanılarak meme dokusu görüntülenir (Memiş, 2002; Avdan Aslan, 2013; Redman ve ark., 2015). Meme X-ışını tüpü ile algılayıcı arasına konularak, oluşan sinyaller bir işlemciye gönderilerek sayısal mamogram oluşur. Sayısal bir mamogramın temel yapısı Şekil 2.2’de görülmektedir (Berg ve ark., 2006).




Şekil 2.2. Sayısal mamografi cihazı yapısı

Bu görüntülemelerde meme bir X-ışını tüpü ve algılayıcı arasına mümkün olduğunca ince bir forma sokularak görüntüleme işlemi gerçekleştirilir. Meme dokusu plaketer yardımcıyla iki yandan sıkıştırılarak daha ince duruma getirilmesi ile görüntünün daha net olması sağlanmaktadır (Memiş, 2002; Akbay, 2015).

Meme tek olarak, iki meme arasından ve görüntüsü çekilen memenin dış kenarından sıkıştırılarak mediolateral oblik (MLO) ve/veya yukarıdan aşağıya sıkıştırılarak

kraniokaudal (CC), olarak görüntülenir (Avdan Aslan, 2013; Akbay, 2015). Mamografi görüntüleme teknikleri Şekil 2.3'te görülmektedir (Fajardo ve Yang, 2016).




Şekil 2.3. MLO ve CC tekniği ile mamografi çekiminin gösterimi

Şekil 2.3'te MLO ve CC çekimlerde memenin sıkıştırıldığı yönler gösterilmiştir (Fajardo ve Yang, 2016). MLO görüntüleme tekniğinde meme pektoral kasta itilerek alındığından CC tekniği ile yakalanamayan anormallikleri görüntüleyebilir. Memedeki anormallikler MLO tekniğinde meme ucunun aşağısında veya yukarısında, CC tekniğinde ise iç ya da dış yanda olarak etiketlenebilir.


Örnek olarak Mamografi Görüntüleme Sayısal Veri Tabanı (DDSM) A\_1517 numaralı hastanın MLO ve CC mamografi görüntüleri Şekil 2.4'te gösterilmektedir. MLO mamografisi, yandan çekim yapıldığı için pektoral kas ve meme dokusunu içerirken, CC mamografide sadece memenin üstten görüntüsü görülmektedir.





Sol MLO

Sağ MLO



Sol CC

Sağ CC

Şekil 2.4. MLO ve CC mamografi görüntüleri

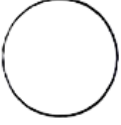




Sayısal mamografilerde meme dokusunun olmadığı arka plan mümkün olan en alt yeğlilik değerini alır. Genelde bu değer sıfırdır. Meme dokusu ise yağ ve deri gibi yumuşak alanlarda ortalama bir değer alırken, kist, kas, süt kanalı gibi alanlarda daha yüksek yeğlilik değeri alırlar. Örneğin 8 bit çözünürlük derinliği olan bir görüntüde yeğlilik değerleri 0 ila 255 arasında, 16 bit derinlikte ise 0 ila 65535 arasında değişmektedir. Bu yeğlilik değerlerine göre meme içerisinde kist, kalsifikasyon ve asimetri gibi anomaliler olup olmadığı anlaşılmaktadır.

### 2.3. Meme Yapısındaki Anomaliler

Meme yapısında yağ dokusu, süt lobülleri ve süt kanalları gibi yapılar dışında görülen normal olmayan yapılardır. Kitle, mimari distorsiyon, asimetri ve kalsifikasyonlar olarak farklı yapıda anomaliler bulunabilir (Oral, 2011; Zonderland ve Smithuis, 2014).

Kitleler meme içerisinde 3-boyutlu yer kaplayan lezyonlardır (Zonderland ve Smithuis, 2014). Boyutları ve şekilleri farklılık gösterebilir. Şekil olarak yuvarlak, oval, lobüllü veya düzensiz olabilir (Çizelge 2.1).



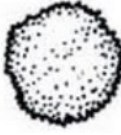

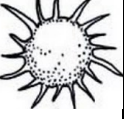
Çizelge 2.1. Memede görülen kitlelerin şekil yapısı olarak sınıflandırılması ve mimari distorsiyon

				
Yuvarlak	Oval	Lobüllü	Düzensiz	Mimari Distorsiyon

Mimari distorsiyon ise meme görüntüsünde bir kitle olmadığı halde bir noktadan yayılan ince çizgiler, belli bir odakta toplanmışlık veya parankima sınırlarını bozma gibi durumlarla kendini belli eder. Eğer memede belli bir yaralanma veya ameliyat geçmişi yoksa şüpheli bir bulgudur (Campos ve ark., 2013).

Memedeki 3-boyutlu kitleler şeklin kenar yapısına göre de gruplara ayrılır; kenar şekli tam olarak belirli olan kitleler (bunlar genel olarak iyi huylu olarak değerlendirilir), tamamen ya da kısmi olarak memedeki başka lifli dokular arkasında kalan gizli kitleler, mikrolobüllü kitleler, tam olarak kenar yapısı belirli olmayana kitleler ve iğne şeklinde çıkıntılı olan spiküle kitleler. Genel olarak, gizli, mikrolobüllü ve spiküle kitleler kanser şüphesi içeren kitleler olarak değerlendirilir (Zonderland ve Smithuis, 2014). Bu yapılara ait şekilsel gösterimler Çizelge 2.2’de görülmektedir (Fischer ve ark., 2007; Zonderland ve Smithuis, 2014).

Çizelge 2.2. Memede görülen kitlelerin sınır yapısı

İyi Huylu			Şüpheli	
				
Düzenli Sınırlı	Bir kenarı gizli	Mikrolobüllü	Gizli kenarlı	Spiküle

Asimetri ise kitlelerden farklı olarak meme yapısında 3 boyutlu olduğu kanıtlanmayan 2 ya da tek boyutta varlığı olan yapılardır. Asimetri söz konusu olduğunda belirgin bir kitle yoktur. Bir memede var olan lifli doku diğer memede yoktur. Asimetri genelde çevresindeki meme dokularını içe doğru çeken bir yapı göstermektedir (Zonderland ve Smithuis, 2014).

Kalsifikasyonlar ise memede bulunan çok küçük ölçekli kalsiyum birikintileridir. Bir sonraki başlıkta daha detaylı açıklanmıştır.

Meme lezyonları, hiçbir görüntüleme tekniği ile biyopsi gibi bir laboratuvar tetkiki yapılmadan kesin kanser teşhisinde bulunulamaz. Ancak, Amerikan Radyoloji Koleji Meme Görüntüleme, Raporlandırma ve Veri Sistemi (BI-RADS) meme lezyonlarının şekillerine, sınırlarına ve dağılımlarına bağlı olarak, genellikle iyi huylu ve kötü huylu olasılığı olduğu yönünde bir sınıflandırma yapmıştır. BI-RADS'e göre meme lezyonları 6 grupta gruplanmıştır ve bunlar Çizelge 2.3'ten görülebilir (Gülsün ve ark., 2002; Oral, 2011; Avdan Aslan, 2013; Akbay, 2015).

Çizelge 2.3. BI-RADS sınıfları

BI-RADS-0	Ek tetkik gerektirenler (Tetkikin tekrarlanması ya da eski verilerin düzenlenmesi gerekenler grubudur)
BI-RADS-1	Normal mamografi (Bulunan tüm veri setlerinin normal meme yapısına ait olduğu grubudur)
BI-RADS-2	İyi huylu bulgular (Memede lezyonlar mevcuttur ve bunlar meme yapısında doğal lezyonlardır)
BI-RADS-3	Büyük olasılıkla iyi huylu bulgular (Memede bulunan lezyonlardır ve büyük bir olasılıkla iyi huyludur)
BI-RADS-4	Şüpheli bulgular (Bulunan lezyonlar iyi huylu arasında sınıflandırılmamış grubudur. Biyopsi gereklidir)
BI-RADS-5	Büyük olasılıkla kötü huylu bulgular (Biyopsi gereklidir)
BI-RADS-6	Kötü huylu bulgular (Biyopsi sonucu kötü huylu olduğu anlaşılan lezyonlardır)

BI-RADS kategorilerine göre, daha önce bahsedildiği gibi sınır kenarları tam belli kitleler büyük olasılıkla iyi huylu iken, sınır kenarları kısmen gizlenmiş olan kitleler şüpheli, spiküle kitleler ise büyük olasılıkla kötü huyludur (Gülsün ve ark., 2002; Avdan Aslan, 2013). Benzer şekilde BI-RADS kalsifikasyonları da şekilsel, büyüklük, kümeleşme, dağılım olarak gruplara ayırmıştır. Bunlar ileriki bölümde anlatılmıştır.

### 2.3.1. Mikrokalsifikasyonlar





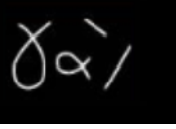






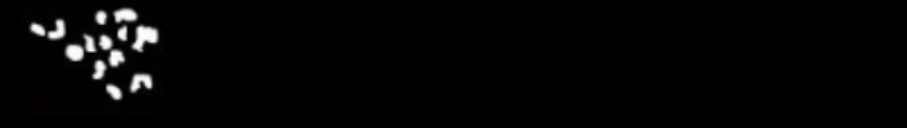
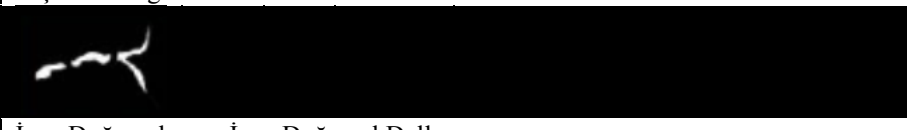
Meme yapısında 15-18 tane lob, her lobda 20-40 tane lobül bulunmaktadır. Her lobülde ise 10 ila 100 kadar alveol bulunmaktadır (Smithuis ve Pijnappel, 2008). Alveoller süt havuzcukları gibi görev yaparak oluşturulan sütü süt kanalları aracılığıyla meme ucuna iletirler. Bu yapılar süt ile ilişkili olduğu için kalsiyum birikintisi oluşturabilir. Memede görülen kalsiyum birikimleri kalsifikasyon olarak adlandırılır (Memiş, 2002; Akbay, 2015). Makrokalsifikasyonlar ve mikrokalsifikasyonlar olarak iki gruba ayrılır: makrokalsifikasyonlar genellikle iyi huylu durumda bulunurlar ve ileri tetkik gerektirmezler. Makrokalsifikasyonlar boyutları 1mm'den büyük olan kalsiyum birikintileridir. Oldukça yaygın olarak 50 yaşın üzerindeki kadınların yarısında bulunur (Oral, 2011). Fakat mikrokalsifikasyonlar, boyutları 100 mikrondan 500 µm - 1 mm'ye kadar olan birikimlerdir ve kötü huylu olma kuşkusunu taşıyabilir, biyopsi gibi ileri tetkik gerektirebilir (Memiş, 2002; Oral, 2011; Abubaker, 2015).

Mikrokalsifikasyonların kötü huylu kitlenin ilk halini yansıttığı düşünülmektedir ve erken teşhis için varlıkları çok önemlidir (Memiş, 2002). Mikrokalsifikasyonlar meme kanseri için belirti veren ilk sinyaller olabilir. Bu boyutlarda lezyonlar hastanın kendi kendine elle muayenesinde veya doktorun elle muayenesinde fark edilemez. Hatta görüntüleme tekniklerinde de bu boyuttaki kireçlenmeleri tespit edebilmek için gelişmiş seviye cihazlara ve tekniklere ihtiyaç duyulmaktadır. Mamografi mikrokalsifikasyonların tespiti için en yaygın kullanılan araçtır.

Mikrokalsifikasyonlar memede birden fazla grup şeklinde bulunabilirler (Memiş, 2002; Oral, 2011; Avdan Aslan, 2013; Akbay, 2015). BI-RADS sisteminde mikrokalsifikasyonlar şekillerine, renklerine, dağılımlarına ve boyutlarına göre muhtemel iyi huylu, şüpheli ve muhtemel kötü huylu olarak gruplanırlar (Gülsün ve ark., 2002; Oral, 2011; Avdan Aslan, 2013). Cilt kalsifikasyonları, patlamış mısır görünümlü kalsifikasyonlar, damar kalsifikasyonları, kalın çubuk şeklinde kalsifikasyonlar, yuvarlak, halkasal veya yumurta kabuğu görünümlü kalsifikasyonlar ve kalsiyum sütü kalsifikasyonları iyi huylu kalsifikasyonlardır. Şekli belirsiz kalsifikasyonlar şüpheli gruptadır. Heterojen, düzensiz veya ince düz damarlanan kalsifikasyonlar ise kötü huylu

olması muhtemel kalsifikasyonlardır (Avdan Aslan, 2013). Mikrokalsifikasyonların şekilsel gösterimi Çizelge 2.4'te gösterilmektedir (Campos ve ark., 2013).


Çizelge 2.4. Kalsifikasyon Şekilleri BI-RADS sınıflandırması

BI-RADS II Muhtemel İyi Huylu					
	Yumurta Kabuğu	Şeffaf Merkezli	Patlamış Mısır	Damarlı	Sütür
BI-RADS II Muhtemel İyi Huylu					
	Kalın Çubuk	Distrofik	Süt Kalsiyumu	Cilt Tipi	Yuvarlak
BI-RADS III Şüpheli					
	Yuvarlak ve noktasal				
BI-RADS IV Şüpheli					
	Biçimsiz Dağınık				
BI-RADS V Yüksek Şüpheli					
	İnce Doğrusal veya İnce Doğrusal Dallanan				

Mikrokalsifikasyonların şekillerinin değerlendirilmesi yanında memedeki dağılımları da iyi huylu- kötü huylu ayrımı yapmakta değerlendirmeye alınmaktadır. Bazı dağılım türleri mikrokalsifikasyonların iyi huylu olduğunu düşündürmekteyken bazı dağılımlar için kötü huylu şüphesi yapılabilir (Smithuis ve Pijnappel, 2008).

Mikrokalsifikasyonların dağılım türlerine göre özeti Çizelge 2.5'te görülmektedir. Dağınık mikrokalsifikasyonlar memenin geneline yayılarak seyrek dağılım göstermektedir. Bölgesel mikrokalsifikasyonlar memenin belirli bir bölümünde bulunan ve genellikle 2 cm<sup>3</sup>'den daha büyük bir bölgeye yayılmış durumdaki mikrokalsifikasyonlardır (Smithuis ve Pijnappel, 2008).

Çizelge 2.5. Mikrokalsifikasyonların dağılım türleri




Kümelenmiş mikrokalsifikasyonlar en az 5 adet mikrokalsifikasyonun 1 cm<sup>2</sup> içerisinde gruplaşmasıyla oluşmaktadır. Doğrusal mikrokalsifikasyonlar, mikrokalsifikasyonların doğrusal bir şekilde kümelenmesidir ve bu tip dağılımın genelde süt kanallarında olduğu düşünülmektedir. Segmental dağılımda mikrokalsifikasyonların memenin bir bölümünde veya bir lobülde oluşarak süt kanallarına ve dallarına yayılmasıyla oluşmaktadır (Zonderland ve Smithuis, 2014).

Dağılımlarına göre dağınık ve bölgesel mikrokalsifikasyonların iyi huylu olduğu düşünülmektedir. Küme mikrokalsifikasyonlar kötü huylu şüphesi taşımaktadırlar. Doğrusal ve segmental mikrokalsifikasyonlar ise genelde kötü huylu olarak değerlendirilir ve ileri tetkikleri bu doğrultuda gerçekleştirilir (Smithuis ve Pijnappel, 2008).


Mikrokalsifikasyonların mümkün olan en erken aşamada tespitleri önemlidir. Zaman geçtikçe mikrokalsifikasyonların boyut, nicelik ve dağılım olarak değişmesi kişiden kişiye yani var olan mikrokalsifikasyon özelliğine göre değişmektedir. Matsunaga ve arkadaşlarının 1998 yılında gerçekleştirdiği bir çalışmaya göre mikrokalsifikasyonların zamanla değişimleri, mikrokalsifikasyonların patolojik olarak özelliklerine bağlıdır. Özellikle komedo tipi mikrokalsifikasyonlar (bunlar kalın duvarları olan ve içerisinde tümörlü dokunun dışarı çıkabildiği yapılardır), zaman içerisinde çok hızlı büyüme ve yayılma yaşarlar. Komedo olmayan mikrokalsifikasyonlar genellikle zamanla büyük ve ani bir değişim göstermezler. Ancak mikrokalsifikasyon sayısı 2 ila 5 olan komedo

olmayan mikrokalsifikasyonlar da hızlı büyüme eğilimindedir (Matsunaga ve ark., 1998). Örnek olarak Şekil 2.5'te bir hastaya ait mikrokalsifikasyon kümesinin zamanla değişimi verilmiştir (Smithuis ve Pijnappel, 2008).



Şekil 2.5. Bir komedo tipi mikrokalsifikasyon kümesinin mamogram görüntüsü. Ortada, soldaki kümenin 36 hafta sonraki, sağda ise ortadaki kümenin 31 hafta sonra çekilmiş mamogram görüntüsü.

Benzer şekilde Şekil 2.6'da 4 yıl arayla çekilmiş iki yumurta kabuğu şeklinde mikrokalsifikasyon görülmektedir.



Şekil 2.6. Dört yıl arayla çekilmiş yumurta kabuğu mikrokalsifikasyonun mamogramı

Görüldüğü gibi mikrokalsifikasyonlar geçen yıllar içinde hızlı ya da yavaş bir şekilde büyüebilmektedir. Bu büyüme mikrokalsifikasyonun patolojik yapısıyla ilişkidir. Her koşulda mikrokalsifikasyonların mümkün olan en erken aşamada görüntülenmesi şekil, renk, sayı ve dağılım bakımından incelenmeleri gerekmektedir. Bu inceleme için uzman hekimlere yardımcı olabilecek bilgisayar uygulamaları kullanmak oldukça yaygın bir yaklaşımdır. CAD konusuna ilişkin detaylar bir sonraki bölümde anlatılmıştır.

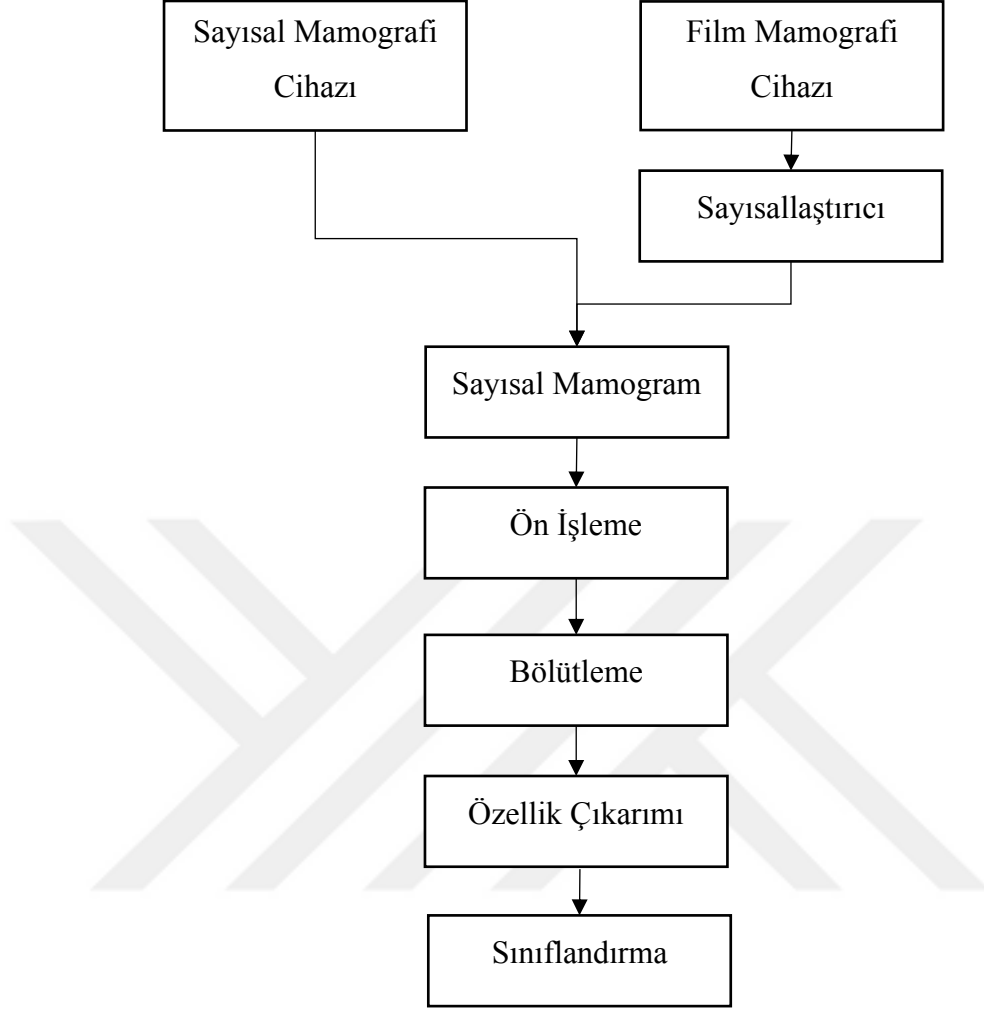


## 2.4. Bilgisayar Destekli Teşhis

Bilgisayar destekli tespit (CAdE) ve bilgisayar destekli teşhis (CAdx) tıbbi değerlendirmelerin hatasız ve hızlı yapılabilmesi için uzmanlara yardımcı olması amacıyla bilgisayar teknolojilerinin kullanılmasıdır (Tang ve ark., 2009; Oral, 2011; Dheeba ve Selvi, 2012; Guo ve ark., 2016; Abubaker, 2017; Shi ve ark., 2018). Medikal alanda birçok hastalığın incelenmesinde kullanılmaktadır. Meme kanseri de bu alanlardan biridir. Meme kanserinde, meme içerisindeki tümörleri, kalsifikasyonları, asimetrik bozuklukları ve benzerlerini bulmaya odaklı sistemler mevcuttur. CAdE bulunduğu anomaliyi işaretleyerek dikkati bölgeye çekerken, CAdx anomalinin olası türünü önermektedir. Her iki yöntemde de radyologların mamografiyi doğru yorumlaması için yardımcı olmak hedeflenmiştir. Genel olarak bir bilgisayar destekli tespit-teşhis (CAd) sisteminde ön-işleme, işleme ve değerlendirme aşamaları bulunmaktadır.

Bir CAd sisteminde öncelikle sayısal mamografiye ihtiyaç duyulmaktadır. Günümüzde çoğu mamografi cihazı sayısal ortamda görüntüyü hazırlar, film mamografi cihazlarında ise veriler sayısallaştırıcı bir birim tarafından sayısalaya dönüştürülür. Sayısal mamografiler bir ön-işlemeden geçirilir. Ön-işleme yapmanın amacı mamografiyi incelerken olası yanlış yönlendirmenin önüne geçmektir. Bunun için gürültü filtreleme, görüntüyü iyileştirme, kontrastı ayarlama ve/veya istenmeyen etiket, yazı, numara gibi verilerin silinmesi gibi işlemler gerçekleştirilmektedir.

İşleme adımında üzerinde çalışılmak istenen veriye uygun bilgisayar teknikleri uygulanır. Bu adımda segmentasyon yapılarak incelenmek veya işlenmek istenen alan kırpılır, ayrıştırılır ya da öne çıkarılır. Segmentasyondan sonra özellik çıkarımı yapılarak hangi özelliklerin kullanılabilir ve ayrıştırıcı olduğu kararlaştırılır. Çıkarılan özellik kümeleri sınıflandırıcılara girdi olarak verilerek mamografiler sınıflandırılır. Bu sınıflandırma da anomali yeri işaretlenebilir ya da anomali olup olmadığı ve varsa sınıfı belirlenebilir. Genel CAd algoritması Şekil 2.7'de görülmektedir.



Şekil 2.7. Bilgisayar destekli tespit ve teşhis algoritması

Literatürdeki çalışmalar tezin ilgisi itibarıyla kitle ve mikrokalsifikasyon üzerine ikiye ayrılmıştır. Öncelikle kitle ile ilgili CAD sistemleri anlatılacaktır.

## 2.5. Literatür Özeti

Sahiner ve ark. (1996), uzamsal bölgede dokusal özellikleri kullanarak konvolüsyonel sinir ağları (CNN) ile mamogram kesitlerini normal ve kitleli şekilde sınıflandırmıştır. Sonuçları alıcı işlem karakteristiği (ROC) kullanarak değerlendirmiş ve %90 TP ve %31 FP oranı elde etmiştir (Sahiner ve ark., 1996).

Hupse ve Karssemeijer (2009), farklı tekniklerle çekilmiş mamografilerde kitlelere etiketlenen FP oranını düşürmek amaçlı bir karşılaştırmalı çalışma gerçekleştirmiştir. Mamografi görüntülerinin pektoral kasi iyileştirerek bir önışlemeden geçirilmiş sonrasında yapay sinir ağı (ANN) ile tümör içerebilecek alanı tespit edilmiştir. Sonra, bölütleme edilen alanlar bir başka ANN ile sınıflandırılmıştır. Bu çalışmaya göre karşılaştırmalı olmayan CAD sistemine göre, FP oranında %6 oranında iyileşme sağlanmıştır (Hupse ve Karssemeijer, 2009).

Mencanetti ve arkadaşlarının (2010), sundukları CAD sisteminde, mamografi görüntüleri ışık-alan temelli alan büyütme algoritması ile kırılmıştır. 25 adet özellik çıkarımı yapılarak, çıkarılan özellikler el ile seçilmiştir. Naïve Bayes (NB) sınıflandırıcı sonucunda ortalama ROC eğrisinin altında kalan alan yani TCC oranı %88.38 olarak belirtilmiştir (Mencattini ve ark., 2010).

Elmoufidi ve arkadaşları (2018), DDSM veri tabanından alınan MLO ve CC (aynı vakaya ait) ve MIAS veri tabanından alınan MLO görüntülenmiş mamogramlar kullanmıştır. Sistem öncelikle potansiyel şüpheli bölgeleri tespit ederek oluşturdukları ROI'lerden dokusal özellikleri ve sınıflandırıcıları kullanılarak iyi huylu veya kötü huylu olarak etiketlenmiştir. Bu çalışmaya göre, DDSM veri tabanından alınan 500 örnekte duyarlılık %95.6 ve MIAS veri tabanından alınan 115 görüntüde %94.78 olarak verilmiştir (Elmoufidi ve ark., 2018).

Literatürde kitleler üzerine olduğu gibi asimetri, kalsifikasyon gibi diğer spesifik özelliklere yönelik de çalışmalar bulunmaktadır (Sahiner ve ark., 1996; Hupse ve Karssemeijer, 2009; Mencattini ve ark., 2010; Elmoufidi ve ark., 2018). Bu çalışmalardan birçoğu meme kanserinin ilk belirtisi olduğu kabul edilen mikrokalsifikasyonlara odaklanmıştır. Mikrokalsifikasyonlara yönelik CAD sistemlerine aşağıda değinilmiştir.

Shen ve arkadaşları (1994), bölge büyütme işlemi ile mikrokalsifikasyonların biçimini belirlemeye çalışmışlardır. Burada tohum pikseli olarak seçilen bir piksel etrafında kendi belirledikleri şartlarla komşuluk ilişkilerine bakılmış, tohum pikselin etrafında komşu kalmayınca kadar işlem tekrarlanmıştır; böylelikle, mikrokalsifikasyonun şekli ortaya

çıkarılıp iyi huylu ya da kötü huylu olduğu bulunmuştur. Mikrokalsifikasyonun kontör olarak şekli bulunduktan sonra bu şekil elips, kare, yıldız gibi birkaç değişik grupta yoğunluk, moment, Fourier dönüşümü gibi yöntemlerle değerleri bulunarak gruplanmıştır. Bu gruplanmalar sonucu mikrokalsifikasyon grubunun iyi huyu-kötü huylu olma oranı %100'e kadar ulaşmıştır (Shen ve ark., 1994)

Kim ve arkadaşları (1997), lezyonu çevreleyen alana bağlı bir yöntem geliştirmiştir. Bu yöntemle, belirlenen bir ilgili alana bağlı bölgelerin, mikrokalsifikasyon içeren bölge ve içermeyen bölge olarak ayrımı yapılarak, dağılım matrisleri bulunmaktadır. Mikrokalsifikasyon belirlenmesi için geri-yayımlı MLPNN algoritması kullanılarak gizli mikrokalsifikasyonların bulunması sağlanmıştır. Dağılım matrislerinin çeşitli özellik çıkarım yöntemleriyle mikrokalsifikasyon içeren ve içermeyen bölgelerin özellikleri belirlenmesi ve mikrokalsifikasyon içeren bölgelere eşik uygulaması yapılarak kireçlenmelerin görünmesi sağlanmıştır. Yöntemin %90'na varan bir duyarlılığı olduğu belirtilmektedir (Kim ve Park, 1999).

Yu ve Guan (2000), Nijmegen veri tabanından alınan 40 mamografiyi 128×128 piksel boyutuna kırparak dalgacık özelliklerini ve gri-seviye istatistiksel özellikleri kullanarak potansiyel mikrokalsifikasyonları bulmaya yönelik çalışmıştır. Bulunan özellikleri aralıklı geri yönlü seçme, aralıklı ileri yönlü seçme ve genel regresyon sinir ağı kullanılarak seçtikten sonra ileri-yayımlı MPLNN ve ileri yönlü olasılık yöntemleri ile sınıflandırılmasını sağlamışlardır. Serbest-yanıt ROC değerlendirmesine önerilen algoritma %90 TP ve imge başına 0.5 FP değeri sunmaktadır (Yu ve Guan, 2000).

Soltanian-Zadeh ve arkadaşları (2004), birden farklı yöntemle mikrokalsifikasyonların tespiti ve sınıflandırılabilirliği üzerinde çalışmışlardır. Bu amaç için 4 farklı yöntemle görüntü iyileştirme yapılarak, genetik algoritmalar ile özellik seçimi çıkarılarak kNN sınıflandırıcı modeli ile mikrokalsifikasyon kümeleri üzerine sınıflandırma yapılmıştır. 0.89'lük ROC değeri ile çoklu-dalgacık dönüşümünün diğerlerinden daha iyi sonuç verdiği belirtilmiştir (Soltanian-Zadeh ve ark., 2004).

Fu ve arkadaşları (2005) mamografiler üzerinde mikrokalsifikasyonları sınıflandırmak için bir çalışma gerçekleştirmiştir. Özellik çıkarımı morfolojik işlemlerle ve ileri sıralı seçim ile gerçekleştirilmiş, seçilen özellikleri genel yayılım ANN ve SVM ile sınıflandırılmıştır. Çıkan sonuçlara göre ileri sıralı seçim ile seçilen özelliklerin SVM ile sınıflandırılması sonucu ROC tablosuna göre %98 oranında başarı elde etmiştir (Fu ve ark., 2005).

Diaz ve arkadaşları (2014), tarafından yürütülen bir çalışmada morfolojik işlemler ve eşik yöntemleriyle Mini-MIAS veri tabanından alınan mamografiler mikrokalsifikasyon türlerine göre sınıflandırılmıştır. Sınıflandırıcı olarak SVM kullanılmış, mamografiler yağlı, glandüler ve sert olarak gruplara ayrılmıştır. Sınıflandırma başarısı yağlı meme için %88.7 ve glandüler meme için %84'tür. Buna göre 3 tür mamografi için ortalama duyarlılık %85.9'dur (Diaz-Huerta ve ark., 2014).

Mohamed ve arkadaşları (2014), Mini-MIAS veri tabanından alınan mamografiler üzerinde histogram eşitleme, morfolojik işlemler ve eşik yöntemleriyle çalışmıştır. Çalışmada mikrokalsifikasyonlar varlığına ve türlerine göre farklı sınıflandırıcılar ile sınıflandırılmıştır. Çalışmaya göre, MLPNN ile normal ve anormal mamogramlar %100, kNN ile %68 ve SVM ile %70 oranında doğrulukla sınıflandırma yapılmıştır. Mikrokalsifikasyon türlerine göre sınıflandırma da ise değerler KNN ve SVM ile aynıdır fakat MLPNN ile %71'e düşmüştür (Mohamed ve ark., 2014).

Andreadis ve arkadaşları (2015), mamografilerde mikrokalsifikasyon kümelerinin yer/konum tespiti ile sınıflandırılması üzerine bir çalışma yapmıştır. DDSM veri tabanından alınan 1715 mamogram kesitinde mikrokalsifikasyon kümeleri bölütlenerek, bu kümelerden 188 farklı özellik çıkarımı gerçekleştirilmiştir. Bu özellikler kümelerin şekil ve morfolojik özellikleriyle beraber, kümeyi çevreleyen meme dokusunun dokusal özelliklerinin birleşimidir. Özellik sayısının fazla olması sebebiyle ardaşıl ileri yönlü özellik seçim yöntemi kullanılarak özellik seçimi yapılmıştır. Bu özellikler aralarında SVM, kNN ve ANN de bulunan 6 farklı sınıflandırıcı ve farklı parametreler kullanarak toplamda 10 farklı sınıflandırma gerçekleştirilmiştir. Bu sınıflandırmada, bir risk değeri saptanmıştır. Ayrıca, çalışmada mikrokalsifikasyonu içeren bölgenin konumu itibarıyla


bir başka risk değeri hesaplanır. Hesaplanan iki risk değeri kullanılarak nihai risk faktörü hesaplanmıştır. Radyoloji uzmanlarıyla aynı mamografiler incelenmiş ve radyologların mikrokalsifikasyonları etiketleme doğruluk oranı %51.4 iken sunulan CAD sistemi bu oranı %69'a çıkarmıştır (Andreadis ve ark., 2015).

Abdul ve arkadaşları (2017), tarafından yürütülen bir çalışmada görüntüleme önce gürültü temizleme uygulanmıştır. Sonrasında ise Canny kenar bulma algoritması ile mikrokalsifikasyon içeren kesitler elde edilmiş ve yazarlar tarafından önerilen yaklaşım ile mikrokalsifikasyonların görünürlüğü artırılmıştır. Sınıflandırma aşamasında Derin-ANN kullanılmış ve mikrokalsifikasyonların iyi huylu ve kötü huylu olma durumları %95.6 doğrulukla sınıflandırılmıştır (Abdul ve ark., 2017)

Bria ve arkadaşları (2018), mamogramlardaki mikrokalsifikasyonları bulmaya yönelik bir gerçekleştirdikleri bir çalışmada, mamogramlarda bulunan gürültülerin temizlenmesinin mikrokalsifikasyonları bulmada önemli bir rol oynadığını savunulmuştur. Bu gürültüler, cihazın algılayıcı hassasiyetinden doğan yapısal gürültü, X-ışını görüntüleme tekniklerinde var olan kuantum gürültüsü ve elektronik gürültü olarak belirtilmiştir. Bu gürültüler uyarlanmış gürültü varyans sabitleme tekniği kullanılarak modellenmiştir. 3 farklı veri setinden alınan mamogramlarla binlerce mikrokalsifikasyonlu ve milyonlarca normal, 1 mm × 1 mm boyutundaki kesitlerle kaskat, ANN, SVM ve DoG modeller ile sınıflandırma yapılmış ve uyarlanmış varyans sabitleme tekniğinin uyarlanmış olmayana göre sınıflandırma başarısı üzerine %0.8 ila %4.5 arasında iyileştirme yaptığı görülmüştür (Bria ve ark., 2018).

### 3. MATERYAL ve YÖNTEM

Bu bölümde meme kanserinin en erken belirtisi olarak kabul edilen mikrokalsifikasyonların görünürlüğünün iyileştirilmesi için tasarlanan uzamsal filtreye ve CAD sistemine ilişkin adımlar ve her adıma ait detaylar verilmiştir. Şekil 3.1’de tasarlanan sistemin öbek gösterimi görülmektedir.




Şekil 3.1. Tasarlanan sistemin öbek gösterimi

Tez çalışmasında önerilen CAD sisteminde öncelikle veri tabanından alınan mamografiler kesitler şeklinde hazırlanmış, her bir kesit 5 farklı filtre ile filtelenmiştir. Filtreli ve orijinal ROI'ler üzerlerinde kontrast germe uygulanarak özellik çıkarımı yapılmıştır. Özellikler SVM, MLPNN ve LDA temelli sınıflandırıcılar ile sınıflandırılmış ve başarı sonuçları ROC analizi ile değerlendirilmiştir.

### 3.1. Veri Tabanı

Meme kanserine yönelik bir veri tabanında, mamografi de bulunan anomaliye kesin olarak iyi huylu veya kötü huylu teşhisi konulması için biyopsi gerekmektedir (Heath ve ark., 2001). Veri tabanlarında bulunan bilgiler çoğu zaman en az 2 uzman radyolog tarafından tespit edilen anomali sınıflandırmasını ve biyopsi sonucunu içermektedir. Tez çalışmasında kullanılan iki önemli veri tabanına ait detaylar aşağıda verilmektedir.

Mamografik Görüntü Analiz Derneği Sayısal Mamogram Veri Tabanı (MIAS) tüm vakalara ait meme beze yapısı (yağlı-sert-glandüler), meme durumu (normal-kalsifikasyon-düzgün hatlı kitle-iğne uçlu kitle-mimari distorsiyon-asimetri) ve varsa anomalinin türü (iyi huylu-kötü huylu) ve merkez koordinatı ile çapı bilgilerini vermektedir (Suckling ve ark., 1994). Şekil 3.2'de MIAS veri tabanına ilişkin bilgi satırı gösterilmektedir.



Şekil 3.2. MIAS veri tabanı bilgi satırı

İçerisinde 161 hastaya ait, her hasta için bir sağ MLO ve bir sol MLO olmak üzere toplam 322 vaka bulunmaktadır. Bu vakalardan 113'ü anomali içeren mamografileri 209'u normal mamografileri içermektedir. Çizelge 3.1'de detaylı dağılım verilmektedir.




Çizelge 3.1. MIAS veri tabanı mamografi dağılımı

	Mimari Distorsiyon	Asimetri	Kalsifikasyon	Kitle	İğne Uçlu Kitle	Diğer	Toplam Anomali	Normal	Toplam
İyi Huylu	9	6	13	20	11	7	120*	209	322
Kötü Huylu	10	9	15	4	8	8			
Toplam	19	15	28	24	19	15			

(\*bazı mamografilerden birden fazla anomali olduğu için toplam anomali sayısı fazladır)


MIAS veri tabanında mamografiler 50 mikron piksel boyutunda sayısallaştırılmış, sonrasında veri tabanı oluşumunda piksel boyutu 200 mikrona düşürülüp meme mamografinin ortasında olacak şekilde doldurma yapılarak mamografinin boyutu 102×1024 piksele sabitlenmiştir. Böylelikle piksel derinliği 8-bit olan mamografiler için bir standart oluşturulmuştur. Şekil 3.3 örnek MIAS mamografilerini göstermektedir.



Şekil 3.3. Örnek MIAS mamogramları

MIAS veri tabanında var olan mamografiler “.pgm” uzantısında olduğu için doğrudan indirilip bilgisayar programında kullanılabilir. Her bir mamografi boyutu 1024×1024 piksel olduğu için bu veri tabanını kullanmak hızlı ve kolaydır ve bu yüzden tasarlanan sistem ilk olarak MIAS veri tabanından alınan mamogramlar ile denenmiştir, ancak mikrokalsifikasyon içeren mamografilerin az olmasından dolayı çalışmada başka bir veri seti kullanılmıştır.

Literatürde MIAS veri tabanı kadar sıklıkla kullanılan diğer bir veri tabanı DDSM veri tabanıdır (Chen ve ark., 2015; Suhail ve ark., 2015; Rabidas ve ark., 2016). Bu veri tabanı Güney Florida Üniversitesi tarafından kullanıma sunulmuştur. Bu veri tabanında toplamda 43 ayrı grupta 2620 vaka bilgisi yer almaktadır. Her bir vakada sağ MLO, sol MLO, sağ CC, sol CC mamografiler ve vakaya ait bilgilerin bulunduğu bir bilgi dosyası bulunmaktadır. Bu bilgi dosyasında vakanın yaşı, mamografi tarihi meme yoğunluğu ve mamografi boyutu gibi bilgiler verilmiştir. Anomali içeren mamografilerde ek bilgi dosyası vardır ve bu dosyada mamografide hangi anomalinin bulunduğu, türü ve boyutu bulunmaktadır. Ayrıca koordinat bilgisi işaretlenmiştir (Heath ve ark., 2001). Örnek mamografi görüntüleri Şekil 3.4’te gösterilmektedir.



Şekil 3.4. Örnek DDSM mamografi görüntüleri

DDSM veri tabanında mamografiye ait anomali işaretlenmiş ve bilgi dosyasında detayları belirtilmiştir. DDSM veri tabanı MIAS veri tabanından farklı olarak anomalinin merkez koordinatları ve çapı yerine, anomali koordinatlarını zincir kod ile verilmiştir. Zincir kodun temel gösterimi Şekil 3.5'te ve örnek zincir kod uygulaması Şekil 3.6'da gösterilmektedir.

7↖	↑ <sup>0</sup>	↗ <sup>1</sup>
6←	X	→ <sup>2</sup>
5↙	4↓	↘ <sup>3</sup>

Şekil 3.5. Zincir kod koordinatları

Örnek olarak X noktasının koordinatları X1, Y1 şeklinde verilmekte ve zincir kod 2 2 5 3 3 0 1 1 6 0 6 4 # olarak belirtilmektedir. Her bir rakam kendisinden bir sonraki pikselin koordinatlarını vermektedir ve # bitiş bitidir.

	↓	←		
	X	↑	←	↗
↙			↗	
	↘	↑		
		↘		

Şekil 3.6. Örnek zincir kod uygulaması

DDSM veri tabanında bulunan mamografilerin bit derinliği 12-16 bit ve çözünürlüğü 42.5, 43 ya da 50 mikrondur. Mamografi boyutları da her hastaya göre değişmekle birlikte 6000×5000 piksel gibi oldukça büyük boyutlara ulaşabilmektedir (Heath ve ark., 2001). Büyük boyutlarından dolayı DDSM veri tabanından alınan tam boyutlu mamografi imgelerinin sayısal görüntü işleme teknikleriyle işlenmesi uzun süreler gerektirmektedir. Bu yüzden tez çalışmamızda DDSM veri tabanından alınan mamografi imgeleri çalışmanın ilgilendiği alanlara kırılarak gerçekleştirilmiştir.

### 3.2. Önışleme


Görüntü işlemede bir görüntünün bilgisayar programında daha doğru okuması için yapılan işlemlere ön işleme denir (Hupse ve Karssemeijer, 2009). Ön işleme işlemleri gürültü filtreleme ve/veya yeğlilik değerlerini değiştirme gibi bir şekilde yapılabilir. Yeğlilik bir görüntüde bir pikselin sahip olduğu sayı değeridir. Derinliği 8-bit olan bir gri-seviye görüntüde yeğlilik değeri 0 ila  $2^8-1=255$  arasında olabilir. Burada 0 siyah rengi ve 255 ise beyaz rengi temsil eder. Renkli bir görüntüde ise her bir piksel için renk uzayı kırmızı-yeşil-mavi (RGB) yeğlilik değerleri mevcuttur. Görüntü işleme de bu yeğlilik değerleri ile işlem yapılmakta ve piksel değerleri uzamsal düzlemde veya frekans düzleminde yeniden hesaplanarak görüntü üzerinde değişiklik yapılmaktadır (Gonzalez ve Woods, 2014).

Mamografilerde görüntünün bir elektronik sistemle X-ışınlarıyla alınmasından dolayı çeşitli gürültüler oluşabilmektedir. X-ışını tüpünün yapısı, radyasyon yayılımı gibi gürültü kaynaklarının yanında elektronik algılayıcıların piksel boyutuna bağlı bulanıklık, hastanın ölçüm esnasındaki hareketine bağlı bulanıklık gibi sebepler genel olarak istenmeyen veri olarak algılanmaktadır (Lee ve ark., 2018). Bunu yanına bir mamografide takibi ve dosyalamayı kolaylaştırmak amacıyla bulunan etiketlerde gürültü olarak kabul edilmektedir. Mamografilerdeki gürültüler memedeki anomalinin radyolog tarafından gözden kaçırılmasına ya da CAD sistemlerinin mamografiyi yanlış okumasına sebep olmaktadır. Yanlış değerlendirmeler kötü huylu bir veriyi normal kabul edip hayati tehlike oluşturabileceği gibi, iyi huylu bir anomaliye sahip bir hastaya kötü huy teşhisi koyarak hastaya gereksiz stres oluşturmakta, biyopsi ve operasyon gibi zorunlu olmayan tıbbi müdahalelere sebep olabilmektedir (Qian ve ark., 2015). Gürültülü bir mamografide gürültü %21'e kadar hatalı okumaya sebep olmaktadır. Mikrokalsifikasyonlar söz konusu olduğunda bu oran %22'ye kadar çıkmaktadır (Naveed ve ark., 2012).

Her mamogram görüntüsünde, çoğu kuantum gürültüsü tarafından meydana gelen belirsiz ve tahmin edilemeyen gürültü miktarı vardır (Romualdo ve ark., 2009). Kuantum gürültüsü, özellikle mikrokalsifikasyonların mamogramlar üzerindeki görünürlüğünü

etkiler, çünkü mikrokalsifikasyonlar yaklaşık 100  $\mu\text{m}$  ila 500  $\mu\text{m}$  arasında değişen küçük partiküllerdir (Romualdo ve ark., 2009).

Şekil 3.7’de (a) örnek olarak DDSM veri tabanından alınan orijinal bir mamogram, (b)’de Gauss ve Poisson gürültüsü eklenmiş bir mamogram görüntüsü görülmektedir. Şekil 3.7(b)’de gösterilen mamogramda mikrokalsifikasyonları gözle ya da bir bilgisayar yardımıyla bulmak oldukça zordur hatta mümkün olmayabilir. Ancak, Şekil 3.7(a)’da ki mamogram görüntüsü daha net olduğu için anomali tespiti daha kolay ve doğru olacaktır. Bu yüzden, mamografilerde gürültü temizleme oldukça önemlidir (Naveed ve ark., 2012; Qian ve ark., 2015).



Şekil 3.7. (a) Orijinal mamogram (b) Gürültü eklenmiş mamogram

Kumar ve arkadaşları (2016), MIAS veri tabanından alınan 10 mamogram ile bir çalışma gerçekleştirmişlerdir. Görüntüler 128×128 piksel boyutuna kırılmış, bu görüntülere adaptif histogram eşitleme (AHE), medyan filtre, Frost filtre, Butterworth filtre ve dalgacık gürültü temizleme filtresi uygulanmıştır. Her görüntü ortalama kare hata (MSE), tepesinyal-gürültü oranı (PSNR), ortalama yapı benzerlik indeksi (MSSIM), maksimum fark (MD), normalleştirilmiş mutlak hata (NAE) ve yapısal içerik (SC) ile değerlendirilmiştir. Çalışma sonuçlarına göre, en çok tercih edilen filtreler, medyan filtre ve dalgacık gürültü temizleme filtresi olarak belirlenmiştir (Kumar ve ark., 2016).


Vijikala ve arkadaşları (2016), gürültüsüz ve Rician gürültüsü eklenmiş mamogram görüntüleri üzerinde hibrit medyan filtre (HMF), doğrusal minimum ortalama kare hata

(LMMSE) filtresi, yönlendirilmiş Rician gürültü azaltma anizotropik difüzyon (ORNRAD) filtresi, yüksek mertebeli filtre (HOF), yerel olmayan araçlar (NLM) filtresi olmak üzere 5 farklı filtre algoritması kullanarak mamografileri analiz etmişlerdir. Filtrelenen görüntüler MSE, PSNR, gürültü oranı karşılığı (CNR), kalite endeksi (IQI) ve ortalama mutlak hata (MAE) değerleri ile karşılaştırılmıştır. Bu çalışmaya göre, ORNRAD filtre sonuçlarının başarılı olma oranının daha yüksek olduğu belirtilmiştir (Vijikala ve Anto Sahaya Dhas, 2016).

Nagaiah ve arkadaşları (2016), mamogram analizi için en iyi geliştirme yönteminin belirlenmesi amacıyla bir çalışma yürütmüştür. MIAS veri tabanından 30 mamogram görüntüsünü alarak ilk olarak, tuz ve karabiber, Gauss, Speckle ve Poisson gürültüsü eklemiştir. Ardından gürültülü imgelere düşük geçişli filtre, medyan filtre ve bileteral filtre olarak bilinen ters T / F filtresi ile filtreleme işlemi uygulanmış ve sonuçlar MSE ve PSNR değerleri ile değerlendirilmiştir. Ters T / F filtresinin mamografiler üzerinde diğerlerinden daha iyi bir iyileştirme sağladığı gösterilmiştir (Nagaiah ve ark., 2016).

Aydın Yurdusev ve arkadaşlarının (2018) yürüttüğü bir çalışmada ise MIAS veri tabanından alınan görüntü kesitlerine tuz&biber gürültüsü, Gauss gürültüsü ve bu iki gürültü beraber eklenerek medyan filtre, hareketli ortalama filtre (MAF) ve GHP filtre incelenmiş, sonuçlar MSE ve PNSR ile değerlendirilmiştir. Bu çalışmaya göre, tuz&biber gürültüsünde medyan filtre, diğerlerinde ise GHP filtre gürültüyü temizlemede ve aynı zamanda mikrokalsifikasyon görünürlüğünü korumada daha başarılıdır (Aydın Yurdusev ve ark., 2018).


Mamografi görüntülerinde bir diğer gürültü tipi ise istenmeyen bilgilerin varlığıdır. Bunlar görüntüleme aracından kaynaklanan artefak etkileri, veri tabanı oluştururken verilerin standardizasyonu için oluşan gürültüler ve veri takibi yapmak için etiketleme ve benzeri bilgilerin oluşturduğu gürültülerdir. Şekil 3.8'de solda MIAS ve sağda DDSM veri tabanlarına ait mamografi imgeleri görülmektedir.



Şekil 3.8 Mamografi imgelerindeki gürültülerin gösterimi

Bu mamografilerde mavi ile işaretlenmiş alanlar artifak gürültüleri, kırmızı alanlar etiketlemeleri göstermektedir. MIAS veri tabanındaki imgedeki yeşil alanlar ise mamografinin resim olarak 1024×1024 boyutunda ortalanması için üretilen bilgi içermeyen alanı göstermektedir. Bu bilgilere ek olarak MLO tipinde çekilen mamogramlarda pektoral kas da gürültü olarak değerlendirilmektedir. Çünkü pektoral kas memenin geri kalanından çok daha yoğun olduğu için CAD sistemlerinde yanlış yönlendirmeye sebep olabilmektedir. Örneğin bir çalışmada MIAS veri tabanından alınan mamografiler orijinal olarak ve pektoral kas temizlenerek sınıflandırmaya tabi tutulmuş ve pektoral kas temizlenmiş görüntülerin orijinal olanlardan yaklaşık %10 daha yüksek doğruluk oranlarına sahip olduğu görülmüştür (Aydın Yurdusev ve ark., 2018b) Bu yüzden literatürde pektoral kasında temizlendiği bir çok ön-işleme çalışması bulunmaktadır (Sultana ve ark., 2010; Liu ve ark., 2012; Ganesan ve ark., 2013; Li ve ark., 2013; Aydın Yurdusev ve ark., 2018b; Oral ve ark., 2019).

Örnek olarak Şekil 3.9’da bir MIAS veri tabanına ait mamogram görülmektedir (Sultana ve ark., 2010)




Şekil 3.9. Örnek pektoral kas ve gürültü temizlenmiş mamogram

Şekil 3.9'dan görüldüğü gibi, mamogram üzerindeki etiket gürültüleri, artifak gürültüler ve pektoral kas temizlenerek memede sadece yumuşak doku içeren alanlar bırakılmıştır. Bu sayede, CAD sisteminin doğru tespit/teşhis oranının artırılması hedeflenmiştir.

### 3.3. Görüntü İyileştirme

Bir sayısal görüntü piksellere atanmış sayısal değerlerin bir matris olarak temsil edilmesiyle oluşmaktadır. Pikseller bir resimdeki en küçük görüntü elemanıdır. Renkli görüntüler için RGB olmak üzere her bir pikselde 3 farklı değer varken, gri-seviye görüntülerde tek bir değer vardır. Örnek olarak göstermek gerekirse 3x3 piksellik bir görüntünün ( $f$ ) koordinatları  $x$  ve  $y$  cinsinden Şekil 3.10'daki gibi ifade edilmektedir.



Şekil 3.10. 3×3 piksellik bir görüntünün koordinat bilgileri.

Piksel değerleri resmi oluşturan sayısal dizinin uzantısına bağlı olarak değişmektedir. Genellikle tüm sayısal dizinlerde siyah en düşük değerle ifade edilirken, beyaz en yüksek




değerle ifade edilmektedir ve aradaki gri tonları da bu skalada değer almaktadır. Örnek olarak kullanılan farklı tiplerdeki dizin uzantıları için piksel değerleri Çizelge 3.2’de gösterilmektedir.

Çizelge 3.2. Sayısal görüntü dizin uzantıları

Uzantı	Siyah	Beyaz
Double	0.00	1.00
Uin8	0	255
Uin16	0	65535
Int16	-32768	32767

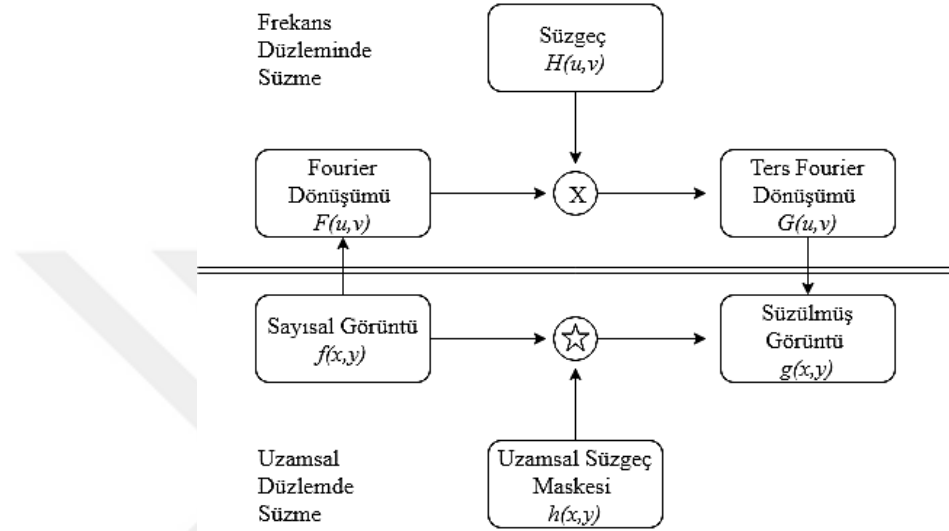
Buna göre örneğin *uint8* uzantısındaki bir görüntüde  $2^8=256$  farklı değişken yani görüntü tonu olacaktır. Benzer şekilde *uint16* uzantısındaki bir sayısal görüntüde  $2^{16}=65536$  adet ton olacaktır. Bu da bit derinliği olarak adlandırılmaktadır. Bir görüntüde bit derinliği ne kadar fazla olursa görüntüde o kadar fazla ton bulunmaktadır. 8-bit derinlikteki bir sayısal görüntünün piksel değerleri Şekil 3.11’de görülmektedir.



Şekil 3.11. 8-bit derinliğinde bir gri-seviye görüntü

Bir sayısal görüntü üzerinde görüntü iyileştirme, görüntü üzerindeki piksel değerleri ile işlemler yapılarak gerçekleştirilir. Görüntü iyileştirmenin temel amacı görüntüye bir takım matematiksel işlemler uygulayarak istenen özellikleri orijinal görüntüden daha belirgin hale getirmektir. Görüntü iyileştirme insan okuyucular için ya da belirli bilgisayar programları için gerçekleştirilmektedir (Bankman, 2000). Bunun için gürültü azaltma, kenar belirleme, kontrast değiştirme gibi birçok farklı teknik vardır. Bu

tekniklerden en yaygın kullanılanlarından biri filtreleme işlemidir. Filtreleme işlemi filtre denilen maskelerin görüntü üzerinde piksel değerlerini değiştirmesiyle gerçekleştirilir ve hem uzamsal düzlemde hem de frekans düzleminde kullanılır (Bankman, 2000; Rangayyan, 2004). Genel olarak görüntü filtreleme işlemi Şekil 3.12’de gösterilmektedir.



Şekil 3.12. Sayısal görüntüyü filtreleme işlemi

Uzamsal düzlemde ve frekans düzleminde filtreleme işlemlerine ait detaylı bilgi bir sonraki bölümde verilmiştir.

### 3.3.1. Uzamsal filtreleme

Uzamsal bir filtreleme, bir sayısal görüntünün belli bir işlem gerçekleştirilmesi amacıyla bir maske tarafından işleme alınmasıdır. Bu maskeye filtre de denilmektedir (Gonzalez ve Woods, 2014). Sayısal görüntüdeki pikseller ile maske katsayılarının çarpılıp toplanması temeline dayanır (Rangayyan, 2004). Örneğin  $3 \times 3$  komşuluk değerine sahip bir maske ( $w$ ) ile bir görüntünün ( $f(x,y)$ ) matematiksel olarak süzülmesi işlemi Eşitlik 3.1 ve 3.2’deki gibi gösterilmektedir.

$$g(x,y) = w(-1,-1)f(x-1,y-1) + w(-1,0)f(x-1,y) + \dots + w(0,0)f(x,y) + \dots + w(1,1)f(x+1,y+1) \quad (3.1)$$

yani

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \quad (3.2)$$

Burada,  $g(x, y)$  filtre çıktısı,  $f$   $m \times n$  boyutunda bir sayısal görüntü ( $m=2a+1$  ve  $n=2b+1$ ),  $w$  filtre katsayılarıdır (Gonzalez ve Woods, 2014).

### Uzamsal korelasyon ve konvolüsyon

Bir sayısal görüntüde bir filtre maskesinin kaydırılarak her bir piksel için çarpımların toplamının hesaplanması işlemine korelasyon denmektedir (Gonzalez ve Woods, 2014).

$$w(x, y) \star f(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \quad (3.3)$$

Filtre maskesinin başlangıçta x-ekseninde simetriğinin alınmasıyla, her bir piksel için çarpımların toplamının bulunmasına konvolüsyon denir (Gonzalez ve Woods, 2014).

$$w(x, y) \star f(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x - s, y - t) \quad (3.4)$$

Korelasyon ve konvolüsyon uzamsal filtrelemenin temellerini oluşturmaktadır. Genel olarak uzamsal filtreler çarpımların toplamı kuralına uymaktadır. Örneğin tüm katsayıları 1 olan bir süzgecin 9'a bölünmesiyle oluşturulan filtreleme işleminde ortalama alma işlemi gerçekleştirilir ve görüntü yumuşatılır. Fakat görüntüyü keskinleştirme işleminde uzamsal türev alma ve Laplace işleci kullanılmaktadır (Bankman, 2000; Gonzalez ve Woods, 2014).

Laplace işleci ya da ikinci-dereceden türev, görüntü işlemede sıkça kullanılmaktadır (Kamgar-Parsi ve ark., 1997; Kuş ve Karagöz, 2013). İkinci-dereceden türev bir pikselin komşu pikselleriyle olan farkına bakarak kenar vurgulama işlemi gerçekleştirebilir.

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (3.5)$$

Eşitlik 3.5'te görülen eşitliğin açılımı yapılırsa,

$$\nabla^2 f(x, y) = f(x + 1, y) + f(x - 1, y) + f(x, y + 1) + f(x, y - 1) - 4f(x, y) \quad (3.6)$$

elde edilir. Burada filtre katsayıları,

0	1	0
1	-4	1
0	1	0

olarak hesaplanmaktadır ve temel iki-boyutlu Laplace işleci olarak değerlendirilmektedir ve 4-yönden komşu pikseller ile merkez pikselin farkını hesaplar (Kamgar-Parsi ve ark., 1997; Young ve ark., 2007; Gonzalez ve Woods, 2014).

Bir diğer sıklıkla kullanılan Laplace işleci ise köşelerdeki komşuları dahil, 8-komşu piksellerin merkez piksel ile farkını hesaplayan filtre maskesidir (Gonzalez ve Woods, 2014).

-1	-1	-1
-1	8	-1
-1	-1	-1

Örnek olarak  $3 \times 3$ 'lük bir matris Laplace işleci ile işleme alındığında 4-komşulu Laplace filtresi ile filtrelenen sonuç aşağıdaki gibi olmaktadır.

10	30	50
20	50	20
60	40	10

0	1	0
1	-4	1
0	1	0

30	20	-50
60	-90	50
-60	0	40


Aynı matris 8-komşulu Laplace filtresi ile filtrelendiğinde ise aşağıdaki sonuç elde edilmektedir.

10	30	50
20	50	20
60	40	10

-1	-1	-1
-1	8	-1
-1	-1	-1

-70	0	50
-90	160	-80
70	40	-80

Laplace filtrelerin bir görüntü kesiti üzerine uygulama örnekleri Şekil 3.13'teki gibi olmaktadır. Şekilden görüldüğü üzere Laplace filtre çıktıları görsel olarak mikrokalsifikasyonları belirginleştirememektedir. Piksel değerleri küçük bir aralıkta olduğu için çıplak göz ile pikseller arasındaki değişimi görmek oldukça güç olmaktadır.




Şekil 3.13. Laplace filtre çıktıları

(a) 4-komşulu Laplace çekirdeği ile filtrelenen görüntü (b) 8-komşulu Laplace çekirdeği ile filtrelenen görüntü

Çalışmada eşitlikteki Laplace işlemi Eşitlik 3.6'da olduğu gibi 4-komşulu olarak kullanılmıştır. Çünkü bu Laplace çekirdeği, Laplace işlecinin en temel halidir ve çalışmamızda filtrelerin mikrokalsifikasyon üzerine olan etkileri incelenmiştir.

### 3.3.2. Frekans bölgesinde filtreleme

Sayısal görüntüler, uzamsal yani piksel değerlerine ve koordinatlarına göre işleme tabi tutuldukları gibi frekans bölgesinde de görüntü işleme tekniklerine tabi tutulabilir. Frekans düzleminde filtreleme işleminde öncelikle görüntü Fourier dönüşümü ile frekans düzlemine aktarılır ve filtreleme işlemi burada gerçekleştirilir (Bankman, 2000; Gonzalez ve Woods, 2014)İ. Sonrasında süzülen görüntü ters Fourier dönüşümü ile uzamsal düzleme aktarılır. Frekans düzleminde filtreleme işlemi Şekil 3.14'da gösterilmektedir.



Şekil 3.14. Frekans düzleminde süzme işlemi

Frekans düzleminde filtreleme işlemi yapılabilmesi için sayısal görüntünün frekans düzlemine aktarılması gerekmektedir. Bunun için Fourier dönüşümünden faydalanılır.

Görüntü işleme de ise sayısal görüntüler Fourier dönüşümüne tabi tutulmaktadır. Ancak sayısal görüntüler zamana bağlı sürekli bir değişken olmadığı için ayrık Fourier dönüşümü ve bir matris olduğu için 2-boyutlu Fourier dönüşümü uygulanmaktadır. 2D DFT Eşitlik 3.7'deki gibi ifade edilmektedir.

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (3.7)$$

Burada,  $M \times N$  boyutlu bir  $f(x, y)$  görüntüsünde,  $F(u, v)$  Fourier dönüşümü çıktısı, ve  $u, v$  ayrık değişkenleri ( $u=0, 1 \dots M-1$  ve  $v=0, 1, \dots N-1$ ) göstermektedir (Bankman, 2000).

Fourier dönüşümünden sonra görüntü üzerinde filtreleme işlemi gerçekleştirilir (Fisher ve ark., 1997; Gonzalez ve Woods, 2014). Uzamsal filtrelemede kullanılan korelasyon ve konvolüsyon, tüm pikselleri tek tek taradığı için uzun ve pahalı bir sürece sebep olmaktadır fakat frekans düzleminde çarpma işlemi, uzamsal düzlemde konvolüsyon işlemine denk gelmektedir.

$$f(x, y) \star h(x, y) \Leftrightarrow F(u, v)H(u, v) \quad (3.8)$$

Eşitlik 3.8’de görüldüğü üzere frekans düzleminde filtreleme işlemi uzamsal düzlemden daha kolay ve ekonomiktir. Frekans düzleminde süzülen görüntü, görüntü olarak spektrum ve faz açısından ibaret olduğu için yeniden uzamsal düzleme alınmalıdır. Bu da 2-D ters ayırık zamanlı Fourier dönüşümü (2D IDFT) ile mümkün olmaktadır (Fisher ve ark., 1997; Gonzalez ve Woods, 2014).

$$f(x, y) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (3.9)$$

Burada Fourier dönüşümü  $F(u, v)$ ,  $u, v$  ayırık değişkenler ve  $M \times N$  boyutlu bir  $f(x, y)$  görüntüsünde  $x=0, 1, \dots, M-1, y=0, 1, \dots, N-1$  olmaktadır (Bankman, 2000).

Frekans düzleminde, sayısal görüntü frekans bileşenlerine ayrıştırılır. Filtreleme işleminde ise görüntüye ait frekans geçişleri manipüle edilmektedir. Bir görüntüye ait belli bir frekansın altı, üstü ya da belli bir frekans aralığının geçişine izin verilebilir ya da frekans geçişleri durdurulabilir. Bu filtrelere yaptıkları iş ile isim verilir; örneğin belli bir frekanstan, kesim frekansı, daha alçak frekansları geçiren filtrelere alçak geçiren filtre, yüksek frekansları geçiren filtreye yüksek geçiren filtre denir (Gonzalez ve Woods, 2014). Filtreler kesim frekansı ile geçişin sağlandığı frekansa göre farklı yöntemlerle üretilir. Örneğin tam olarak kesim frekansından itibaren geçiş sağlanması istenen filtreler ideal filtrelerdir, kesim frekansını belli matematiksel fonksiyonlarla hesaplayan Butterworth ve Gauss gibi filtreler de vardır (Gonzalez ve Woods, 2014; Shaikh, 2016).



### Gauss yüksek geçiren filtre


Gauss yüksek geçiren (GHP) filtre, kesim frekansını ideal filtrede olduğu gibi birden ayırmak yerine kesim frekansını Gauss fonksiyonuna göre yumuşatarak frekansları yüksek ve alçak olarak ayırır ve yüksek frekansların geçişine izin verirken alçak frekans bileşenlerini baskılar.

$$H(u, v) = 1 - e^{-\frac{D^2(u,v)}{2D_0}} \quad (3.10)$$

burada  $D_0$  kesim frekansı ve  $D(u, v)$  ise  $(u, v)$  noktasının frekans dikdörtgeni merkezine olan uzaklığıdır (Gonzalez ve Woods, 2014).

Bir görüntü, frekans düzlemine aktarıldığında, görüntü yüksek frekans bileşenleri, alçak frekans bileşenlerine ve DC terimine ayrılır. Şekil 3.15(b)'de görülen  $M \times N$  boyutundaki Fourier spektrumunda resmin merkez bileşeni ( $F'(M/2, N/2)$ ) DC bileşeni oluşturmaktadır. DC bileşen uzamsal düzlemde görüntünün genel parlaklığını ifade etmektedir (Fisher ve ark., 1997; Gonzalez ve Woods, 2014). Merkezden kenarlara doğru gidildikçe frekans yoğunluğu artmaktadır. Kenarlarda yüksek frekanslı bileşenler ve ortalarda alçak frekanslı bileşenler mevcuttur. Alçak frekanslı bileşenler ani değişim içermeyen piksel komşuluklarını içerirken, yüksek frekanslı bileşenler ani geçişleri, köşeleri, kenarları, gürültüleri içerirler. Yüksek geçiren filtre yüksek frekans bileşenlerini içerdiğinden görüntüde kenarlar, geçişler ve gürültüleri vurgular (Rangayyan, 2004).

Mikrokalsifikasyonlar boyutları ve dağılımları nedeniyle yüksek frekanslı bileşenlerdir. Dolayısıyla bir görüntüye yüksek geçiren filtre uygulamak mikrokalsifikasyonları belirgin hale getirecektir (Wang ve Karayiannis, 1998). Şekil 3.15'te bir ROI'ye GHP filtre uygulaması görülmektedir (a)'da orijinal ROI, (b)'de ROI'nin Fourier dönüşümü ile frekans düzlemine aktarılmasıyla oluşan Fourier spektrumu görülmektedir.



Şekil 3.15. ROI'ye GHP filtre uygulaması

(a) Orijinal ROI, (b) ROI'nin Fourier dönüşümü yapılarak elde edilen genlik görüntüsü  
(c) GHP filtre (d) GHP filtre süzölmüş görüntü

Mikrokalsifikasyonların boyutlarından dolayı küçük kesim frekansı (15) seçilen GHP filtre oluşturulmuştur. (c)'de filtrenin 3-boyutlu olarak temsili bulunmaktadır. Yüksek frekans bileşenlerinin çoğunu geçirmekte ve düşük frekans bileşenlerini baskılamaktadır. (d)'de ise GHP filtre ile süzölmüş mamogram kesiti görölmektedir. Ancak burada GHP filtrede DC bileşen olmadığı için görüntünün kontrastı oldukça düşük olduğundan görüntüye kontrast germe uygulanmıştır. Şekil 3.15(d)'de göröldüğü gibi mikrokalsifikasyonlar oldukça belirgin hale gelmiştir. Bu filtre uygulamasının dezavantajı ise mikrokalsifikasyonlar kadar yüksek frekanslı bileşen olması sebebiyle gürültüyü de belirgin hale getirmesidir.

## Gabor filtre


Gabor filtre iletişim alanına Dennis Gabor tarafından sunulduktan sonra, Daugman tarafından iki-boyuta uyarlanmış bir filtre türüdür (Gabor, 1946; Daugman, 1988). Genel olarak Gabor filtre bir kompleks sinüzoidal sinyalin, Gauss zarfı ile çarpımından oluşan bir bant geçiren filtredir (Movellan, 2002; Derpanis, 2007). Daugman'ın önerdiği Gabor filtre formülünün sadeleştirilmiş yapısı Eşitlik 3.11'de verilmektedir. Eşitlik 3.11'de Gauss dağılımı merkezidir ve faz kayması yoktur.  $x$  ve  $y$  görsel alana giren ışık dürtünün yönünü, gama ( $\gamma$ ) Gauss dağılımındaki çanın uzamsal boyut oranı yani çanın boyunun enine oranı, sigma ( $\sigma$ ) dalga boyu ( $\lambda$ ) ile ilişkili olarak ortaya çıkan standart sapma değeri, teta ( $\theta$ ) ise Gauss dağılımının, 0-360 derece arasında yönelimini vermektedir (Daugman, 1985; Petkov ve Kruizinga, 1997; Kruizinga ve Petkov, 1999).

$$g(x, y) = e^{-\frac{(x'^2 + \gamma^2 y'^2)}{2\sigma^2}} \quad (3.11)$$

Burada

$$\begin{aligned} x' &= (x)\cos\theta - (y)\sin\theta \\ y' &= (x)\sin\theta + (y)\cos\theta \end{aligned} \quad (3.12)$$

Bu çalışmada, simetrik varyanslar 1.68, dalga boyu 3 piksel/çevrim, uzamsal boyut oranı 0.5, bant genişliği 1 oktav ve yönelimi ise 90 derece seçilmiştir. Bu seçimlerde mikrokalsifikasyonların genel yapıları göz önünde bulundurularak, gürültülere odaklanacak kadar çok büyük sapma, çok küçük dalga boyu veya mikrokalsifikasyonları kaçırarak kadar çok küçük standart sapma ve çok büyük dalga boyu verilmemiştir. Yine genel yapıları gereği mikrokalsifikasyonlar yatayda eliptik bir şekle sahip olduklarından yönelim açısı yatay düzlemde verilmiştir. Şekil 3.6'da görülmektedir.



(a)

(b)

Şekil 3.16. Mikrokalsifikasyon kesitine Gabor filtre uygulaması

(a) Orijinal mamogram mikrokalsifikasyon görüntüsü (b) (a) görüntüsünün Gabor filtre ile süzölmüş çıktısı

Gabor filtre çıktısı daha önceki filtrelerde olduđu gibi kontrast germe yapılmış olarak gösterilmiştir. Çünkü, Gabor filtre ile süzölmüş görüntüde çıplak gözle fark edilemeyecek kadar küçük yeğlilik değeri bulunmaktadır ve görüntü tamamen siyah görünmektedir. Şekil 3.16'dan göröldüğü gibi mikrokalsifikasyon kesiti Gabor filtre çıktısında net olarak görölememektedir.

### 3.3.3. Morfolojik görüntü işleme

Morfoloji kelime anlamı olarak biçimsel yani biçimle ilgili demektir (Oral, 2011; Gonzalez ve Woods, 2014). Görüntü işlemede kullanılan morfoloji daha çok kümeler kuramı ile ilgili olmaktadır (Gonzalez ve Woods, 2014). Bu kümelerde görüntü siyah-beyaz olarak piksellerine ayrıldığında iki kümeden ve bu kümelerin kesişiminden, birleşiminden, haricinden vb. bahsedilebilir. Burada bir görüntü ve de yapı taşı olarak adlandırılan bir diğeri görüntü parçacığı küme teorisi için kullanılabilir. Morfoloji işlemlerinde küme kuramı kadar mantık işlemleri de kullanılmaktadır. Ve, Veya, Değil işlemleri ile görüntü üzerinde istenilen yönde değışikler yapılabilir (Gonzalez ve Woods, 2014).

#### Gri-seviye morfolojik işlemler

Görüntü işlemede siyah-beyaz görüntülerde kullanılan morfolojik işlemler kadar gri-seviye morfolojik işlemler de kullanılmaktadır. Mamografi görüntülerinin gri-seviye

görüntüler olması nedeniyle gri-seviye morfolojik işlemler önem taşımaktadır. Görüntü işlemede kullanılan en temel gri-seviye morfolojik işlemler genişletme, aşındırma, açma, ve kapama işlemidir (Özşen, 2004; Oral, 2011; Gonzalez ve Woods, 2014).

Genişletme (dilation) ( $A \oplus B$ ), bir yapı elemanının bir görüntü üzerinde kaydırılarak görüntüde ana noktasının kesiştiği her noktaya yapı elemanı eklemesiyle gerçekleştirilir. Burada  $A$  temel görüntüyü,  $B$  yapı elemanını,  $z$  kaydırma bölgesini temsil etmektedir (Gonzalez ve Woods, 2014). Genişletme işlemi var olan parçaları genişleterek boşlukları küçültür, köprü oluşturur ve görüntüdeki küçük boşlukları tamir eder (Oral, 2011; Gonzalez ve Woods, 2014).

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (3.13)$$

Aşındırma (erosion) işlemi ( $A \ominus B$ ),  $B$  yapı elemanını  $A$  görüntüsü üzerinde gezdirir ve yapı elemanı tamamıyla görüntü üzerindeyse görüntüyü olduğu gibi bırakır aksi halde görüntüyü siler. Böylelikle boşlukları büyültür, görüntüdeki ilgisiz parçaları temizler (Gonzalez ve Woods, 2014).

$$A \ominus B = \{z | (\hat{B})_z \subseteq A\} \quad (3.14)$$


Açma (opening) işlemi ( $A \circ B$ ),  $A$  görüntüsü üzerinde  $B$  yapı taşı ile önce aşındırma ardından genişletme işlemi yaparak görüntüde dar bağlantıları, sivri tepelikleri, küçük adacıkları yok eder (Shih, 2009; Gonzalez ve Woods, 2014).

$$A \circ B = (A \ominus B) \oplus B \quad (3.15)$$

Kapama (closing) işlemi ( $A \bullet B$ ) ise  $B$  yapı taşı olarak  $A$  görüntüsü üzerinde önce genişletme ardından aşındırma işlemi yapar. Böylelikle, görüntüde küçük bağlantı kopuklukları giderilir ve küçük delikler doldurulmuş olur (Shih, 2009; Gonzalez ve Woods, 2014).

$$A \bullet B = (A \oplus B) \ominus B \quad (3.16)$$

Örnek bir mamogram mikrokalsifikasyon kümesi üzerinde aşındırma, genişletme, açma ve kapama morfolojik işlemleri Şekil 3.17’de görülmektedir.



Şekil 3.17. Mikrokalsifikasyon kesitine morfolojik işlemlerin uygulanması  
(a) Aşındırma, (b) Genişletme, (c) Açma, (ç) Kapama işlemlerinin gösterilmesi

Mikrokalsifikasyonlar çok küçük noktacıklar olarak ele alındığında, genişletme ve kapama işlemlerinin onları belirginleştirdiği ve aşındırma ve açma işlemlerinin ise mikrokalsifikasyonları sildiği görülebilir.

#### Top-hat ve Bottom-hat dönüşümleri

Meyer tarafından geliştirilen Top-hat ve Bottom-hat dönüşümleri morfolojik açma ve kapama işlemlerini kullanır (Young ve ark., 2007). Top-hat dönüşümü koyu bir zemin üzerinde parlak objeleri belirginleştirmek için kullanılırken Bottom-hat dönüşümü parlak

zemin üzerinde koyu objeleri belirginleştirmek için kullanılmaktadır (Gonzalez ve Woods, 2014).

Top-hat dönüşümünde görüntünün kendisinden açma işlemi yapılmış hali çıkarılır. Böylece görüntüde yüksek yeğlilik değerine sahip alanlar vurgulanır. Örneğin A görüntü ve B yapı elemanı olmak üzere, A görüntüsünün B yapı elemanı ile Top-hat dönüşümü Eşitlik 3.17'deki gibi ifade edilir.


$$TopHat(A, B) = A - (A \circ B) \quad (3.17)$$

Bottom-hat dönüşüm ise kapama işlemi yapılmış görüntüden, görüntünün kendisinin çıkarılmasıyla gerçekleştirilir. Yine A sayısal imge ve B yapı elemanı olmak üzere,

$$BottomHat(A, B) = (A \bullet B) - A \quad (3.18)$$

Örnek mamogram kesiti üzerinde Top-hat ve Bottom-hat dönüşümü gösterimlerinin kontrast germe uygulanmış halleri Şekil 3.18'de görülmektedir. Çalışmada mikrokalsifikasyonların belirginleştirilmesine yönelik bir odak noktası olduğu için sadece Top-hat yöntemi uygulanmıştır. Top-hat yöntemi, gri-tonlarında arka plan üzerine daha parlak yeğlilik değerine sahip pikselleri yani mikrokalsifikasyonları belirtmekte oldukça başarılıdır (Guo ve ark., 2016).

Tez çalışmasında, mikrokalsifikasyonların yuvarlak olmasından dolayı disk şeklinde ve 10 piksel çapında yapı elemanları tercih edilmiştir




Şekil 3.18. Mikrokalsifikasyon kesitine Top-hat ve Bottom-hat uygulaması  
(a) örnek ROI üzerinde Top-hat dönüşümünün uygulanması (b) örnek ROI üzerinde Bottom-hat dönüşümünün uygulanması

#### 3.3.4. Önerilen filtre

Mamografilerde mikrokalsifikasyonların görünürlüğünün iyileştirilmesine yönelik özel bir filtre tasarımı gerçekleştirmek için öncelikle mikrokalsifikasyonun yapısına yakından bakmak gerekmektedir.

Şekil 3.19’da DDSM veri tabanından indirilmiş 3 farklı mikrokalsifikasyonlu mamografi kesiti görülmektedir. Şekil 3.19 (a), (b) ve (c) sırasıyla, DDSM veri tabanından alınan A\_1472 Sağ MLO, A\_1482 Sağ CC ve A\_1495 Sağ MLO mamografilerine ait 256×256 piksellik kesitlerdir. Bu kesitler üzerindeki mikrokalsifikasyonlar kırmızı daire ile işaretlenmiştir.






Şekil 3.19. Farklı mamografilere ait mikrokalsifikasyon görüntüleri

Şekil 3.19’da (ç), (d) ve (e) sırasıyla (a), (b) ve (c)’deki kesitlerin mikrokalsifikasyon kümelerine yakınlştırılmış 50×50 piksel boyutundaki imgeleridir. Buradan da görülebileceği gibi mikrokalsifikasyonlar zemine göre daha parlak (yüksek yeğlilik değerlikli) olarak görülmektedir. Her bir kesitte, tek bir mikrokalsifikasyona odaklanıldığında ise 14×14 piksellik imgelerle Şekil 3.19(f), (g) ve (h) görüntüleri elde edilmiştir. Bu görüntülerin yeğlilik değerleri incelendiğinde, mikrokalsifikasyonun merkezinde yer alan pikselde yeğlilik değerlerinin en yüksek olduğu, yatay ve dikey

yönde merkezde uzaklaştıkça bu yağınlık değerin azalarak, imgenin ortalama piksel yağınlık değeriine kadar düştüğü görülmüştür.

Şekil 3.20’de Şekil 3.19(f)’de görülen mikrokalsifikasyon imgesinin tam ortasından kesit alınması ve bu kesitin karşılığı olan piksel yağınlık değeriinin grafiksel gösterimi görülmektedir. Şekilden de net olarak görülebileceği gibi bir mikrokalsifikasyon kenarlarından ortasına doğru gittikçe artan yağınlık değeriine sahiptir. Bu temel önerilen filtre tasarımı için temel oluşturmaktadır.



Şekil 3.20. Tek mikrokalsifikasyon görüntüsünden kesit alınması ve yağınlık değeri

Önerilen süzgecin yapısı merkez piksel ve çevresindeki piksellerin yağınlık değeriinin kademeli olarak azalması temeline dayanmaktadır. Merkez piksel ile çevre piksellerin mutlak farkları alınarak, çevresinden farklı merkez pikselin ön plana çıkarılması hedeflenmektedir. Eğer merkez piksel çevre piksellerle benzer yağınlık değeriine sahipse görünürlüğü bastırılmış olacaktır.

Bu temel bilgilerle oluşturulan önerilen süzgecin matematiksel ifadesi şu şekildedir,

$$\begin{aligned}
 K(x, y) = & |f(x - 1, y - 1) - f(x, y)| + |f(x - 1, y) - f(x, y)| \\
 & + |f(x - 1, y + 1) - f(x, y)| + |f(x, y - 1) - f(x, y)| \\
 & + |f(x, y + 1) - f(x, y)| + |f(x + 1, y - 1) - f(x, y)| \\
 & + |f(x + 1, y) - f(x, y)| + |f(x + 1, y + 1) - f(x, y)|
 \end{aligned} \tag{3.19}$$

Burada,  $M \times N$  piksel boyutunda bir görüntü için  $f(x,y)$  merkez piksel,  $f(x \pm 1, y \pm 1)$  komşu pikselleri,  $K(x,y)$  ise merkez pikselin yeni yeğlilik değerini göstermektedir. Filtrenin tüm görüntü üzerinde işlem yapabilmesi için görüntüdeki tüm pikselleri taraması gerekmektedir. Bu yüzden  $x=1,2,3,\dots,M$  ve  $y=1,2,3,\dots,N$  olarak işlem gerçekleştirilmektedir.  $K(x,y)$  eşitliği kısaca Eşitlik 3.20 şeklinde ifade edilebilir.

$$K(x,y) = \sum_{i=-1}^1 \sum_{j=-1}^1 |f(x+i, y+j) - f(x,y)| \quad (3.20)$$

$K(x,y)$  eşitliği ile aşağıdaki matrisin işleme alındığında çıkış matrisi şekildeki gibi olacaktır. Matris çıktılarında mutlak değerden dolayı negatif değer bulunmayacak ve tüm hücreler komşularının mutlak farkının toplamına eşit olacaktır.


10	30	50
20	50	20
60	40	10

$\rightarrow K(x,y) \rightarrow$

70	80	50
110	180	110
70	100	80

Bir görüntüdeki tüm pikseller önerilen filtre ile süzülürken oluşan yeni görüntüde kenarlar daha belirgin hale gelirken arka plan mikrokalsifikasyonlardan ayrıştırılır. Örnek olarak, Şekil 3.19(a)'da görülen mamografi kesitinin önerilen filtre ile işlem yapılmış hali Şekil 3.21(a)'da görülmektedir.


Ancak görüntünün yeğlilik aralık değeri dar olduğu için çıplak göz ile mikrokalsifikasyonları fark etmek oldukça güç olabilmektedir. Bu yüzden önerilen filtre ile süzölmüş görüntü üzerinde tüm yeğlilik değerlerinin, en düşük yeğlilik değeri ile en yüksek yeğlilik değeri arasına (ör:0-255) yayılacak şekilde kontrast ayarlaması yapılmıştır. Şekil 3.21(b)'deki görüntüye bakılırsa mikrokalsifikasyon kümesi ilk bakışta fark edilmektedir. Bu görüntülere ait kontrast dağılımları da sırasıyla (c) ve (ç)'de verilmiştir.



Şekil 3.21. ROI'ye önerilen filtre uygulaması ve histogram değerleri  
 (a) önerilen filtre ile filtrelenmiş mikrokalsifikasyonlu ROI (b) önerilen filtre ile filtrelenmiş ve kontrast germeli mikrokalsifikasyonlu ROI (c) (a)'daki ROI'nin histogramı (ç)(b)'deki ROI'nin histogramı

Şekil 3.21(a) önerilen filtre ile filtrelenmiş bir mamografi kesitinde sağ-alt konumda mikrokalsifikasyon kümeleri belirgin halde bulunmaktadır. Ancak görüntünün histogram aralığı çok geniş olmadığı için (c)'de gösterildiği üzere, tüm yeğnlik skalası 0 ila 30 arasında değişmektedir bu da mikrokalsifikasyonun çıplak gözle kolayca görünmesini engellemektedir. Şekil 3.21(b)'de ise önerilen filtre ile filtrelenen görüntüye histogram germe uygulanmıştır ve histogram aralığı (ç)'de gösterildiği gibi 0-255 yeğnlik değerleri arasına genişletilmiştir. Böylece mikrokalsifikasyonlar (b)'de görüldüğü gibi kolaylıkla çıplak gözle seçilebilmektedir.

Ek olarak Şekil 3.22’de önerilen filtre ile filtrelenmiş ve kontrast ayarlaması yapılmış mamografi kesiti orijinal mamografi kesiti ile karşılaştırılmıştır.



Şekil 3.22. Kontrast germeli orijinal ROI ve önerilen filtreli-kontrast germeli ROI karşılaştırılması

(a) orijinal mikrokalsifikasyonlu kesit (b) orijinal kesitin kontrast ayarlaması yapılmış görüntüsü. (c) önerilen filtre ile filtrelenmiş mikrokalsifikasyonlu kesit (ç) önerilen filtre ile filtrelenmiş ve kontrast ayarlanmış mikrokalsifikasyonlu kesit

Şekil 3.22(a)’da orijinal mamografi kesitinin kontrast ayarlaması yapılması ile elde edilen (b)’de mikrokalsifikasyonlar oldukça belirgin hale gelmiştir. Buna karşın mikrokalsifikasyona sahip olmayan normal meme dokusunda da bir kısım pikseller mikrokalsifikasyon gibi yüksek yeğlilik değeri almıştır. Bu durum CAD sistemi yanlış yönlendirme yaparak FP/negatif oranını artırabilmektedir. Şekil 3.22(c) ve (ç)’de önerilen

filtre ile filtrelenmiş ve kontrast ayarlaması yapılmış görüntülerde ise arka planda benzer bir öbek yoktur. Önerilen filtre mikrokalsifikasyonların görünürlüğünün iyileştirmesi yanında arka planda istenmeyen yeğlilik yükselmelerini de engellemektedir. Bunun CAD sistemi için daha yüksek sınıflandırma başarısına yol açması beklenmektedir.

### 3.4. Özellik Çıkarımı

Bu çalışmada uzamsal özellik çıkarımı tercih edilmiştir. Uzamsal özellikler sayısal görüntüler üzerindeki piksel değerlerinden çıkarılmaktadır. Literatürde farklı özellik çıkarımları bulunmaktadır. Bu çalışmada 6 adet, literatürde sıklıkla kullanılan istatistiksel parametreler kullanılarak özelliklerin çıkarımı yapılmıştır (Zheng ve ark., 1996; Oral, 2011).

Bir sayısal görüntünün ortalaması  $m$ , standart sapması  $\sigma$ , entropisi  $I$ , enerjisi  $E$ , yamukluğu  $s$  ve basıklığı  $k$  ile sembolize edilmektedir. Eşitlikler aşağıda 3.21 ile 3.26 arasında gösterilmektedir.

Ortalama,

$$m = \sum_{i=0}^{L-1} ip_i \quad (3.21)$$

Standart sapma,

$$\sigma = \sqrt{\sum_{i=0}^{L-1} (i - m)^2 p_i} \quad (3.22)$$

Entropi,

$$I = - \sum_{i=0}^{L-1} p_i \log_2 p_i \quad (3.23)$$

Enerji,

$$E = \left( \sum_{i=0}^{L-1} p_i \right)^2 \quad (3.24)$$

Yamukluk,

$$s = \frac{1}{\sigma^3} \sum_{i=0}^{L-1} (i - m)^3 p_i \quad (3.25)$$

Basıklık,

$$k = \frac{1}{\sigma^4} \sum_{i=0}^{L-1} (i - m)^4 p_i \quad (3.26)$$

Burada  $p_i$  normalize edilmiş kümelenmiş histogram değeri,  $L$  görüntüdeki gri seviye sayısı,  $h_i$  gri-seviye histogramı,  $N$  toplam piksel sayısıdır ve  $p_i = h_i/N$  olarak bulunur (Haralick ve diğerleri, 1973; Gonzalez ve Woods, 2014).

### 3.5. Sınıflandırma

Özellik çıkarımında ortalama, standart sapma, entropi, enerji, basıklık ve yamukluk istatistiksel özellikleri çıkarılmıştır. Özellik çıkarımı aşamasında her bir özellik hesabının oldukça farklı formlere sahip olmasından dolayı özellik değerleri arasında çok büyük farklar bulunabilmektedir. Örneğin bir özellik kümesinde  $2 \cdot 10^{11}$  ve  $7 \cdot 10^{-3}$  gibi değerler bir arada işlenmek durumunda kalabilir, bu da veri setleri arasında  $10^{13}$  kadar bir fark olması demektir. Bu kadar büyük bir fark özellik kümelerini yanlış işlemeye sebep olmaktadır. Bu sebeple özellik çıkarımı yapılan veri setlerinin normalizasyonunun sağlanması gerekmektedir. Normalizasyon yapılırken her bir veri seti için en yüksek değer 1 olması sağlanır. Böylece tüm veriler 0 ile 1 arasında değer almış olur. Eşitlik 3.27'de  $x_n$  normalize edilmiş özellik kümesini simgeliyor olmak üzere,  $x_i$  özellik kümesi,  $\max|x_i|$  ise  $i$ . özellik kümesindeki en yüksek  $x_i$  değeridir.


$$x_n = \frac{x_i}{\max|x_i|} \quad (3.27)$$

Normalizeli özellik vektörleri farklı sınıflandırıcılara girdi olarak sunulurken, farklı filtrelerin mikrokalsifikasyonların varlığını tespit etmede başarısı incelenmiştir. Bunun için her bir sınıflandırıcıda aynı mamografi kesitlerinin eğitim veya test olarak kullanılmasına dikkat edilmiştir. Bu yüzden veri seti 2-kat çapraz doğrulama ile %50 oranıyla test ve eğitim veri setleri olarak ayrıştırılmıştır. Bu yöntemle her kat için veri noktaları  $d_0$  ve  $d_1$  gibi rastgele iki gruba ayrılır. Algoritma önce  $d_0$  grubunu eğitim  $d_1$  grubunu test verisi olarak sonrasında  $d_1$  grubunu eğitim ve  $d_0$  grubunu test verisi olarak sunar ve başarısını, sınıflandırma hatasını denetler. En düşük sınıflandırma hatasına sahip gruba bularak o grubu eğitim ve test verisi olarak kullanır. Bu yöntem hem eğitim hem de test setlerinin büyük olması ve her veri noktasının hem eğitim hem de test verisi için kullanılması avantajına sahiptir (Hekim, 2016).

### 3.5.1. Destek vektör makineleri

Destek Vektör Makineleri (SVM) bir veri setini, özelliklerin sayısına yakın olan bir hiper düzleme dönüştürür. Bunu takiben veri kümesini gruplara ayırır. Hiper düzlem, veri kümesini sınıflara ayıramazsa, SVM çekirdeği kullanarak başka bir özellik oluşturur ve veri kümesini yeni bir hiper düzleme taşır. Gruplar arasında, maksimum mesafeye sahip en iyi ayırma çizgisini seçer (Zheng ve Xue, 2009). Bu maksimum mesafesine optimal ayırma hiper-düzlemi denir ve hiper-düzleme en yakın veri noktaları destek vektörleri olarak adlandırılır (Saraswathi ve Srinivasan, 2017). Şekil 3.23'te SVM'ye ait örnek bir hiper-düzleme aktarma ve optimal ayırma düzlemi görülebilir.





Şekil 3.23. SVM Hiper-Düzlemi

SVM veri setini hiper-düzleme aktararak veriyi gruplara ayırmaktadır. Burada en yüksek ayırma çizgisini seçerek destek vektörleri ve optimal ayırma düzlemini oluşturmaktadır. Böylece şekildeki gibi ayrılamayan karmaşık bir veri seti gruplara ayrılabilir.

SVM sınıflandırıcı fonksiyonu şu şekilde tanımlanır

$$f_{SVM}(x) = \sum_{k=1}^K K(x, s_k) + b \quad (3.28)$$

$$K(x, s_k) = \phi^T(x)\phi(s_k) \quad (3.29)$$

burada  $b$  bias ,  $\phi$  doğrusal olmayan haritalama fonksiyonu,  $x$  giriş vektörü,  $s_k$  destek vektörü ve  $K$  çekirdek fonksiyonudur (Ren, 2012).

Tipik olarak SVM için 3 tip çekirdek kullanılır: lineer, polinom ve radyal temel fonksiyonu (RBF) çekirdekleridir. Lineer çekirdek genel olarak doğrusal olarak ayrılabilir veri türleri için kullanılırken, doğrusal olmayan ayrılabilir veri türleri için polinom ve RBF uygulanır. SVM çekirdekleri şu şekilde formüle edilir (Ren, 2012).

$$K_{(x_i, x_j)_{Lin}} = x_i^T x_j \quad (3.30)$$

$$K_{(x_i, x_j)_{Pol}} = (x_i^T x_j + 1)^p \quad (3.31)$$


$$K_{(x_i, x_j)_{RBF}} = e^{-\left(\frac{1}{2\sigma^2}\right)\|x_i - x_j\|^2} \quad (3.32)$$

Bu çalışmada RBF çekirdeği kullanılmıştır.  $\sigma$  deneme-yanılma yöntemi ile 2.8 olarak seçilmiştir.

### 3.5.1. Çok katmanlı algılayıcı sinir ağı

Genel olarak, ANN, birbirine bağlı basit işleme elemanları ağından, yani nöronlardan oluşan bir bilgi işlem sistemi olarak düşünülebilir (Ren, 2012). ANN insan öğrenmesini taklit ederek makine öğrenmesini sağlayan bilgisayar sistemleridir (Öztemel, 2003). Bu çalışmada yaygın olarak kullanılarak çok katmanlı algılayıcı sinir ağı (MLPNN) tercih edilmiştir


Yaygın olarak kullanılan ileri beslemeli ANN algoritmalarından biri olan MLPNN, hızlı işlem algoritmasına, optimum uygulama karmaşıklığına ve büyük miktarda eğitim verisine bağlı olmama gibi avantajlara sahiptir (Dalkıran ve Danışman, 2010). MLPNN bir giriş, bir gizli ve bir çıkış katmanı olmak üzere en az üç katmandan oluşur (Öztemel, 2003; Dalkıran ve Danışman, 2010). Şekil 3.24'te genel olarak MLPNN yapısı gösterilmektedir.



Şekil 3.24. Bir MLPNN yapısı örneği

Burada Giriş bilgileri nöronlara iletilir. Her bir nöron bir sonraki katmandaki tüm nöronlara bilgi göndererek en uygun katsayıları bulmayı amaçlar.

Birinci katman girdi verilerinin sunulduğu katmandır. Gizli katman, verileri nöronlarla hesaplayarak çıkış katmanına sonuçları gönderir. Gizli katmandaki yetersiz veya aşırı sayıda nöron, yanlış eğitime veya aşırı eğitime neden olabilir, dolayısıyla nöronların sayısı önemlidir. Bununla birlikte, tam olarak ihtiyaç duyulan nöronların sayısını bulmak için spesifik bir yöntem veya formül yoktur. Gizli katmandaki nöronların sayısı çoğunlukla deneme yanılma ile belirlenir (Übeyli ve Güler, 2004). Bu çalışmada, tek gizli katman için 10 nöron yeterli bulunmuştur. Şekil 3.25'te bir nöronun yapısı görülmektedir. Giriş sinyallerini bağlantı ağırlıkları ile çarparak aktivasyon fonksiyonunu oluşturarak çıkışa aktarır.



Şekil 3.25. MLPNN'de nöron yapısı

Gizli katmanda, her nöron  $j$ , giriş sinyallerinin ( $x_i$ ) ve bağlantı ağırlıklarının ( $w_{ij}$ ) çarpımını toplar.  $f$  aktivasyon fonksiyonunu,  $b$  bias değerini temsil eder ve her bir nöronun çıkışı ( $y$ ) aşağıdaki gibi formüle edilir (Dalkıran ve Danışman, 2010),

$$y_j = f \left( \sum w_{ij} x_i + b \right) \quad (3.33)$$

Aktivasyon fonksiyonu basit eşik, sigmoid veya hiperbolik tanjant fonksiyonu olarak uygulanabilir (Oral, 2011; Valarmathi ve Robinson, 2014). Bu çalışmada aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanılmıştır.

Her aktivasyon fonksiyonunun başarısı, çıkış nöronlarının istenen ve gerçek değerleri arasındaki karesel farkların toplamı ile değerlendirilir. Aşağıdaki şekilde tanımlanan  $E$  ile temsil edilir (Dalkıran ve Danışman, 2010),

$$E = \frac{1}{2} \sum_j (y_{dj} - y_j)^2 \quad (3.34)$$

Bu formülde  $y_{dj}$  hedef değerdir ve  $y_j$  bu nöron  $j$ 'nin gerçek çıkış değeridir. Bir nöronun her ağırlığı, hata oranı  $E$ 'yi en aza indirmek için yeniden düzenlenir (Dalkıran ve Danışman, 2010). Hata oranı  $E$ 'nin ayarlanması, geri yayılma algoritmasıyla yaygın olarak gerçekleştirilir. Geri yayılma algoritması, optimum ağırlıkları belirlemek için birkaç varyasyona sahiptir. Bu çalışmada, eğitim için Levenberg – Marquardt (LM) geri yayılım algoritmasını kullanılmıştır (Übeyli ve Güler, 2004; Dalkıran ve Danışman, 2010).

### 3.5.2. Doğrusal diskriminant analizi

LDA, sınıf etiketlerini dikkate alan yaygın bir tekniktir. LDA veriyi ayırmada sınıf içi ve sınıflar arası ilişkileri baz almaktadır (Belhumeur ve ark., 1997; Panahi ve ark., 2011; Junoh ve Mansor, 2012). Bu işlem üç adımda gerçekleştirilir: ilk adım, sınıf içi saçılma matrisi ( $S_w$ ) olarak adlandırılan her bir sınıfın ortalaması ile örnek arasındaki mesafenin hesaplanması, ikinci adım sınıflar arası dağılım matrisi ( $S_b$ ) olarak da adlandırılan farklı sınıflar arasındaki ayırımın hesaplanması (yani, farklı sınıfların ortalaması arasındaki mesafe) ve son olarak, sınıflar arası varyansı en üst düzeye çıkararak ve sınıf içi varyansı en aza indiren düşük boyutlu alanın inşasıdır. Bu üç adımın matematiksel ifadeleri aşağıda sırasıyla Eşitlik 3.35, 3.36 ve 3.37'de tanımlanmıştır (Belhumeur ve ark., 1997; Panahi ve ark., 2011; Junoh ve Mansor, 2012). Sınıf içi ve sınıf içi dağılım matrislerinin matematiksel ifadeleri aşağıdaki gibidir:

$$S_w = \sum_{i=1}^c \sum_{x_k \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (3.35)$$

$$S_b = \sum_{i=1}^c N_i(\mu_i - \mu)(\mu_i - \mu)^T \quad (3.36)$$

burada  $c$  toplam sınıf sayısını,  $i$  sınıf numarasını,  $X_i$  inci sınıftaki veri,  $\mu_i$   $i$  sınıfının ortalama değeri,  $\mu$  tüm sınıfların ortalama değeri ve  $N_i$   $i$  sınıfındaki toplam örnek sayısını tanımlar.

$S_w$  ve  $S_b$  hesaplandıktan sonra, LDA dönüşüm matrisini Fisher'in kriteri olarak adlandırılan eşitlik ile hesaplar,

$$w_{LDA} = \arg \max_w \frac{w^T S_b w}{w^T S_w w} = [w_1, w_2, \dots, w_m] \quad (3.37)$$

Bu eşitlik aynı zamanda  $S_b w_i = \lambda_i S_w w_i$  olarak yazılabilir. Burada  $\lambda_i \{ \lambda_i \mid i=1,2,\dots,m \}$ , ve  $w_i \{ w_i \mid i=1,2,\dots,m \}$  sırasıyla dönüşüm matrisinin öz değerleri ve öz vektörleri olmak üzere  $m$  sınıfın üst sınır değeridir.

### 3.5.3. Sınıflandırma başarısının ölçülmesi

Makine öğrenmesinde sınıflandırıcıların sınıflandırma başarısının ölçülmesi, sınıflandırıcının etiketlediği sınıf ile gerçek sınıf değeri arasındaki ilişkilerle gerçekleştirilir. Bununla ilgili terimler doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatiftir. Ayrıca bu terimlerin birbiriyle olan oranlarından elde edilen TCC, duyarlılık ve özgüllük olarak adlandırılan başarı ölçütü parametreler vardır. Bu değerler bir sınıflandırıcının ne derece doğru sınıflandırdığını gösterir. Tüm terimleri açıklamak için karışıklık matrisinden yararlanmak faydalı olacaktır. Karışıklık matrisi (Çizelge 3.3) bir sınıflandırma sonucunda sınıflandırmanın başarısını gösterilmektedir.

Çizelge 3.3. Karışıklık matrisi

		Gerçek Sonuçlar	
		Pozitif	Negatif
Sınıflandırıcı Sonuçları	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Gerçek sınıf değeri pozitif olan bir veriyi pozitif olarak etiketlemeye TP (doğru pozitif), negatif olarak etiketlemeye yanlış negatif (FN), gerçek sınıf değeri negatif olan bir veriyi negatif olarak etiketlemeye doğru negatif (TN), pozitif olarak etiketlemeye de FP (yanlış pozitif) denmektedir. FN ve FP sınıflandırıcıda oluşan hatalı sınıflandırma sonuçlarıdır. Bir sınıflandırıcının genel sınıflandırma başarısı doğruluk değeri ile gösterilir bu da tüm doğru sonuçların tüm veriye olan oranıdır. Pozitif olarak etiketlenenlerin tüm verinin TP olan veriye oranı duyarlılık, negatif olarak etiketlenen tüm verinin TN olan veriye oranı ise özgüllüktür (Hekim, 2016).


$$TCC = \frac{TN + TP}{TN + TP + FN + FP} \quad (3.38)$$

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.39)$$

$$Özgüllük = \frac{TN}{TN + FP} \quad (3.40)$$

Bir sınıflandırıcının duyarlılık ve özgüllük başarısını göstermek için ROC eğrisi de kullanılabilir. Bu eğri bir ekseninde duyarlılık ve diğer ekseninde özgüllük (1-Özgüllük) değerlerini gösterir. Eksenlerin orijini yani (0,0) noktası %0 duyarlılığa karşın %100 özgüllük göstermektedir. Buradan yola çıkarak ROC eğrisi ne kadar özgüllük ekseninden uzaklaşır ve duyarlılık eksenine yaklaşırsa o kadar başarılıdır. Örnek bir ROC eğrisi Şekil 3.26'da gösterilmektedir. Burada ç eğrisi rastgelelilik çizgisidir, yani sınıflandırıcı sınıflandırması gereken verinin yarısını rastgele olarak pozitif, yarısını da negatif olarak

etiketlerse bu sonucu alacaktır. *c* eğrisi yaklaşık %70-75 oranında doğruluk, duyarlılık ve duyarlılık gösterirken *b* eğrisi %80-85 oranını göstermektedir. *a* eğrisi ise tüm değerler için %100 başarı simgelemektedir.



Şekil 3.26. Örnek bir ROC eğrisi gösterimi

Bu çalışmada sınıflandırıcılar değerlendirilirken tüm verilerin görsel olarak okunabilmesi için ROC eğrisinden yararlanılmıştır. Böylelikle gerçekleştirilen her bir sınıflandırıcı için duyarlılık ve özgüllük değerleri kolaylıkla görülebilir.


#### 4. BULGULAR

Sayısal mamogramlardaki mikrokalsifikasyonlar ve meme dokuları benzer yoğunluk değerlerine sahip olabilir. Bu nedenle, sadece eşik teknikleri gibi piksel yoğunluklarına bağlı olan bazı algoritmaların uygulanması, mikrokalsifikasyonların görselliği üzerinde istenen etkilere sahip olmayacaktır. Bu nedenle, özel filtrelerin uygulanması gereklidir. Farklı filtrelerin kullanılmasının amacı, normal göğüs dokuları, damarlar, glandüler dokular, kanallar ve benzerlerinden oluşan arka plan dokularının bastırılması ve mikrokalsifikasyonların görünürlüğünün açık bir şekilde iyileştirilmesidir. Orijinal ROI'lerde mikrokalsifikasyonların görünümü arka plandaki glandüler dokuya oldukça benzerdir ve bu nedenle mikrokalsifikasyonların varlığı kolaylıkla tanımlanamaz.


Bu tez çalışmasında sayısal mamografilerde mikrokalsifikasyonların görünürlüğünün ve CAD sistemlerinde tespit oranlarının iyileştirilmesi için yeni bir filtre geliştirilmiştir. Bu amaç için, DDSM veri tabanından alınan mamogramlar mikrokalsifikasyon alanlarından ve normal alanlardan kırılarak işleme hazırlanmıştır. Tüm ROI'ler filtrelerin performansının karşılaştırılması için hem önerilen filtre ile hem de diğer filtrelerle ayrı ayrı filtrelenerek filtreli görüntüler elde edilmiştir. Ayrıca her bir ROI için bir kopya da orijinal hali ile bırakılmıştır. Sonrasında orijinal ve filtreli ROI'ler sınıflandırmada eşitlik olması amacı ile kontrast germe aşamasına tabi tutulmuştur. Kontrast germeli filtreli görüntülerden, genel olarak sıklıkla kullanılan özellikler olan ortalama, standart sapma, entropi, enerji, yamukluk ve basıklık özellik çıkarımı yapılmıştır. Hesaplanan değerleri normalize edilerek sınıflandırıcılara girdi olarak sunulmuş ve sınıflandırma sonuçları ROC eğrileri ile değerlendirilmiştir. Çalışmada tüm bu algoritmik fonksiyonların uygulanması için Matlab<sup>®</sup> R2016a programı ve uygun araç kutuları (Toolboxlar) kullanılmıştır. Bilgisayar programı Intel i7 işlemcili 12 GB RAM ile çalışılmıştır.

Filtrelerin mamografiler ve içerisinde bulunan mikrokalsifikasyonlara etkilerini gözlemek için öncelikle filtreli mamografi kesitlerinin bir bütün olarak verilmesi uygun bulunmuştur. Bunun için, aşağıda iki mikrokalsifikasyon bulunan ve bir mikrokalsifikasyon veya başka anomali bulunmayan, toplam üç kesit üzerinde filtrelerin etkileri gösterilmiştir.







(a)




(b)




(c)



(ç)



(d)




(e)


Şekil 4.1. A\_1201\_SAG\_MLO'dan alınan mikrokalsifikasyonlu ROI örneği ve bu görüntüden elde edilen filtreli-kontrast germeli ROI'ler  
(a) Kontrast germeli orijinal ROI, (b) Önerilen filtreli-kontrast germeli ROI, (c) Laplace filtreli-kontrast germeli ROI, (ç) Gabor filtreli-kontrast germeli ROI, (d) Top-hat filtreli-kontrast germeli ROI, (e) GHP filtreli-kontrast germeli ROI




(a)




(b)



(c)



(ç)




(d)




(e)


Şekil 4.2. A\_1496\_SOL\_MLO'dan alınan mikrokalsifikasyonlu ROI örneği ve bu görüntüden elde edilen filtreli-kontrast germeli ROI'ler  
(a) Kontrast germeli orijinal ROI, (b) Önerilen filtreli-kontrast germeli ROI, (c) Laplace filtreli-kontrast germeli ROI, (ç) Gabor filtreli-kontrast germeli ROI, (d) Top-hat filtreli-kontrast germeli ROI, (e) GHP filtreli-kontrast germeli ROI




(a)




(b)




(c)



(ç)



(d)



(e)

Şekil 4.3. D\_4528\_SAĞ\_MLO'dan alınan mikrokalsifikasyonsuz ROI örneği ve bu görüntüden elde edilen filtreli-kontrast germeli ROI'ler  
(a) Kontrast germeli orijinal ROI, (b) Önerilen filtreli-kontrast germeli ROI, (c) Laplace filtreli-kontrast germeli ROI, (ç) Gabor filtreli-kontrast germeli ROI, (d) Top-hat filtreli-kontrast germeli ROI, (e) GHP filtreli-kontrast germeli ROI

Şekil 4.1 ve Şekil 4.2’de mikrokalsifikasyonlu bir mamogram kesitinin filtrelerle filtrelenmiş halleri verilmektedir. (a)’da orijinal ROI’nin kontrast germe yapılarak elde edilen görüntüsü bulunmaktadır. Bu görüntülerde sadece mikrokalsifikasyonlar değil arka zemindeki kas/bağ dokusunun da bir kısmı yoğun yeşinlik değerlerine bürünmüştür. Özellikle Şekil 4.2(a)’da mikrokalsifikasyon kümesinin sol-alt çaprazında çok büyük bir kitle varmış gibi görünmektedir.

Şekil 4.3(a)’da ise mikrokalsifikasyon ya da başka anomalilerin olmadığı normal bir meme dokusuna ait mamogram kesiti görülmektedir.


Şekil 4.1, Şekil 4.2 ve Şekil 4.3 (b), (c), (ç), (d) ve (e)’deki görüntülerde sırasıyla önerilen filtre, Laplace filtre, Gabor filtre, Top-hat filtre ve GHP filtre çıktısının kontrast germe uygulanmış ROI’ler görülmektedir. Daha önce bahsedildiği gibi işleme alınan tüm filtreli ROI’ler ve orijinal ROI’ler kontrast germeye tabi tutularak piksel yeşinlikleri eşit seviyede tutulmuştur.

Şekil 4.1 ve Şekil 4.2’ de Laplace ve Gabor filtreli-kontrast germeli ROI’lerde çıplak göz ile mikrokalsifikasyonları tespit etmek oldukça güçtür. Buna karşın önerilen, Top-hat ve GHP filtreli-kontrast germeli ROI’lerde mikrokalsifikasyon kümeleri oldukça net görülebilmektedir. Çıplak gözle inceleme için en iyi sonuçların GHP ve önerilen filtrelerle elde edildiği söylenebilir.

Diğer bir örnek ise üzerinde mikrokalsifikasyon bulunmayan normal meme dokusuna sahip Şekil 4.3’teki mamogram görüntüsüdür. Bu görüntüde mikrokalsifikasyon olmadığı için filtrelerin arka zemindeki meme dokusunu doğru şekilde filtrelemesi beklenmektedir. Tüm filtreler bu görüntüde mikrokalsifikasyon olmadığını çıplak göz ile de belli olacak şekilde filtreleme işlemi gerçekleştirmiştir ancak Şekil 4.3(d)’de bulunan Top-hat filtreli-kontrast germeli ROI’lerde çıplak gözle bakıldığında mikrokalsifikasyon benzeri noktaların belirdiği görülebilir.

Buraya kadar mamografi kesitleri sadece çıplak gözle görünürlük açısından incelenmiştir. Bu çalışmanın devamında, elde edilen orijinal kontrast germeli veya filtreli-kontrast germeli ROI'ler sınıflandırmaya tabi tutulmuştur.

Sınıflandırma işlemi iki aşamada gerçekleşmiştir. 1. aşamada mamogramlar normal ve anormal olarak sınıflandırılırken, 2. aşamada ise mikrokalsifikasyon içeren mamogramlar iyi huylu ve kötü huylu olarak sınıflandırılmıştır (Şekil 4.4).



Şekil 4.4. Sınıflandırma aşamaları

DDSM veri tabanından alınan 219 mamogram kesiti mikrokalsifikasyon içerip içermemesine göre anormal ve normal olarak sınıflandırılmıştır. Mikrokalsifikasyon bulunan mamografi kesitleri hem iyi huylu hem de kötü huylu türleri için 95 mamografi kesiti anormal, mikrokalsifikasyon bulunmayan 124 kesit ise normal olarak etiketlenmiştir. Bu kesitlerden özellik çıkarımı yapılmıştır. Eşitlik 3.27'de verildiği gibi özellik vektörlerinin normalizasyonu sağlanmıştır. DDSM veri tabanından alınan mamografiler 2-kat çapraz doğrulama yöntemi ile %50 oranında eğitim ve test verisine ayrılmıştır. DDSM veri tabanından alınan mamografi kesitlerinin mikrokalsifikasyonların varlığını tespit etmeye yönelik CAD sistem için eğitim ve test veri dağılımları Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Mikrokalsifikasyon varlığı tespiti için eğitim ve test verilerinin dağılımı

DDSM Mamografi Kesitleri	Eğitim Verisi	Test Verisi	Toplam
Anormal	47	48	95
Normal	62	62	124
Toplam	109	110	219

Eđitim ve test verisine 2-kat apraz dođrulama yntemi ile ayrılan veriler SVM, MLPNN ve LDA sınıflandırıcılar ile sınıflandırılmıştır. Sınıflandırıcılara ilişkin parametre girdileri Sınıflandırma bölümünde verilmiştir. Bu sınıflandırıcılar ile elde edilen sınıflandırma sonuçları hem duyarlılık hem de özgülük deđerlerini gösterdiđi için ROC eđrisi ile gösterilmektedir.

Sınıflandırma işleminin 2. aşamasında anormal mamogram kesitleri iyi huylu ve kötü huylu olarak sınıflandırılmıştır. Bunun için önceki sınıflandırma aşamasında kullanılan anormal mamogram kesitleri kullanılmıştır. Her bir mamografi kesitine bulgular bölümünde belirtilen filtrelerle ve kontrast germe ile işlem yapılarak görüntüler özellik çıkarımı için uygun hale getirilmiştir. Özellik çıkarımı için ortalama, standart sapma, entropi, enerji, yamukluk ve basıklık özellik deđerleri hesaplanmıştır. Hesaplanan özellik vektörleri normalize edilerek özellikler verisi oluşturulmuştur. Özellik vektörleri 1. aşamada olduđu gibi 2-kat apraz dođrulama yntemi ile eđitim ve test veri setlerine ayrılmıştır. izelge 4.2’de mikrokalsifikasyonların türlerinin tespiti için kullanılan veri dağılımları görlmektedir.

izelge 4.2. Mikrokalsifikasyon türlerinin tespiti için eđitim ve test veri setlerinin dağılımı


Mikrokalsifikasyon Kesitleri	Eđitim Verisi	Test Verisi	Toplam
İyi Huylu	18	18	36
Kt Huylu	29	30	59
Toplam	47	48	95

#### 4.1. Mikrokalsifikasyonların Tespiti için CAD Sistemi

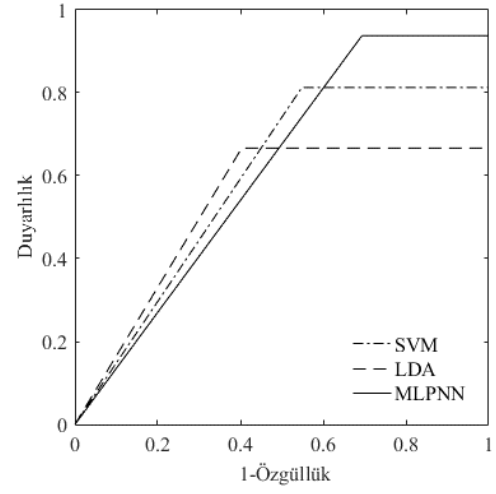
Mikrokalsifikasyonların bir mamografi kesitinin içerisinde bulunup bulunmadığına ait sınıflandırmaya ilişkin sonuçlar, Şekil 4.5’te görlmektedir. Şekil 4.5(a)’da kontrast germeli orijinal ROI’lerin sınıflandırma deneyleri için ROC analizi, (b)’de GHP filtreli-kontrast germeli ROI’lerin sınıflandırma deneyleri için ROC analizi, (c)’de Gabor filtreli-kontrast germeli ROI’lerin sınıflandırma deneyleri için ROC analizi, ()’de Top-hat

filtreli-kontrast germeli ROI'lerin sınıflandırma deneyleri için ROC analizi, (d)'de Laplace filtreli-kontrast germeli ROI'lerin sınıflandırma deneyleri için ROC analizi ve (e)'de önerilen filtreli-kontrast germeli ROI'lerin sınıflandırma deneyleri için ROC analizi sonuçları görülmektedir. Şekil 4.5(a)'ya göre kontrast germeli orijinal ROI'lerin ROC analizi iyi bir karar oranına sahip değildir. MLPNN ve SVM sınıflandırıcı için özgüllük %100'dür. Ancak her iki sınıflandırıcı için duyarlılık %60-62, TCC oranları %80-83 seviyelerindedir. Buna göre mikrokalsifikasyon içermeyen ROI'leri başarılı bir şekilde tespit ederken, mikrokalsifikasyon içeren ROI'lerin tespitinde başarılı değildir. Benzer şekilde Laplace filtreli-kontrast germeli ROI'lerin ROC eğrisi, orijinal olanlarla benzer bir niteliğe sahiptir. Öte yandan, Gabor filtreli-kontrast germeli ROI'ler ile GHPF filtreli-kontrast germeli ROI'lerin sınıflandırılmasında sınıflandırıcı modeller yetersiz genellemeye sahiptir ve tüm vakaları tek bir sınıf olarak etiketlemeye meyillidir.


Top-hat filtreli-kontrast germeli ROI'lerin ve önerilen filtreli-kontrast germeli ROI'lerin ROC analizi, diğerlerinden daha başarılı eğriler göstermektedir. Top-hat filtreli-kontrast germeli ROI'lerin, duyarlılık ve özgüllük değerleri LDA, MLPNN ve SVM için sırasıyla %75 ve %100, %83 ve %97, %83 ve %87'dir. Aynı şekilde TCC %89.09, %90.9 ve %87.28'dir. Önerilen filtreli-kontrast germeli ROI'lerin duyarlılık ve özgüllük değerleri, LDA, MLPNN ve SVM için sırasıyla %81 ve %98, %83 ve %94, %91 ve %89'dur. Önerilen filtreli-kontrast germeli ROI'lerin TCC oranları, her üç sınıflandırıcı için %89-%90.9 aralığındadır ve SVM sınıflandırıcı için en başarılı sonuçlar önerilen filtreli-kontrast germeli ROI'ler ile gerçekleşmiştir. Top-hat filtreli görüntüler için de sınıflandırma başarısı benzer şekilde yüksektir. Bu iki filtre LDA sınıflandırıcı için en başarılı sonuçları vermiştir.




(a) Kontrast germeli orijinal ROI'ler için




(b) GHP Filtreli-kontrast germeli ROI'ler için




(c) Gabor Filtreli-kontrast germeli ROI'ler için



(e) Top-hat Filtreli-kontrast germeli ROI'ler için



(d) Laplace Filtreli-kontrast germeli ROI'ler için



(e) Önerilen Filtreli-kontrast germeli ROI'ler için

Şekil 4.5. Mikrokalsifikasyonların varlığını saptamaya yönelik CAD sonuçlarının ROC analizi



MLPNN sınıflandırıcı için önerilen filtreden biraz daha iyi sonuç vermiştir. Tüm sınıflandırıcılar için Laplace filtreli-kontrast germeli ROI'lerin ve filtreli-kontrast germeli orijinal ROI'lerin sınıflandırma sonuçları sırasıyla üçüncü ve dördüncü sıradadır. GHP filtreli-kontrast germeli ROI'lerin sınıflandırma sonuçları ise MLPNN sınıflandırıcı için daha yüksek duyarlılığa sahip olmasına rağmen, bu çalışma için yetersiz filtrelerden biridir. Özgüllük değeri %30 olduğu için sınıflandırıcılar GHP filtreli-kontrast germeli ROI'lerin tüm vakalarını pozitif olarak işaretleme eğiliminde olduğunu göstermektedir. Üç sınıflandırıcının ortalama doğruluk oranları orijinal mamogramlar için %81.82, Gabor filtreli-kontrast germeli ROI'ler için %58.79, GHP filtreli-kontrast germeli ROI'ler için %60.6, Laplace filtreli-kontrast germeli ROI'ler için %84.55, Top-hat filtreli-kontrast germeli ROI'ler için %89.1 ve önerilen filtreli-kontrast germeli ROI'ler için %90'dır. Çizelge 4.3'te sınıflandırma başarıları detaylı olarak görülmektedir.


Çizelge 4.3. Mikrokalsifikasyon varlığını saptamaya yönelik sınıflandırma sonuçları

Kullanılan Filtre	Sınıflandırıcı Başarısı								
	SVM			LDA			MLPNN		
	Öz.*	Duy.**	TCC*	Öz.	Duy.	TCC	Öz.	Duy.	TCC
Orijinal	1.000	0.604	0.827	0.952	0.583	0.791	1.000	0.625	0.836
GHP	0.452	0.813	0.609	0.597	0.667	0.627	0.307	0.938	0.582
Gabor	0.484	0.708	0.582	0.532	0.729	0.618	1.000	0.000	0.564
Top-hat	0.871	0.875	0.873	1.000	0.750	0.891	0.968	0.833	0.909
Laplace	0.919	0.708	0.827	1.000	0.667	0.855	1.000	0.667	0.855
Önerilen	0.887	0.917	0.900	0.984	0.813	0.909	0.935	0.833	0.891

\* Özgüllük    \*\* Duyarlılık    \* TCC

Çizelge 4.3.'ten görüldüğü gibi Gabor filtre ile süzölmüş kesitlerde en düşük sınıflandırma doğruluğu elde edilmiştir. GHP filtre ise %50-%60 civarında doğruluk sağlayarak başarısını düşük tutmuştur. Orijinal kesitler %80 civarında başarı sağlamıştır. Top-hat, Laplace ve önerilen filtre ile süzölmüş kesitlerin duyarlılık, özgüllük ve doğruluk oranları birbirine yakındır ve %90 civarındadır.

Sınıflandırıcı başarısının seçilen eğitim ve test verisinden bağımsızlığını kontrol etmek amacıyla deney 100 kez farklı eğitim ve test gruplarıyla tekrarlanarak doğruluk oranları not edilmiştir. Doğruluk oranlarının ortalaması alınarak genel sıralama elde edilmiştir. Şekil 4.6'de tekrarlı sınıflandırmaya ilişkin doğruluk sonuçları görölmektedir.



Şekil 4.6. Mikrokalsifikasyonların varlığını tespit için tekrarlı sınıflandırma doğruluk sonuçları


Şekil 4.6'dan görüldüğü üzere, tekrarlı sınıflandırma sonuçlarına göre sırasıyla önerilen, Top-hat, Laplace filtreli-kontrast germeli ROI'ler en başarılı olmuştur. Filtre ile işleme alınmayan orijinal ROI'ler de %80'e kadar başarılı olmuştur. ROC analizi sonuçlarında olduğu gibi GHP ve Gabor filtreli-kontrast germeli ROI'lerde %30'lara kadar düşük bir doğruluk oranı vermektedir. Bu çalışmaya göre sınıflandırma başarısı o anki eğitim/test verisinden bağımsızdır, bu sebeple bir kez yapılan ve çok kez tekrarlanan sınıflandırma sonuçları aynı eğilimi göstermektedir.

## 4.2. Mikrokalsifikasyonların Sınıflandırılması için CAD Sistemi


Mikrokalsifikasyonlu mamogram kesitleri SVM, LDA ve MLPNN ile sınıflandırmanın 1. aşamasında kullanılan aynı parametreler kullanılarak sınıflandırılmıştır. Sınıflandırma sonuçları ROC eğrisi ile Şekil 4.7’de gösterilmektedir. Şekil 4.7(a) kontrast germeli orijinal ROI’nin ROC analizi, Şekil 4.7(b)’de GHP filtreli-kontrast germeli ROI’lerin ROC analizi, Şekil 4.7(c)’de Gabor filtreli-kontrast germeli ROI’lerin ROC analizi, (ç)’de Top-hat filtreli-kontrast germeli ROI’lerin ROC analizi, Şekil 4.7(d)’de Laplace filtreli-kontrast germeli ROI’lerin ROC analizi ve Şekil 4.7(e)’de önerilen filtreli-kontrast germeli ROI’lerin ROC analizi sonuçları görülmektedir. Mikrokalsifikasyonların türlerine göre sınıflandırılmasına ilişkin sınıflandırma sonuçları duyarlılık, özgüllük ve TCC oranlarıyla detaylı olarak Çizelge 4.4’te gösterilmiştir.

Çizelge 4.4. Mikrokalsifikasyonların türlerine göre sınıflandırılmasına ilişkin sınıflandırma sonuçları


Kullanılan Filtre	Sınıflandırıcı Başarısı								
	SVM			LDA			MLPNN		
	Öz.	Duy.	TCC	Öz.	Duy.	TCC	Öz.	Duy.	TCC
Orijinal	1.000	0.944	0.965	1.000	1.000	1.000	1.000	1.000	1.000
GHP	0.414	0.444	0.433	0.483	0.389	0.424	0.793	0.167	0.402
Gabor	0.483	0.500	0.494	0.483	0.611	0.563	0.724	0.444	0.549
Top-hat	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
Laplace	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
Önerilen	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000




(b) Kontrast germeli orijinal ROI'ler için




(a) GHP Filtreli-kontrast germeli ROI'ler için




(d) Gabor Filtreli-kontrast germeli ROI'ler için



(e) Top-hat Filtreli-kontrast germeli ROI'ler için



(ç) Laplace Filtreli-kontrast germeli ROI'ler için

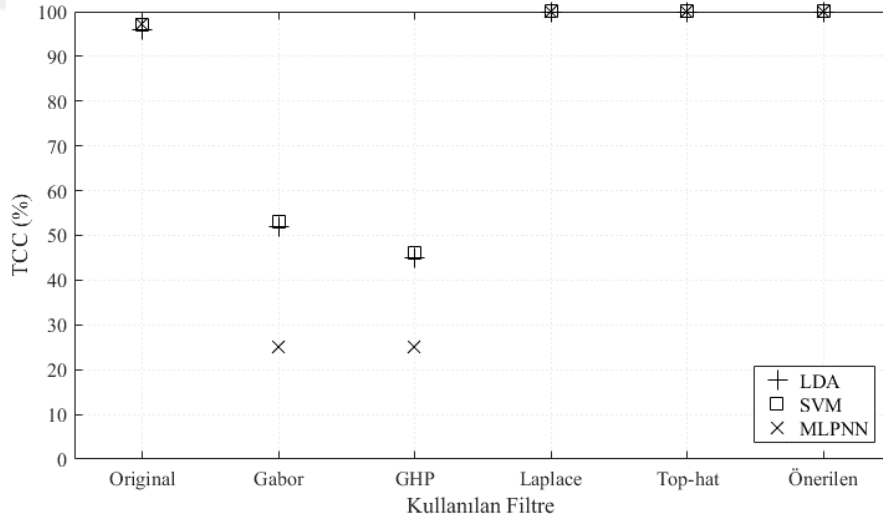


(c) Önerilen Filtreli-kontrast germeli ROI'ler için

Şekil 4.7. Mikrokalsifikasyonların türlerinin tespitine yönelik CAD sonuçlarının ROC analizi

Mamografi ROI'lerinde mikrokalsifikasyon türlerini sınıflandırma sonuçlarına göre, Gabor filtreli-kontrast germeli ROI'leri kullanan sınıflandırıcıların ROC analizi, SVM sınıflandırıcı için %49 gibi çok düşük bir sınıflandırma doğruluğunu göstermektedir. GHP filtreli-kontrast germeli ROI'lerin sınıflandırma oranları bu sınıflandırmada kullanılan tüm filtrelerden daha başarısızdır ve sadece %43'tür. Bu sonuç rastgelelilik sınırından bile daha düşük bir başarıdır. Gerçek sınıf etiketleri ve sonuç etiketleri arasında ters bir korelasyon vardır. Kontrast germeli orijinal ROI'lerin duyarlılık ve özgüllük değerleri SVM ve LDA sınıflandırıcılar için %100 iken, MLPNN sınıflandırıcı için %95'tir. Mikrokalsifikasyon türlerini sınıflandırmada en başarılı sonuçlar Laplace, Top-hat ve önerilen filtreli-kontrast germeli ROI'lere aittir. Laplace, Top-hat ve önerilen filtreli-kontrast germeli ROI'lerin ROC eğrisi, tüm sınıflandırıcılar için %100 TCC oranına ulaşmıştır.

Aynı sınıflandırma farklı eğitim ve test gruplarıyla 100 kez tekrarlanmıştır. Bu sınıflandırma sonuçlarının ortalaması Şekil 4.8'de görülmektedir.



Şekil 4.8. Mikrokalsifikasyonların türlerini tespit için tekrarlı sınıflandırma doğruluk sonuçları

Tekrarlı sınıflandırma sonuçları bir önceki detayları ROC analizi sonuçları destekler niteliktedir. Bu da sınıflandırmanın tesadüfi ve o anki girdilere bağlı olmadığını göstermektedir.

Bu çalışmada veri tabanından alınan mamografi görüntüleri çeşitli filtrelerle süzölmüş ve çeşitli sınıflandırıcılar ile sınıflandırılmıştır. Özet olarak mamografi görüntülerinin, filtrelerle süzöldükten sonra sınıflandırma sonuçları (mikrokalsifikasyon varlığına ve türlerine göre) Çizelge 4.5'te verilmiştir.

Çizelge 4.5. Uygulanan filtrelerin başarı özeti

	Görünörlük		Sınıflandırma	
	Mikrokalsifikasyonları Belirginleştirme	Arka Zemini Bastırma	Mikrokalsifikasyon Varlığını Tespit	Mikrokalsifikasyon Türlerini Tespit
Orijinal	Başarılı	Başarısız	%82	%99
Gabor	Başarısız	Başarılı	%59	%54
GHP	Başarılı	Başarılı	%61	%42
Laplace	Başarısız	Başarılı	%84	%100
Top-hat	Başarılı	Başarısız	%89	%100
Önerilen	Başarılı	Başarılı	%90	%100

Çalışmada kullanılan tüm filtrelerin görünörlük ve sınıflandırma bakımından değerlendirilmesiyle genel bir karşılaştırma yapılabilir. Burada önemli nokta filtrelerin mikrokalsifikasyon görünörlüğünü belirginleştirme ve arka zemini bastırma kriterleri Şekil 4.1, Şekil 4.2 ve Şekil 4.3'teki görüntüler kullanılarak sübjektif olarak değerlendirilmiştir. Buna göre mikrokalsifikasyonların görünörlüğünü belirginleştirmede kontrast germeli orijinal ROI'ler ve Top-hat filtreli-kontrast germeli ROI'ler başarılı olmasına karşın bu filtreler arka planı bastırmada başarılı olmamaktadır. Arka plandaki süt kanalları, fibro-glandüler doku vb. dokuları bastırma da yetersiz kalmışlardır. Gabor ve Laplace filtreli-kontrast germeli ROI'ler ise memenin arka zemin dokusunu bastırdıkları gibi mikrokalsifikasyonların görünörlüğünü de bastırmaktadır.

GHP ve önerilen filtreli-kontrast germeli ROI'ler ise hem mikrokalsifikasyonların görünürlüğünü belirginleştirmede hem de arka zemini bastırma da oldukça iyidir. Kontrast germeli orijinal ROI'lerin sınıflandırma başarısı SVM, LDA ve MLPNN sınıflandırıcıların TCC ortalaması olarak sırasıyla mikrokalsifikasyon varlığı ve türlerini tespit için %82 ve %99 başarılı olmuştur. Bu da seçilen mikrokalsifikasyon kesitlerinin doğru olarak seçildiğini göstermektedir. Gabor filtre hem görünürlük olarak hem de sınıflandırma başarısı olarak yetersiz kalmıştır. Burada Gabor filtre için çoklu veya hibrit filtre seçmek gerektiği, tekli Gabor filtrenin yetersiz olduğu düşünülmektedir. GHP filtre sınıflandırma başarısı olarak en düşük başarı oranına sahip filtrelerden biridir. Görünürlük olarak mikrokalsifikasyonları belirginleştirse de arkada ki gürültüyü de yoğunlaştırıp mikrokalsifikasyon gibi gösterdiği ve bu yüzden sınıflandırıcıların mikrokalsifikasyonları tespit edemediği düşünülmektedir. Bu filtrelerden Laplace filtre, görünürlük olarak çıplak gözle fark edilmeyecek şekilde işlem yapmasına rağmen sınıflandırma başarısı tüm sınıflandırıcıların doğruluk ortalaması olarak sırasıyla mikrokalsifikasyon varlığı ve türlerini tespit için %84, %100 başarılı olmuştur. Top-hat filtre ise Şekil 4.3'te olmayan mikrokalsifikasyon dokusunu mikrokalsifikasyon gibi göstermesine karşın sınıflandırmada, her 3 sınıflandırıcıların doğruluk ortalaması, %89, %100 başarı oranı vermiştir. Önerilen filtre hem mikrokalsifikasyonların görünürlüğünü vurgulamış, arka zemin dokusunu bastırılmış hem de sınıflandırma başarısı sınıflandırıcıların doğruluk ortalaması olarak %90, %100 oranında başarı elde etmiştir (Hekim ve ark., 2019). Bu tabloya göre önerilen filtre çıplak gözle fark edilebilir iyileştirme yapmanın yanında sınıflandırıcılar ile de yüksek duyarlılık ve özgüllük oranına sahip olduğu için tercih edilebilir.

## 5. TARTIŞMA ve SONUÇ

Meme kanseri hem ülkemizde hem de global ölçekte ölümcül komplikasyonları olan bir hastalıktır. Tedavide en önemli etken kanserin metastaz yapmadan, mümkün olan en erken evrede tespit edilmesidir. Kanser teşhisinde ve taramasında en ekonomik, yaygın ve başarılı araç mamografidir. Mamografide ultrason gibi diğer araçlarla görülemeyen en küçük kireçlenmeler yani olası kanser hücreleri tespit edilebilmektedir (Memiş, 2002) . Mamografilerin kireçlenmeleri göstermesindeki başarı, kanser teşhisi için mamografinin doğru okunmasına bağlıdır. Uzman hekimler tarafından okunan mamografiler büyük bir oranda doğru yorumlanmasına rağmen hasta yoğunluğu, deneyim, süre gibi etkenlerle bu oran düşebilmektedir. Bu problemi ortadan kaldırmak doğru teşhis oranını artırmak için bir mamografinin 2 hekim tarafından okunması sağlanmaktadır (Blanks ve ark., 1998; Bazzocchi ve ark., 2007). İkinci görüş olarak 2 hekimin görevlendirilmesi ise hem maliyetli hem de süre bakımından ekonomik değildir. Bu sebeple ikinci bir görüş olarak bilgisayarlı sistemler devreye girmektedir.

Bu tez çalışmasında, mikrokalsifikasyonların görünürlüğünü iyileştirme, belirginleştirme ve arka zemin dokusunu bastırma amacı ile bir filtre tasarımı yapmak hedeflenmiştir. Tasarımı yapılan filtre, uzamsal düzlemde çalışmaktadır ve piksel komşuluğu üzerinden işlem yapmaktadır. Görüntü işlemede filtre tasarımında, belirli bir maske katsayıları oluşturularak çarpımlarının toplamı mantığı ile hareket edilmesine rağmen, önerilen filtrede pikseller arası ilişkiye bakılmaktadır. Bir pikselin kendisini çevreleyen piksel komşuları ile olan büyüklüğü veya küçüklüğü baz alınmaktadır. Bu algorithmada süzölmüş piksel yeğlilik değerini, bir pikselin büyük ya da küçük olması değil aralarında fark vermektedir. Böylece yeni pikselin değeri arka zeminden bağımsız olmaktadır.

Önerilen süzgecin objektif olarak değerlendirilmesi için bir CAD sistemi gerçekleştirilmiştir. Önerilen filtre ile görünürlüğü belirginleştirilen mikrokalsifikasyon içeren ve içermeyen mamografi kesit görüntüleri ortalama, standart sapma, entropi, enerji, yamukluk ve basıklık istatistiksel özellik çıkarımı yapılarak sınıflandırıcılara girdi olarak sunulmuştur. Sınıflandırıcı olarak hem doğrusal hem de doğrusal olmayan,



literatürde sıklıkla kullanılan LDA, SVM ve MLPNN sınıflandırıcılar tercih edilmiştir. Sınıflandırıcı başarıları ROC analizi ile değerlendirilmiştir.

Kim ve arkadaşlarının yaptığı bir çalışmada mikrokalsifikasyon içeren mamografi bölgeleri %90 bir duyarlılık sınıflandırılırken, Mohamed ve arkadaşlarının yaptığı bir başka çalışmada ise mikrokalsifikasyon içeren mamografiler farklı sınıflandırıcıların ortalaması olarak %79 doğrulukla sınıflandırılmıştır (Kim ve ark., 1997; Mohamed ve ark., 2014). Bu tez çalışmasında, mikrokalsifikasyonların varlığını tespit etme sınıflandırma sonuçlarına göre 3 sınıflandırıcının ortalaması olarak duyarlılık %85.4 iken doğruluk %90'dır. Tez çalışmasında sadece filtreleme işlemi gerçekleştirilip morfolojik yöntemler, eşik yöntemleri, gürültü temizleme gibi başka görüntü işleme algoritmaları kullanılmamıştır. Karşılaştırılan çalışmalar ise bu algoritmaları kullanarak mikrokalsifikasyonlu bölgeyi sınıflandırmaya yönelik CAD sistemi tasarlamıştır.

Mikrokalsifikasyonların iyi huylu ve kötü huylu olarak sınıflandırma aşamasında Fu ve arkadaşları %98, Mohamed ve arkadaşları %69.6, Abdul ve arkadaşları %95.6 ve Shen ve arkadaşları %100 oranında doğruluk değeri vermektedir. Bu çalışmalarda sırasıyla morfolojik işlemler, eşik yöntemleri, kenar bulma algoritmaları ve bölge büyütme algoritmaları kullanılmıştır (Shen ve ark., 1994; Fu ve ark., 2005; Mohamed ve ark., 2014; Abdul ve ark., 2017). Tez çalışmasında ise sadece filtreleme işlemi gerçekleştirilmiş, her 3 sınıflandırıcı için ve her tekrarda TCC oranı %100 olarak elde edilmiştir.

Çalışmada mikrokalsifikasyonların belirginleştirilmesi için bir filtre tasarımı hedeflendiğinden CAD sistemi de en temel halde tutulmuştur. Çünkü CAD sistemine eşik yöntemleri, morfolojik işlemler, hibrit filtreleme gibi daha detaylı teknikler eklendiğinde elde edilen sınıflandırma başarısının filtreye ya da eklenen diğer tekniklere bağlı olup olmadığı bilinmeyecektir. Çalışmada sunulan CAD sistemine ait sınıflandırma sonuçlarına bakıldığında önerilen filtre en az diğer filtreler kadar başarılıdır.

## 6. KAYNAKLAR

- Abdul, M., Ahmed, J., Waqas, A. ve Sawand, A., 2017. Intelligent System for Detection of Micro-Calcification in Breast Cancer. *International Journal of Advanced Computer Science and Applications*, 8, (7), 382–387.
- Abubaker, A.A., 2015. Automatic Microcalcification Detection Using Wavelet Transform. 7, (1), 40–45.
- Abubaker, A., 2017. An Adaptive CAD System to Detect Microcalcification in Compressed Mammogram Images. *International Journal of Advanced Computer Science and Applications*, 8, (6), 133–138.
- Akbay, C., 2015. Application Of Image Enhancement Algorithms To Improve The Visibility And Classification Of Microcalcifications In Mammograms. *Middle East Technical University*, 1–98 p, 1–98pp.
- Andreadis, I.I., Spyrou, G.M. ve Nikita, K.S., 2015. A CADxScheme for mammography empowered with topological information from clustered microcalcifications' atlases. *IEEE Journal of Biomedical and Health Informatics*, 19, (1), 166–173.
- Avdan Aslan, A., 2013. Duktal Karsinoma İn Situ'da BI-RADS Tanımlayıcıları İle Moleküler Prognostik Faktörler Arasındaki İlişki. *Gazi Üniversitesi*.
- Aydın Yurdusev, A., Oral, C. ve Hekim, M., 2018a. The Investigation of the Effects of Different Filters on Mammogram Images. *Journal of Applied Sciences of Mehmet Akif Ersoy University*, 2, (1), 55–68.
- Aydın Yurdusev, A., Oral, C. ve Hekim, M., 2018b. Mamografi Normalizasyonunun Sınıflandırma Performansı Üzerindeki Etkileri. *İleri Teknoloji Bilimleri Dergisi Journal*, 7, (1), 75–82.
- Bankman, I.N., 2000. *Handbook Of Medical Imaging Processing And Analysis*. Academic Press, 69–80 p
- Bazzocchi, M., Mazzarella, F., Del Frate, C., Girometti, F. ve Zuiani, C., 2007. Sistemi CAD in mammografia: Reale opportunit??? Revisione della letteratura. *Radiologia Medica*, 112, (3), 329–353.
- Belhumeur, P.N., Hespanha, J.P. ve Kriegman, D.J., 1997. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19, (7), 711–720.
- Berg, W., Birdwell, R., Combs, E., Wang, S.-C., Raza, S., Green, G., Kettler, M. ve Kennedy, A., 2006. Mammography: Screening. In: *Diagnostic imaging Breast*. Amirsys, 11.
- Blanks, R.G., Wallis, M.G. ve Moss, S.M., 1998. A comparison of cancer detection rates achieved by breast cancer screening programmes by number of readers, for one and two view mammography: Results from the UK national health service breast screening programme. *Journal of Medical Screening*, 5, (4), 195–201.
- Bria, A., Marrocco, C., Borges, L.R., Molinara, M., Marchesi, A., Mordang, J.J., Karssemeijer, N. ve Tortorella, F., 2018. Improving the Automated Detection of Calcifications Using Adaptive Variance Stabilization. *IEEE Transactions on Medical Imaging*, 37, (8), 1857–1864.
- Campos, V.M., Martinez, J.M.S., Carron, C.B., Guirola, J.A. ve Gomez, J.A.F., 2013. Tracks to face a breast imaging and succeed. *European Society of Radiology*, 1–44.
- Chen, Z., Strange, H., Oliver, A., Denton, E.R.E., Boggis, C. ve Zwiggelaar, R., 2015. Topological Modeling and Classification of Mammographic Microcalcification

- Clusters. IEEE Transactions on Biomedical Engineering, 62, (4), 1203–1214.
- Dalkıran, İ. ve Danişman, K., 2010. Artificial neural network based chaotic generator for cryptology. Turk J Elec Eng & Comp Sci, 18, (2), 225–240.
- Daugman, J.G., 1985. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. Optical Society of America, 2, (7), 1160–1169.
- Daugman, J.G., 1988. Complete Discrete 2-D Gabor Transforms by Neural Networks for Image Analysis and Compression. IEEE Transactions on Acoustics, Speech, and Signal Processing, 36, (7), 1169–1179.
- Derpanis, K.G., 2007. Gabor filters (Lecture Notes).
- Dheeba, J. ve Selvi, S.T., 2012. A swarm optimized neural network system for classification of microcalcification in mammograms. Journal of Medical Systems, 36, (5), 3051–3061.
- Diaz-Huerta, C.C., Felipe-Riveron, E.M. ve Montaño-Zetina, L.M., 2014. Quantitative analysis of morphological techniques for automatic classification of microcalcifications in digitized mammograms. Expert Systems with Applications, 41, (16), 7361–7369.
- Elmoufidi, A., El Fahssi, K., Jai-andaloussi, S., Sekkaki, A., Gwenole, Q. ve Lamard, M., 2018. Anomaly classification in digital mammography based on multiple-instance learning. IET Image Processing, 12, (3), 320–328.
- Fajardo, L.L. ve Yang, L., 2016. Radiology Key Breast Imaging. Available at <https://radiologykey.com/11-breast-imaging/> (30.01.2018)
- Fischer, J.E., Bland, K.I. ve Callery, M.P. (ed.), 2007. Mastery of Surgery. Lippincott Williams & Wilkins, 494 p, Philadelphia, USA
- Fisher, R., Perkins, S., Walker, A. ve Wolfart, E., 1997. Hypermedia image processing reference. 318 p
- Fu, J.C., Lee, S.K., Wong, S.T.C., Yeh, J.Y., Wang, A.H. ve Wu, H.K., 2005. Image segmentation feature selection and pattern classification for mammographic microcalcifications. Computerized Medical Imaging and Graphics, 29, (6), 419–429.
- Gabor, D., 1946. Theory of communication. J. Institute of Electr. Eng., 93, 429–457.
- Ganesan, K., Acharya, U.R., Chua, K.C., Min, L.C. ve Abraham, K.T., 2013. Pectoral muscle segmentation: A review. Computer Methods and Programs in Biomedicine, 110, (1), 48–57.
- Gonzalez, R.C. ve Woods, R.E., 2014. Sayısal Görüntü İşleme. Palme Yayıncılık, 834 p, Ankara
- Gülsün, M., Başaran Demirkazık, F., Köksal, A. ve Arıyürek, M., 2002. Meme mikrokalsifikasyonlarının BI-RADS kriterlerine göre değerlendirilmesi ve yorumcular arasındaki uyumun araştırılması. Tanısal ve Girişimsel Radyoloji, 8, 358–363.
- Guo, Y., Dong, M., Yang, Z., Gao, X., Wang, K., Luo, C., Ma, Y. ve Zhang, J., 2016. A new method of detecting micro-calcification clusters in mammograms using contourlet transform and non-linking simplified PCNN. Computer Methods and Programs in Biomedicine, 0, (222), 31–45.
- Hacıkamiloğlu, E., Gültekin, M., Boztaş, G., Dündar, S., Utku, E.Ş., Kavak Ergün, A., Sevinç, A., Tütüncü, S., Seymen, E. ve Türkiye Halk Sağlığı Kurumu, 2017. Türkiye Kanser İstatistikleri. Türkiye Halk Sağlığı Kurumu, [www.kanser.gov.tr/daire-faaliyetleri/kanser-istati](http://www.kanser.gov.tr/daire-faaliyetleri/kanser-istati).(22.08.2017)
- Haralick, R.M., Shanmugam, K., Dinstein, I.I., Haralick M., R., Shanmugam, K.,

- Dinstein, I.I., Haralick, R.M., Shanmugam, K. ve Dinstein, I.I., 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics SMC-3*, 6, (6), 610–621.
- Heath, M., Bowyer, K., Kopans, D., Moore, R. ve Kegelmeyer, W.P., 2001. The Digital Database for Screening Mammography. In: M.J. Yaffe (Editör) *Proceedings of the Fifth International Workshop on Digital Mammography*. Medical Physics Publishing, 212–218.
- Hekim, M., 2016. The classification of EEG signals using discretization-based entropy and the adaptive neuro-fuzzy inference system. *Turkish Journal of Electrical Engineering and Computer Sciences*, 24, (1), 285–297.
- Hekim, M., Aydın Yurdusev, A. ve Oral, C., 2019. The Detection and Classification of Microcalcifications in the Visibility-Enhanced Mammograms Obtained by using the Pixel Assignment-Based Spatial Filter. *Advances in Electrical and Computer Engineering*, 19, (4), 73–82.
- Hupse, R. ve Karssemeijer, N., 2009. Use of normal tissue context in computer-aided detection of masses in mammograms. *IEEE Transactions on Medical Imaging*, 28, (12), 2033–2041.
- Junoh, A.K. ve Mansor, M.N., 2012. Safety System Based on Linear Discriminant Analysis. *International Symposium on Instrumentation & Measurement, Sensor Network and Automation (IMSNA)*, 32–34.
- Kamgar-Parsi, B., Kamgar-Parsi, B. ve Rosenfeld, A., 1997. Optimum Laplacian for Digital Image Processing. *International Conference on Image Processing*, 0–3.
- Kim, J.K. ve Park, H.W., 1999. Statistical textural features for detection of microcalcifications in digitized mammograms. *IEEE Transactions on Medical Imaging*, 18, (3), 231–238.
- Kim, J.K., Park, J.M., Song, K.S. ve Park, H.W., 1997. Adaptive mammographic image enhancement using first derivative and local statistics. *Medical Imaging, IEEE Transactions on*, 16, (5), 495–502.
- Kruizinga, P. ve Petkov, N., 1999. Nonlinear Operator for Blob Texture Segmentation. *IEEE Transactions on Image Processing*, 8, (1), 881–885.
- Kumar, M., Thakkar, V.M., Bhaduria, H.S., Kumar, I. ve Pant, G.B., 2016. Mammogram 's Denoising in Spatial and Frequency Domain. In: 2016 2nd International Conference on Next Generation Computing Technologies (NGCT). IEEE, Dehradun, 654–659.
- Kuş, P. ve Karagöz, I., 2013. Detection of microcalcification clusters in digitized X-ray mammograms using unsharp masking and image statistics. *Turkish Journal of Electrical Engineering and Computer Sciences*, 21, (suppl. 1), 2048–2061.
- Lee, S., Jin Park, S., Jeon, J.M., Lee, M.-H., Ryu, D.Y., Lee, E., Kang, S.-H. ve Lee, Y., 2018. Noise removal in medical mammography images using fast non-local means denoising algorithm for early breast cancer detection: a phantom study. *Optik*, 180, (november 2018), 569–575.
- Lewin, R., Amoroso, M., Plate, N., Trogen, C. ve Selvaggi, G., 2016. The Aesthetically Ideal Position of the Nipple–Areola Complex on the Breast. *Aesthetic Plastic Surgery*, 40, (5), 724–732.
- Li, Y., Chen, H., Yang, Y. ve Yang, N., 2013. Pectoral muscle segmentation in mammograms based on homogenous texture and intensity deviation. *Pattern Recognition*, 46, (3), 681–691.
- Liu, C.-C., Tsai, C.-Y., Liu, J., Yu, C.-Y. ve Yu, S.-S., 2012. A pectoral muscle

- segmentation algorithm for digital mammograms using Otsu thresholding and multiple regression analysis. *Computers & Mathematics with Applications*, 64, (5), 1100–1107.
- Malich, A., Fischer, D.R. ve Böttcher, J., 2006. CAD for mammography: The technique, results, current role and further developments. *European Radiology*, 16, (7), 1449–1460.
- Matsunaga, T., Nakamura, Y., Mimuro, M., Fujii, M., Kusama, M., Kaise, H. ve Koyanagi, Y., 1998. Chronological changes of microcalcifications of breast carcinoma. *Breast Cancer*, 5, (3), 269–277.
- Memiş, A., 2002. Meme Radyolojisi. 1–8 p
- Mencattini, A., Salmeri, M., Rabottino, G. ve Salicone, S., 2010. Metrological characterization of a CADx system for the classification of breast masses in mammograms. *IEEE Transactions on Instrumentation and Measurement*, 59, (11), 2792–2799.
- Mohamed, H., Mabrouk, M.S. ve Sharawy, A., 2014. Computer aided detection system for micro calcifications in digital mammograms. *Computer Methods and Programs in Biomedicine*.
- Movellan, J.R., 2002. Tutorial on Gabor Filters
- Murthy, R.K., Valero, V. ve Buchholz, T.A., 2016. Breast Cancer. In: *Clinical Radiation Oncology*. 1284-1302.e3.
- Nagaiah, K., Manjunathachari, K. ve Rajinikanth, T. V., 2016. Advanced image enhancement method for mammogram analysis. 2016 International Conference on Recent Trends in Information Technology (ICRTIT), 1–5.
- Naveed, N., Hussain, A., Arfan Jaffar, M. ve Choi, T.S., 2012. Quantum and impulse noise filtering from breast mammogram images. *Computer Methods and Programs in Biomedicine*, 108, (3), 1062–1069.
- Oral, C., 2011. Sayısal Mamografi Görüntülerine Yapay Zeka Yöntemlerinin Uygulanması. Ondokuz Mayıs Üniversitesi, 1–118 p, 1–118pp.
- Oral, C., Yurdusev, A. ve Berg, E., 2019. Mamogramların Sınıflandırılmasında Dokusal Özelliklerin Etkileri. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10, (1), 23–33.
- Özşen, Ö., 2004. Mamogramlar Üzerinde Uygulanan Görüntü İşleme Tekniklerinin İncelenmesi. 1–5 p
- Öztemel, E., 2003. Yapay Sinir Ağları. Papatya Yayıncılık, 231 p, İstanbul
- Panahi, N., Shayesteh, M.G., Mihandoost, S. ve Zali Varghahan, B., 2011. Recognition of different datasets using PCA, LDA, and various classifiers. 2011 5th International Conference on Application of Information and Communication Technologies, AICT 2011.
- Petkov, N. ve Kruizinga, P., 1997. Biological Cybernetics Computational models of visual neurons specialised in the detection of periodic and aperiodic oriented visual stimuli : bar and grating cells. *Biological Cybernetics*, 76, 83–96.
- Petrick, N., Sahiner, B., Chan, H.P., Helvie, M.A., Paquerault, S. ve Hadjiiski, L.M., 2002. Breast cancer detection: evaluation of a mass-detection algorithm for computer-aided diagnosis -- experience in 263 patients. *Radiology*, 224, (1), 217–224.
- Qian, W., Sun, W. ve Zheng, B., 2015. Improving the efficacy of mammography screening: the potential and challenge of developing new computer-aided detection approaches. *Expert review of medical devices*, 12, (5), 497–9.

- Rabidas, R., Midya, A., Chakraborty, J. ve Arif, W., 2016. A Study of Different Texture Features Based on Local Operator for Benign-malignant Mass Classification. *Procedia Computer Science*, 93, (september), 389–395.
- Rangayyan, R.M., 2004. *Biomedical Image Analysis*.
- Redman, A., Lowes, S. ve Leaver, A., 2015. Imaging techniques in breast cancer. *Surgery (United Kingdom)*, 34, (1), 8–18.
- Ren, J., 2012. ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging. *Knowledge-Based Systems*, 26, 144–153.
- Ricks, D., 2005. *Breast Cancer Basics and Beyond*. Hunter House Inc., Publishers, 355 p, Alameda
- Romualdo, L.C.D.S., Vieira, M.A.D.C. ve Schiabel, H., 2009. Mammography images restoration by quantum noise reduction and inverse MTF filtering. *Proceedings of SIBGRAPI 2009 - 22nd Brazilian Symposium on Computer Graphics and Image Processing*, (1), 180–185.
- Sağlık Bakanlığı, H.S.G.M., 2017. TC Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü Kanser Daire Başkanlığı. <https://hsgm.saglik.gov.tr/tr/kanser-taramalari> (18.09.2017)
- Sahiner, B., Chan, H.P., Petrick, N., Wei, D., Helvie, M.A., Adler, D.D. ve Goodsitt, M.M., 1996. Classification of mass and normal breast tissue: A convolution neural network classifier with spatial domain and texture images. *IEEE Transactions on Medical Imaging*, 15, (5), 598–610.
- Saraswathi, D. ve Srinivasan, E., 2017. Performance Analysis of Mammogram CAD System Using SVM and KNN Classifier. In: *International Conference on Inventive Systems and Control*. IEEE, Coimbatore, India, 1–5.
- Shaikh, S., 2016. Analysis of Digital Image Filters in Frequency Domain. *International Journal of Computer Applications*, 140, (6), 12–19.
- Shen, L., Rangayyan, R.M. ve Desautels, J.E.L., 1994. Application of Shape-Analysis to Mammographic Calcifications. *IEEE Transactions on Medical Imaging*, 13, (2), 263–274.
- Shi, P., Zhong, J., Rampun, A. ve Wang, H., 2018. A hierarchical pipeline for breast boundary segmentation and calcification detection in mammograms. *Computers in Biology and Medicine*, 96, (march), 178–188.
- Shih, F.Y., 2009. *Image Processing and Mathematical Morphology Fundamentals and Applications*. CRC Press, 416 p, Boca Raton
- Smithuis, R. ve Pijnappel, R., 2008. Breast - Calcifications Differential Diagnosis. <http://www.radiologyassistant.nl/en/p4793bfde0ed53/breast-calcifications-differential-diagnosis.html> (16.04.2018)
- Soltanian-Zadeh, H., Rafiee-Rad, F. ve Siamak Pourabdollah-Nejad, D., 2004. Comparison of multiwavelet, wavelet, Haralick, and shape features for microcalcification classification in mammograms. *Pattern Recognition*, 37, (10), 1973–1986.
- Suckling, J., Hutt, I., Boggis, C.R.M., Astley, S., Betal, D., Cerneaz, N., Dance, D.R., Kok, S.-L., Parker, J., Ricketts, I., Savage, J., Stamatakis, E. ve Taylor, P., 1994. The Mammographic Image Analysis Society Digital Mammogram Database. In: *International Congress Series*. International Congress Series, 375–378.
- Suhail, Z., Sarwar, M. ve Murtaza, K., 2015. Automatic detection of abnormalities in mammograms. *BMC Medical Imaging*, 15, (1), 1–8.
- Sultana, A., Ciuc, M. ve Strungaru, R., 2010. Detection of Pectoral Muscle in

- Mammograms using a Mean-Shift Segmentation Approach. In: 2010 8th International Conference on Communications. 165–168.
- Tang, J., Member, S., Rangayyan, R.M., Xu, J. ve Naqa, I. El, 2009. Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography : Recent Advances. 13, (2), 236–251.
- Türkiye Meme Vakfı, 2007. Meme Sağlığı Teşhis Yöntemleri. *Available at* <http://www.memekanseri.org/teshis?yentemleri/4576129656> (11.04.2016).
- Übeyli, E.D. ve Güler, I., 2004. Multilayer perceptron neural networks to compute quasistatic parameters of asymmetric coplanar waveguides. *Neurocomputing*, 62, (1–4), 349–365.
- Valarmathi, P. ve Robinson, S., 2014. Efficacy of Feature Selection Techniques for Multilayer Perceptron Neural Network to Classify Mammogram. *International Conference on Advanced Computing (ICoAC)*, 26–31.
- Vijikala, V. ve Anto Sahaya Dhas, D., 2016. Identification of Most Preferential Denoising Method for Mammogram. In: *Conference on Emerging Devices and Smart Systems (ICEDSS)*. IEEE, Namakkal.
- Wang, T.C. ve Karayiannis, N.B., 1998. Detection of microcalcifications in digital mammograms using wavelets. *IEEE transactions on medical imaging*, 17, (4), 498–509.
- Yılmaz, M.H., 2006. Meme Kanserinde Radyolojik Tanı ve Değerlendirme. *İ.Ü.Cerrahpaşa Tıp Fakültesi Sürekli Tıp eğitimi Etkinlikleri*, (54), 27–30.
- Young, I.T., Gerbrands, J.J. ve van Vliet, L.J., 2007. *Fundamentals of Image Processing*. Delft University of Technology, 1–112 p
- Yu, S. ve Guan, L., 2000. A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films. *IEEE transactions on medical imaging*, 19, (2), 115–126.
- Zheng, B., Qian, W. ve Clarke, L.P., 1996. Digital mammography: mixed feature neural network with spectral entropy decision for detection of microcalcifications. *IEEE Transactions on Medical Imaging*, 15, (5), 589–597.
- Zheng, N. ve Xue, J., 2009. *Statistical Learning and Pattern Analysis for Image and Video Processing*. Springer, 365 p, New York
- Zonderland, H. ve Smithuis, R., 2014. *Bi-RADS for Mammography and Ultrasound 2013*.

## 7. ÖZGEÇMİŞ

**Adı Soyadı** : Ayşe AYDIN YURDUSEV  
**Doğum Yeri** : Kütahya  
**Doğum Tarihi** : 1985  
**Medeni Hali** : Evli  
**Yabancı Dil** : İngilizce

### Eğitim Durumu

#### Yüksek Lisans

– The University of Leeds- Elektronik ve Elektrik Mühendisliği Bölümü – 2012 – Leeds/İngiltere

#### Lisans

– Mersin Üniversitesi- Elektronik Eğitimi Bölümü – 2007- Mersin/Türkiye

#### Lise

– Haydarpaşa Teknik Lisesi -Elektronik Bölümü -2003 -İstanbul/Türkiye

### Kurslar

– University Collage London – English for Academic Purposes- 2011 – Londra/İngiltere  
– Hacettepe Üniversitesi – IELTS hazırlık kursu – 2010- Ankara/Türkiye

### Burslar

– 5 yılda 5000 öğrenci projesi kapsamında 1416 sayılı kanun ile Yurtdışı Yüksek Öğrenim Bursu (2009)

### İş Deneyimi

– Amasya Üniversitesi – Teknoloji Fakültesi- Elektrik-Elektronik Mühendisliği- Araştırma Görevlisi 2013- Halen

**İletişim Bilgileri** : Amasya Üniversitesi Teknoloji Fakültesi Amasya/Türkiye

**Telefon** : 0358 211 50 05 / 1495

**E-Posta** : ayse.yurdusev@amasya.edu.tr



## Yayınlar

Aydın Yurdusev, A., Hekim, M., ve Oral, C. (2016). Pectoral Muscle Elimination and Mammography Normalization. Uluslararası Akdeniz Bilim ve Mühendislik Kongresi (IMSEC 2016), Adana.

Aydın Yurdusev, A., Oral, C., ve Hekim, M. (2017). Mamografi Normalizasyonunun Sınıflandırma Performansı Üzerindeki Etkileri. Uluslararası Mühendislik Araştırmaları Sempozyumu (UMAS'2017), Düzce.

Oral, C., Bergil, E., ve Aydın Yurdusev, A. (2017). Mamogram Sınıflandırmada Morfolojik İşlemlerin Etkilerinin İncelenmesi. Uluslararası Mühendislik Araştırmaları Sempozyumu (UMAS'2017), Düzce.

C. Oral, A. Aydın Yurdusev, and E. Bergil, The Investigation Of First Order And Second Order Textural Features Effects In Mammograms Classification. International Conference on Advanced Technology & Sciences (ICAT'Rome), Roma, 2016.

Aydın Yurdusev, A., Oral, C., ve Hekim, M. (2017). Mamografi İmgelerini Farklı Filtreler İle Filtreleme. Uluslararası Bilimsel ve Mesleki Çalışmalar Sempozyumu, (BİLMES'2017) Nevşehir.

Aydın Yurdusev A., Oral C., Hekim M. (2018). The Investigation of the Effects of Different Filters on Mammogram Images. Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi, (MAKUUBD). 2(1), 55-68  
<https://doi.org/10.31200/makuubd.346442>

Aydın Yurdusev, A., Oral, C., ve Hekim, M. (2018). Mamografi Normalizasyonunun Sınıflandırma Performansı Üzerindeki Etkileri. Düzce Üniversitesi İleri Teknoloji Bilimleri Dergisi, 7(1), 75–82.

Oral, C, Aydın Yurdusev, A, ve Bergil, E. (2019). Mamogramların Sınıflandırılmasında Dokusal Özelliklerin Etkileri. DÜMF Mühendislik Dergisi, 10 (1), 23-33. DOI: 10.24012/dumf.403657

M. Hekim, A. Aydın Yurdusev, C. Oral. "The Detection and Classification of Microcalcifications in the Visibility-Enhanced Mammograms Obtained by using the Pixel Assignment-Based Spatial Filter", Advances in Electrical and Computer Engineering, 19(4), 2019. DOI: 10.4316/AECE.2019.04009

### **Projeler**

Bergil E, Oral C, Aydın Yurdusev A. Meme Kanserinin Bilgisayar Destekli Teşhisinde Özellik Çıkarım Yöntemlerinin Etkilerinin İncelenmesi. Araştırmacı. Bilimsel Araştırma Projesi, FMB-BAP 16-0181. 2016-2017.