

Mamogram İmgelerinde Göğüs Kanseri Teşhisi

Onur Kılınç

**YÜKSEK LİSANS TEZİ**

Elektrik Elektronik Mühendisliği Anabilim Dalı

Ağustos 2013

Breast Cancer Diagnosis on Mammogram Images

Onur Kılınç

**MASTER OF SCIENCE THESIS**

Department of Electrical and Electronics Engineering

August 2013

# Mamogram İmgelerinde Göğüs Kanseri Teşhisi

Onur Kılınç

Eskişehir Osmangazi Üniversitesi  
Fen Bilimleri Enstitüsü  
Lisansüstü Yönetmeliği Uyarınca  
Elektrik Elektronik Mühendisliği Anabilim Dalı  
Telekomünikasyon / Sinyal İşleme Bilim Dalı  
YÜKSEK LİSANS TEZİ  
Olarak Hazırlanmıştır

Danışman: Yrd. Doç. Dr. Semih Ergin

Ağustos 2013

## ONAY

Elektrik Elektronik Mühendisliđi Anabilim Dalı Yüksek Lisans öđrencisi Onur Kılınç'ın YÜKSEK LİSANS tezi olarak hazırladıđı “Mamogram İmgelerinde Göğüs Kanseri Teşhisi” başlıklı bu çalıřma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek kabul edilmiřtir.

**Danıřman** : Yrd. Doç. Dr. Semih ERĐİN

**İkinci Danıřman** : -

**Yüksek Lisans Tez Savunma Jürisi:**

**Üye** : Yrd. Doç. Dr. Semih ERĐİN

**Üye** : Prof. Dr. M. Bilginer GÜLMEZOĐLU

**Üye** : Yrd. Doç. Dr. Serkan GÜNAL

**Üye** : Yrd. Doç. Dr. Hatice ÇINAR AKAKIN

**Üye** : Yrd. Doç. Dr. Alper Kürřat UYSAL

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararıyla onaylanmıřtır.

Prof. Dr. Nimetullah BURNAK

Enstitü Müdürü

## ÖZET

Bu tezde, mamogram imgeleri kullanılarak çağımızda en sık karşılaşılan kanser türlerinden biri olan göğüs kanserinin tanısı ve teşhisi hedeflenmiştir. Bu amaç doğrultusunda, tezin ilk aşamasında, X-ışını mamogramları üzerinden normal ve kanserli dokuyu ayırt etmek için çalışmalar yapılmıştır. Bu kapsamda, Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı, HOG), Dense Scale Invariant Feature Transform (Ölçekten Bağımsız Yoğun Öznitelik Dönüşümü, DSIFT), Local Configuration Pattern (Yerel Konfigürasyon Örüntüsü, LCP) öznitelik çıkartma yöntemleri kullanılmıştır. Elde edilen öznitelikler, Support Vector Machine (Destekçi Vektör Makinesi, SVM), K-Nearest Neighbour (K-En Yakın Komşu, KNN), Fisher Linear Discriminant Analysis (Fisher Doğrusal Ayırtaç Analizi, FLDA) ve Karar Ağacı sınıflandırıcılarına tabi tutulmuş ve %100 tanıma oranı başarıyla sağlanmıştır. Tezin ikinci aşamasında ise, normal, iyi huylu ve kötü huylu göğüs kanseri yapılarının sınıflandırılması amaçlanmıştır. Bu bağlamda, öncelikle, iki sınıflı çalışmada kullanılan yöntemler tekrarlanmış olup; istenilen sonuçlar alınamamıştır. Başarı oranlarını arttırmak için, iki adet farklı ve yeni yaklaşım bu tez kapsamında önerilmiştir. Bu yaklaşımlardan ilki, öznitelik çıkartım adımından önce bazı ön işlemler uygulanmasını öngören ve çeşitli ağırlıklandırma parametrelerine sahip Weighted-Wavelet LCP (Ağırlıklı Dalgacık Yerel Konfigürasyon Örüntüsü, WWLCP) yöntemidir. Önerilen yaklaşımlardan ikincisi ise, iki sınıflı çalışmada %100 başarı sağlamış öznitelik çıkartma yöntemini kullanarak öncelikle normal dokuların düzgün bir şekilde ayrılmasını sağlayan ve ardından WWLCP yöntemini kullanarak iyi huylu-kötü huylu kanser dokusu teşhisini gerçekleştiren iki seviyeli çalışmadır. Bu iki seviyeli çalışmada, IRMA (Image Retrieval in Medical Applications) projesi kapsamında edinilmiş veritabanı için % 99,20 gibi üstün bir sınıflandırma başarısına ulaşılmıştır.

Anahtar Kelimeler: Göğüs Kanseri, Dijital Mamografi, Bilgisayar Destekli Tanı, Dense Scale Invariant Feature Transform, Local Configuration Pattern, Histogram of Oriented Gradients, Destekçi Vektör Makinesi, K-En Yakın Komşu, Karar Ağacı, Fisher Doğrusal Ayırtaç Analizi.

## SUMMARY

This thesis aims to make detection and diagnosis of breast cancer which is the most frequently seen cancers in this day and age. Firstly, a two-class classification, normal and cancerous breast tissue detection is performed on X-ray mammograms images toward this purpose. Within this scope, Histogram of Oriented (HOG), Dense Scale Invariant Feature Transform (DSIFT), Local Configuration Pattern (LCP) feature extraction techniques are used. Extracted features are used to train and test the following classifiers; Support Vector Machine (SVM), K-Nearest Neighbour (KNN), Fisher Linear Discriminant Analysis (FLDA) and Decision Tree which results recognition rates of 100%. Secondly, classification of normal, benign and malignant structures on digitized mammograms are tried to be performed. To do so, same feature extraction techniques of two-class classification are used. Though, satisfactory results could not be met. Two different newly proposed approaches are presented to increase classification results. First one uses some pre-processing methods and different weighting parameters named Weighted-Wavelet LCP (WWLCP). Second approach, proposes a two level classification that combines feature extraction techniques that have 100% performance in classifying normal tissues against cancerous ones with WWLCP method which distinguishes benign and malignant tumors accurately. Outstanding results are obtain as 99,20 % for the database that is retrieved by IRMA (Image Retrieval in Medical Applications) project with the presented two-level classification technique.

Keywords: Breast Cancer, Digital Mammography, Computer-Aided Diagnosis, Dense Scale Invariant Feature Transform, Local Configuration Pattern, Histogram of Oriented Gradients, Support Vector Machine, K-Nearest Neighborhood, Decision Tree, Fisher Linear Discriminant Analysis.

## TEŞEKKÜR

Yönlendirmeleri ve çalışma disiplini dolayısıyla danışmanım Yrd. Doç. Dr. Semih Ergin'e, tez çalışmasında kullanılan veri setini sağladığı için Almanya'nın Aachen Üniversitesi Medikal Bilişim Bölümü'ndeki Prof. Dr. T.M. Deserno'ya, bana tezimle ilgili çalışmalarda yol gösteren Araş. Gör. Zuhal Kurt'a ve Araş. Gör. İsmail San'a, destekleri için Araş. Gör. Altan Onat, Araş. Gör. Can Uysal ve Araş. Gör. Gökçe Mehmet Ay'a teşekkürü bir borç bilirim. Ayrıca bütün bu süreçte bana destek olan aileme özel teşekkürlerimi sunarım.

## İÇİNDEKİLER

### Sayfa

<b>ÖZET .....</b>	<b>V</b>
<b>SUMMARY .....</b>	<b>VI</b>
<b>TEŞEKKÜR .....</b>	<b>vii</b>
<b>İÇİNDEKİLER .....</b>	<b>viii</b>
<b>ŞEKİLLER DİZİNİ.....</b>	<b>XI</b>
<b>ÇİZELGELER DİZİNİ.....</b>	<b>XIII</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ .....</b>	<b>XVI</b>
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. ÖZİNİTELİK ÇIKARTIM YÖNTEMLERİ .....</b>	<b>6</b>
2.1    Yönlendirilmiş Gradyanların Histogramı Betimleyicisi .....	6
2.2    Ölçekten Bağımsız Öznitelik Dönüşümü Betimleyicisi.....	8
2.2.1    Ölçek Uzayı Uç Noktalarının Bulunması.....	8
2.2.2    Karşıtlığı Düşük Bölgeler ve Kenarların Elenmesi .....	9
2.2.3    Dönme Açısı ve Ölçekten Bağımsızlaştırma.....	9
2.2.4    Hücrelerin Betimlenmesi.....	10
2.2.5    Ölçekten Bağımsız Yoğun Öznitelik Dönüşümü Betimleyicisi.....	12
2.3    Yerel Konfigürasyon Örüntü Betimleyicisi .....	13
2.4    Gabor Dalgacık Öznitelikleri .....	14
<b>3. SINIFLANDIRICILAR.....</b>	<b>17</b>
3.1    K-En Yakın Komşu Sınıflandırıcısı .....	17
3.2    Karar Ağacı Sınıflandırıcısı .....	18
3.3    Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısı.....	19
3.4    Destekçi Vektör Makinesi Sınıflandırıcısı .....	20

## İÇİNDEKİLER (devam)

### Sayfa

<b>4. DENEYSEL ÇALIŞMALAR.....</b>	<b>22</b>
4.1 Veritabanları.....	22
4.1.1 DDSM Veritabanı.....	23
4.1.2 IRMA Veritabanı.....	24
4.1.3 MIAS Veritabanı .....	24
4.1.4 LLNL Veritabanı .....	24
4.2 İki Sınıflı Örüntü Tanıma Problemi Üzerine Yapılan Çalışmalar.....	25
4.2.1 Giriş .....	25
4.2.2 HOG Özniteliklerinin Çıkartılması .....	26
4.2.3 DSIFT Özniteliklerinin Çıkartılması.....	27
4.2.4 LCP Özniteliklerinin Çıkartılması.....	27
4.2.5 İki Sınıflı Örüntü Tanıma Sonuçları.....	28
4.3 Üç Sınıflı Örüntü Tanıma Üzerine Yapılan Çalışmalar .....	29
4.3.1 Giriş .....	29
4.3.2 İki Sınıflı Çalışmada Kullanılan Yöntem ile Alınan Sonuçlar .....	30
4.4.3 Gabor Dalgacık Özniteliklerinin Çıkartılması.....	31
4.4 Üç sınıflı Örüntü Tanıma Üzerine Yeni Bir Yaklaşım .....	33
4.4.1 Yerel-Olmayan Ortalama Filtresi .....	33
4.4.2 HOG Özniteliklerinin Çıkartılması .....	36
4.4.3 DSIFT Özniteliklerinin Çıkartılması .....	36
4.4.4 LCP Özniteliklerinin Çıkartılması.....	37
4.4.5 Üç Sınıflı Örüntü Tanıma Sonuçları.....	38
4.5 İki Seviyeli Yeni Bir Örüntü Tanıma Yaklaşımı .....	42
4.5.1 İki Seviyeli Yaklaşımında İzlenen Süreç.....	42
4.5.2 İki Seviyeli Örüntü Tanıma Sonuçları.....	44
4.6 Deneysel Çalışmalarda Geliştirilen Kullanıcı Grafik Arayüzü.....	45

**İÇİNDEKİLER (devam)****Sayfa**

<b>5. SONUÇLAR VE TARTIŞMA.....</b>	<b>47</b>
<b>6. KAYNAKLAR DİZİNİ.....</b>	<b>49</b>

## ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1 Soldaki imgeye 8 x 8 hücre boyutlu HOG uygulandığında ortaya çıkan öznitelik vektörleri bloklar halinde sağda gösterilmiştir. ....	6
2.2 SIFT betimleyicisi için DOG tabanlı hesaplanan 4 x 4 hücrelerden 8 farklı oryantasyon için elde edilen gradyanlar .....	11
2.3 DSIFT betimleyicisi için kullanılan anahtar noktalar .....	12
2.4 LCP öznitelik çıkartma işleminin yapısı .....	13
2.5 İki farklı ölçek ve dört farklı oryantasyon için Gabor filtresi. 4 x 4 pencere boyutu (a), 16 x 16 pencere boyutu (b).....	16
3.1 KNN sınıflandırıcısı. Hangi sınıfa dahil olduğu bilinmeyen yuvarlak ile temsil edilen vektör $k$ değeri 1,5 ve 10 için sırasıyla dikdörtgen (a), karo (b) veya üçgen (c) sınıfına dahil olabilir.....	17
3.2 SVM sınıflandırıcısı çalışma prensibi .....	21
4.1 DDSM veritabanına ait 128 x 128 boyutlu imgeler: Birinci satırda 5 tane normal doku, ikinci satırda 5 tane iyi huylu lezyon ve üçüncü satırda ise 5 adet kötü huylu lezyon vakası gösterilmiştir.....	26
4.2 İki sınıflı çalışma için LCP, HOG ve DSIFT öznitelikleri kullanılarak elde edilen sınıflandırma başarısı .....	29
4.3 İki sınıflı çalışmadaki yöntem baz alınarak yapılan, üç sınıflı çalışma için sınıflandırma sonuçları .....	31
4.4 Histogram eşitleme yapılmış kötü huylu lezyon (solda) Histogram eşitlemeyi takiben NLM filtresi uygulanmış imge (sağda).....	35
4.5 Üç sınıflı çalışma için LCP öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları. SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği .....	40
4.6 Üç sınıflı çalışma için HOG 2-1-1-X, DSIFT $r=3,4,5$ öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları grafiği. SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği.....	41

**ŞEKİLLER DİZİNİ (devam)****Sekil****Sayfa**

- 4.7 İki seviyeli çalışmada ön işlem, öznelik çıkartma ve sınıflandırma adımları. .... 43
- 4.8 İki seviyeli çalışma için LCP 1,8-1 öznelikleri kullanılarak elde edilen sınıflandırma sonuçları. SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği.. 43
- 4.9 Tez çalışmasında geliştirilen kullanıcı grafik arayüzü ..... 46

## ÇİZELGELER DİZİNİ

### Çizelge

### Sayfa

4.1	IRMA veritabanınının 12 farklı sınıfı: I,II,III ve IV azdan çoğa doğru doku yoğunluklarını belirtirken, 1,2 ve 5 sırasıyla normal, iyi huylu ve kötü huylu lezyonları içeren dokulara karşılık gelmektedir.....	22
4.2	IRMA projesi ile elde edilen veritabanlarınının imge dağılımı .....	23
4.3	İki sınıflı çalışma için 10 katlamalı çapraz doğrulama yöntemi elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('p',2) 2. dereceden SVM çekirdek .....	28
4.4	Üç sınıflı çalışma için, iki sınıflı çalışmadaki öznelik çıkartma yöntemi kullanılarak elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('p',2) 2. derceden SVM çekirdek .....	30
4.5	Üç sınıflı çalışma için Gabor dalgacık öznelikleri kullanılarak 10 katlamalı çapraz doğrulama yöntemi ile elde edilen sınıflandırma sonuçları (%). GabPCA, Gabor dalgacık öznelik vektörleri PCA kombinasyonu .....	32
4.6	DSIFT öznelikleri çıkartılırken kullanılan yarıçap parametresi .....	37
4.7	LCP ile öznelik vektörleri oluşturulurken alt bantların çarpıldığı katsayılar ve onlara ait LCP kodu (LCP histeq üretilirken NLM kullanılmamıştır).....	38
4.8	Üç sınıflı örüntü tanıma çalışması için elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği .....	39
4.9	İki seviyeli çalışma için 10 katlamalı çapraz doğrulama yöntemi ile elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği .....	44

## SİMGELER VE KISALTMALAR DİZİNİ

<b><u>Simgeler</u></b>	<b><u>Açıklama</u></b>
$\theta(x, y)$	(x,y) koordinatındaki HOG veya SIFT için oryantasyon
$\Delta f(x, y)$	(x,y) koordinatındaki HOG gradyanının büyüklüğü
$G(x, y, \sigma)$	SIFT için değişken ölçekli Gauss dağılım fonksiyonu
$m(x, y)$	(x,y) koordinatındaki DSIFT gradyanının büyüklüğü
$H$	Hessien Matrisi
$LBP(P, R)$	R yarıçapı için alınan P örnekle LBP hesabı
$LBP^{riu2}(P, R)$	Dönme açısından bağımsız uniform 2 boyutlu LBP hesabı
$\lambda, \theta, \varphi, \sigma, \gamma(x, y)$	Beş farklı parametre için Gabor yöntemi
$\Psi_k(z)$	Gabor dalgacık dönüşümü
$k_v$	Gabor dalgacık dönüşümü ölçek
$lex\varphi_\mu$	Gabor dalgacık dönüşümü oryantasyon
$I_k$	Imge ile Gabor dalgacık fonksiyonunun evrilmesi
Öklit_uzaklığı(X, Y)	(X,Y) parametreleri için öklit normu
$S_W$	FLDA sınıf içi değişim matrisi
$S_B$	FLDA sınıflar arası değişim matrisi
$W$	FLDA yansıtılmış matris
$(x_i, L_i)$	SVM için test vektörleri
$f(x_{test})$	SVM için hazırlanan test seti
$\alpha_i$	SVM test vektör katsayıları
$b$	SVM test bileşenleri için optimal hiper yüzeye dik uzaklık
$NLM(I(p))$	I(p) imgesine uygulanan NLM filtresi
$w(p, q)$	SVM test vektör katsayıları
$R_{sim}$	NLM için kullanıcı tarafından girilen karesel komşuluk
$N_p, N_q$	NLM'de p ve q'nun birbirlerine benzerliğinin bir ölçütü

## SİMGELER VE KISALTMALAR DİZİNİ (devam)

<b><u>Simgeler</u></b>	<b><u>Açıklama</u></b>
$Z(p)$	NLM için normalizasyon sabiti
$h$	$Z(p)$ 'deki üstel bozulma parametresi
$d(p, q)$	NLM'de tüm piksellerin her bir komşudan Gauss ağırlıklı öklit uzaklığı
$W(p, q)$	Piksel benzerliği azaltım ağırlık fonksiyonu
<b><u>Kısaltmalar</u></b>	<b><u>Açıklama</u></b>
BI-RADS	Breast Imaging-Reporting and Data System (Göğüs Görüntüleme ve Raporlama Bilgi Sistemi)
CAD	Computer-Aided Diagnosis (Bilgisayar Destekli Tanı)
CWT	Continuous Wavelet Transform (Sürekli Zaman Dalgacık Dönüşümü)
DWT	Discrete Wavelet Transform (Kesikli Dalgacık Dönüşümü)
DDSM	Digital Database for Screening Mammography (Mamografi Görüntüleme Dijital Veritabanı)
DOG	Difference of Gaussian (Gauss Dağılımlı Farklar)
DSIFT	Dense Scale Invariant Feature Transform (Ölçekten Bağımsız Yoğun Öznitelik Dönüşümü)
FLDA	Fisher Linear Discriminant Analysis (Fisher Doğrusal Ayırtaç Analizi)
HL	Daubechies I – High-low bileşeni
HH	Daubechies I – High-high bileşeni
HOG	Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı)

## SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklama</u>
IDWT	Inverse Discrete Wavelet Transform (Ters Kesikli Dalgacık Dönüşümü)
IRMA	Image Retrieval in Medical Applications (Medikal Uygulamalarda Bilgi Çıkartma)
KNN	K-Nearest Neighbour (K-En Yakın Komşu)
LBP	Local Binary Pattern (Lokal İkili Örüntü)
LCP	Local Configuration Pattern (Yerel Konfigürasyon Örüntüsü)
LL	Daubechies I – Low-low bileşeni
LH	Daubechies I – Low-high bileşeni
NLM	Non-Local Means (Yerel-Olmayan Ortalama)
OWT	Overcomplete Kesikli Dalgacık Dönüşümü (Eksik Kesikli Dalgacık Dönüşümü)
PCA	Principal Component Analysis (Temel Bileşenlerine Ayırma Analizi)
SIFT	Scale Invariant Feature Transform (Ölçekten Bağımsız Öznitelik Dönüşümü)
SVM	Support Vector Machine (Destekçi Vektör Makinesi)
UoCTTI	University of Chicago Toyota Technological Institute (Chicago Üniversitesi Toyota Teknoloji Enstitüsü)
VAR	LCP Yerel varyans hesabı
WWLCP	Weighted-Wavelet Local Configuration Pattern (Ağırlıklı Dalgacık Yerel Konfigürasyon Örüntüsü)

## BÖLÜM 1

### GİRİŞ

Medikal imgeler X-ışını, Bilgisayar Tomografisi (CT), Manyetik Rezonans İmge (MRI) ve Pozitron Emisyon Tomografisi, Ultrasonografi gibi tekniklerle elde edilen imgelerden oluşur (Wang et al., 2008). Literatürdeki bir çalışmada (Scharcanski and Jung, 2006) anlatılana göre, meme kanseri kadınlardaki tüm kanser türleri içinde % 30'u oluşturmaktadır. Meselhy Eltoukhy et al., (2010) çalışmalarında bahsettiklerine göre göğüs kanseri her yıl bir milyondan fazla kişide görülmekte ve bunların 400.000 tanesi ölümle sonuçlanmaktadır. Bu yüksek ölümcül sonuçları olan kanser, gelişmiş ve gelişmekte olan ülkelerin ikisinde de kendini göstermektedir. Kanserde erken tanı ölüm vakalarının önüne geçmede önemli bir role sahiptir. Literatürdeki bir çalışmada (Cheng et al., 2010) söylendiğine göre erken tanı sadece lezyonun tespitini içermemeli, lezyona ait iyi ya da kötü huylu bilgisini de ortaya koymalıdır. Fakat bu tespit uzman radyolojistler tarafından bile zordur öyle ki, % 10-30 kanserli bölge mamografide gözden kaçmaktadır. (Jaffar et al., 2011). Bu sebeple çekilen mamografi ile birlikte uzmanlara destek olacak Computer-Aided Diagnosis (bilgisayar destekli tanı, CAD) uygulamalarına ihtiyaç vardır.

Tüm teknolojik ilerlemelere rağmen göğüs kanserinin röntgen üzerinden tespiti çok zor bir işlemdir. Mamografinin kanser tespiti üzerinde sınırlı bir rolü vardır (Cheng et al., 2010). Vakaların türünün ayrılmasındaki zorluk sebebiyle % 65-85 oranlarında gereksiz biyopsi uygulanmaktadır. Bu sebeple birçok hasta psikolojik olarak zor bir süreçten geçmek zorunda kalmaktadır. Mamografi yöntemlerinden biri de göğüs ultrasonudur. İstatistiklere göre her dört araştırmacıdan biri göğüs kanseri tespiti için ultrasona başvurmaktadır. Ultrason iyi huylu ve kötü huylu bölgeleri tespit etmekte başarılı bir yöntemdir. Mamografi radyolojistleri, röntgen üzerindeki kitleleri, kötü huylu kansere işaret eden bulguları, mikrokalsifikasyonları ve deri kalınlaşmalarını gözlemlene konusunda eğitim almış kişilerdir. Literatürdeki bir çalışmada (Rabottino et al., 2011) belirtildiğine göre bir röntgenin iki uzman radyolojist tarafından incelenmesi kanserli dokuyu tespit oranını % 5 ile % 10 arasında artırmaktadır fakat bununla beraber maliyet

de artacaktır. Bu konuda görüntü iyileştirmeler üzerine çok fazla gayret sarf edilmiş ancak bulguların iyileştirilmesi için röntgen tekniklerinin gelişmesi tek başına yeterli değildir.

Genelde mamografi görüntüleri çok düşük bilgi taşımaktadır. Bunun sebebi, normal vakalar ile kötü huylu dokular arasında X-ışını geçirgenliği açısından çok küçük fark olmasıdır. Özellikle genç kadınlarda bu ayrımı yapmak çok sıkı dokuya sahip oldukları için zorlaşmaktadır çünkü göğüs dokusu çok yoğun olduğunda röntgende kemik dokusu gibi çıkmaktadır. Diğer taraftan, mikrokalsifikasyon yapılarından geçen X-ışını çok zayıflamaktadır ve imgede düşük karışıklığa sahip bölgeler olarak göründükleri için tespit edilmesi zorlaşmaktadır. Özellikle küçük tümörlerin bulunması bu sebeplerle problem teşkil etmektedir. Literatürdeki bir çalışmada (Cheng et al., 2010) anlatılana göre daha yoğun doku yoğunluğuna sahip 35 yaş altı kadınlar için ultrasonun daha etkili bir tanıma sağlamaktadır. Göğüs ultrasonu çekirmek küçük kistlerin tespitini % 96-100 oranında yapmaya imkan tanımaktadır. Fakat ultrason diğer yöntemlere göre daha iyi eğitilmiş uzmanlar tarafından yapıldığı müddetçe tanıma oranları yüksek oranda sonuç verebilmektedir.

Mamogram imgelerinin sınıflandırma başarısı imgede bulunan gürültüden çok fazla etkilenir. Mamogram imgelerinde sıklıkla oluşan gürültü türleri, Gauss toplanabilir gürültü, poisson gürültü ve çarpılabilir gürültü olan kuantum gürültüdür. Gürültü oluşmasının sebebi, imge elde edilirken ortaya çıkan X-ışını dozu, yapılan ön işlemler veya diğer imge işleme adımlarıdır. Literatürdeki bir çalışmada (Naveed et al., 2012) anlatılana göre çekilen mamogramlardaki gürültü nedeniyle imgedeki kalite düşüşü % 21'e kadar çıkabilmektedir. Bu kalite düşüşü de imgede bulunan mikrokalsifikasyonların ve kitlelerin ayrımını güçleştirmektedir. Kalite düşüşüne bağlı sınıflandırma başarısı mikrokalsifikasyonlar için % 89'dan % 67'ye, kitle tespit başarısı da % 93'ten % 79'a düşebilmektedir. Görüntü iyileştirme, sınıflandırmanın önemli bir parçasını oluşturmaktadır. Liu and Li, (2004) incelemelerinde, bu iyileştirmeyi 2 kategoride inceliyor: Konvansiyonel ve kör restorasyon. Konvansiyonel olanı imge ile ilgili sahip olunan bir ön bilgi gerektiriyor. Bu teknikler arasında bulanıklık tabanlı bozulma, çarpıklık ve toplanabilir gürültü sayılabilir. Yine de, gerçek hayatta bu tip ön bilgiye sahip olmak pek mümkün değildir ve dolayısıyla ikinci teknikte anlatıldığı gibi kör restorasyon yöntemlerine gidilir. Bu tekniklerin amacı imgedeki önemli kısımları kaybetmeyecek

şekilde temizleme sağlamaktır. İmgeye yumuşatma metodu uygulandığında kenarlar kaybedilecektir ve keskinleştirme işlemi yapıldığında ise de gürültünün güçlenmesi söz konusudur. Mamogram imgelerinde ortaya çıkan kuantum ve poisson tarzı gürültüleri bastırmak için Romualdo et al., (2009) Anscombe dönüşümü ve bunu izleyen Wiener filtreleme işlemini kullanılmıştır. Bu problemi çözmek için Aziz and Shahed, (2010) ise çalışmalarında Nöro-bulanık filtre kullanmıştır. Eğer gürültünün imgeye oranı 0,5 değerinden fazlaysa bu filtreleme teknikleri hayati öneme sahip detayları da imgeden alıp götürmektedir. Literatürde bulunan bir çalışmada (Ko and Lee, 1991) bir takım ağırlık parametreleri kullanılarak işlem yapan ağırlıklı medyan filtresinin özel bir hali olan olan Center Weighted Median (CWM) yöntemi de bu tip gürültüleri temizlemede etkili bir yaklaşımdır. Yine başka bir filtre olan Noise Adaptive Soft Switching Median, ince detaylardaki düşük kayıp oranı ile filtreleme yapabilmektedir, (Eng and Ma, 2001). Naveed et al., (2012) çalışmalarında, mamogramlarda oluşan gürültüleri etkili bir şekilde yok etmek için Frost filtresi, Wiener filtresi ve Non-local Means (Yerel-Olmayan Ortalama, NLM)'i kullanmıştır. Gürültünün arındırılması işlemi, mümkünse imge üzerindeki gürültüyü tahmin etmek suretiyle daha etkin bir biçimde yapılabilir. Eero, (1996) imgeden uzaklaştırılması istenen gürültüyü tahmin eden Bayes tabanlı bir tahmin metodu kullanmıştır ve döndürülebilir dalgacık piramidi tabanlı bu yöntem Wiener filtreye kıyasla daha iyi sonuç vermektedir. Gürültü temizlemede dalgacık dönüşümü tabanlı başka modeller de sıklıkla kullanılmaktadır. Yaptıkları çalışmada Malfait and Roose, (1997) iki farklı imge ölçüsü kullanan bir filtre tekniği sunmuşlardır. İlki Hölder Üsteli ve ikincisi de geometrik kısıtlamaların bir ölçütü. Bu ölçütler birleştirilip Bayesian olasılıksal çatısı üzerinde Markov Random Field modeli kullanılarak çalışmaktadır. Fakat bu olasılıksal yöntemde performans problemleri bulunmaktadır. Chang and Vetterli, (1997) çalışmalarında, toplanabilir Gauss gürültüsü şeklinde modellenmiş gürültüyü yok etmek için, genelleştirilmiş Gauss fonksiyonları modeli de olasılıksal işlem yapan ve dalgacık dönüşüm katsayıları üzerinden işlem yapan bir model kullanmışlardır. Bu yöntemde içerik modeline giriş yapılmış ve her dalgacık katsayısı genelleştirilmiş Gaussian rastgele değişkeni olarak uzamsal bilgiye göre ifade edilmiştir. Her bir katsayı için eşik değer tahmini yapılmıştır. Literatürde başka bir dalgacık dönüşümü tabanlı model olan Yoshida et al., (1995) çalışmalarında mamogram imgeleri için özelleşmiş bir yöntemden bahsedilmektedir. Bu çalışmada dijital mamogramları gürültüden arındırmak

için Discrete Wavelet Transform (Kesikli Dalgacık Dönüşümü, DWT) kullanılmaktadır. DWT alınırken her bir ölçek için ayrı bir ağırlıklandırma faktörü vardır ve daha sonra Inverse Discrete Wavelet Transform (Ters Kesikli Dalgacık Dönüşümü, IDWT) uygulanarak gürültüsüz imgeye ulaşılmaktadır. DWT öteleme ile değişmez olmadığı için imgedeki ufak kaymalar sonucunda çok olumsuz sonuçlar elde edilebilmektedir. Heinlein et al., (2003) ise çalışmalarında mikrokalsifikasyonları görsel olarak iyileştirmede yeni bir yöntem olarak Continuous Wavelet Transform (Sürekli Zaman Dalgacık Dönüşümü, CWT) kullanmıştır. CWT'nin sorunu deneysel olarak bir eşik değere ihtiyaç duyuyor olmasıdır. Literatürdeki Scharcanski ve Jung, (2006) çalışmalarında mamografi imgeleri için yeni bir adaptif metot olan gürültüden arındırma ve iyileştirme sağlamada gürültü eşitleme yapan ve dalgacık dönüşümü katsayılarını küçültme üzerine kurulu bir yöntemden bahsetmektedirler. Bu yöntemde, dalgacık dönüşümü yapılan bazı ölçekler için dalgacık dönüşüm fonksiyonlarından bazıları ağırlıklandırılmış ve dalgacık dönüşümünde sadece dikey ve yatay bileşenleri içeren bölümler kullanılmıştır. Katsayıların bazı ölçek-uzayı kısıtlamaları kullandığı dalgacık dönüşümü üzerinde çalışılmıştır. Çok esnek bir yaklaşım olmasına karşın parametrelerin kullanıcı tarafından ayarlanmasına ihtiyaç duyulmaktadır.

Mamografide hangi yöntem kullanılırsa kullanılsın imge üzerinde bulunan lezyonu tespit edebilecek bir öznelik çıkartmak hayati derece önem teşkil etmektedir. Bu işlem imgede bulunan iyi ve kötü huylu yapılara ait ayırt edici anlamlı bilgiyi korurken diğer gereksiz bilgiyi imgeden atmayı amaçlamaktadır. Bunun yapılması, hem ayırt edilmek istenen bölge için alakalı bilgiyi koruma hem de sınıflandırma algoritmalarında kullanılmak üzere, hesaplama hızını artıran, kabul edilebilir boyutlu öznelik vektörlerinin elde edilmesini sağlamaktadır. Mamogram imgelerinden öznelik çıkartma işlemi yapmak için kullanılan yöntemler uzay dönüşümlerine ihtiyaç duyar. Öznelik çıkartma işlemleri için birçok çalışma gerçekleştirilmiştir. Gabor dalgacık dönüşümü (Buciu and Gacsadi, 2011), dalgacık dönüşümü yöntemi (Ferreira and Borges, 2003), Principal Component Analysis (Temel Bileşenlerine Ayırma Analizi, PCA) (Bellotti et al., 2006), medikal imgelerdeki başarısı literatürdeki Song et al., (2012) çalışmasında kanıtlanmış bir yöntem olan Local Binary Pattern (LBP) (Ojala et al., 1996), bunlara örnek gösterilebilir. Angelini et al., (2006) çalışmasında Digital Database for Screening Mammography (Mamografi Görüntüleme Dijital Veritabanı, DDSM) veritabanını

sınıflandırmak için Overcomplete Wavelet Transform (Eksik Dalgacık Dönüşümü, OWT) ve Haar dalgacıkları modelini kullanarak imge üzerinde bir kitle bulunup bulunmadığını % 90 oranda tespit etmiştir. Literatürdeki bir çalışmada (Campanini et al., 2004) ise öznelik dönüşümü yapmak yerine imgelere ait kesikli dalgacık dönüşümü verilerini birbiri ardı sıra uygulanan Support Vector Machine (Destekçi Vektör Makinesi, SVM)'ler ile direkt olarak kullanmış ve DDSM veritabanında kitleleri tespitinde % 80 oranında sınıflandırma başarısı sağlamıştır. Literatürdeki bir başka yöntemde (De Oliveira Martins et al., 2009) aynı veri tabanı için öznelik çıkartımı için uzamsal özellikler olan eşdeğişimlilik matrisleri için karışıklık, homojenlik, ters fark momenti, entropi ve enerji değerlerini hesaplamış ve kanserli kitleleri ayırmada % 93 sınıflandırma başarısı elde etmişlerdir.


Bu tezde, mamogram imgeleri kullanılarak göğüs kanserinin tanısı ve teşhisi yapılmıştır. Tezin ilk aşamasında, normal ve kanserli dokuyu ayırt etmek için çalışmalar yürütülmüştür. Bu kapsamda, Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı, HOG), Dense Scale Invariant Feature Transform (Ölçekten Bağımsız Yoğun Öznelik Dönüşümü, DSIFT), Local Configuration Pattern (Yerel Konfigürasyon Örüntüsü, LCP) öznelik çıkartım yöntemleri kullanılmıştır. Elde edilen öznelikler, SVM, K-Nearest Neighbour (K-En Yakın Komşu, KNN), Fisher Linear Discriminant Analysis (Fisher Doğrusal Ayırtaç Analizi, FLDA) ve Karar Ağacı sınıflandırıcılarına tabi tutulmuş ve %100 başarı sağlanmıştır. Tezin ikinci aşamasında ise, normal, iyi huylu ve kötü huylu göğüs kanseri yapılarının sınıflandırılması amaçlanmıştır. Bu bağlamda, iki adet farklı ve yeni yaklaşım bu tez kapsamında önerilmiştir. Bu yaklaşımlardan ilki, öznelik çıkartım adımından önce bazı önlemler uygulanmasını öngören ve çeşitli ağırlıklandırma parametrelerine sahip Weighted-Wavelet LCP (Ağırlıklı Dalgacık Yerel Konfigürasyon Örüntüsü, WWLCP) yöntemidir. Önerilen yaklaşımlardan ikincisi ise, iki sınıflı çalışmada %100 başarı sağlamış öznelik çıkartma yöntemini kullanarak öncelikle normal dokuların düzgün bir şekilde ayrılmasını sağlayan ve ardından WWLCP yöntemini kullanarak iyi huylu-kötü huylu kanser dokusu teşhisini gerçekleştiren iki seviyeli çalışmadır. Bu iki seviyeli çalışmada, IRMA (Image Retrieval in Medical Applications) projesi kapsamında edinilmiş veritabanı için % 99,20 gibi üstün bir sınıflandırma başarısına ulaşılmıştır.

## BÖLÜM 2

### ÖZİNİTELİK ÇIKARTIM YÖNTEMLERİ

#### 2.1 Yönlendirilmiş Gradyanların Histogramı Betimleyicisi

Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı, HOG) betimleyicisi, imge üzerinde bulunan ışık şiddeti dağılımının türevsel ifadelerinin bir sıklık fonksiyonunu oluşturan bir modeli kullanır (Xu et al., 2013). Her imge Şekil 2.1'deki gibi birbiri ardı sıra dizilmiş hücre denilen bloklara ayrılır. Her bir hücre üzerinden hesaplanan gradyan sıklıkları modele katkı sağlar. Betimleyici bu histogramların birleşiminden oluşur. Daha yüksek tutarlılıkta çalışan betimleyici için, imgede bulunan her bir yerel bölge karşıtlık-normalizasyonu daha büyük bölgedeki pikseller baz alınarak yapılır. Blok içinde bulunan her bir hücre ışık şiddeti yönünden de normalize edilir.



**Şekil 2.1** Soldaki imgeye 8 x 8 hücre boyutlu HOG uygulandığında ortaya çıkan öznelik vektörleri bloklar halinde sağda gösterilmiştir.

İmgenin bloklara ayrılan her bir parçası hücre yoğunluklarını oluşturur. Her piksel için ışık şiddeti gradyanı  $\Delta f(x, y)$  Eş. (2.1)'deki gibi alınır ve hücredeki oryantasyonu yapılmış gradyanlar için bir ağırlık oluşturur.

$$\Delta f(x, y) = \left( \frac{\partial f(x, y)}{\partial x}, \frac{\partial f(x, y)}{\partial y} \right) \quad (2.1)$$

Burada  $x$  ve  $y$  değerleri iki boyutlu imgenin yatay ve dikey koordinatlarını göstermektedir.  $f(x, y)$  ise o koordinattaki pikselin ışık şiddeti değeridir. Burada yapılan işlem, uzamsal olarak iki boyutlu imgeyi yatayda ve dikeyde  $[-1, 0, 1]$  ve  $[-1, 0, 1]^T$  filtreleriyle Eş. (2.2) ve Eş. (2.3)'teki gösterilen işlemi yapacak şekilde filtrelemektir.

$$\frac{\partial f(x, y)}{\partial x} = \frac{f(x+1, y) - f(x-1, y)}{(x+1) - (x-1)} \quad (2.2)$$

$$\frac{\partial f(x, y)}{\partial y} = \frac{f(x, y+1) - f(x, y-1)}{(y+1) - (y-1)} \quad (2.3)$$

Eş. (2.2) ve Eş. (2.3)'teki  $\partial f(x, y) / \partial x$ 'e  $G_x$ ,  $\partial f(x, y) / \partial y$ 'e  $G_y$  dersek, piksele ilişkin ağırlık ve oryantasyon sırasıyla Eş. (2.4) ve Eş. (2.5)'teki gibi hesaplanır.

$$\Delta f(x, y) = \sqrt{G_x^2 + G_y^2} \quad (2.4)$$

$$\theta(x, y) = \tan^{-1} \left( \frac{G_y}{G_x} \right) \quad (2.5)$$

Histogramın içerdiği kanallar, değişkenin sırasıyla işaretli ya da işaretsiz olmasına göre  $0-180^\circ$  ya da  $0-360^\circ$ , arasına eşit olarak yayılmıştır.

HOG özneliği dokuları ya da Felzenszwalb et al., (2010) çalışmasında anlatıldığı gibi, deforme edilebilir objeleri tasvir etmede başarılı bir yöntemdir. Bununla beraber

HOG betimleyicisi, medikal imgelerde hastalıklı bölge tasvirinde Song et al., (2012) çalışmasında anlatıldığına göre etkili bir yöntemdir.

## 2.2 Ölçekten Bağımsız Öznitelik Dönüşümü Betimleyicisi

Scale Invariant Feature Transform (Ölçekten Bağımsız Öznitelik Dönüşümü, SIFT) betimleyicisi, imgedeki bir bölge için gradyan vektörleri hesaplayan bir yöntemi baz alır (Zhang et al., 2006). SIFT betimleyicisinin yapısı dört bölümde incelenebilir (Lowe, 2004).

### 2.2.1 Ölçek Uzayı Uç Noktalarının Bulunması

Ölçek uzayında tüm ölçekler için anahtar nokta olabilecek bölgeler araştırılır. Bu işlemi etkili bir şekilde yapabilmek için Difference of Gaussian (Gauss Dağılımlı Farklar , DOG)'dan yararlanılır. Bu sayede dönme açısından ve ölçekten bağımsız olarak anahtar nokta olabilecek potansiyel bölgeler belirlenir. Kabul edilebilir birkaç kabullenme altına bir ölçek uzayı fonksiyonu elde etmek için en iyi yöntem Gaussian fonksiyonu kullanmaktır. Bu durumda ölçek uzayı Eş. (2.6)'daki gibi tanımlanabilir.

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (2.6)$$

$I(x, y)$  imge girdisini ifade ederken,  $G(x, y, \sigma)$  Eş. (2.7)'deki bir değişken ölçekli Gauss dağılım fonksiyonudur.

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (2.7)$$

Eş. (2.6)'da yapılan anahtar noktaları kararlı bir şekilde belirlemeye çalışan yöntem Eş. (2.8)'deki değişimle daha etkili çalışır hale getirilebilir.

$$\begin{aligned}
D(x, y, \sigma) &= ((G(x, y, k \sigma) - G(x, y, \sigma))^2 * I(x, y)) \\
&= L(x, y, k \sigma) - L(x, y, \sigma)
\end{aligned}
\tag{2.8}$$

### 2.2.2 Karşıtlığı Düşük Bölgeler ve Kenarların Elenmesi

DOG fonksiyonu kenarlara aşırı tepki veren bir fonksiyondur ve dolayısıyla gürültülere karşı duyarlıdır. Bu sebeple, aday olan her bir anahtar nokta için sabit olmayan alt pikseller kullanılmamak üzere etkisi ortadan kaldırılmalıdır. DOG fonksiyonu kenar olan bir bölgede hesaplanması durumunda yatayda çok yüksek bir değere sahip olurken dikeyde çok küçük bir değeri vardır. Bu noktada, Eş. (2.9)'daki Hessian matrisinden yararlanılır.

$$H = \begin{bmatrix} D_{xx} & D_{yx} \\ D_{xy} & D_{yy} \end{bmatrix}
\tag{2.9}$$

$D_{xx}$ ,  $D_{yx}$ ,  $D_{xy}$  ve  $D_{yy}$  x ve y yönündeki kısmi türevlere karşılık gelmektedir. Komşu piksellerden alınan örneklerin özdeğerlerinin oranlarına bakılarak işlem yükü azaltılabilir. Bu sayede kenar olmayan bölgelerin betimleyici bozucu etkisi giderilmiş olur.

### 2.2.3 Dönme Açısı ve Ölçekten Bağımsızlaştırma

SIFT betimleyicisi her bir anahtar nokta için hesaplama yaparken Gauss yumuşatma fonksiyonu kullanır. Anahtar noktanın bulunduğu yerel bölgenin, bu fonksiyonun doğası gereği ölçekten bağımsız çıkması beklenir.  $L$  mevcut ölçekteki yatay ve dikey koordinatı  $L(x, y)$  fonksiyonu ile belirtilmiş imge olsun. Bölgedeki gradyanların büyüklüğü,  $m(x, y)$  ve oryantasyonları da  $\theta(x, y)$  olsun. Bu durumda her

bir örnek için gradyan büyüklüğü ve oryantasyon Eş. (2.10) ve Eş (2.11)'daki gibi hesaplanır.

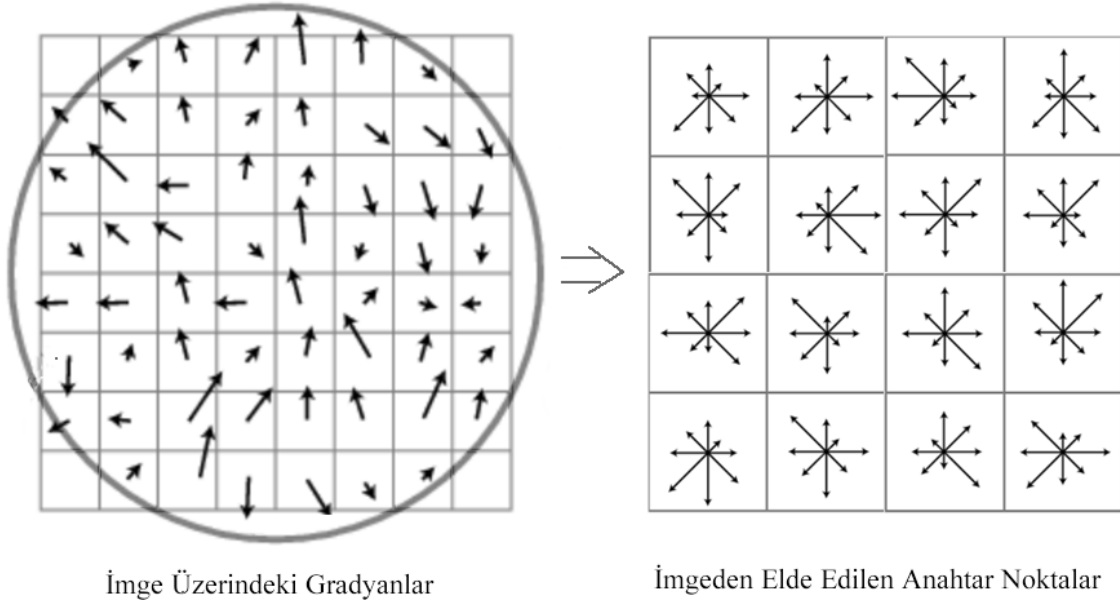
$$m(x, y) = \sqrt{(L(x+1, y) - L(x, y-1))^2 + (L(x, y+1) - L(x, y-1))^2} \quad (2.10)$$

$$\theta(x, y) = \tan^{-1} \left( \frac{(L(x, y+1) - L(x, y-1))}{(L(x+1, y) - L(x-1, y))} \right) \quad (2.11)$$

Bu noktadan itibaren, anahtar nokta etrafındaki örnek noktaların oryantasyonundan bir oryantasyon yoğunluk fonksiyonu oluşturulur. Oryantasyon histogramı 36 hücreden oluşur ve bu da 360 dereceye karşılık gelmektedir. Hesaplanan gradyanlar, histogramdaki her bir hücreye büyüklükleri oranında ve anahtar noktanın ölçeğinin 1,5 katı bir çembersel Gauss ağırlık penceresi kullanılarak eklenir. Histogramda pik yapan değer fonksiyondaki baskın değere karşılık gelir ve bu pikin % 80 büyüklüğüne yaklaşan her pik için de ayrıca anahtar noktaya yapılan işlemler yapılır. Bu sayede dönme açısından bağımsız özniteliklerin çıkartımı sağlanmış olur.

#### 2.2.4 Hücrelerin Betimlenmesi

Önce her bir anahtar nokta etrafından imge gradyanlar büyüklükleri ve oryantasyonları hesaplanır. Her bir hücre için gradyan ağırlıkları hesaplanırken Şekil 2.2'deki sol bölümde bulunan çembersel pencere üzerinde Gauss dağılımı standart sapması  $\sigma$  mevcut ölçeğin 1,5 katı olacak şekilde ağırlıklara hafif bir yumuşatma işlemi yapar.




**Şekil 2.2** SIFT betimleyicisi için DOG tabanlı hesaplanan 4 x 4 hücrelerden 8 farklı oryantasyon için elde edilen gradyanlar

Bu işlemden sonra her bir hücre, oryantasyon histogramları kullanılarak bir öznelik vektörü oluşturur. Başarılı bir şekilde çalışan yöntemde imge Şekil 2.2'deki gibi 4 x 4 histogram bloklarına ayrılmıştır. Şekil 2.2'nin sağında görüldüğü gibi ve her bir blok için 8 farklı oryantasyon seçilmiştir. Bu metot,  $4 \times 4 \times 8 = 128$  boyutlu öznelik vektörlerinin çıkartılmasını sağlar. Son olarak aşırı ışık değişimlerinden etkilenmenin önüne geçebilmek için tüm vektör birim fonksiyon ile normalize edilir.

### 2.2.5 Ölçekten Bağımsız Yoğun Öznitelik Dönüşümü Betimleyicisi

Dense Scale Invariant Feature Transform (Ölçekten Bağımsız Yoğun Öznitelik Dönüşümü, DSIFT) betimleyicisi ölçekten ve dönme açısından bağımsız öznitelikler çıkarmayı sağlayan bir çeşit SIFT varyantıdır (Wang et al., 2010). SIFT'ten farklı anahtar noktalar hesaplanırken bir anahtar nokta arayıcı algoritma yerine imgenin her yerinden, verilen yarıçapa göre, çakışmalı olarak ve eşit aralıklarla çok sayıda örnek almaktır. Bunun dışında algoritma SIFT'teki gibidir. Şekil 2.3'te DSIFT'in imge üzerinde uygulanışı şematize edilmiştir.

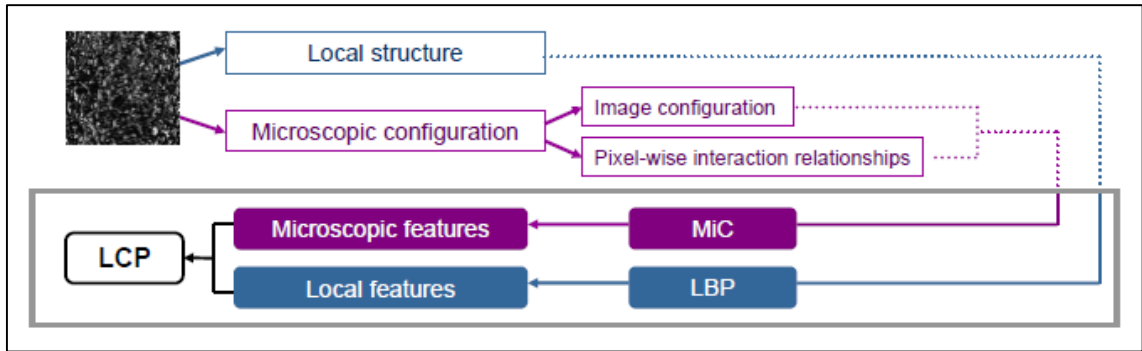


Şekil 2.3 DSIFT betimleyicisi için kullanılan anahtar noktalar

DSIFT yoğun bir şekilde aldığı imge bloklarıyla tanınması istenen ya da sınıflandırılması istenen imgelerde hangi bilginin önemli olup olmadığı kesin olarak ayırt edilemeyen durumlarda, önemli bilginin yanlışlıkla atılmasını engelleyerek, etkili bir öznitelik çıkartma işleminin yapılmasına imkan sağlar.

### 2.3 Yerel Konfigürasyon Örüntü Betimleyicisi

Local Configuration Pattern (Yerel Konfigürasyon Örüntüsü, LCP) betimleyicisi, literatürdeki Guo et al., (2011) çalışmasında ifade edilene göre, iki boyutlu bir imgeyi ifade eden yerel bölge bilgisi ile örüntü sıklıklarının harmanlayan Şekil 2.4'te gösterildiği gibi bir algoritma kullanır.



Şekil 2.4 LCP öznelik çıkartma işleminin yapısı

Yerel bölge bilgisi genellikle doku yapısı bilgilerini içerirken, örüntü sıklıklarını Local Binary Pattern (LBP) tabanlı bir yöntem ile hesaplar (Song et al., 2012). Hesaplanan vektörler çembersel olarak en büyük değeri son eleman olacak şekilde kaydırılır ve bu sayede dönme açısından bağımsız öznelikler çıkartılmış olur. Örüntü sıklıkları her bir gri seviye imgenin piksellerini çembersel olarak komşu piksellerle karşılaştırarak etiketleyen yerel-LBP ile hesaplanır.. Verilen yarıçap değeri  $R$  için LBP metodu Eş. (2.12)'deki gibi işlem yapar.

$$LBP(P, R) = \sum_{i=0}^{P-1} u(g_i - g_c) 2^i \quad (2.12)$$

$P$  sayısı, burada alınan örnek piksel sayısına karşılık gelirken  $g_i$ , her bir merkez pikselin ışık şiddeti değeridir. LBP tabanlı metotlar ışık şiddeti değişimlerine karşı çok

üstün başarı göstermelerine rağmen, eğer yerel bölge pürüzsüz bir yapıda ise, (merkez piksel değeri komşu piksellerden çok yüksek ya da düşük ışık şiddetine sahip değilse) ışık şiddeti merkez piksellerden çok farklı olan bir imgedeki yerel bölge ile aynı öznitelik vektörünü oluşturma gibi bir dezavantajı vardır.

Bu tip problemden kaçınmak için her bir bölgenin yerel varyans hesabı (VAR) yapılmalıdır. VAR değeri Eş. (2.13)'teki gibi hesaplanır.

$$VAR = \frac{1}{P} \sum_{i=0}^{P-1} (g_i - \mu)^2 \quad (2.13)$$

$\mu$  değeri merkez piksel etrafındaki piksellerin ortalamasını ifade etmektedir.

Sonuç olarak bu metot, imgede mikroskopik yapı olarak adlandırılan dalgacık dönüşümü tabanlı dönme açısından bağımsız dokusal yapı modeli ile imgedeki örüntü sıklıklarını ifade eden LBP tabanlı metottan gelen verileri yine dönme açısından bağımsız şekilde düzenleyerek Eş. (2.14)'teki gibi birleştirir.

$$LBP^{riu2}(P, R) = \begin{cases} \sum_{i=0}^{P-1} u(g_i - g_c), & \text{eğer : } U(LBP(P, R)) \leq 2 \\ \text{yoksa, } P + 1, & \end{cases} \quad (2.14)$$

$LBP^{riu2}$  burada dönme açısından bağımsız uniform iki boyutlu LBP'yi ifade etmektedir. LCP algoritması gerek dönme açısından bağımsız yapısı gerekse imgeye ait mikroskopik nitelikleri temsil eden modelleri sayesinde, doku sınıflandırmada etkin bir yöntem olarak kullanılmaktadır.

## 2.4 Gabor Dalgacık Öznitelikleri

İki boyutlu Gabor filtreler bilgisayarla görü uygulamalarında yoğun bir şekilde kullanılmaktadır. Gabor öznitelik yönteminin medikal çalışmalarda kullanıldığı Zainudin et al., (2011) çalışmasındaki araştırmalarla kanıtlanmıştır. Gabor filtrelerin impuls cevabı harmonik fonksiyonların Gauss dağılım fonksiyonu ile çarpımı ile hesaplanabildiği için

doğrusallık özelliği gösterir. Zaman alanındaki konvolüsyon, frekans alanındaki çarpma işlemine karşılık geldiğinden, Gabor filtresinin impuls cevabı Gauss fonksiyonunun frekans alanı dönüşümü ile harmonik fonksiyonun frekans alanı dönüşümü çarpımına eşittir. İki boyutlu Gabor fonksiyonu Eş. (2.15-2.17)'deki gibi gösterilebilir.

$$\lambda, \theta, \varphi, \sigma, \gamma(x, y) = \exp\left(\frac{-x^2 + \gamma^2 y^2}{2\sigma^2}\right) \cos\left(2x \frac{x'}{\lambda} + \varphi\right) \quad (2.15)$$

$$x' = x \cos \theta + y \sin \theta \quad (2.16)$$

$$y' = -x \sin \theta + y \cos \theta \quad (2.17)$$

$x$  ve  $y$ , iki boyutlu imgedeki piksel koordinatlarına karşılık gelmektedir. Gabor fonksiyonu dalga boyu ( $\lambda$ ) oryantasyon ( $\theta$ ), faz ötelemesi ( $\varphi$ ), en boy oranı ( $\sigma$ ) ve bant genişliği ( $\gamma$ ) gibi parametreler alır. Gabor filtresi ile üretilen veri, imgenin boyutuna eşittir. Gabor dalgacık yöntemi Tai Sing Lee, (1996) ve Arivazhagan et al., (2006) çalışmalarında da dile getirdikleri üzere beyindeki görme duyularının matematiksel modellenmesi yapılarak elde edilmiştir. Gabor dalgacık modeli dönme açısından bağımsız özelliği ile doku analizi gibi bazı uygulamalar için uygundur. Gabor filtrenin kompleks formu, Gabor dalgacığı, Gauss çekirdeğinin kompleks bir sinüsoidal ile çarpımı ile hesaplanır. Bu hesaplama Eş. (2.18)'de gösterilmiştir.

$$\Psi_k(z) = \frac{k^T k}{\sigma^2} \exp\left(\frac{k^T k}{2\sigma^2} z^T z\right) \left( \exp(ik^T z) - \exp\left(-\left(\frac{\sigma^2}{2}\right)\right) \right) \quad (2.18)$$

Burada  $k$  dalga vektörünün karakteristiği göstermektedir ve Eş (2.19)'daki gibi bulunur. Burada  $z$  uzamsal bölgedeki imgeyi ifade eden sinyaldir.

$$k_v = 2 - \frac{v+2}{2} \pi \quad (2.19)$$


$v$  parametresi filtrenin frekansıdır. Filtreye ait oryantasyon ise Eş. (2.20)'de gösterildiği şekilde bulunur.

$$\text{lex}\varphi_\mu = \mu \frac{\pi}{8} \quad (2.20)$$

İki boyutlu Gabor dalgacık dönüşümü ise Eş. (2.21)'de gösterildiği şekilde hesaplanır.

$$I_k = \iint I(z') \psi_k(z-z') dz' \quad (2.21)$$

Gabor dalgacık yöntemi kullanılarak farklı iki ölçek ( $\nu = 0, 1$ ) ve dört farklı oryantasyon ( $\mu = 0, 1, 2, 3$ ) için elde edilen verilerin değişimi Şekil 2.5'te gösterilmiştir (Zhou et al., 2013).



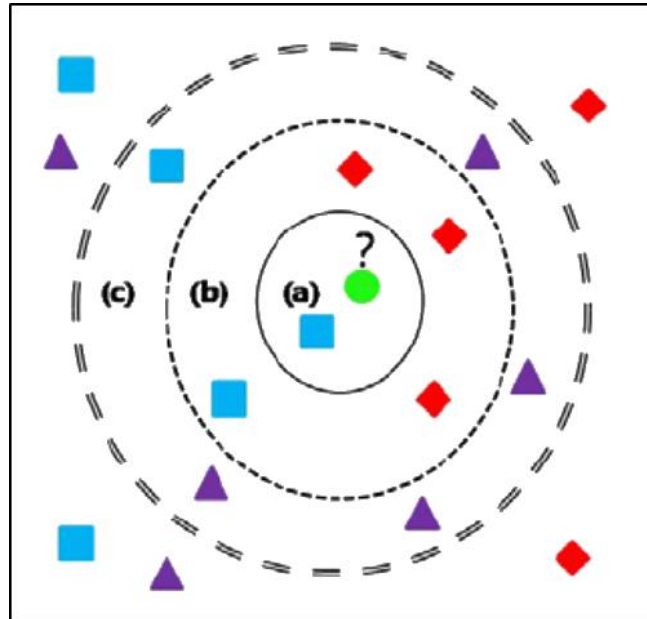
**Şekil 2.5** İki farklı ölçek ve dört farklı oryantasyon için Gabor filtresi. 4 x 4 pencere boyutu (a), 16 x 16 pencere boyutu (b)

## BÖLÜM 3

### SINIFLANDIRICILAR

#### 3.1 K-En Yakın Komşu Sınıflandırıcısı

Popüler sınıflandırma algoritmalarından biri olan K-Nearest Neighbor (K-En Yakın Komşu, KNN) sınıflandırıcısı, öznitelik uzayında bulunan öznitelik vektörlerinin yakınlık kriterine göre sınıflandırma işlemi yapar (Kim et al., 2012). Hangi sınıfa ait olduğu bilinmeyen bir vektör bir sınıfa dahil edilirken,  $k$  pozitif tamsayı için, Şekil 3.1'deki gibi  $k$  tane en yakın komşusuna bakılarak atama işlemi yapılır.



**Şekil 3.1** KNN sınıflandırıcısı. Hangi sınıfa dahil olduğu bilinmeyen yuvarlak ile temsil edilen vektör  $k$  değeri 1,5 ve 10 için sırasıyla dikdörtgen (a), karo (b) veya üçgen (c) sınıfına dahil olabilir.

$k$  sayısını belirlemek için sınıflandırma oranında en yüksek doğruluğu veren değeri deneysel yollarla bulmak gerekmektedir. Literatürdeki bir çalışmada (Uysal vd., 2013) anlatılana göre  $k=1$  özel durumunda sınıflandırılmak istenen vektör kendisine en yakın olan vektörle aynı gruba dahil edilir. Sadece iki sınıf varsa  $k$  sayısı tek sayı olmalıdır. Fakat çok sınıflı çalışmada hala vektörün hangi sınıfa dahil olduğunu belirsiz bırakan  $k$  değerleri vardır. Bu sebeple  $k$  sayısı sınıf sayısının katı seçilmemelidir.

Her bir vektörü boyut sayısı aynı olacak şekilde belirledikten sonra KNN uygulanmakta en yaygın kullanılan yöntem, vektörler arasındaki öklit uzaklığına bakılmasıdır. Öklit uzaklığı,  $n$  boyutlu iki vektör  $X = (x_1, x_2, \dots, x_n)$  ve  $Y = (y_1, y_2, \dots, y_n)$  için Su, (2011) çalışmasında anlatıldığı şekilde, Eş. (3.1)'deki gibi bulunur.

$$\text{Öklit\_uzaklığı}(X, Y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (3.1)$$

KNN algoritmasının temel avantajı çoklu sınıflarla çalışırken karar aşamasında gayet başarılı olmasıdır çünkü benzer örüntülerin arasında çok küçük farklar bulunmaktadır ve bu da vektörler arasındaki uzaklığa yansır.

### 3.2 Karar Ağacı Sınıflandırıcısı

Karar Ağacı sınıflandırıcısı literatürdeki bir çalışmada (Ye et al., (2000) değinildiği gibi yaygın olarak kullanılan ve iyi bilinen sınıflandırıcılardan biridir. İki parametreye göre işlem yapar. Bunlardan birincisi hedef sınıftır ve ikincisi ise tahmin değeridir. Eğitim aşaması, eğitim örneklerini kullanarak durma kriteri sağlanana kadar kendi içinde dönen bir işlem yürütür. Her bir parça için, örnek setleri göreceli olarak düşük bir hedef değere sahiptir. Ağaçtaki bir dalın durması için tüm örnekler aynı sınıfa dahil olması ya da yaprak oluşumu ile sonuçlanacak durma kriterine erişilmiş olması gerekmektedir.

### 3.3 Fisher Doğrusal Ayırtaç Analizi Sınıflandırıcısı

Fisher Linear Discriminant Analysis (Fisher Doğrusal Ayırtaç Analizi, FLDA) algoritması istatistiksel örüntü tanıma metotları içinde önemli bir role sahiptir. Fisher'in optimizasyon metodu, çalışmasında da anlatılan sınıflar arası ve sınıf içi benzerliği dikkate alan metotlardan biridir (Gülmezoğlu vd., 2005). Fisher çok sınıflı problemleri çözmek için sınıflar arası benzerlik oranı ile sınıf içi benzerlik oranını maksimize eden Linear Discriminant Analysis (LDA)'i kullanmıştır.

Fisher'in maksimizasyon kriteri Eş. (3.2)'deki gibi gösterilebilir.

$$J(\mathbf{W}) = \text{Tr} \{ (\mathbf{W}^T \mathbf{S}_w \mathbf{W})^{-1} (\mathbf{W}^T \mathbf{S}_b \mathbf{W}) \} \quad (3.2)$$

$\mathbf{S}_w$  sınıf içi değişimi ve  $\mathbf{S}_b$  ise sınıflar arası değişimi göstermektedir.  $\mathbf{W}$  ise yansıtılmış matrisi gösterir. Bu optimizasyon kriterinden elde edilecek alt-uzayın boyutu sınıf sayısından bir eksiktir. Bu alt-uzayda tanıma oranları yüksek değildir. Eş. (3.2)'de gösterilen değerlerin önceki çalışmalarda optimize edilmesi sağlanmıştır ve optimizasyon Eş. (3.3)'teki gibi özetlenebilir:

$$\begin{aligned} \mathbf{w}_i^T \mathbf{w}_j = 0, \quad \forall i \neq j \text{ yerine } \mathbf{w}_i^T \mathbf{S}_i \mathbf{w}_j = 0, \quad \forall i \neq j \text{ kullanılır} \\ i, j = 1, 2, \dots, d \quad \forall i \neq j \text{ iken } \mathbf{S}_i = \mathbf{S}_w + \mathbf{S}_b \end{aligned} \quad (3.3)$$

Literatürdeki (Loog et al., 2001) çalışmasında sınıflar arası değişim matrisi sınıf ortalamalarının farkı cinsinden yazılmıştır. Sınıflar arası değişim matrisi ile sınıf içi değişim matrisi arasındaki fark Loog and Haeb-Umbach, (2000) çalışmasındaki gibi sınıflar arası matrisin özdeğerleri ile tanımlanmış ağırlık fonksiyonlarıyla çarpılarak artırılmakta ve kriter çoklu sınıf için optimize edilmektedir. Tezin sınıflandırma kısmında FLDA için Duin, (2013) tarafından hazırlanan Matlab paketi kullanılmıştır.

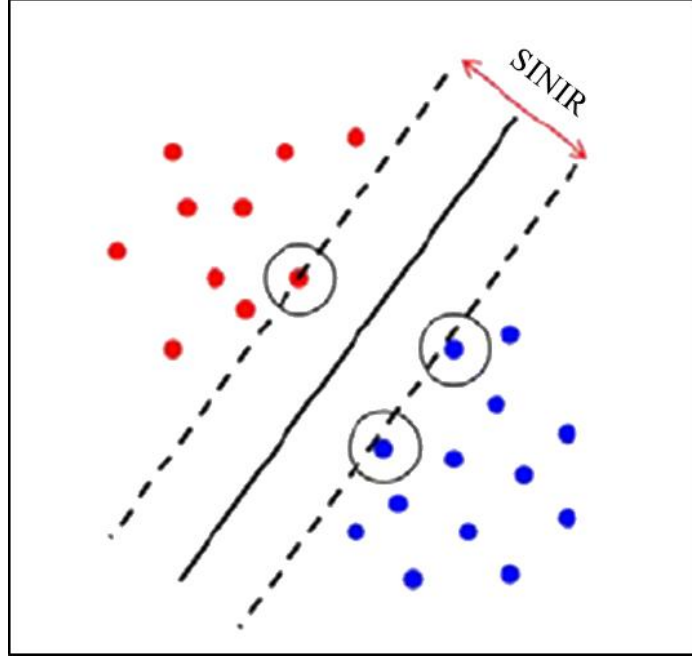
### 3.4 Destekçi Vektör Makinesi Sınıflandırıcısı

Örüntü tanımada modern sınıflandırma algoritmalarından biri olan Support Vector Machine (Destekçi Vektör Makinesi, SVM) sınıfları oluşturan vektörler arasındaki en iyi sınırı ifade eden bir hiper yüzey bulmayı amaçlar (Uysal vd., 2013). Bunu yaparken de çekirdek yöntemini kullanır. SVM sınıflandırılacak vektörleri en yakın hiper yüzeye yaklaştırır ve bu sebeple sınır sınıflandırıcısı olarak da bilinir.

SVM sınıflandırıcısı KNN'in aksine eğitim aşamasına ihtiyaç duyar. İki sınıflı çalışma için eğitim aşamasındaki vektörlerimiz  $TS = \{(x_1, L_1), (x_2, L_2), \dots, (x_M, L_M)\}$  olsun.  $M$  pozitif tam sayısı veri setindeki  $M$  tane örneği temsil etsin,  $x_i$  ( $i = 1, 2, \dots, M$ ) ve  $L_i$  ( $L_i \in \{-1, 1\}$ ) negatif ya da pozitif elemanları içeren negatif ve pozitif sınıflarının elemanlarını temsil etsin. Testte kullanılacak veri  $x_{test}$ 'in karar fonksiyonu Eş. (3.4)'te verilmiştir.

$$TS = f(x_{test}) = \sum_{i=1}^M \{\alpha_i L_i (x_i^T x_{test}) + b\} \quad (3.4)$$

$\alpha_i$  ( $i= 1, 2, \dots, M$ ) burada kuadratik denklemin sıfırdan farklı katsayıları olsun.  $b$  ise optimal hiper yüzeyin orjine dik uzaklığı olsun. İki sınıflı çalışma vektörlerin lineer olarak ayrılabilirdiğini varsaymaktadır. Birçok çekirdek çeşidi olmasına rağmen iki sınıf ayrımı için lineer çekirdek kullanılmıştır çünkü iki sınıfı en iyi ayıracak eğri bir doğrudur. SVM'in amacı verilen verinin hangi sınıfa ait olduğunu daha yüksek oranda bulacak modeli geliştirmektir. Şekil 3.2'de SVM sınıflandırıcısının nasıl çalıştığını temsil eden bir çizim görülmektedir.



**Şekil 3.2** SVM sınıflandırıcısı çalışma prensibi

Literatürdeki bir çalışmada (Kim et al., 2012) anlatılana göre, eğer çok sayıda özellik içeren az sayıda öznelik vektörü varsa SVM çok iyi çalışır. Dezavantajları arasında hesaplama süreleri ve vektörlerdeki boyut sınırlamaları sayılabilir. Bu tezdeki iki sınıflı örüntü tanıma işlemlerinde Duin, (2013) tarafından sağlanan lineer ve kuadratik SVM çekirdek kullanılmıştır.

## BÖLÜM 4

### DENEYSEL ÇALIŞMALAR

#### 4.1 Veritabanları

Yapılan lisans sözleşmesi ile Image Retrieval in Medical Applications, (Medikal Uygulamalarda Bilgi Çıkartma, IRMA) projesi kapsamında elde edilen ve üzerinde çalışılan veri seti De Oliveira et al., (2008) çalışmasında da kullanılan dört farklı veritabanını içermektedir. Bu çalışma mamogramlarda tespit edilen lezyonları dokularına ve hastalık tanılarına göre Breast Imaging-Reporting and Data System (Göğüs Görüntüleme ve Raporlama Bilgi Sistemi, BI-RADS) standartlarını kendi kod sistemine Çizelge 4.1'deki gibi dönüştürdüğü Oliveiraa et al., (2008) çalışmasının ışığında yapılmıştır.

**Çizelge 4.1** IRMA veritabanınının 12 farklı sınıfı: I,II,III ve IV azdan çoğa doğru doku yoğunluklarını belirtirken, 1,2 ve 5 sırasıyla normal, iyi huylu ve kötü huylu lezyonları içeren dokulara karşılık gelmektedir.

Sınıf	Biyosistem kodu
I-1	d1
I-2	d2
I-5	d5
II-1	e1
II-2	e2
II-5	e5
III-1	f1
III-2	f2
III-5	f5
IV-1	g1
IV-2	g2
IV-5	g5

Veri setleri 4 farklı doku yoğunluğuna ayrılmış ve her bir sınıf da 3 farklı hastalık tanısı olan normal, iyi huylu ve kötü huylu alt sınıflarına ayrılmıştır ve toplamda 12 farklı sınıf oluşturulmuştur. Veri setinde bulunan tüm imgelerin dağılımı Çizelge 4.2'den incelenebilir.

**Çizelge 4.2** IRMA projesi ile elde edilen veritabanlarının imge dağılımı.

Veritabanı	İmge Sayısı
IRMA	69
MIAS	150
DDSM	2796
LLNL	1

#### 4.1.1 DDSM Veritabanı

Literatürdeki bir çalışmada (Oliveiraa et al., 2008) belirtildiği üzere Digital Database for Screening Mammography, (Mamografi Görüntüleme Dijital Veritabanı, DDSM) veritabanı resmi olarak 2,479 hastayı (695 normal, 870 iyi huylu ve 914 kanserli vaka) içermektedir. Her bir hasta tek bir göğüse ait iki farklı açı olan craniocaudal (CC) ve mediolateral (ML) yönlerinden çekilmiş filmlere sahiptir. Çekim yapan cihazın çözünürlüğü ise 42 ile 50 mikron/piksel arasında değişmektedir. İmgeler kayıpsız JPEG (Joint Pictures Expert Group) olarak kaydedilmiş olup, C kaynak koduyla yazılmış özel bir yazılım ile dönüştürülebiyecek şekilde internet ortamında tutulmaktadır.

Her bir vaka için ACR (American College Radiology) sistemine göre, doku yoğunlukları, lezyon çeşitleri ve yer bilgileri sunulmaktadır. IRMA projesi kapsamında ise bu imgeler üzerinde yapılan çalışma ile hastalıklı ve normal bölgeler çıkartılmış ve 128 x 128 boyutlu 16-bit PNG (Portable Network Graphics) formatına dönüştürülmüştür. Bünyesinde toplamda 932 normal, 934 iyi huylu ve 930 kötü huylu imgeyi barındırmaktadır.

#### 4.1.2 IRMA Veritabanı

Image Retrieval in Medical Applications IRMA veritabanı, Oliveiraa et al., (2008) çalışmasında anlatıldığına göre, Almanya'nın Aachen Üniversitesi Radyolojik Tanı Bölümü'nün katkılarıyla rastgele 170 hastadan elde edilen röntgenler üzerinde yapılan çalışma ile elde edilmiştir. General Electric Senographe ile enerjisi 26 kV ile 32 kV arası değişen değerler ile düşük enerjili ışın gönderilerek elde edilen imgeler üzerinden 128 x 128 boyutlu hastalıklı bölgeleri ve normal bölge dokuları, Digital Imaging and Communications in Medicine (DICOM) ile elde edilen veriler ışığında hazırlanmış ve IRMA kod sistemine dönüşümünü sağlamıştır. Bu veritabanında yalnızca 69 adet normal sınıfa ait doku sunulmuştur.

#### 4.1.3 MIAS Veritabanı

Mammographic Image Analysis Society (MIAS) veritabanı da yine (Oliveiraa et al., 2008) çalışmasında belirtildiği üzere sınıflandırılması yapılmıştır. Toplamda 322 mamografiden elde edilen 50 mikron/piksel imgeleri içeren bu veritabanındaki tüm imgeler 200 mikron/piksel olacak şekilde küçültülmüş ve daha sonra 1,024 x 1,024 piksele indirilmiştir. Dosyalar PNG formatında tutulmuş ve ek olarak sunulan veride sağ/sol göğüs, doku yoğunluğu, hastalık bilgisi, var olan lezyonun sınıfı ve yer bilgisi sağlanmıştır. Bu veritabanından elde edilen bilgiler ışığında 128 x 128 boyutlu hastalıklı bölge üzerine yoğunlaşmış imgeler çıkartılmış ve 90 normal, 32 iyi huylu ve 28 kötü huylu imge IRMA projesi kapsamında sunulmuştur.

#### 4.1.4 LLNL Veritabanı


Literatürdeki ilgili çalışmada (Oliveiraa et al., 2008) anlatılana göre, bu veritabanı Lawrence Livermore National Laboratories (LLNL)'den alınan örneklerle University of California at San Fransisco (UCSF) işbirliğiyle oluşturulmuş 50 hastaya ait toplamda 197 mamografi imgesi içermektedir. İmgeler 35 mikron/piksel çözünürlüğünde olup ICS

(image cytometry standard) formatındadır ve C kaynak kodu aracılığıyla PGM (portable grey map) formatına dönüştürülebilmektedir. Bu veri tabanında 190 imge için düz metin halinde hastaların özelliklerini, biyopsi ve takip programlarını içeren sağlam dayanak noktası oluşturacak bilgiler bulunmaktadır. IRMA projesi kapsamında sağlanan imge sayısı 1'dir.

## **4.2 İki Sınıflı Örüntü Tanıma Üzerine Yapılan Çalışmalar**

### **4.2.1 Giriş**

Bu tezde yapılan çalışmanın birinci kısmı normal dokuyu kanserli dokudan ayırma işleminin yapıldığı iki sınıflı çalışmadır. Çalışmada kullanılan veri seti, IRMA projesi kapsamında edinilmiş DDSM veritabanındaki imgelerden elde edilmiş hastalıklı ve normal doku örneklerini içeren mamogram imgelerinin parçalarıdır. Bu parçalar sağlam bir dayanak noktası olan ve Deserno et al., (2011) çalışmasında öngörülen şekilde sınıflara ayrılmıştır. Çalışmada kullanılan normal, iyi huylu ve kötü huylu lezyonları içeren örnek imgeler Şekil 4.1'de gösterilmiştir.



**Şekil 4.1** DDSM veritabanına ait 128 x 128 boyutlu imgeler: Birinci satırda 5 tane normal doku, ikinci satırda 5 tane iyi huylu lezyon ve üçüncü satırda ise 5 adet kötü huylu lezyon vakası gösterilmiştir.

Bu çok sınıflı veritabanı, hastaliksız 200 örneğe karşı iyi huylu 100 örnek ve kötü huylu 100 örnek alınarak eşit sayıda normal ve kanserli dokuya ayrılmıştır. Seçilen bu dokuların dönmeden ve ölçekten bağımsız öznitelikleri üç farklı öznitelik çıkarma yöntemi olan HOG, DSIFT ve LCP ile çıkartılarak 10 katlamalı çapraz doğrulama yöntemi ile beş farklı sınıflandırıcıdaki performansları izlenmiştir.

#### 4.2.2 HOG Özniteliklerinin Çıkartılması

Bu öznitelik çıkartma yöntemi, her bir imgeyi çakışma olmaksızın işlem yapacağı bloklara ayırır ve verilen oryantasyon sayısı ile doğru orantılı olarak öznitelik vektörleri oluşturur. Blok boyutları 16 x 16 seçilmiş ve oryantasyon sayısı ise her bir dönme açısı 20° olacak şekilde 18 seçilerek öznitelik çıkartma işlemine gidilmiştir. Kullanılan HOG varyantı Felzenszwalb et al., (2010) çalışmasına referans verilen birçok varyanttan biri olan Chicago Üniversitesi Toyota Teknoloji Enstitüsü (Chicago Üniversitesi Toyota

Teknoloji Enstitüsü, UoCTTI)'dir. Bu işlem sonunda dikey ve yatayda  $16 \times 16$  boyutundaki bloklara sahip  $128 \times 128$  piksel imgeler için  $8 \times 8 \times 58$  boyutunda matrisler elde edilir. Boyut indirgeme işlemi gereklidir ve bu sebeple zaman alanı özelliklerinin çıkarılması düşünülmüştür. Son iki boyut olan  $8 \times 58$  bölüm birbiri ardı sıra dizilir ve 6 farklı zaman alanı özelliği hesaplanır; enerji, ortalama, standart sapma, maksimum, basıklık ve çarpıklık. Elde edilen matrisler  $8 \times 6$  boyutludur. Bu matrisler arka arkaya dizilere HOG öznitelik vektörlerine  $48 \times 1$  olan son boyutu verilir. Vektörler artık sınıflandırıcıyı eğitmek ve testte kullanılmak için hazırdır.

#### 4.2.3 DSIFT Özniteliklerinin Çıkartılması

Kullanılan öznitelik yöntemi bize seçtiğimiz yarıçapın büyüklüğüne göre yoğunluğu değişmekle beraber, imge üzerinden çakışmalı bloklar halinde aldığı türevsel verilerle ölçekten bağımsız öznitelik vektörleri sunar (Vedaldi and Fulkerson, 2010). Seçilen 5 piksel yarıçap değeri için uygulanan algoritma 4 piksel aralıklarla birbiri ardı sıra aldığı imge bölümlerinden  $128 \times 400$  boyutlu matrisler çıkarır. Bu vektörleri sınıflandırıcıya sokmadan önce boyut indirgeme işlemine gidilmesi gerekmektedir. Bu sebeple her bir sütun için zaman alanı özelliklerinin kullanılması düşünülmüştür. Enerji, ortalama, standart sapma, maksimum, basıklık ve çarpıklık olmak üzere 6 farklı özellik seçilerek her bir 400 boyutlu sütuna uygulanmıştır ve  $6 \times 128$  vektör uzayı elde edilmiştir. Daha sonra bu vektör uzayı tek bir satıra dönüştürülmüş ve  $768 \times 1$  boyutundaki vektörler sınıflandırıcıyı eğitmekte kullanılmıştır.

#### 4.2.4 LCP Özniteliklerinin Çıkartılması

Bu öznitelik yönteminin özelliği ise girdiden bağımsız olarak  $1 \times 81$  boyutlu histogram tabanlı vektörler döndürmesidir. Bu öznitelik yönteminin özelliği en çok tekrarlanan değeri ifade eden, vektördeki en büyük değeri çembersel olarak en sona kaydırmasıdır. Sunulan öznitelik çıkarma yöntemi tüm imgelere uygulanmış ve  $1 \times 81$  boyutlu vektörlerin en büyük elementleri diğerlerinin üzerinde baskı kurmaması için


atılmıştır ve 1 x 80 boyutlu vektörler elde edilmiştir. Elde edilen vektörler hiçbir ölçek değişimi yapılmaksızın sınıflandırıcılara sokulmuştur.

#### 4.2.5 İki Sınıflı Örüntü Tanıma Sonuçları

İki sınıflı örüntü tanımada kullanılan beş farklı sınıflandırıcı sonucu elde edilmiştir. SVM sınıflandırıcısının birinci ve ikinci dereceden hiperdüzlemleri kullanılmıştır. KNN sınıflandırıcısı için de deneysel yollarla seçilen  $K=5$  en yakın komşuya bakılarak en iyi sonucun elde edildiği gözlemlenmiştir. KNN ve Karar ağacı algoritmaları ile de % 100'e ulaşan sonuçlar elde edilmiştir. Sınıflandırma sonuçları Çizelge 4.3'ten ve Şekil 4.2'den incelenebilir.

**Çizelge 4.3** İki sınıflı çalışma için 10 katlamalı çapraz doğrulama yöntemi ile elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('p',2) 2. dereceden SVM çekirdek.

Sınıflandırıcı	Öznitelik Çıkartım Yöntemi		
	LCP	HOG	DSIFT
<b>SVM('p',1)</b>			
Ortalama	99,55	99,80	89,20
Std. Sapma	0,96	0,63	6,32
<b>SVM('p',2)</b>			
Ortalama	84,00	99,60	61,60
Std. Sapma	5,48	0,84	8,83
<b>KNN (K=5)</b>			
Ortalama	75,80	100,00	65,00
Std. Sapma	5,65	0	6,50
<b>Karar Ağacı</b>			
Ortalama	99,30	99,80	100,00
Std. Sapma	1,64	0,63	0
<b>FLDA</b>			
Ortalama	99,30	99,80	99,80
Std. Sapma	2,21	0,63	0,63



Şekil 4.2 İki sınıflı çalışma için LCP, HOG ve DSIFT öznitelikleri kullanılarak elde edilen sınıflandırma başarısı.

### 4.3 Üç Sınıflı Örüntü Tanıma Üzerine Yapılan Çalışmalar

#### 4.3.1 Giriş

Tezdeki çalışmanın ikinci kısmını oluşturan normal, iyi huylu ve kötü huylu lezyonların, oluşturulan bilgisayar destekli tanı algoritmalarıyla doğru bir şekilde sınıflandırılmasıdır. Çalışmada kullanılan veri seti IRMA projesi lisans sözleşmesi ile edinilmiş DDSM veritabanındaki imgelerden elde edilmiş doku örneklerini içeren mamogram imgelerinin 128 x 128 piksel boyutlarındaki parçalarıdır. Bu parçalar, sağlam bir dayanak noktası olan Deserno et al., (2011) çalışmasında öngörülen şekilde toplamda 12 sınıfa ayrılmıştır. Bu çok sınıflı veritabanı, hastaliksız 200 örneğe karşı iyi huylu 200 örnek ve kötü huylu 200 örnek alınarak 3 sınıfa indirgenmiştir. Seçilen bu dokulara HOG,


DSIFT, LCP ve Gabor dalgacık öznitelik çıkartma algoritmaları uygulanmış ve 10 katlamalı çapraz doğrulama yöntemi ile beş farklı sınıflandırıcıdaki performansları izlenmiştir.

#### 4.3.2 İki Sınıflı Çalışmada Kullanılan Yöntem ile Alınan Sonuçlar

Bu kısımda, çalışmada kullanılmak için seçilmiş 200 normal, 200 iyi huylu ve 200 kötü huylu olarak üç sınıfa ayrılmış veri seti için, öznitelik çıkarımları, aynı iki sınıflı çalışmada olduğu gibi yapılmış ve beş farklı sınıflandırıcıdaki sonuçları incelenmiştir. İlgili sonuçlar Çizelge 4.4 ve Şekil 4.3'te sonuçlar gösterilmiştir.

**Çizelge 4.4** Üç sınıflı çalışma için, iki sınıflı çalışmadaki öznitelik çıkartma yöntemi kullanılarak elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('p',2) 2. dereceden SVM çekirdek.

Sınıflandırıcı	Öznitelik Çıkartım Yöntemi		
	LCP	HOG	DSIFT
<b>SVM('p',1)</b>			
Ortalama	64,30	58,40	57,40
Std. Sapma	8,01	13,89	7,37
<b>SVM('p',2)</b>			
Ortalama	55,00	63,20	42,00
Std. Sapma	7,07	9,75	6,11
<b>KNN (K=5)</b>			
Ortalama	49,50	56,60	42,20
Std. Sapma	4,72	11,44	7,66
<b>Karar Ağacı</b>			
Ortalama	57,40	54,50	54,90
Std. Sapma	6,59	10,79	6,77
<b>FLDA</b>			
Ortalama	62,50	58,20	48,70
Std. Sapma	8,48	9,86	6,80



**Şekil 4.3** İki sınıflı çalışmada kullanılan yöntem baz alınarak yapılan üç sınıflı çalışma için sınıflandırma sonuçları.

Söz konusu üç sınıf olduğunda aynı yöntem ile etkili bir sınıflandırma işlemine gidilememiştir. Bu sebeple imgelere ön işlem uygulama ve öznelik çıkarma işleminde iyileştirmelere gidilmiştir.

### 4.3.3 Gabor Dalgacık Özneliklerinin Çıkartılması

Gabor dalgacık modeli kullanması sonucunda öznelik vektörleri çıkartıldığında çok büyük boyutlu vektörler elde edilmektedir. Bu vektörlerin sınıflandırıcıya sokulmadan önce uygun boyuta indirgenmesi gerekmektedir.

Bu tezin kapsamında yapılan üç sınıflı çalışmada Gabor öznitelikleri çıkartılırken, 15 farklı ölçek ( $v= 0, 1, \dots, 15$ ) ve 10 farklı oryantasyon ( $\mu = 0, 1, \dots, 9$ ) parametreleri kullanılmıştır. Bunun sonucunda her bir imge için 150 farklı Gabor filtresi kullanıldığında  $150 \times 128 \times 128 = 2.457.600$  boyutlu bir vektör gelmektedir. Bu vektörler  $128 \times 128$  boyutlu imge ile çarpılır ve  $\mu \times v$  boyutlu dalgacık dönüşümü katsayıları elde edilir. Elde edilen dalgacık dönüşümü katsayıları 150 boyutludur ve kompleks bileşenlere sahiptir. Kompleks bileşenlerden kurtulmak için vektördeki her bir elemanın büyüklüğü alınır. Bu sayede  $150 \times 1$  boyutlu Gabor öznitelik vektörleri elde edilir. Bu vektörler daha düşük bir boyut olan  $40 \times 1$  boyutlu vektörlere PCA ile indirilir ve doğrusal ayırtaç analizi sınıflandırıcısını eğitmekte ve test işleminde kullanılır. Bu şekilde hazırlanmış Gabor dalgacık öznitelikleriyle elde edilen üç sınıflı sınıflandırma sonuçları Çizelge 4.5'ten görülebilir.

**Çizelge 4.5** Üç sınıflı çalışma için Gabor dalgacık öznitelikleri kullanılarak 10 katlamalı çapraz doğrulama yöntemi ile elde edilen sınıflandırma sonuçları (%). GabPCA, Gabor dalgacık öznitelik vektörleri PCA kombinasyonu.

Test Aralığı	GabPCA
1-20	48
21-40	35
41-60	65
61-80	70
81-100	68
101-120	65
121-140	62
141-160	62
161-180	63
181-200	60
Ortalama	59,80
Std. Sapma	10,54

## 4.4 Üç Sınıflı Örüntü Tanıma Üzerine Yeni Bir Yaklaşım

### 4.4.1 Yerel-Olmayan Ortalama Filtresi

Non-Local Means (Yerel-Olmayan Ortalama, NLM), medikal imgelerde yaygın bir biçimde ortaya çıkan gürültü modeli olan salt & pepper tarzı gürültüyü gidermede etkili bir filtreleme tekniğidir (Naveed et al., 2012). Literatürdeki bir çalışmaya (Naveed et al., 2012) istinaden NLM filtreleme tekniği şu şekilde özetlenebilir. İmge üzerindeki yerel piksellerin ışık şiddeti değerlerinin birbirine benzerliğine göre pencere boyutunu değiştirerek, hızlı bir şekilde geniş bir bölgeyi tararken, ufak pencerede ise türevleri baz alması dolayısıyla kenarların düzgün biçimde korumasını sağlayacak ağırlıklandırma fonksiyonunu kullanır. İki boyutlu imge  $I(p, q)$  için NLM Eş. (3.5) ve Eş. (3.6)'daki gibi hesaplanır.

$$NLM(I(p)) = \sum_{\forall q \in \eta} w(p, q)I(q) \quad (4.1)$$

$$0 \leq w(p, q) \leq 1, \sum_{\forall q \in \eta} w(p, q) = 1 \quad (4.2)$$

$p$  burada filtrelenecek istenen pikseli ifade ederken,  $q$  arama penceresinde bulunan  $\eta$  komşuluğundaki piksellere karşılık gelmektedir. Ağırlık fonksiyonu  $w(p, q)$  ise komşu pikseller olan  $p$  ve  $q$ 'nin birbirlerine benzerliğinin bir ölçütü olan  $N_p$  ve  $N_q$  üzerinden hesaplanır.  $N_i$  karesel komşuluk penceresi, kullanıcı tarafından girilen bir  $R_{sim}$  değeriyle belirlenir. Benzerliklerin ağırlığı olan  $w(p, q)$  Eş. (3.8)'deki gibi hesaplanır.

$$w(p, q) = 1 / (Z(p)) e^{-\left(\frac{d(p, q)}{h^2}\right)} \quad (4.3)$$

$Z(p)$  normalizasyon sabitidir ve Eş. (3.8)'deki gibi hesaplanır.

$$Z(p) = \sum_{\forall q} e^{-\frac{d(p,q)}{h^2}} \quad (4.4)$$


$h$  üstel bozulma parametresi ve  $d$  Eş. (3.9)'da da gösterildiği gibi tüm piksellerin her bir komşudan Gauss ağırlıklı öklit uzaklığıdır.

$$d(p, q) = G_\alpha \left\| Y(N_p) - Y(N_q) \right\|^2 R_{sim} \quad (4.5)$$

$G_\alpha$  sıfır ortalamalı standart sapması 1 olan Gauss ağırlık fonksiyonunu ifade etmektedir.  $p = q$  olduğunda piksel benzerliği çok yüksek oluyor ve bu durum aşırı ağırlık etkilerine neden olabiliyor. Bu problemi çözmek içinse Eş. (3.10)'deki işlemi yapmak gerekmektedir.

$$W(p, q) = \text{maksimum}(w(p, q) \quad \forall q \neq p) \quad (4.6)$$

Tezdeki üç sınıflı çalışmadaki yeni yaklaşımda ve iki seviyeli çalışmanın bir kısmında bir ön işlem olarak NLM filtrelemesi tercih edilmiştir. Şekil 4.4'te tezde kullanılan veritabanına ait kötü huylu lezyon içeren bir imgenin histogram eşitleme işlemi yapıldıktan sonraki ve hem histogram eşitleme hem de Darbon et al., (2008) çalışmasında anlattığı hızlı NLM filtre uygulandıktan sonraki hali gösterilmektedir.



**Şekil 4.4** Histogram eşitleme yapılmış kötü huylu lezyon (solda) Histogram eşitlemeyi takiben NLM filtresi uygulanmış lezyon (sağda).

Şekil 4.4'te de görüldüğü gibi imgeye ait düzensiz kenarlar korunurken genel olarak gereksiz bilgi içeren bölgeler yumuşatılmıştır. Bu sayede daha gürbüz sınıflandırma sonuçlarını verecek özneliklerin çıkartılması sağlanmıştır.

#### 4.4.2 HOG Özniteliklerinin Çıkartılması

HOG betimleyicisi imgelere uygulanmadan önce resim iyileştirme tekniği olarak histogram eşitleme ve NLM filtreleme işlemleri imgeye uygulanmıştır. Bu işlemden sonra imge, tek seviye dalgacık dönüşümü ile bileşenlerine Daubechies-1 varyantı ile ayrılmış ve sinyale ait 4 farklı alt bant; LL (low-low), LH (low-high), HL (high-low), HH (high-high) elde edilmiştir. Bu aşamadan sonra her bir alt bant için blok boyutları 16 x 16 seçilmiş ve oryantasyon sayısı ise her bir dönme açısı 20° olacak şekilde 18 seçilerek öznitelik çıkartma işlemine gidilmiştir. Kullanılan HOG varyantı Felzenszwalb et al., (2010) çalışmasına referans verilen birçok varyanttan biri olan UoCTTI'dır. Bu işlem sonunda dikey ve yatayda 16 x 16 boyutundaki bloklara sahip 64 x 64 piksel her bir alt bant için 4 x 4 x 58 boyutunda matrisler elde edilir. Boyut indirgeme işlemi için ise zaman alanı özelliklerinin çıkartılması düşünülmüştür. Son iki boyut olan 8 x 58 bölüm birbirini ardı sıra dizilir ve 6 farklı zaman alanı özelliği hesaplanır; enerji, ortalama, standart sapma, maksimum, basıklık ve çarpıklık. Elde edilen matrisler 8 x 6 boyutludur. Bu matrisler arka arkaya dizilere HOG öznitelik vektörlerine 48 x 1 olan son boyutu verilir. Bu işlem her bir alt bant için uygulandıktan sonra her bir alt bant sırayla 2,1,1,0 sayılarıyla çarpılıp toplanır (2 x LL+ 1 x LH+ 1 x HL+ 0 x HH). Bu şekilde elde edilen vektörlerin sınıflandırma sonuçlarındaki kodu HOG 2-1-1-X'tir. Vektörler artık sınıflandırıcıyı eğitmek ve testte kullanılmak için hazırdır.

#### 4.4.3 DSIFT Özniteliklerinin Çıkartılması

Öncelikle histogram eşitleme ve NLM filtreleme işlemleri imgeye uygulanmıştır. Bu işlemden sonra imge, tek seviye dalgacık dönüşümü ile bileşenlerine Daubechies-1 varyantı ile ayrılmış ve sinyale ait 4 farklı alt bant; LL (low-low), LH (low-high), HL (high-low), HH (high-high) elde edilmiştir. DSIFT betimleyicisi imgelere uygulanırken yarıçap 5 piksel için uygulanan algoritma 4 piksel aralıklarla birbirini ardı sıra aldığı imge bölümlerinden her bir alt bant için  $128 \times (128 / \text{yarıçap})^2$  boyutlu matrisler çıkartır. Bu matrisleri sınıflandırıcıya sokmadan önce boyut indirgeme işlemine gidilmesi gerekmektedir. Bu sebeple her bir sütun için zaman alanı özellikleri kullanılmıştır.

Enerji, ortalama, standart sapma, maksimum, minimum, basıklık ve çarpıklık olmak üzere 7 farklı özellik seçilerek her biri yarıçap bağımlı olan matrisin son kısmına uygulanır ve  $7 \times 128$  vektör uzayı elde edilmiştir. Bu işlem her bir alt bant için uygulandıktan sonra her bir alt bant sırayla 2,1,1,0 sayılarıyla çarpılıp toplanır ( $2 \times LL + 1 \times LH + 1 \times HL + 0 \times HH$ ). Daha sonra bu vektör uzayı tek bir satıra dönüştürülmüş ve  $896 \times 1$  boyutundaki vektörler sınıflandırıcıyı eğitmekte kullanılmıştır. Bu şekilde elde edilen özniteliklerin sınıflandırıcıdaki kodu yarıçapa göre değişmektedir ve Çizelge 4.6'dan görülebilir.

**Çizelge 4.6** DSIFT öznitelikleri çıkartılırken kullanılan yarıçap parametresi.

DSIFT kodu	Açıklama
DSIFT $r=3$	Öznitelikler, $r=3$ yarıçaplı DSIFT kullanılarak çıkartılmıştır
DSIFT $r=4$	Öznitelikler, $r=4$ yarıçaplı DSIFT kullanılarak çıkartılmıştır
DSIFT $r=5$	Öznitelikler, $r=5$ yarıçaplı DSIFT kullanılarak çıkartılmıştır

#### 4.4.4 LCP Özniteliklerinin Çıkartılması

Histogram eşitleme ve NLM filtreleme işlemleri yapıldıktan sonra tek seviye dalgacık dönüşümü ile bileşenlerine Daubechies-1 varyantı ile ayrılmış ve sinyale ait 4 farklı alt bant; LL (low-low), LH (low-high), HL (high-low), HH (high-high) elde edilmiştir. LCP öznitelik çıkartma yöntemi her bir imge için tüm alt bantlara uygulanmış ve  $1 \times 81$  boyutlu vektörler oluşturan her bir alt bant sırayla Çizelge 4.7'deki katsayılarla çarpılıp toplanarak oluşturulmuş yöntem Weighted-Wavelet Local Configuration Pattern (Ağırlıklı Dalgacık Yerel Konfigürasyon Örüntüsü, WWLCP) diye adlandırılır.

**Çizelge 4.7** LCP ile öznelik vektörleri oluşturulurken alt bantların çarpıldığı katsayılar ve onlara ait LCP kodu. (“LCP histeq” üretilirken NLM kullanılmamıştır).


LCP kodu	LL-LH-HL-HH katsayıları
LCP histeq	2-1-1-0
LCP e	$e^2 \cdot e^1 \cdot e^0 \cdot 0$
LCP 2-1-HH	2-1-1-1
LCP 2-1	2-1-1-0
LCP 1,8-1	1,8-1-1-0
LCP 1,6-1	1,6-1-1-0
LCP 1,4-1	1,4-1-1-0
LCP 1,2-1	1,2-1-1-0
LCP 1-1	1-1-1-0

#### 4.4.5 Üç Sınıflı Örüntü Tanıma Sonuçları


Üç sınıflı örüntü tanımda kullanılan beş farklı sınıflandırıcı sonucu elde edilmiştir. SVM sınıflandırıcısının lineer çekirdeği ve öklit metriği kullanılmıştır. KNN sınıflandırıcısı için de deneysel yollarla seçilen  $K=5$  en yakın komşuya bakılarak en iyi sonucun elde edildiği gözlemlenmiştir. Karar ağacı ve FLDA algoritmaları da sınıflandırmaya dahil edilmiştir. Sınıflandırma sonuçları Çizelge 4.8, Şekil 4.5 ve Şekil 4.6'dan incelenebilir. Üç sınıflı örüntü tanımda LCP betimleyişinin dalgacık dönüşümü sonrası yapılması sonuçları yükseltmişken, HOG ve DSIFT için sonuçların düştüğü gözlemlenmiştir. Gabor dalgacık ile uygulanan yöntemde ise genel olarak HOG ve DSIFT yöntemlerinden daha iyi olsa da yeterince yüksek başarı elde edilememiştir.

**Çizelge 4.8** Üç sınıflı örüntü tanıma çalışması için elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği.

Sınıflandırıcı	Öznitelik Çıkartım Yöntemi												
	LCP histeq	LCP e	LCP 2-1-HH	LCP 2-1	LCP 1,8-1	LCP 1,6-1	LCP 1,4-1	LCP 1,2-1	LCP 1-1	HOG 2-1-1-X	DSIFT r=3	DSIFT r=4	DSIFT r=5
<b>SVM('p',1)</b>													
Ortalama	88,10	87,40	89,00	90,10	90,30	89,90	90,60	90,50	90,30	52,90	54,80	61,70	49,40
Std. Sapma	8,96	5,68	4,29	3,98	3,86	3,98	4,50	4,35	4,52	6,01	7,33	7,86	9,54
<b>SVM('d',2)</b>													
Ortalama	88,50	88,83	88,30	90,00	90,00	89,70	89,70	89,60	89,60	30,70	43,90	61,90	47,30
Std. Sapma	9,10	8,11	4,99	5,98	6,07	5,98	6,58	6,59	6,59	4,74	7,96	6,81	5,79
<b>KNN (K=5)</b>													
Ortalama	62,20	67,40	75,70	70,20	71,30	72,20	75,20	74,30	75,60	38,70	46,70	47,90	44,90
Std. Sapma	8,22	8,00	7,94	9,47	7,66	8,64	8,63	6,57	6,83	2,45	6,40	5,82	5,47
<b>Karar Ağacı</b>													
Ortalama	58,00	52,90	51,00	51,30	46,20	48,30	53,40	51,90	51,20	41,60	48,70	56,20	46,00
Std. Sapma	9,51	5,76	6,51	3,53	8,74	3,92	7,26	10,07	3,22	5,34	7,47	7,08	6,29
<b>FLDA</b>													
Ortalama	88,20	88,40	87,80	89,70	89,70	89,30	89,20	89,10	87,50	52,10	44,10	62,20	46,10
Std. Sapma	9,04	5,25	6,41	5,89	6,58	6,02	5,88	5,95	6,20	5,76	6,59	7,67	6,01



Şekil 4.5 Üç sınıflı çalışma için LCP öznelikleri kullanılarak elde edilen sınıflandırma sonuçları. SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği.



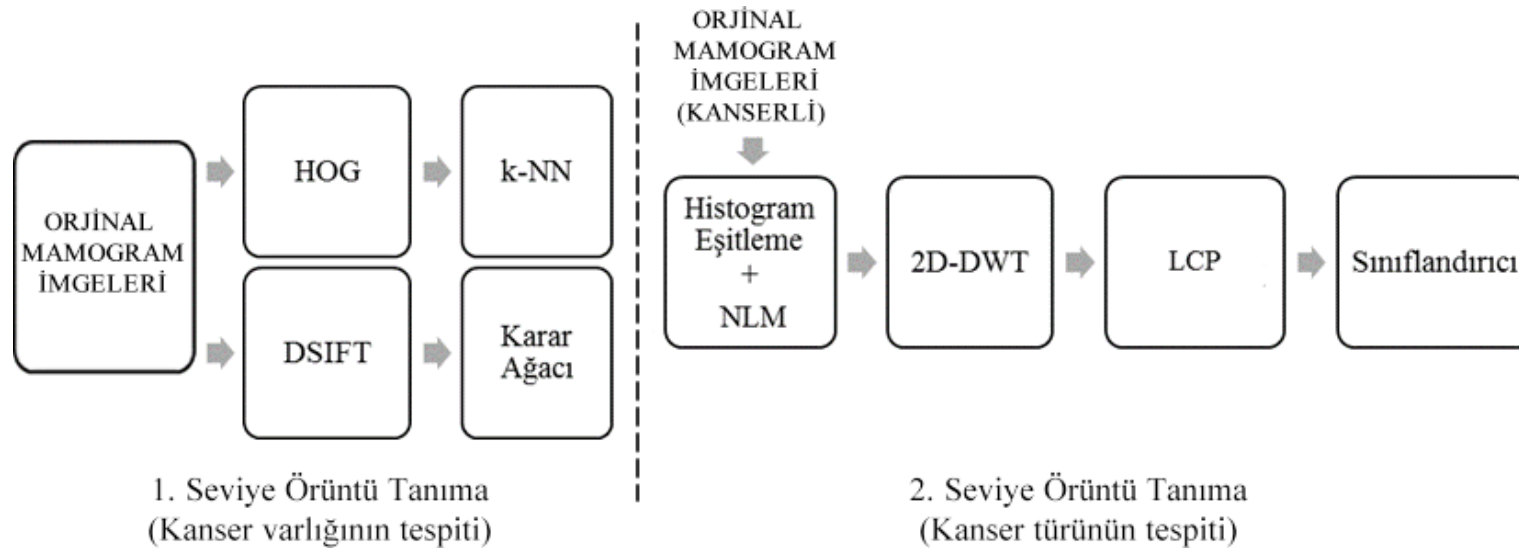
**Şekil 4.6** Üç sınıflı çalışma için HOG 2-1-1-X, DSIFT r= 3,4,5 öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları grafiği. SVM(p',1) lineer SVM çekirdek, SVM(d',2) öklit metriği.

## 4.5 İki Seviyeli Yeni Bir Örüntü Tanıma Yaklaşımı

Üç sınıflı örüntü tanımada kullanılan beş farklı sınıflandırıcı sonucu elde edilmiştir. SVM sınıflandırıcısının lineer çekirdeği ve öklit metriği kullanılmıştır. KNN sınıflandırıcısı için en yakın 5 komşuya bakılarak en iyi sonucun elde edildiği gözlemlenmiştir. Karar ağacı ve FLDA algoritmaları da sınıflandırmaya dahil edilmiştir.

### 4.5.1 İki Seviyeli Yaklaşımda İzlenen Süreç

İki seviyeli örüntü tanımının birinci seviyesini iki sınıflı çalışmada % 100 başarı sağlamış öznitelik vektörleri ve onlarla eşleşen sınıflandırma algoritmaları oluşturmaktadır. İki sınıflı çalışma mamogram dokularını LCP'den elde edilen öznitelikler lezyonları bulmada çok yüksek oranda başarı sağlarken, HOG ve DSIFT ile elde edilen özniteliklerle ise hastalıklı ve hastaliksız olarak tam olarak doğru ayırabilmektedir. Bunun sonucunda iki sınıflı çalışmada ayrılan hastalıklı dokuları türlerine göre iyi huylu ve kötü huylu olarak daha etkin bir biçimde ayırabilmek mümkün olmaktadır. Tezde sunulan üç sınıflı çalışmanın, birbiri ardı sıra yapılan iki sınıflı çalışmaların uç uca eklenmesi ile başarı oranı artırılabilir. Öznitelik vektörlerinin çıkartılma aşamasından sınıflandırıcı sonuçları elde edilinceye kadar izlenmesi gereken adımlar Şekil 4.7'de gösterilmiştir.



**Şekil 4.7** İki seviyeli çalışmada ön işlem, öznelik çıkartma ve sınıflandırma adımları


LCP öznitelikleri, her biri 200 imge içeren iki ayrı sınıf olan iyi huylu ve kötü huylu için üç sınıflı çalışmadaki gibi çıkartılmış ve sınıflandırıcıları eğitmede kullanılmıştır. Yapılan çalışmada anlaşılmıştır ki ikinci seviye sınıflandırmada en başarılı öznitelik çıkartma yöntemi LCP 1,8-1 kodlu WWLCP vektörleridir.

#### 4.5.2 İki Seviyeli Örüntü Tanıma Sonuçları

İki seviyeli örüntü tanıma için tek bir betimleyiciden elde edilen vektörlerin beş farklı sınıflandırıcıda 10 katlamalı çapraz doğrulama yöntemi kullanarak başarı oranı izlenmiştir. Sınıflandırma başarısı Çizelge 4.9 ve Şekil 4.8'den incelenebilir.

**Çizelge 4.9** İki seviyeli çalışma için 10 katlamalı çapraz doğrulama yöntemi ile elde edilen sınıflandırma sonuçları (%). SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği.

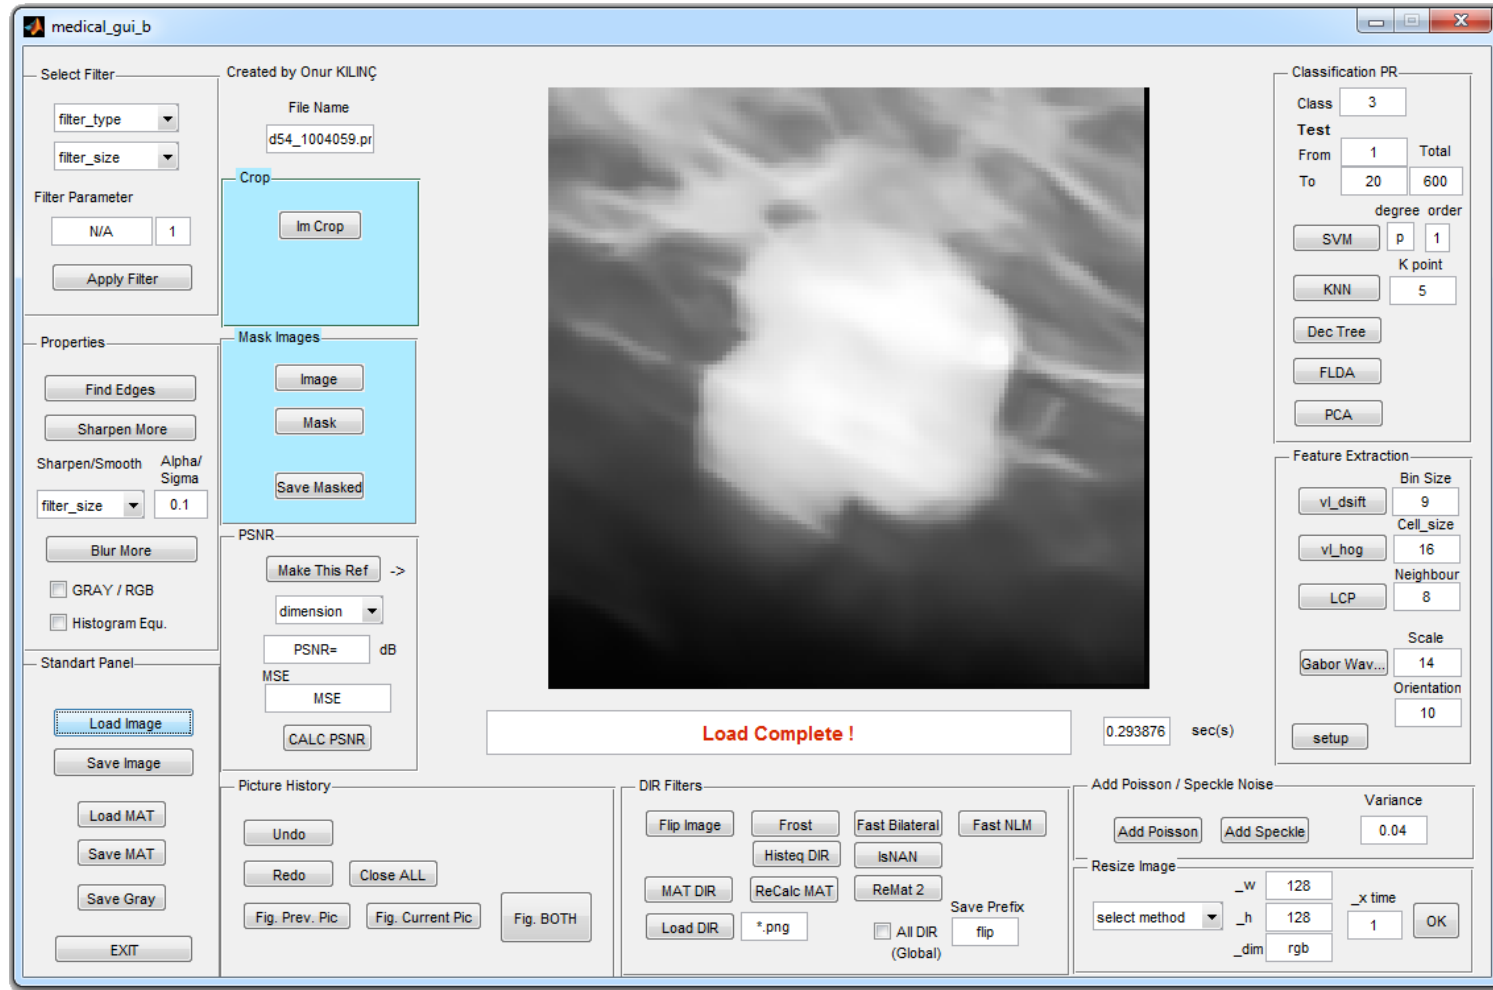
	<b>Öznitelik Çıkartım Yöntemi</b>
<b>Sınıflandırıcı</b>	<b>HOG/ DSIFT- WWLCP</b>
<b>SVM('p',1)</b>	
Ortalama	97,90
Std. Sapma	2,18
<b>SVM('d',2)</b>	
Ortalama	98,80
Std. Sapma	1,03
<b>KNN (K=5)</b>	
Ortalama	79,20
Std. Sapma	7,81
<b>Karar Ağacı</b>	
Ortalama	51,50
Std. Sapma	7,91
<b>FLDA</b>	
Ortalama	98,80
Std. Sapma	1,03



**Şekil 4.8** İki seviyeli çalışma için LCP 1,8-1 öznitelikleri kullanılarak elde edilen sınıflandırma sonuçları. SVM('p',1) lineer SVM çekirdek, SVM('d',2) öklit metriği.

#### 4.6 Deneysel Çalışmalarda Geliştirilen Kullanıcı Grafik Arayüzü

Örüntü tanıma işlemleri tez çalışmasında anlatılan farklı birçok önışlem ve öznitelik çıkartım yöntemi kullanmayı gerektirmektedir. Parametre deęişimlerdeki ufak farklılıklar deneyin tekrarlanması gerektirir ve tüm bu süreç titiz bir şekilde yapılmalıdır. Bu sebeplerden dolayı Matlab platformu üzerinde, tezdeki işlemler için özelleştirilmiş bir kullanıcı grafik arayüzü oluşturulmuştur. Şekil 4.9'da gösterilen arayüz, gürültü ekleme, filtreleme, önışlem, öznitelik çıkartımı, çeşitli matris manipülasyonları ve sınıflandırma algoritmalarını içermektedir.



Şekil 4.9 Tez çalışmasında geliştirilen kullanıcı grafik arayüzü

## BÖLÜM 5

### SONUÇLAR VE TARTIŞMA

Dijital mamogram imgelerinde lezyonları tespit edip bireylerde oluşan göğüs kanseri hastalığının türünü belirlemek bilgisayarla görü uygulamalarının en zor problemlerinden biridir. Bunun sebebi, normal bir göğüs dokusu ile kanserli bir göğüs dokusu arasında bazen çok küçük farkların bulunmasıdır. Aynı zamanda, çoğu kanser vakasında iyi huylu lezyon ile kötü huylu lezyon arasında ayırt edilmesi oldukça güç doku oluşumları gözlemlenmektedir. Literatürdeki çalışmalarda bahsedildiği üzere, uzman radyolojistler tarafından bile ancak % 75 oranında doğru kanser teşhisi yapılabilmektedir.

Literatürde, bu tez çalışması kapsamında kullanılan veritabanı (DDSM) üzerinde farklı yöntemlerle lezyon sınıflandırma çalışmaları yapılmış olup, % 97'ye kadar başarı sağlayan yöntemlerden bahsedilmektedir. Eş Merkezli Katman Modeli (Concentric Layer Model) sınıflandırıcısı kullanılarak 540 imge için iki sınıflı çalışmada % 96 başarı sağlanmıştır. Diğer bir sınıflandırıcı olan Üreysel Algoritma (Generic Algorithm) ise, 360 imge üzerinde denenmiş ve iki sınıf için % 86 başarı elde edilmiştir. Bir başka çalışmada, aynı veritabanında bulunan 2,563 imge için kitle varlığı araştırılırken kitle şekli, kitle sınırı ve doku yoğunluğunu betimleyen üç boyutlu öznitelik vektörleri kullanılmış ve radyal SVM çekirdeği ile % 70 civarında başarıya ulaşılmıştır. Şablon Eşleştirme (Template Matching) kullanılarak 1,852 imge üzerinde çalışılmış ve kötü huylu kitlelerde % 71,90, normal imgelerde ise, % 83,20 sınıflandırılma başarı gözlemlenmiştir. Yumuşak Kümelenebilir Doğrudan Öğrenme (Soft-clustered Direct Learning) sınıflandırıcısından faydalanılarak DDSM üzerindeki 200 imgede ise % 97 başarı sağlandığı görülmüştür.

Bu tezdeki çalışmaların ilk kısmında, normal dokuyu kanserli dokudan ayırmada üç farklı öznitelik çıkartım yöntemi kullanılmış ve % 100 başarı sağlandığı görülmüştür. Tezin ikinci aşamasında ise, normal, iyi huylu ve kötü huylu göğüs kanseri yapılarının sınıflandırılması amaçlanmıştır. Bu bağlamda, öncelikle, iki sınıflı çalışmada kullanılan yöntemler tekrarlanmış; fakat istenilen sonuçlar alınamamıştır. Bunun sebebi ise, iyi huylu-kötü huylu lezyon ayrımının çok daha zor bir problem olmasıdır. Başarı oranlarını arttırmak için, iki adet farklı ve yeni yaklaşım bu tez kapsamında önerilmiştir. Bu

yaklaşımlardan ilki, öznitelik çıkartım adımından önce bazı önlemler uygulanmasını öngören ve çeşitli ağırlıklandırma parametrelerine sahip Weighted-Wavelet LCP (Ağırlıklı Dalgacık Yerel Konfigrasyon Örüntüsü, WWLCP) yöntemidir. Bu yöntem sayesinde, üç sınıflı örüntü tanıma problemine % 90,60 gibi azımsanmayacak kadar iyi bir oranda çözüm getirilmiştir. Önerilen yaklaşımlardan ikincisinde ise, iki sınıflı çalışmada %100 başarı sağlamış öznitelik çıkartma yöntemini kullanarak önce, normal dokuların düzgün bir şekilde ayrılması sağlanmış; ardından WWLCP yöntemi kullanılarak iyi huylu-kötü huylu kanser dokusu teşhis edilmiştir. Bu iki seviyeli çalışmada, IRMA (Image Retrieval in Medical Applications) projesi kapsamında edinilmiş veritabanı için % 99,20 gibi üstün bir sınıflandırma başarısına ulaşılmıştır. Bu oranın, mamografi imgelerini inceleyen ve araştıran uzman radyolojistlere yönelik Bilgisayar Destekli Tanı (Computer Aided Diagnosis, CAD) uygulamalarına etkin bir şekilde destek olabileceği düşünülmektedir.

## KAYNAKLAR DİZİNİ

- Angelini, E., Campanini, R., Iampieri, E., Lanconelli, N., Masotti, M. and Roffilli, M., 2006, Testing the performances of image representations for mass classification in digital mammograms, *International Journal of Modern Physics C*, 17, 113-131.
- Arivazhagan, S., Ganesan, L., Priyal, S.P., 2006, Texture classification using Gabor wavelets based rotation invariant features, *Pattern Recognition Letters*, 27, 1976–1982.
- Bellotti, R., De Carlo, F., Tangaro, S., Gargano, G., Maggipinto, G., Castellano, M., Massafra, R., Cascio, D., Fauci, F., Magro, R., Raso, G., Lauria, A., Forni, G., Bagnasco, S., Cerello, P., Zanon, E., Cheran, S.C., Lopez Torres, E., Bottigli, U., Masala, G.L., Oliva, P., Retico, A., Fantacci, M.E., Cataldo, R., De Mitri, I. and De Nunzio, G., 2006, A completely automated CAD system for mass detection in a large mammographic database, *Medical Physics*, 33, 3066-3076.
- Buciu, I., Gacsadi, A., 2011, Directional features for automatic tumor classification of mammogram images, *Biomedical Signal Processing and Control*, 6, 370–378.
- Campanini, R., Dongiovanni, D., Iampieri, E., Lanconelli, N., Masotti, M., Palermo, G., Riccardi, A. and Roffilli, M., 2004, A novel featureless approach to mass detection in digital mammograms based on support vector machines, *Physics in Medicine and Biology*, 49, 961.
- Chang, S.G., Vetterli, M., 1997, Spatial adaptive wavelet thresholding for image denoising, *Proceedings., 7. International Conference On Image Processing*, 74–377.
- Cheng, H.D., Shan, J., Ju, W., Guo, Y. and Zhang, L., 2010, Automated breast cancer detection and classification using ultrasound images: A survey, *Pattern Recognition*, 43, 299–317.
- Darbon, J., Cunha, A., Chan, T.F., Osher, S. and Jensen, G.J., 2008, Fast nonlocal filtering applied to electron cryomicroscopy, 5. *IEEE International Symposium On Biomedical Imaging: From Nano to Macro*, 1331–1334.
- De Oliveira, J.E., Deserno, T.M. and Araújo, A. de A., 2008, Breast Lesions Classification applied to a reference database, 2. *International Conference on E-Medical Systems*, 29-31.
- De Oliveira Martins, L., Junior, G.B., Silva, A.C., de Paiva, A.C. and Gattass, M., 2009, Detection of masses in digital mammograms using K-means and support vector machine, *Electronic Letters on Computer Vision and Image Analysis*, 8, 39–50.

**KAYNAKLAR DİZİNİ (devam)**

- Deserno, T.M., Soiron, M., de Oliveira, J.E.E. and de A Araujo, A., 2011, Towards computer-aided diagnostics of screening mammography using content-based image retrieval, 24. SIBGRAPI Conference On Graphics, Patterns and Images, 211–219.
- Duin, R.P.W, 2013, PRTools (Version 4.2.4) A Matlab toolbox for pattern recognition, Pattern recognition group, University of Delft.
- Eero, P.S.,1996, 3. IEEE International Conference on Image Processing, 1, 379-382.
- Eng, H.-L., Ma, K.-K., 2001, Noise adaptive soft-switching median filter, IEEE Transactions on Image Processing, 10, 242–251.
- Felzenszwalb, P.F., Girshick, R.B., McAllester, D. and Ramanan, D., 2010, Object detection with discriminatively trained part-based models, IEEE Transactions on Pattern Analysis and Machine Intelligence, 32, 1627–1645.
- Ferreira, C.B.R., Borges, D.L., 2003, Analysis of mammogram classification using a wavelet transform decomposition, Pattern Recognition Letters, 24, 973–982.
- Guo, Y., Zhao, G. and Pietikäinen, M., 2011, Texture classification using a linear configuration model based descriptor, British Machine Vision Association, 119, 1–10.
- Gülmezoğlu, M.B., Edizkan, R., Ergin, S., Barkana, A., 2005, Improvements on isolated word recognition using subspace method, 13. European Signal Processing Conference, 1, 317-320, 2559p.
- Heinlein, P., Drexler, J., Schneider, W., 2003, Integrated wavelets for enhancement of microcalcifications in digital mammography, IEEE Transactions on Medical Imaging, 22, 402–413.
- Jaffar, M.A., Naveed, N., Zia, S., Ahmed, B. and Choi, T.-S., 2011, DCT features based malignancy and abnormality type detection method for mammograms, International Journal of Innovative Computing Information and Control, 7, 5495–5513.
- Kim, J., Kim, B.-S. and Savarese, S., 2012, Comparing image classification methods: K-nearest-neighbor and support-vector-machines, 6. WSEAS International Conference on Computer Engineering and Applications, 133-138.
- Ko, S.-J., Lee, Y.H., 1991, Center weighted median filters and their applications to image enhancement, IEEE Transactions on Circuits and Systems, 38, 984–993.

### KAYNAKLAR DİZİNİ (devam)

- Liu, P., Li, H., 2004, Fuzzy techniques in image restoration research - A survey, *International Journal of Computational Cognition*, 2, 131–149.
- Loog, M., Duin, R.P.W. and Haeb-Umbach, R., 2001, Multiclass linear dimension reduction by weighted pairwise Fisher criteria, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23, 762–766.
- Loog, M., Haeb-Umbach, R., 2000, Multi-class linear dimension reduction by generalized Fisher criteria., 1. Annual Conference of The International Speech Communication Association (INTERSPEECH), 1069–1072.
- Lowe, D.G., 2004, Distinctive image features from scale-invariant keypoints, *International Journal of Computer Vision*, 60, 91–110.
- Malfait, M., Roose, D., 1997, Wavelet-based image denoising using a Markov random field a priori model, *IEEE Transactions on Image Processing*, 6, 549–565.
- Meselhy Eltoukhy, M., Faye, I., Belhaouari Samir, B., 2010, A comparison of wavelet and curvelet for breast cancer diagnosis in digital mammogram, *Computers in Biology and Medicine*, 40, 384–391.
- Naveed, N., Hussain, A., Arfan Jaffar, M. and Choi, T.-S., 2012, Quantum and impulse noise filtering from breast mammogram images, *Computer Methods and Programs in Biomedicine*, 108, 1062–1069.
- Ojala, T., Pietikäinen, M. and Harwood, D., 1996, A comparative study of texture measures with classification based on featured distributions, *Pattern recognition* 29, 51–59.
- Oliveiraa, J.E., Guelda, M.O., Araújo, A. de A., Ottc, B. and Deserno, T.M., 2008, Towards a standard reference database for computer-aided mammography, *SPIE Medical Imaging*, 6915, 1-9.
- Rabottino, G., Mencattini, A., Salmeri, M., Caselli, F. and Lojacono, R., 2011, Performance evaluation of a region growing procedure for mammographic breast lesion identification, *Computer Standards & Interfaces*, 33, 128–135.
- Romualdo, L.C. dos S., Vieira, M.A. da C., Schiabel, H., 2009, Mammography Images Restoration by Quantum Noise Reduction and Inverse MTF Filtering, 22. Brazilian Symposium on Computer Graphics and Image Processing, 180–185, 357p.

**KAYNAKLAR DİZİNİ (devam)**

- Scharcanski, J., Jung, C.R., 2006, Denoising and enhancing digital mammographic images for visual screening, *Computerized Medical Imaging and Graphics*, 30, 243–254.
- Song, L., Liu, X., Ma, L., Zhou, C., Zhao, X. and Zhao, Y., 2012, Using HOG-LBP features and MMP learning to recognize imaging signs of lung lesions, 25. *International Symposium On Computer-Based Medical Systems*, 1–4.
- Su, M.-Y., 2011, Real-time anomaly detection systems for denial-of-service attacks by weighted k-nearest-neighbor classifiers, *Expert Systems with Applications*, 38, 3492–3498.
- Tai Sing Lee, 1996, Image representation using 2D Gabor wavelets, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18, 959–971.
- Uysal, A.K., Gunal, S., Ergin, S., Sora Gunal, E., 2013, The Impact of Feature Extraction and Selection on SMS Spam Filtering, *Electronics and Electrical Engineering*, 19, 67–72.
- Vedaldi, A., Fulkerson, B., 2010, VLFeat: An open and portable library of computer vision algorithms, *International Conference on Multimedia*, 1469–1472.
- Wang, J.-G., Li, J., Yau, W.-Y. and Sung, E., 2010, Boosting dense SIFT descriptors and shape contexts of face images for gender recognition, *IEEE Computer Society Conference On Computer Vision and Pattern Recognition Workshops*, 96–102.
- Wang, Y., Zheng, J., Zhou, H., Shen, L., 2008, Medical image processing by denoising and contour extraction, *International Conference On Information and Automation*, 618–623.
- Xu, Y., Imou, K., Kaizu, Y. and Saga, K., 2013, Two-stage approach for detecting slightly overlapping strawberries using HOG descriptor, *Biosystems Engineering*, 115, 144–153.
- Ye, N., Li, X. and Emran, S.M., 2000, Decision tree for signature recognition and state classification, *IEEE Systems, Man and Cybernetics*, 194–199.
- Yoshida, H., Zhang, W., Cai, W., Nishikawa, R.M., Giger, M.L., 1995, Optimizing wavelet transform based on supervised learning for detection of microcalcifications in digital mammograms, *International Conference On Image Processing*, 3, 152–155.

**KAYNAKLAR DİZİNİ (devam)**

Zainudin, M.N.S., Mohd Said, M., Ismail, M.M., 2011, Feature extraction on medical image using 2D Gabor filter, *Applied Mechanics and Materials*, 52-54, 2128–2132.

Zhou, S.-R., Yin, J.-P., Zhang, J.-M., 2013, Local binary pattern (LBP) and local phase quantization (LBQ) based on Gabor filter for face representation, *Neurocomputing*, 116, 260–264.

Zhang, J., Marszałek, M., Lazebnik and S., Schmid, C., 2006, Local features and kernels for classification of texture and object categories: a comprehensive study, *International Journal of Computer Vision*, 73, 213–238.