

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ İLE MAMOGRAFİ
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

DOKTORA TEZİ

Nebi GEDİK

**ŞUBAT 2013
TRABZON**

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ İLE MAMOGRAFİ
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Elektrik-Elektronik Mühendisi Nebi GEDİK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 24.12.2012
Tezin Savunma Tarihi : 22.02.2013

Tez Danışmanı : Yrd. Doç. Dr. Ayten ATASOY

Trabzon 2013

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalında
Nebi Gedik Tarafından Hazırlanan

BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ İLE MAMOGRAFİ
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 26/06/2012 gün ve 1463 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda

DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof.Dr. H. Işıl BOZMA

Üye : Prof.Dr. İsmail Hakkı ÇAVDAR

Üye : Yrd.Doç.Dr. Ayten ATASOY

Üye : Yrd.Doç.Dr. Tuğrul ÇAVDAR

Üye : Yrd.Doç.Dr. Yusuf SEVİM

.....
.....
.....
.....
.....

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

En başından beri bana inanan, bana yol gösteren, her zaman desteğini hissettiğim saygıdeğer hocam Yrd. Doç. Dr. Ayten ATASOY'a, bu çalışma süresince hiçbir yardımdan kaçınmayan, eleştirileri ile çalışmama katkıda bulunan değerli hocam Yrd. Doç. Dr. Yusuf SEVİM'e teşekkür ederim. Yine saygıdeğer hocalarım Prof. Dr. İsmail Hakkı ÇAVDAR ve Yrd. Doç. Dr. Tuğrul ÇAVDAR'a teşekkür ederim.

Bana doğru bildiğim, inandığım yolda yürümeyi öğreten, hayatım boyunca attığım her adımda, aldığım her kararda arkamda duran, yurduma ve insanlara yararlı bir insan olmam için hiçbir fedakârlıktan kaçınmadan, maksimum sevgi ve çabayla beni yetiştiren, bugünlere gelmemdeki en büyük paya sahip canım aileme teşekkür ederim.

Nebi GEDİK

Trabzon 2012

TEZ BEYANNAMESİ

Doktora tezi olarak sunduđum “Bilgisayar destekli teřhis sistemi ile mamografi grntlerinin sınıflandırılması” bařlıklı bu alıřmayı bařtan sona kadar danıřmanım Yrd. Do. Dr. Aytan ATASOY’un sorumluluđunda tamamladıđımı, verileri/rnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, bařka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gsterdiđimi, alıřma srecinde bilimsel arařtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her trl yasal sonucu kabul ettiđimi beyan ederim.
24.12.2012

Nebi GEDİK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIV
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.1.1. Meme Kanseri ve İstatistikler	1
1.1.2. Mamografi ve Bilgisayar Destekli Teşhis.....	2
1.2. Literatür Özeti	10
2. MATERYAL VE YÖNTEMLER	19
2.1. İlgili Alanlarının Elde Edilmesi: Morfolojik İşlemler ve Ortalama Filtre	19
2.2. Özellik Çıkarımı.....	21
2.2.1. Eğricik Dönüşümü	21
2.2.1.1. Ayrık Eğricik Dönüşümü	22
2.2.1.2. Sarma Yoluyla Ayrık Eğricik Dönüşümü	25
2.2.2. Dalga Atom Dönüşümü	26
2.2.2.1. 1B Dalga Atom Dönüşümü.....	28
2.2.2.2. 2B Dalga Atom Dönüşümü	29
2.3. Özellik Seçimi.....	30
2.3.1. Doğrusal Ayırıcı Analizi	30
2.3.2. Temel Bileşenler Analizi	33
2.4. Sınıflandırma.....	34
2.4.1. Destek Vektör Makineleri.....	34
2.4.2. En Küçük Kareli Destek Vektör Makineleri.....	44
2.4.3. k En Yakın Komşuluk Sınıflandırıcı.....	45

2.4.4.	Sınıflandırma Performans Değerlendirmesi.....	47
2.4.4.1.	Sınıflandırma Başarı Oranı	47
2.4.4.2.	Duyarlılık ve Özgüllük	47
2.4.4.3.	ROC Eğrileri	48
2.4.4.4.	k Kat Çapraz Doğrulama.....	49
3.	BULGULAR.....	50
3.1.	MIAS Veri Bankası.....	50
3.2.	Çalışmanın Tanımı.....	51
3.2.1.	İlgi Alanlarının Elde Edilmesi	53
3.2.2.	Sınıflandırma I: Eğricik Dönüşümü.....	68
3.2.3.	Sınıflandırma II: Eğricik Dönüşümü	80
3.2.4.	Sınıflandırma III: Dalga Atom Dönüşümü	85
4.	İRDELEME	92
5.	SONUÇ VE ÖNERİLER.....	97
6.	KAYNAKLAR	100
	ÖZGEÇMİŞ	

Doktora Tezi

ÖZET

Bilgisayar Destekli Teşhis Sistemi İle Mamografi Görüntülerinin Sınıflandırılması

Nebi GEDİK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Anabilim Dalı
Danışman: Yrd. Doç. Dr. Ayten ATASOY
2013, 108 Sayfa

Meme kanseri, özellikle kadınlarda kansere bağlı ölümlerin en sık nedenlerinden olup tüm kadın kanserlerinin %23'ünü teşkil etmektedir. Meme kanserini henüz kesin önleyen bir yöntem yoktur. Kansere mücadelede erken teşhis ve tanı çok önemlidir. Günümüzde, tanısında radyoloğa yardımcı olacak otomatik algılama sistemleri üzerine araştırmalar yapılmaktadır. Bu otomasyon sistemlerine Bilgisayar Destekli Teşhis (BDT) sistemi denilmektedir. BDT yazılımları, radyoloji uzmanlarına medikal görüntülerdeki anormalliklerin tespitinde ikinci bakış olarak görev yapmaktadır. Teşhis konusunda nihai karar radyoloğa aittir.

Bu çalışmada, Eğricik Dönüşümü (ED), Dalga Atom Dönüşümü (DAD), Temel Bileşen Analizi (TBA), Doğrusal Ayırıcı Analiz (DAA), Destek Vektör Makineleri (DVM), k-En yakın Komşuluk (k-EK) ve En Küçük Kareli Destek Vektör Makinelerinden (EK-DVM) oluşan melez BDT sistemleri sunulmaktadır. Oluşturulan sistemlerde, ilk olarak mamogramlarda şüpheli bölgeler top-hat dönüşümü, bottom-hat dönüşümü ve ortalama filtre kullanılarak, otomatik olarak belirlenmekte ve alt görüntüler oluşturulmaktadır. Daha sonra alt görüntülerden elde edilen veri setine özellik çıkarımı ve sınıflandırma işlemleri uygulanmaktadır. Sınıflandırma, görüntülerin önce normal-anormal olarak daha sonra anormal görüntülerin iyi huylu-kötü huylu olarak ayrıştırılmasını içermektedir. Özellik çıkarımı için ED ve DAD kullanılmakta ve sınıflandırma için DVM, k-EK ve EK-DVM karşılaştırmalı olarak uygulanmaktadır. TBA ve DAA yöntemleri özellik seçimi için kullanılmaktadır. Oluşturulan melez sistemlerde %100 sınıflandırma başarısına ulaşılmıştır.

Anahtar Kelimeler: Mamografi, BDT, Matematiksel Morfoloji, Dalga Atom Dönüşümü, Eğricik Dönüşümü, DAA, TBA, DVM, k-EK, EK-DVM.

PhD. Thesis

SUMMARY

Classification of Mammographic Images via Computer Aided Diagnosis System

Nebi GEDİK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Assoc. Prof. Ayten ATASOY
2013, 108 Pages

Breast cancer which is one of the most common cancers causing death, particularly among women, constitutes %23 of all types of cancerous cases among women. There is no way to prevent breast cancer yet. To fight against breast cancer, it is crucial to detect it in an early stage. Today, some researches on automated recognition systems which will help radiologists to scan mammograms are being done. These automated systems are called as "Computer Aided Diagnosis Systems" (CAD). CAD software is used to ensure a second look on mammograms to assist radiologists using mammogram. There is no question that the ultimate determination is made by radiologists.

In this study, a hybrid CAD system which consists of Curvelet Transform (CT), Wave Atom Transform (WAT), Principle Component Analysis (PCA), Linear Discriminant Analysis (LDA), Support Vector Machines (SVM), k-Nearest Neighbor (k-NN), Least Squares Support Vector Machines (LS-SVM) are presented. In the generated systems, firstly, suspicious areas in mammograms are determined by using top-hat transform, bottom-hat transform and average filter automatically and sets of sub-images are created. Following this process, feature extraction and classification operation are applied to the data set obtained from sub-images. Classification is performed in two stages as abnormal-normal of all the mammogram images and benign-malignant of the separated abnormal images. CT and WAT are used for feature extraction and SVM, k-NN and LS-SVM are applied for classification comparatively. LDA and PCA are used for feature selection. Successful classification results have been achieved at %100.

Key Words: Mammography, CAD, Mathematical Morphology, Wave Atom Transform, Curvelet Transform, LDA, PCA, SVM, k-NN, LS-SVM.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.	Sağlıklı memenin enine (transversal kesiti), yandan görünüş.....	2
Şekil 2.	Dijital mamografi cihazı ve kompresyon sistemi.	3
Şekil 3.	a) Kraniokaudal (CC) görünümü sol, b) Kraniokaudal (CC) görünümü sağ, c) Mediolateral eğik görünümü (MLO) sol, d) Mediolateral eğik görünümü (MLO) sağ	5
Şekil 4.	Meme kanseri tipleri.	6
Şekil 5.	Geleneksel BDT sistemi aşamaları	9
Şekil 6.	T görüntüsü ve görüntüye ait eğricik dönüşümü 8 detay band görüntüsü.....	17
Şekil 7.	Eğriciğin a) frekans düzlemi gösterimi, b) verilen bir ölçek ve yönelimle ilişkili uzaysal Kartezyen ızgara gösterimi	24
Şekil 8.	a) Fourier dönüşümü ve b) uzaysal uzayda eğricik.....	24
Şekil 9.	Eğricik katsayılarının belirlenmesi	25
Şekil 10.	Verinin orjin etrafında sarmalanması.....	26
Şekil 11.	(α , β) parametreleriyle bir dalga paketinin temel desteği, a) uzaysal düzlemde b) frekans düzleminde	27
Şekil 12.	α ve β parametrelerine göre çok çözümlü dönüşüm formları.....	28
Şekil 13.	Ayrılabilir durumlar için doğrusal ayıran hiper düzlem.	35
Şekil 14.	Maksimum ve minimum marjin gösterimi	36
Şekil 15.	Üst üste gelen veriyi birbirinden ayırma durumu için karar sınırları.....	39
Şekil 16.	Doğrusal olmayan durum için DVM	42
Şekil 17.	Doğrusal olmayan giriş uzayının özellik uzayına haritalanması	42
Şekil 18.	k parametresinin seçimi ve sınıflandırma	46
Şekil 19.	Farklı durumlar için ROC eğrileri.....	48
Şekil 20.	5 kat çapraz doğrulama için test (koyu renk) ve doğrulama verisi (açık renk) prosedürü	49
Şekil 21.	BDT sistemlerine ait temel adımlar	52
Şekil 22.	mdb005 görüntüsüne ait orjinal ve şüpheli bölge görünümü.....	54
Şekil 23.	MIAS veri bankası mdb134 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü	55
Şekil 24.	MIAS veri bankası mdb095 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü	56

Şekil 25. MIAS veri bankası mdb019 yağlı-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.....	57
Şekil 26. MIAS veri bankası mdb090 yağlı-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.....	58
Şekil 27. MIAS veri bankası mdb198 yoğun-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.....	59
Şekil 28. MIAS veri bankası mdb110 yoğun-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.....	60
Şekil 29. MIAS veri bankası mdb231 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü	64
Şekil 30. MIAS veri bankası mdb248 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü	65
Şekil 31. MIAS veri bankası mdb219 yağlı-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü.....	66
Şekil 32. MIAS veri bankası mdb239 yoğun-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü.....	67
Şekil 33. Mamografi görüntülerinin sınıflandırması için kullanılan akış şeması	69
Şekil 34. İlk görüntü orijinal kırılmış görüntüyü, ikinci görüntü yaklaşık alt bant ve diğerleri detay alt bant katsayılarından elde edilen görüntüyü temsil etmektedir	70
Şekil 35. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için	74
Şekil 36. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için	74
Şekil 37. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için	78
Şekil 38. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için	78
Şekil 39. İkinci uygulamaya ait işlem aşamaları.....	81
Şekil 40. Normal-anormal sınıflandırma başarı oranlarının değişimi.....	84
Şekil 41. İyi huylu-kötü huylu sınıflandırma başarı oranlarının değişimi	85
Şekil 42. Mamografi görüntülerinin sınıflandırılması için kullanılan akış şeması	86

Şekil 43. Dalga atom katsayıları ile yapılan doğrudan sınıflandırılma işlemine ait ROC eğrileri.....	88
Şekil 44. TBA ile özellik seçimi gerçekleştirilerek yapılan sınıflandırmaya ait ROC eğrileri.....	88
Şekil 45. Dalga atom katsayıları kullanılarak gerçekleştirilen doğrudan sınıflandırmaya ait ROC eğrileri.....	91
Şekil 46. TBA algoritması kullanılarak özellik seçimi üzerinden gerçekleştirilen sınıflandırmaya ait ROC eğrileri.....	91
Şekil 47. Alt görüntü boyutuna göre sınıflandırıcı başarıları.....	92
Şekil 48. DAA ve TBA algoritmaları üzerinden sınıflandırma sonuçları.....	93
Şekil 49. Tüm alt örnekler ve sınıflandırıcılar için doğrudan sınıflandırma başarıları.....	93
Şekil 50. DAA ve TBA algoritmaları üzerinden iyi huylu-kötü huylu sınıflandırma sonuçları.....	94
Şekil 51. Bütün ölçekler için dalga atomu katsayıları üzerinden normal-anormal (N-A) ve iyi huylu-kötü huylu (IH-KH) sınıflandırma sonuçları	94
Şekil 52. Bütün ölçekler için, dalga atomu katsayıları üzerinden normal-anormal (N-A) ve iyi huylu-kötü huylu (IH-KH) sınıflandırma sonuçları	95

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. MIAS veri bankası görüntü ayrıntı listesi, 20 görüntü için.....	50
Tablo 2. Mikrokalsifikasyon içeren görüntüye ait örnek veri matrisi.....	61
Tablo 3. Filtrelenmiş görüntü verisi.....	62
Tablo 4. Asıl görüntüden filtre görüntüsünün çıkarılmasıyla elde edilen veri değerleri.....	62
Tablo 5. Elde edilen ilgi alanlarının istatistiksel değerleri.....	68
Tablo 6. Veri seti görüntü dağılımı.....	70
Tablo 7. Eğricik dönüşümü, k-EK ve DVM algoritmaları yoluyla mamografi görüntülerinin normal-anormal sınıflandırmasına ait başarı oranları.....	71
Tablo 8. Eğricik dönüşümü, DAA, k-EK ve DVM algoritmaları yoluyla mamografi görüntülerinin normal-anormal sınıflandırmasına ait başarı oranları.....	71
Tablo 9. Eğricik dönüşümü, TBA, k-EK ve DVM algoritmaları yoluyla mamografi görüntülerinin normal-anormal sınıflandırmasına ait başarı oranları.....	72
Tablo 10. Doğrudan eğricik katsayıları üzerinden gerçekleştirilen normal-anormal sınıflandırılmaya ait duyarlılık ve özgüllük değerleri.....	72
Tablo 11. DAA ile özellik seçimi gerçekleştirerek yapılan sınıflandırılma için duyarlılık ve özgüllük değerleri.....	73
Tablo 12. İyi huylu kötü huylu sınıflandırması için veri seti görüntü sayısı dağılımı.....	75
Tablo 13. Eğricik dönüşümü katsayılarının doğrudan sınıflandırıcı girişi olarak kullanılması sonucu iyi huylu-kötü huylu ayırıştırma başarı oranları.....	75
Tablo 14. DAA kullanılarak özellik seçimi üzerinden iyi huylu-kötü huylu ayırıştırma başarı oranları.....	76
Tablo 15. TBA kullanılarak özellik seçimi sonucunun iyi huylu-kötü huylu sınıflandırmasına ait başarı oranları, farklı TBA bileşenler için.....	76
Tablo 16. Doğrudan eğricik dönüşümü katsayıları kullanılarak yapılan iyi huylu-kötü huylu sınıflandırılmaya ait duyarlılık ve özgüllük değerleri.....	77
Tablo 17. Eğricik dönüşümü ardından DAA ile özellik seçimi yoluyla, iyi huylu-kötü huylu sınıflandırılmaya ait duyarlılık ve özgüllük değerleri.....	77
Tablo 18. Özellik seçimi yapılmadan eğricik dönüşümü ile 5 kat çapraz doğrulama başarı oranları.....	79
Tablo 19. DAA ile özellik seçimi sonucu 5 kat çapraz doğrulama başarı oranları.....	79
Tablo 20. İyi huylu-kötü huylu sınıflandırmaya ait 5 kat çapraz doğrulama başarı oranları.....	80

Tablo 21. DAA ile özellik seçimi ardından iyi huylu-kötü huylu sınıflandırmaya ait 5 kat çapraz doğrulama başarı oranları	80
Tablo 22. Normal-anormal sınıflandırma için, 2x5 kat çapraz doğrulama başarı oranları	82
Tablo 23. DAA ile özellik seçimi yoluyla normal-anormal sınıflandırma için, 2x5 kat çapraz doğrulama başarı oranları	82
Tablo 24. Eğricik katsayılarının, 2x5 kat çapraz doğrulama ile iyi huylu-kötü huylu sınıflandırılma sonuçları	83
Tablo 25. DAA ile özellik seçimi ve 2x5 kat çapraz doğrulama ile iyi huylu-kötü huylu sınıflandırılma sonuçları	83
Tablo 26. Normal-anormal sınıflandırma aşamasına ait bütün başarı oranları	84
Tablo 27. İyi huylu-kötü huylu sınıflandırma aşamasına ait bütün başarı oranları.....	84
Tablo 28. Normal-anormal sınıflandırma için veri seti dağılımı.....	86
Tablo 29. Dalga atom katsayıları ile mamografi görüntülerinin normal-anormal sınıflandırma başarı oranları	87
Tablo 30. Dalga atom ve TBA algoritmaları ile mamografi görüntülerinin normal-anormal sınıflandırma başarı oranları	87
Tablo 31. İyi huylu-kötü huylu sınıflandırma için veri seti dağılımı.	89
Tablo 32. Dalga atom katsayılarının doğrudan sınıflandırıcı girişi olarak kullanılması sonucu, iyi huylu-kötü huylu sınıflandırma için başarı oranları	89
Tablo 33. TBA kullanılarak özellik seçimine bağlı gerçekleştirilen iyi huylu-kötü huylu sınıflandırma için başarı oranları	90
Tablo 34. En yüksek sınıflandırma başarısına sahip sistemlerin işlem süreleri.....	95
Tablo 35. Daha önce yapılan çalışmalarla elde edilen sonuçların karşılaştırılması	96

SEMBOLLER VE KISALTMALAR DİZİNİ

ACR	Amerikan radyoloji koleji
BDT	Bilgisayar destekli teşhis veya tanı
BIRADS	Meme görüntüleme raporlama ve veri sistemi
BBA	Bağımsız bileşen analizi
BT	Bilgisayarlı tomografi
CC	Kraniokaudal görünüm
DAA	Doğrusal ayırıcı analizi
DVM	Destek vektör makinesi
DSÖ	Dünya sağlık örgütü
DP	Gerçek pozitif
DN	Gerçek negatif
EK-DVM	En küçük kareli destek vektör makinesi
FFT	Hızlı Fourier dönüşümü
FDCT	Hızlı ayrık eğricik dönüşümü
FAO	Fisher'in ayırım oranı
GRSA	Genel regresyon sinir ağı
İDVM	İkiz destek vektör makinesi
k-EK	k-en yakın komşuluk
KKT	Karush-kuhn-tucker koşulları
MIAS	Mammographic image analysis society veri bankası
MLO	Mediolateral eğik görünüm
MRG	Manyetik rezonans görüntü
MR	Manyetik rezonans
ROC	Receiver operating characteric
TBA	Temel bileşen analizi
USFFT	Eşitsiz aralıklanan hızlı Fourier dönüşümü
UKAA	Uluslararası kanser araştırma ajansı
YSA	Yapay sinir ağı
YP	Yanlış pozitif

YN	Yanlış negatif
L	Lagrangian
L_D	İkili Lagrangian
C	Düzenleyici parametre
w	DVM'de ağırlık katsayısı
b	DVM'de eşik değeri
μ	Ortalama değer
$P_{j,l}$	Paralel kenar fonksiyonu
S_B	Sınıflar arası kovaryans matrisi
Σ	Kovaryans matrisi
S_w	Sınıf içi kovaryans matrisi
β_i, α_i	Lagrange çoklayıcılar
$d(p_1, p_2)$	Euclidean mesafesi
$\Phi(x)$	Doğrusal olmayan haritalama fonksiyonu
$K(x_i, x_j)$	Çekirdek fonksiyonu
ξ_i	Gevşek değişkenler
λ_i	Öz değerler

1. GENEL BİLGİLER

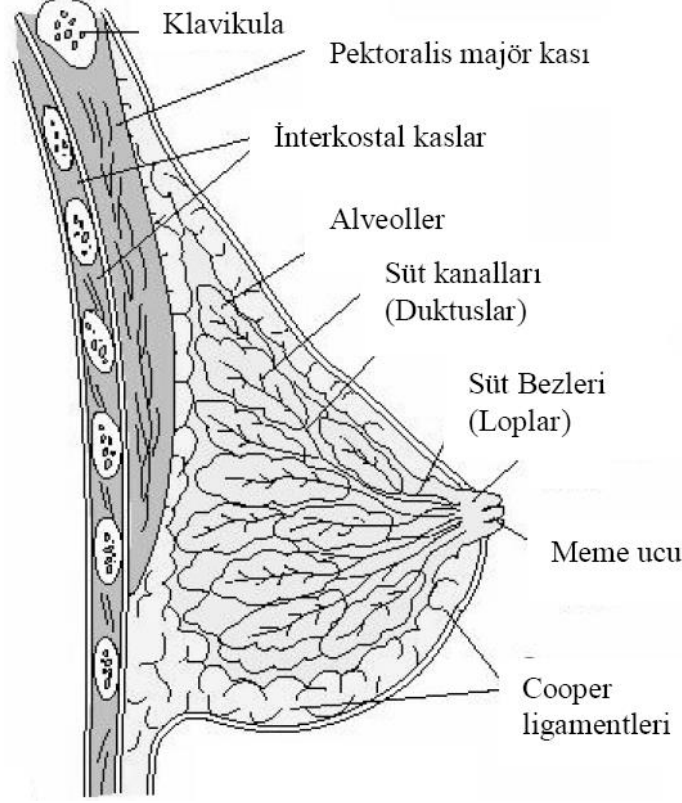
1.1. Giriş

1.1.1. Meme Kanseri ve İstatistikler

Meme kanseri, özellikle kadınlarda kansere bağlı ölümlerin en sık nedenlerinden olup tüm kadın kanserlerinin %23'ünü teşkil etmektedir. Dünya Sağlık Örgütü'nün (DSÖ) 1990 yılında yaptığı çalışmada, 314.000 kadının meme kanserinden öldüğü tespit edilmiştir. Yine DSÖ'ye bağlı Uluslararası Kanser Araştırma Ajansı'nın (UKAA) 2002 yılındaki değerlendirmesinde; meme kanserinden ölen kadın sayısının 411.000'e yükseldiği ve 1.152.000 yeni meme kanserli olduğu saptanmıştır [1]. Türkiye de de meme kanseri kadınlar arasında en yaygın kanser türü olarak belirtilmekte ve %28.3 ile ilk sırayı almaktadır [2]. Meme kanseri riski 35 yaş ve üzerinde artmasına rağmen 20-30 yaş arasında da görülmektedir. Türkiye de de meme kanseri vakaları giderek artmakta ve araştırmalar sonucunda 2012 yılında meme kanseri olan kişi sayısının 51 binden fazla olacağı tahmin edilmektedir [3].

Meme, süt bezleri ve burada üretilen sütü meme başına taşıyan kanallardan oluşmaktadır (Şekil 1). Araştırmalar, normal meme hücrelerinin DNA'sındaki değişikliklerin kansere neden olduğunu göstermektedir. Normal hücreler büyür ve vücudun ihtiyaç duyduğu yeni hücreleri oluşturmak için bölünür. Normal hücreler yaşlandıklarında ya da hasar gördüklerinde, ölürlere ve yeni hücreler onların yerini alırlar. Bazen bu süreç anlatıldığı gibi gerçekleşmez. Olması gerektiği gibi, yaşlı ya da hasarlı hücreler ölmezler ve vücudun ihtiyaç duymadığı yeni hücreler oluşur [4]. Kansere neden olan çoğu DNA mutasyonunun nedeni bilinmemektedir. Kansere ilgili risk faktörleri ve diğer hastalıklarla olan bağlantısı iyi bilinse de, hala çalışmaya açık bir alandır. Bu faktörler aile geçmişi, ilk gebelik yaşı, geç menopoz, sigara alkol kullanımı, daha önce meme biyopsisi yapılmış olması, fertil çağ süresi, östrojen hormonu tedavisi görenler, şişmanlık ve yağlı beslenme şeklinde sıralanmaktadır [5]. Meme kanserini henüz kesin önleyen bir yöntem yoktur. Günümüzde bilinen tek yöntem, erken tanıdır. Kansere mücadelede başarılı bir sonuç için erken teşhis ve tanı çok önemlidir [4,6]. İstatistikler göstermiştir ki kanserin erken evrede tespitiyle ölüm oranlarında % 30-70 oranında azalma gerçekleşmektedir [7]. Bu nedenle

risk grubunda yer alan 40 yaş üzerindeki bayanlara yıllık mamografi taraması tavsiye edilmektedir.



Şekil 1. Sağlıklı memenin enine (transversal kesiti), yandan görünüş [8]

1.1.2. Mamografi ve Bilgisayar Destekli Teşhis

Mamografi, meme kanserinin teşhisi ve tanısı için radyologlar tarafından en sık kullanılan tekniktir. Diğer teknikler ise kanser teşhisi üzerine görüntüleme için Manyetik Rezonans Görüntü (MRG) ve Ultrason gibi tekniklerdir. Mamografi, sıkıştırılmış mememin yüksek çözünürlüklü X-ışını görüntülemesidir ve meme kanserinin erken teşhisinde güvenilir bir yöntemdir (Şekil 2). Temel avantajı, diğer tekniklerle karşılaştırıldığında, düşük maliyeti ve düşük radyasyon dozunda kaliteli görüntüleme performansındır. Görüntülemelerde, kompresyon işlemiyle memenin kalınlığı homojen bir şekilde azaltılarak dozun ve saçılan radyasyonun azaltılması, görüntü keskinliğinin artırılması sağlanır. Ayrıca, memeyi sabit tutarak harekete bağlı görüntü bulanıklığını, görüntülenene meme dokusu miktarının en üst düzeyde olmasını ve obje reseptör

mesafesinin kısaltılması yoluyla geometrik bulanıklığı azaltılmasını sağlar. Kompresyon sistemi ince sert plastikten yapılan kompresyon plağı ve kontrol mekanizmasından oluşur [9].



Şekil 2. Dijital mamografi cihazı ve kompresyon sistemi

Mamografi çekilirken her bir meme kompresyon sistemi aracılığıyla sıkıştırıldıktan sonra ayrı ayrı görüntülenmektedir. Uygulanan X-ışınları sıkıştırılmış meme bölgesinden geçer ve meme altına yerleştirilmiş film kaset üstüne yayılır. X-ışınları memeden geçtiğinde doku yoğunlukları farklı olduğundan yoğunluğa bağlı olarak zayıflar. Yağlı doku X-ışınlarının büyük bir kısmını zayıflatır veya soğurur. Buna karşılık meme kanalları ve yağ etrafındaki bağlı doku daha az yoğundur daha az zayıflatır. X-ışınları kasetin içinde bulunan özel fosfor tabakaya çarpar. Bu fosfor X-ışınlarının yoğunluğuna bağlı oransal olarak parlar, bunun sonucunda memenin iç yapısının görüntüsünü içeren film ortaya çıkar. Oluşan görüntüler yağ, fibrogulandular doku, meme kanalları ve meme ucu gibi yapıları gösterir. Memede bulunan anormallikler X-ışınlarına farklı tepkiler vermektedirler. Yüksek duyarlıklılı film ve özel X-ışınları, en düşük dozda, en yüksek nitelikli görüntüleri oluşturmak amacıyla mamografi için kullanılmaktadır. Mamografide, gri seviyeler görüntülenenen farklı dokuların yoğunluklarına karşılık gelir. Bir bölgenin daha parlak görünmesi daha yoğun dokuyla ilişkilidir. Geleneksel mamografi cihazları görüntüyü oluşturmada film kullanır. Modern mamografi cihazlarında ise X-ışınları yarı iletken


algılayıcılar yardımıyla sayısallaştırılır ve anında ekranda görüntülenir. Her kadının mamografi görüntüsü farklı olduğundan ayırt edici bir özellik olarak ortaya çıkmaktadır. Elde edilen mamografi radyoloji uzmanı tarafından yorumlanmaktadır. Mamografi aracılığıyla, belirtileri olmadan kadınlarda meme kanserlerinin yaklaşık % 80-90'ı tespit edilebilmektedir [5].

Meme kanserinin belirtileri ile ilgili olarak, literatürde yer alan ifadelere bakıldığında;

- Memede bir kitlenin varlığı,
- Meme görüntüsünün portakal kabuğu şeklinde olması,
- Doğuştan olmamak kaydıyla meme başının içe çekilmesi,
- Memeden kanlı ya da kansız akıntı,
- Meme derisinde ülser, kızarıklık ve ödem,
- Lenf bezlerinde şişlik,
- Kolda şişlik ve ödem,

önemli belirtiler olarak değerlendirilmektedir [10].

İki çeşit mamografi incelemesi vardır, bunlar tanı ve tarama amaçlı görüntülemedir. Tarama amaçlı mamografi çekimi hastalık belirtisi olmadan risk grubunda olan kadınların (40 yaş üzerindeki kadınlar) hastalık ortaya çıkmadan erken teşhis edilip önlem alınması amacıyla yapılır. Tedavi başarısı ve yaşam süresinin uzaması, hastalığın erken evrede yakalanmasıyla doğru orantılıdır. Tarama işlemi için görüntüleme dört şekilde yapılır. Bunlar her iki meme için mediolateral eğik görünümü (MLO) ve kraniokaudal (CC) görünümüdür (Şekil 3). Bu iki görüş, meme içinde anormal yapıların bir izlenimini radyologlara vermek için tasarlanmıştır [5]. Meme kanserini ele gelmediği küçük boyutlarda yakalayabilmek için başvuru en önemli tanı aracı tarama mamografisidir. Tanı mamografisi, görüntülemeye bulunan şüpheli bölgenin derinlemesine taranması veya biyopsiye ihtiyaç olup olmadığının araştırılmasıdır [9]. Diğer bir deyişle meme yakınması olan kadınlarda ya da taramada patolojik bir bulgu saptandığında, mamografinin kullanımı tanısız mamografi olarak adlandırılır. Daha fazla zaman almaktadır ve hastalık belirtileri mevcuttur. Anormalliğin tam yeri ve boyutu tespit edilmeye çalışılmaktadır ve incelemeler sonucunda lezyonda kanser kuşkusu olup olmadığı belirlenir ve buna göre yönlendirme yapılır. Mamografinin en önemli katkılarından biri tedavi planlamasında olmaktadır. Özellikle cerrahi müdahalelerde görüntüleme bulguları yol göstericidir.




Şekil 3. a) Kraniokaudal (CC) görünümü sol, b) Kraniokaudal (CC) görünümü sağ, c) Mediolateral eğik görünümü (MLO) sol, d) Mediolateral eğik görünümü (MLO) sağ.

Meme kanserinin tipleri:

- İyi tanımlanmış kitle, Şekil 4-a.
- Şüpheli kitle, Şekil 4-b.
- Kötü tanımlanmış kitle, Şekil 4-c.
- Kalsifikasyon, Şekil 4-d.
- Asimetri, Şekil 4-e.
- Yapısal bozukluk, Şekil 4-f, şeklindedir.

Mamografi görüntülerinden elde edilen bulgulara göre meme kanseri türlerinin sınıflandırılması ve raporlama sisteminin standart hale getirilmesi için Amerikan Radyoloji Koleji (ACR) tarafından 1993 yılında ‘Meme Görüntüleme Raporlama ve Veri Sistemi’ (BIRADS) adı altında standart bir raporlama sistemi geliştirilmiştir. Böylece mamografi raporlarındaki terminolojinin standardizasyonu, lezyonların belirli kriterlere göre sınıflandırılması ve tarama mamografilerinde saptanan lezyonların işlem adımları standartlaştırılmıştır.



Şekil 4. Meme kanseri tipleri

BIRADS değerlendirme kategorileri [11]:

<u>Kategori</u>	<u>Tanımlama</u>
1	Normal mamogram
2	İyi huylu bulgular
3	Olası iyi huylu bulgular; kısa süreli takip önerilir
4	Kuşkulu bulgular; biyopsi önerilir
5	Çok kuşkulu kötü huylu bulgular; biyopsi ve tanı gereklidir

Mamografinin bir dezavantajı genellikle düşük kontrastta üretilmesidir. Bu durum birçok tümörün radyologlar tarafından kaçırılmasına ya da yanlış yorumlanmasına neden olmaktadır. İstatistikler meme kanserlerinin yaklaşık %30'nun tespit edilemediğini göstermektedir [12]. Bu olumsuz durumun önüne geçmek için iki kez okuma işlemi uygulanmıştır [13,14]. İki kez okumadan kasıt aynı mamogramı farklı iki radyoloğun okumasıdır. Bu ise kaçırılan vakaları azaltmakta ama maliyeti yükseltmekte ve radyologların iş yükünü artırmaktadır. Blanks ve ark. [15] mamografinin iki kez okunmasının geri çağırma oranı (daha fazla test için döndürülen görüntü sayısı) artmadan bir kez okunmasından daha duyarlı olduğunu ifade etmektedirler. Bununla birlikte iki kez okuma işlemi gerçekleştirecek uzman radyolog sayısı, oluşturulamayacak bir durum almaktadır. BDT tekniği ikinci kez okumaya etkili bir alternatif sunmaktadır.

Günümüzde, şüpheli görüntüleri mümkün olduğunca erken tespit etmede radyoloğa yardımcı olacak otomatik algılama sistemleri üzerine araştırmalar yapılmaktadır. Bu otomasyon sistemlerine Bilgisayar Destekli Teşhis veya Tanı (BDT) sistemi denilmektedir. BDT sistemleri, ileri örüntü tanıma ve görüntü işleme yöntemlerini kullanarak radyoloji uzmanlarına medikal görüntülerdeki anormalliklerin tespitinde yardımcı olan yazılımlardır. BDT sistemi, radyologlara destek olması amacıyla, ikinci bakış olarak tasarlanmaktadır. Kullanılmasıyla meme kanseri tespitinde radyologların teşhis hassasiyetini önemli ölçüde artırdığı [16] ve ölüm oranlarında azalış gözlemlendiği belirtilmiştir. Mamografi ve BDT sistemi yardımıyla meme kanseri tespitinde istenilen duyarlılığa ulaşılması sonucunda ve iyi huylu ve kötü huylu ayrımının daha doğru algılanmasıyla sadece biyopsi maliyetlerinin azalması değil oldukça zahmetli olan biyopsinin hastalara travmatik anlar yaşatmasının da önüne geçilmiş olacaktır [17]. Bununla birlikte son zamanlarda yapılan çalışmalar BDT sistemi performansının iyileştirilmeye ihtiyacı olduğunu ve gelecek araştırmalarda ve geliştirmelerde güncel bir başlık olduğu belirtilmiştir [18, 19].

BDT sistemleri, mamografi görüntülerinin sınıflandırılması için çeşitli araştırma grupları tarafından geliştirilmeye çalışılmaktadır [20]. Birdwell ve ark. [21] BDT sistemli ve BDT sistemi olmadan 8682 durumu değerlendirmişler ve bunlardan 165'ine müdahalede bulunmuş ve 29 kanser tespit etmişlerdir. 21 kanserli görüntü hem BDT sistemi tarafından hem de radyolog tarafından tespit edilmiş, altı vaka sadece radyolog tarafından iki vakada sadece BDT sistemi tarafından tespit edilmiştir. BDT sistemiyle birlikte okuma kanser tespitinde %7,4 artış sağlamıştır. Freer ve ark. [22] bir meme görüntüleme merkezinde BDT sistemi kullanımının etkisini araştırmışlardır. 12.860 mamografi görüntüsünden tespit edilen kanser sayısında % 19,5 artış rapor edilmiştir. Bu araştırmalar açıkça bir tarama ortamında BDT sistemi kullanımının, yanlış pozitif tahminler nedeniyle gereksiz biyopsiyi azaltırken; kanser olarak tespit edilen örneklerin sayısını artırarak, ölümlerle sonuçlanan vakaları azalttığını göstermektedir. BDT sistemleri radyoloğa teşhiste yardımcı olacak ve onun performansını artıracak şekilde tasarlanmaktadır. Fakat nihai karar yine radyoloğa aittir.

Meme kanseri algılama ve tanısında radyolog performansını etkileyen pek çok neden vardır. Örneğin, kanser lezyonlarının geniş aralığı ve çeşitliliği söylenebilir. Bu zorluğun bir başka nedeni de bazı mamografilerde normal örüntü ile tümör örüntüsünün benzerliğinden kaynaklanmaktadır. Diğer bir zorluk ise radyolog tarafından değerlendirilecek görüntülerin sayısının çokluğudur. Radyolog tarafından incelenen


görüntülerin çoğu normal, çok az bir kısmı da anormal (hastalıklı) durumlardır. Araştırmalar biyopsiye gönderilen vakaların sadece %25'inin kanser olduğunu ortaya koymuştur [23]. Bu durum, normal mamografi görüntülerinin sınıflandırılarak ayrılmasının performans açısından önemini ortaya koymaktadır.

Radyoloğun performansına etki eden sebepler maddeler halinde şunlardır [24]:

- Radyoloğun deneyimi
- Mamografinin kalitesi
- Radyolog tarafından gözden geçirilecek vaka sayısının çokluğu
- Sınıflandırılması zor olan durumlar

Meme kanserinin teşhisinde ve tanısında iki temel unsur etkili olmaktadır. Bunlardan birincisi kullanılan BDT sisteminin doğruluğu, ikincisi mamografinin okunmasında ve teşhis aşamasında radyoloğun performansıdır. Bu çalışmada, mamografi taramasında ikinci bir bakış olacak bir BDT sistemi oluşturmak ve bu sistemle radyologların performansını ve BDT sistemlerinin performansını artırmaya yardımcı olmak hedeflenmiştir. Bu amaç doğrultusunda geleneksel BDT sistemlerinin takip ettiği anormal bölgenin tespiti yerine, normal ve anormal sınıflandırılmasına odaklanılmıştır. BDT sistemlerinin çoğu şüpheli bölgelerin sorgulanmasında araştırma hatalarının önlenmesi üzerine odaklanmıştır. Yapılan çalışmalar tanı sistemiyle desteklenen radyologların, desteklenmeyenlere göre daha yüksek performans seviyesine sahip olduğunu göstermiştir [25]. Önerilen BDT sistemleri görüntülerin öncelikle normal ve anormal olarak, daha sonra da iyi huylu ve kötü huylu olarak belirlenmesinde ikinci bir bakış olacaktır. Bu ise radyologların iş yükünü azaltacak ve onların sınıflandırılması zor olan durumlara daha iyi konsantre olmalarını sağlayacaktır. Genel anlamda BDT sistemi, teşhis aşamasında radyologlara destekleyecek yararlı bilgiler vermesi, karar verme sürecini hızlandırması, insan kaynaklı hataların teşhisteki yerini azaltması ve sağlık sektöründe maliyetlerin düşürülmesi gibi avantajlara sahiptir.

Uygulamada, çoğu BDT sistemi veri işlemede benzer yolları takip etmektedir. Geleneksel BDT sistemi aşamaları Şekil 5’de gösterilmektedir.



Şekil 5. Geleneksel BDT sistemi aşamaları

Tıbbi görüntülerin bilgisayar aracılığıyla işlenmesi ve analizi, son yılların en popüler bilimsel çalışma alanlarından biridir. Özellikle akciğer kanseri, göğüs kanseri, beyin hastalıkları ve göz hastalıkları üzerinde pek çok bilimsel çalışma yapılmış ve yapılmaktadır. Bu tezin amacı mamografi görüntülerine görüntü işleme tekniklerini uygulayıp önce anormal ve normal yapıların tespit edilmesi daha sonra anormal yapıların iyi huylu ve kötü huylu olarak ayrılmasını sağlayacak yöntemleri uygulamalı olarak araştırmaktır.

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

Literatürde, BDT sistemlerinde çok çözünürlüklü araçlar (dalgacık dönüşümü gibi) yöntem olarak yaygınca kullanılmaktadır. Bu çalışmada bir BDT sistemi oluşturmak amacıyla; eğricik dönüşümü, dalga atom dönüşümü, temel bileşenler analizi ve doğrusal

ayırıcı analiz algoritmaları kullanılmıştır. Her iki dönüşüm de, kısa zaman önce geliştirilen çok çözünürlüklü dönüşüm algoritmalarıdır. Diğer çok çözünürlüklü dönüşüm algoritmalarına göre daha iyi yön kabiliyetine ve etkili kenar temsili özelliklerine sahiptirler. Çalışmamızda mamografiye dayalı geleneksel BDT sistemlerine alternatif bir yaklaşım olarak mamografi görüntülerinden elde edilen alt görüntülere eğricik dönüşümü, dalga atom dönüşümü, DAA ve TBA algoritmalarından oluşan bir kombinasyon uygulanmıştır. Görüntüler önce normal-anormal olarak daha sonrada iyi huylu-kötü huylu olarak sınıflandırılmıştır. Sınıflandırma aşamasında DVM, k-EK ve EK-DVM algoritmaları kullanılmıştır. Çalışmada kullanılan mamografi görüntüleri, MIAS veri bankasından temin edilmiştir.

1.2. Literatür Özeti

Meme kanserinin bilgisayar destekli tanısı üzerine çok sayıda çalışma bulunmaktadır. Sadece normal mamografi algılama üzerine birkaç yayınlanmış sistem bulunmaktadır ve farklı yaklaşımlar kullanılmıştır. Örneğin Heine ve ark.[26] normal mamografi görüntülerini belirlemek için çok çözünürlüklü istatistiksel analiz kullanmıştır. Mini ve ark. [27] basit doğrusal işaret ile birlikte dalgacık dönüşümünü, mamografi görüntülerinden normal dokuyu ayırmak için kullanmıştır. Liu [28] ilk olarak normal mamografi görüntüsünün sınıflandırılması fikrini ortaya atarak, normal doku özelliği tanımlamaya ve bu dokuları görüntüden kaldırmaya dayalı bir yöntem önermiştir. Bu yaklaşım, mamografi görüntülerindeki anormalliklerin türlerinden bağımsızdır. Ayrıca, bastırılan normal arka plan yapılarının karşıtlığını ve anormal yapıların belirginliğini iyileştirdiği için anormalliklerin sınıflandırılmasını kolaylaştırmıştır. Bu yöntemin temel işlemi orijinal mamografi görüntüsünden normal yapı özellikleri çıkararak kalan görüntüde anormal yapı özelliklerini belirleyip normal mamografiyi tanımlamaktır. Y. Sun ve ark. [29,30] yeni bir mamografi analizi yöntemi sunmuşlardır. Mamografi görüntüsü bölge bölge analiz edildikten sonra normal veya anormal olarak sınıflandırılmıştır. Y. Sun ve ark. [31] önceki çalışmayı geliştirerek çakışmayan haritalama ve yerel olasılık farkı dönüşümü yöntemlerini DVM ile birlikte kullanmışlardır.

Mamografi görüntülerinin BDT sınıflandırmasında normal-anormal veya iyi huylu-kötü huylu ayrımı dışında anormal yapıya (kitle, mikrokalsifikasyon, yapısal bozukluk gibi) yönelik de sınıflandırma gerçekleştirilmektedir. Kom ve ark.[32] ilk kez görüntü

iyileştirme için lineer dönüşüm filtre algoritması kullanarak kitle tespit algoritması önermişlerdir. Yeni bir görüntü elde etmek için iyileştirilen görüntüyü orijinal görüntüden çıkarmışlardır. Elde edilen fark görüntüye kitle tespiti için yerel uyarlanır eşikleme tekniği uygulamışlardır. Bu çalışmada uzman radyolog tarafından işaretlenen 61 mamografi görüntüsü kullanılmıştır. Eltonsy ve ark. [33] mamografide kitle tespit etmek için çoklu eş merkezli katman tabanlı bir algoritma önermişlerdir. Bu algoritma üç aşamadan oluşmaktadır. İlk olarak mamografi görüntüsü; bölümlenme ve granülasyon tekniği ile ön işleme tabi tutulmaktadır. Daha sonra şüpheli alanlar, bilgiye dayalı akıl yürütme kullanılarak tespit edilmektedir. Son olarak iki farklı ölçüt yanlış pozitif oranını azaltmak için uygulanmıştır. Çalışmada DDSM (tarama mamografi için veri bankası) veri bankasından elde edilen 270 CC mamografi görüntüsü kullanılmıştır. Görüntülerin yarısı eğitim verisi olarak, diğer yarısı test verisi olarak kullanılmıştır. Timp ve ark. [34] ardışık iki görüntüleme arasında mamografideki kitlelerde değişiklikleri tespit etmek için otomatik kitle tespit yöntemi sunmuşlardır. Aralık değişim analizini gerçekleştirmek için farklı özellikler ve benzer özellikler olmak üzere iki tane zaman özelliği belirlenmiştir. Sınıflandırıcı olarak DVM kullanılmıştır. Zamansal özelliklerin kullanımı ve kullanılmaması durumu karşılaştırılarak sınıflandırma yapılmıştır.

Özellik tabanlı BDT sistemi tasarımlarından farklı olarak, şablon eşleme tasarımı arka plandan kitlelerin ayrıştırılması için önceki bilgileri kullanmaktadır. Tourassi ve Vargas-Voracek [35] karşılıklı bilgiye dayalı bir şablon eşleme yöntemi önermişlerdir. Algoritma, veri bankasında saklanan şüpheli mamografi bölgeleri ve ilgi alanları (ROI) arasındaki benzerliği ölçmek için karşılıklı bilgiyi kullanmıştır. Lai ve ark. [36] ilk kez tümör benzeri bir şablonu, şablon eşleştirme adımıyla kullanmışlardır. Şüpheli bölge ve şablon arasındaki benzerlik mamogramdaki kitleyi tespit etmek için incelenmiştir. Moayedı ve ark. [37] kitle tespiti için, destek vektör tabanlı bulanık sinir ağı sınıflandırıcı önermişlerdir. Tourassi ve ark. [38] farklı iki sayısallaştırıcı kullanılarak sayısallaştırılan iki veri setini test ederek, kitle tespiti için bilgi tabanlı bir BDT sistemi çalışmışlardır. Yazarlar, sistemi veri seti üzerinde üç deney yaparak ölçmüşlerdir. Bu deneyler; bağımsız olarak veri setleri üzerinde sistemin test edilmesi, bilgi tabanı olarak kullanılan diğer verilerle birlikte veri seti üzerinde sistemin test edilmesi ve bilgi tabanı karışık durumları içerdiği zaman sistemin performansının değerlendirilmesidir.

Yapı bozukluğu, meme kanserinin en yaygın üçüncü tipidir ve tespiti üzerine çalışmalar yapılmaktadır. Broeders ve ark. [39] yapı bozukluğu tespitindeki iyileşmenin,

meme kanseri hastalarının prognozunda etkili bir iyileşmeye yol açacağını önermiştir. Ayres ve Rangayyan [40,41] ve Rangayyan ve Ayres [42] yapı bozukluğunu tespit etmek amacıyla mamografide yönlü doku örneklerini karakterize etmek için Gabor filtresi ve faz portre haritası uygulamışlardır. Guo ve ark. [43] yapısal bozukluk sergileyen ilgi alanlarıyla ve normal mamografi yapısını ayırmak için Hausdorff fraktal boyut ve DVM sınıflandırıcı kullanmışlardır. 19 yapı bozukluğu, 21 normal mamografi içeren 40 ilgi alanından oluşan veri ile sınıflandırma doğruluğunu %72,5 olarak elde etmişlerdir. Tourassi ve ark. [44] mamografi görüntülerinde normal ve yapısal bozukluk olan görüntüleri ayırmak için fraktal boyut kullanmıştır. Matsubara ve ark. [45] meme bezi içerisinde yapı bozukluğunu belirlemede yoğunluk indeksi ve cilt hattı etrafında yapı bozukluğu tespit etmek için matematiksel morfoloji kullanmıştır. Ichikawa ve ark. [46] görüntünün ortalama eğriliğini kullanarak çıkarılan lineer yapıların; yoğunluk indeksi aracılığı ile yapısal bozuklukları tespit etmek için otomatik bir yöntem geliştirmişlerdir.

Sağ ve sol mamogram görüntüsü arasındaki asimetri, meme kanserini teşhis etmek için radyolog tarafından kullanılan yöntemlerden biridir. Asimetri analizi; meme kanserinin erken belirtileri hakkında, gelişmekte olan yoğunluklar ve küçük asimetric yoğun bölgeler gibi ipuçları sağlar. Kalsifikasyonlar ve kitlelerin tespiti ve analizinden farklı olarak, iki taraflı asimetri tespiti üzerine sadece birkaç yayın bulunmaktadır [47,48,49]. Scutt ve ark. [50] 252 kişiden oluşan ve yaş olarak eşleştirilmiş iki kadın grubu arasında iki taraflı asimetri araştırması gerçekleştirmişlerdir. İlk grup, normal mamografiye sahip ancak daha sonra meme kanseri gelişmiş kadından oluşan çalışma grubu, ikinci grup ise çalışma süresince kanser olmayan ve normal mamograma sahip kontrol grubudur. Asimetrinin, menopoz sonrası kadınlarda alt modele dâhil menopoz yaşı ile meme kanserinin önemli bir belirleyicisi olduğu tespit edilmiştir. Miller ve ark. [51] fibroglandular disk parlaklık dağılımı ve topoloji testlerine bağlı iki taraflı asimetri tespiti için bir metot sunmuşlardır. Araştırma 104 mamografi çifti üzerine yapılmış ve %74 sınıflandırma doğruluğu elde edilmiştir. Lau ve Bischof [52] parlaklık, pürüzlülük ve yönlülük testlerini kapsayan, asimetrinin yerleşik tanımını kullanarak meme kanserinin tespiti için bir yöntem tasarlamışlardır. Yöntem, radyolog tarafından asimetri teşhisi konulmuş 10 çift mamografi kullanılarak değerlendirilmiştir.

Diğer bir meme kanseri olan mikrokalsifikasyonlarla ilgili çalışmalar, 2000 yılından sonra artmıştır. Yu ve Guan [53] mamografide mikrokalsifikasyonları tespit etmek için bir sistem tasarlamışlardır. Gri seviye istatistiklerini ve dalgacık özelliklerini kullanarak

mikrokalsifikasyon piksellerini bölümlenmiş ve olası mikrokalsifikasyonları etiketlemişlerdir. Bölümlenen olası mikrokalsifikasyonların arasından doğru mikrokalsifikasyonları tespit etmek için, ikinci bir ayırt edici adım kullanmışlardır. Etiketlenen alanlardan özellik çıkarımı ve özellik seçimi yapıldıktan sonra çok katmanlı sinir ağı ile sınıflandırma yapılmıştır. Verma ve Zakos [54] mikrokalsifikasyon tespiti için özellik çıkarımına dayalı bir yöntem önermişlerdir. Şüpheli mikrokalsifikasyon alanlarını belirlendikten sonra mamogram görüntülerinden 14 özellik hesaplamışlardır. Elde edilen özellikler ayrı ayrı sınıflandırıcıya uygulanarak karşılaştırma yapılmıştır. 58 mikrokalsifikasyon içeren mamografiye uygulanan işlem sonucunda sınıflandırma başarısını %88.9 olarak elde etmişlerdir. De Santo ve ark. [55] mikrokalsifikasyon tespiti için DVM'ye dayalı bir yaklaşım önermişlerdir. Yaklaşımları çoklu uzman sisteme dayanmaktadır. Bu uzman sistemlerden bazılarını mikrokalsifikasyonları sınıflandırmak için, bazılarını da mikrokalsifikasyon kümelerini sınıflandırmak için kullanmışlardır. Sınıflandırıcı olarak çok katmanlı geriye yayılım ağı kullanmışlardır. Soltanian-Zadeh ve ark. [56] mikrokalsifikasyonları; iyi huylu ve kötü huylu olarak sınıflandırmak için, dört farklı doku ve şekilsel özellik çıkarım yönteminin başarı sonuçlarını karşılaştırarak değerlendirmişlerdir. Geleneksel şekil niteleyicileri, Haralick'in eş oluşum tabanlı yöntemini, dalgacık dönüşümlerini ve çoklu-dalgacık dönüşümlerini kullanarak doku ve şekil özellikleri çıkarmışlardır. Elde edilen özellikler, genetik algoritma (GA) özellik seçim yöntemi kullanılarak ayırt edici özellikler k-en yakın sınıflandırıcıya uygulanmıştır. Çoklu dalgacık yönteminin daha başarılı sonuçlar verdiği tespit edilmiştir. Fu ve ark. [57] mikrokalsifikasyonları tespit etmek için iki aşamalı bir model önermişlerdir. Önce şüpheli mikrokalsifikasyonların yerini ve şeklini hesaplamak için matematiksel model kullanmışlardır. Daha sonra özellik çıkarımı işlemi gerçekleştirilmiş ve genel regresyon sinir ağı (GRSA) ve DVM sınıflandırıcılarına uygulanmıştır. DVM için %98 ve GRSA için %97.8 sınıflandırma başarısı elde edilmiştir. Zhang ve ark. [58] mikrokalsifikasyon tespiti için ikiz destek vektör makinesi (İDVM) temelli bir yaklaşım kullanmışlardır. Özellik çıkarımı için, birleştirilmiş görüntü özellik çıkarıcısı kullanmışlardır. Sınıflandırma için eğitilmiş İDVM kullanmışlar ve % 97.06 sınıflandırma başarısı elde etmişlerdir.

BDT sistemlerinde ve görüntü işleme sistemlerinde; özellik çıkarımı, önemli bir aşamadır ve sınıflandırma aşamasının başarısını ve doğruluğunu önemli oranda artırmaktadır. Bu nedenle çalışmaların bir bölümü bu doğrultuda gerçekleştirilmiştir. Ferrari ve ark. [59] Gabor dalgacıkları ile yönsel filtreleme yöntemi önermişlerdir.

Dalgacık tabanlı temsil fazlalığını azaltmak amacıyla özel olarak tasarlanan iki boyutlu Gabor filtresiyle belirli bir dalgacık şeması görüntülere uygulanmıştır. MIAS veri bankasından 20 normal, 14 asimetri ve 6 yapı bozukluğu olan mamografi görüntüsü kullanılarak, birini dışarda bırak yöntemiyle sınıflandırma gerçekleştirmişlerdir. Ortalama sınıflandırma doğruluğu %74,4 olarak elde edilmiştir. Bocchi ve ark. [60] Fraktal modelleme kullanmışlardır. Fraktal model mamografi görüntüsünün arka planı ile anormallikleri arasındaki ayrımın daha fazla ortaya çıkarılması doğrultusunda kullanılmıştır. Sınıflandırma aşaması için yapay sinir ağı tabanlı sınıflandırıcı kullanılmıştır. Fadi Abu-Amara ve Ikhlal Abdel-Qader [61] dijital mamografi görüntülerinde şüpheli bölgeleri belirlemek için Temel Bileşen Analizi (TBA) ve Bağımsız Bileşen Analizi (BBA) algoritmalarından oluşan bir yöntem sunmuşlardır. Önerilen yöntem MIAS veri bankasına ait mamografi görüntülerinden elde edilen 35x35 ve 45x45 piksel boyutlarındaki alt görüntülere uygulanmıştır. Uygulamada TBA-BBA algoritmasının performansı ayrı ayrı TBA ve BBA algoritmalarının performansı ile karşılaştırılmıştır. Yapılan deneysel çalışmalar, TBA kullanılarak yapılan boyut indirgeme işleminden sonra özellik seçimi için BBA algoritmasının kullanılması, TBA algoritmasıyla elde edilen sonucu %32,42, BBA algoritmasıyla elde edilen sonucu %8,2 oranında iyileştirdiği sonucuna varmışlardır. Sınıflandırma önce normal-anormal mamogram ayrımı şeklinde daha sonrada iyi huylu-kötü huylu şeklinde gerçekleştirilmiştir. En iyi sınıflandırma sonucu 45x45 piksel boyutlu veri setinde, normal-anormal ayrımı için %79 iyi huylu-kötü huylu ayrımı için %71,2 olarak elde edilmiştir. Campos ve ark. [62] BBA ve Yapay Sinir Ağı (YSA) kullanarak mamografi görüntülerinin normal, iyi huylu ve kötü huylu olarak sınıflandırılması için bir yöntem sunmuşlardır. Uygulamada hızlı BBA algoritması kullanılarak üç farklı yapay sinir ağı algoritmasıyla karşılaştırma yapılmıştır. Karşılaştırılan sınıflandırıcılar çok katmanlı algılayıcı yapay sinir ağı, olasılıksal sinir ağı ve radyal taban fonksiyon sinir ağıdır. En iyi sınıflandırma sonucu olasılıksal sinir ağı ile %97,3 olarak elde edilmiştir. Christoyianni ve ark. [63] bağımsız bileşen analizine dayalı özellik çıkarma üzerine çalışmışlardır. Yaklaşımları gözlenen mamografi görüntüsünden elde edilen bağımsız kaynak bölgelerinin bir setini bulmaya odaklanmıştır. Kaynak bölgelerin lineer dönüşüm katsayıları, mamografi görüntülerinin normal-anormal olarak ayrıştırılmasında ve şüpheli bölgelerinde iyi huylu-kötü huylu olarak ayrıştırılmasında, özellikler olarak kullanılmıştır. MIAS veri tabanına ait mamografi görüntüleriyle yapılan uygulamalarda, normal-anormal bölge ayrımında %88,23 sınıflandırma doğruluğuna iyi

huyulu-kötü huyulu ayırımında %79,31 sınıflandırma doğruluğuna ulaşmışlardır. Anna ve ark. [64] kanser teşhisi için doku analizinde Laws'un doku enerjisi ölçüm yönteminin doku analizinde iyi bir yöntem olduğunu önermektedirler. Doku enerji ölçümü görüntüdeki yüksek enerji noktalarını vurgulamaktadır. Basıklık, çarpıklık, ortalama ve standart sapma gibi temel özellikler göz önüne alınarak doku enerji ölçüm kanunları ile elde edilen sınıflandırma doğruluğu % 90'dır. Costa ve ark. [65] mamografi görüntülerindeki şüpheli bölgelerde kitle ayırımı gerçekleştirmek için DAA ile birlikte verimli kodlama kullanan bir yöntem sunmuşlardır. Sunulan verimli kodlama modeli %90,07 sınıflandırma başarısına ulaşmıştır.


Özellik çıkarımı, sınıflandırma doğruluğuna doğrudan etki ettiği için BDT sistemleri ve görüntü işlemede önemli bir aşamadır. Dijital görüntü özellikleri, farklı bir boyuttan veya doğrudan uzaysal veriden elde edilebilir. Fourier dönüşümü, dalgacık dönüşümü, çevritcik dönüşümü veya eğricik dönüşümü gibi çok çözünürlüklü dönüşüm vasıtasıyla farklı bir uzay kullanarak uzaysal veriyi ayırmak mümkün olabilir. Çok çözünürlük, belli çözünürlük seviyesine göre bir görüntünün korunmasına olanak sağlar. Altta kalan doku yapıları üzerine, yakınlaştırma ve uzaklaştırma işlemi gerçekleştirmeye de izin verir. Çok çözünürlüklü analiz yöntemi, görüntü sıkıştırmadan gürültü gidermeye ve sınıflandırma dâhil pek çok uygulamada iyi sonuçlar vermiştir [66,67]. Liu ve ark. [68] çok çözünürlüklü analizin, dalgacık katsayılarına dayalı teşhis sisteminin etkinliğini artırdığını kanıtlamışlardır. Çalışmalarında şüpheli kitlenin tespitinde, ikili ağaç sınıflandırıcı ile istatistiksel özelliklerin bir setini kullanmışlardır. Sınıflandırma sonucunda %84.2 sınıflandırma doğruluğuna ulaşmışlardır. Yang ve ark. [69] dalgacık dönüşümü kullanarak dijital mamografide mikrokalsifikasyonların tespiti için karşılaştırmalı bir çalışma yapmışlardır. Görüntüyü, farklı frekans bantlarına sahip farklı katmanlara ayırmışlardır. Birkaç normal dalgacık ailesi fonksiyonu, karşılaştırmalı olarak çalışılmış ve her bir dalgacık fonksiyonu için, farklı çözünürlük seviyeleri mikrokalsifikasyonların tespiti için araştırılmıştır. Yapılan deneysel çalışmalar sonucunda dördüncü seviye ayırıştırma ile Daubechies dalgacık fonksiyonun en iyi tespit değerine sahip olduğuna ulaşmışlardır. Moayed ve ark. [70] destek vektör makinesi ve çevritcik dönüşümü tabanlı teşhis sistemi çalışması sunmuşlardır. Dördüncü ayırıştırma seviyesinden çevritcik katsayılarının istatistiksel özelliklerinin bir setini, geometrik özellikleri ve eş oluşum matrisi özelliklerini ilgi alanlarının özellik vektörü olarak kullanmışlardır. Örüntü sınıflandırma işlemi için sinir ağı kullanmışlar ve özellik seçimi işlemi, genetik algoritmasıyla

gerçekleştirmişlerdir. Çevritcik dönüşümünün sınıflandırma aşamasında iyileştirme sağladığını göstermişlerdir.

Diğer birçok çözünürlüklü analiz yöntemi olan eğricik dönüşümü, Candes ve Donoho tarafından geliştirilmiştir. Farklı yapılar arasındaki sınırları tespit etme ve iyileştirme, görüntü işleme için özellikle medikal görüntüler için önemlidir [71]. Bu önem doğrultusunda bazı görüntü işleme çalışmalarında eğricik yaklaşımı kullanılmıştır. Ali ve ark. [72] Manyetik Rezonans (MR) ve Bilgisayarlı Tomografi (BT) görüntülerini birleştirme için, bir eğricik dönüşümü yaklaşımı sunmuşlardır ve eğricik dönüşümünün, yapmış olduğu birleştirme işlemi başarılı olduğu sonucunu bulmuşlardır. Bind ve Tahan [73] benekli görüntüde obje tespiti için eğricik dönüşümüne dayalı bir yöntem sunmuştur. Murtagh ve Stark [74] özellik olarak çok çözünürlüklü dönüşüm (eğricik ve dalgacık dönüşümleri) katsayılarının ikinci, üçüncü ve dördüncü derece momentlerini kullanmışlardır. Sınıflandırma aşaması için, k-en yakın komşuluk sınıflandırıcısını kullanmışlardır. Eltoukhy ve ark. [75] eğricik dönüşümüne dayalı mamografi görüntülerinin sınıflandırması üzerine çalışmışlardır. Özellik vektörü olarak, eğricik dönüşümünden elde edilen her bir ayrışım seviyesine ait katsayıları paket paket kullanmışlardır. Mamografi görüntülerinin normal ve anormal olarak ayrıştırılmasında, en yüksek sınıflandırma doğruluğu %98.59 olarak elde edilmiştir. Dalgacık dönüşümü ile yaptıkları karşılaştırmada dalgacık tabanlı özelliklerden eğricik tabanlı özelliklere bağlı sınıflandırma başarısının daha yüksek olduğunu tespit etmişlerdir. Eltoukhy ve ark. [76] bu çalışmalarında, dalgacık dönüşümü ile eğricik dönüşümünü karşılaştırmışlardır. Çok çözünürlüklü dönüşüm araçları 4. seviye ölçeğe kadar uygulanmıştır. Sınıflandırıcı olarak Öklid uzaklığına dayanan en yakın komşu sınıflandırıcı kullanılmıştır. Eğricik dönüşümü daha başarılı sonuçlar vermiştir. Elde edilen en yüksek sınıflandırma başarısı, normal-anormal ayrımı için %94.07 ve iyi huylu-kötü huylu ayrımı için %94.28'dir. Eltoukhy ve ark. [77] dalgacık dönüşümü, eğricik dönüşümü ve istatistiksel t-test yöntemi kullanarak yeni bir meme kanseri tespit sistemi sunmuşlardır. Dalgacık ve eğricik dönüşümü katsayılarına dinamik eşikleme uygulanarak önemli özelliklerin ön plana çıkması amaçlanmıştır. Sınıflandırıcı olarak, DVM algoritması kullanılmış ve en yüksek başarı oranına normal-anormal sınıflandırmasında %95.98, iyi huylu-kötü huylu sınıflandırmasında %97.3 ile eğricik dönüşümü ile ulaşmışlardır.

Bu çalışma dört bölümden oluşmaktadır. İlk bölüm, MIAS veri bankasından elde edilen görüntülerde otomatik şüpheli bölge tespiti ve alt görüntülerin oluşturulmasını

içermektedir. İkinci, üçüncü ve dördüncü bölümler, alt görüntülerin farklı kombinasyonlarda sınıflandırılmasını içermektedir. Sınıflandırma işlemi, alt görüntü boyutu, özellik çıkarımı, özellik seçimi ve farklı sınıflandırıcılar üzerinden değerlendirilmesidir. Sınıflandırma içeren ikinci ve üçüncü bölümde, her bir mamografi görüntüsünün ayrı ayrı eğricik dönüşümü alınarak, görüntülerin ayrıştırılması ölçek 3 ve açı 8 olarak gerçekleştirilmektedir. Eğricik dönüşümü sonucunda elde edilen katsayıların tümü kullanılmamış, sadece yaklaşım bandı ismiyle ifade edilen eğricik katsayıları özellikler olarak kullanılıp özellik matrisi elde edilmiştir. Ölçek 3 ve açı 8 ile eğricik dönüşümü uygulandığında, 25 bileşenden oluşan eğricik katsayıları elde edilmektedir. Bu bileşenlerden biri yaklaşım bandı ve diğerleri detay bantlar olarak isimlendirilmektedir. Yaklaşım bandına odaklanmamızın nedeni, maksimum standart sapmaya sahip olması ve elde edilen detay bantların simetrik veri içermesidir. Şekil 6'da T görüntüsüne ait eğricik dönüşümü 8 detay bant katsayılarına ait görüntüleri gösterilmektedir. Şekilden 1. ve 8. bant katsayılarına ait görüntülerin ve benzer şekilde 2. ve 3., 4. ve 5., 6. ve 7. bant katsayılarına ait görüntülerin hemen hemen aynı olduğu görülecektir. Bu nedenle her bir görüntünün elde edilen alt bantlarından en büyük standart sapmaya sahip olan yaklaşım bandı kullanılarak BDT sistemi, DVM, k-EK ve EK-DVM sınıflandırıcıları ile gerçekleştirilmiştir.



Şekil 6. T görüntüsü ve görüntüye ait eğricik dönüşümü 8 detay band görüntüsü [78]

Sınıflandırma içeren dördüncü bölümünde, dalga atom dönüşümü kullanılmıştır. Literatürde şu ana kadar; mamografi görüntülerinin sınıflandırılması konusunda, dalga atom dönüşümüyle yapılmış hiçbir çalışma bulunmamaktadır ve bu çalışma ilk olacaktır. Çok çözünürlüklü analiz yöntemlerinin son üyesi olan dalga atom dönüşümü ile alt görüntü veri setine her bir mamografi 4 ölçeğe kadar ayrıştırılmaktadır. Her bir ölçeğe ait katsayılar özellik vektörlerinin oluşturulmasında kullanılmakta ve sınıflandırma bu katsayılar üzerinden gerçekleştirilmektedir. Sınıflandırıcı olarak DVM algoritması kullanılmıştır. İlave olarak, dalga atom katsayılarına TBA algoritması ile özellik seçimi gerçekleştirilerek sınıflandırma başarısı tekrar değerlendirilmiştir. Her bölüme ait detaylar bulgular bölümünde verilmektedir.

2. MATERYAL VE YÖNTEMLER

2.1. İlgili Alanlarının Elde Edilmesi: Morfolojik İşlemler ve Ortalama Filtre

Mamografi görüntülerinde anormallikler; kitle, asimetri, yapısal bozukluk ve mikrokalsifikasyonlar olarak ifade edilmekte ve görüntülerde ilgilenilen bölgeleri oluşturmaktadırlar. Otomatik olarak ilgi alanlarının elde edilmesi, sınıflandırma işleminden önce mamografinin tüm yüzeyinin taranarak anormal olma ihtimali olan yapıların diğerlerinden ayrılmasını sağlayarak mamografiye ait bu bölgelerden alt görüntülerin oluşturulmasıdır. Mamografi görüntüleri üzerinde yapılan incelemeler sonucunda, şekilsel özellikleri dikkate alınarak anormallikler mikrokalsifikasyonlar ve diğerleri (kitle, asimetri, yapısal bozukluk) şeklinde iki gruba ayrılmıştır. Mamografi görüntüsü üzerinde şüpheli mikrokalsifikasyon alanlarının konumunun belirlenmesinde ortalama filtre kullanılmıştır. Diğer anormalliklere ait konumların belirlenmesinde, morfolojik işlemler olan top-hat ve bottom-hat dönüşümleri kullanılmaktadır. Her iki durumda da, mamografi yüzeyinde şüpheli kısımlar diğerlerinden ayrıştırılmaktadır. Daha sonra konumları belirlenerek orijinal görüntüde o bölgelere karşılık gelen alanlar alt görüntüler şeklinde çıkarılıp sınıflandırmaya tabi tutulmaktadır. İşlemlere ait detaylar bulgular bölümünde verilmektedir.

Top-hat ve bottom-hat yöntemleri, matematiksel morfolojik görüntü işleme tekniklerindedir. Matematiksel morfolojik görüntü işlemede temel amaç, parça korelasyonu yoluyla bir görüntünün yapısal karakteristiğinin anlaşılması amacıyla derinlemesine inceleme yapmaktır. Bunu gerçekleştirmek için, yapı elemanı adı verilen çeşitli geometrik şekillere sahip (kare, dikdörtgen, daire vb.) ikili resim kullanılmaktadır. Aşındırma ve genişletme en temel matematiksel morfolojik işlemlerdir ve diğer işlemler bu iki işlemden elde edilmektedir. Genişletme, görüntüde bulunan nesneyi yapı elemanına uygun olarak büyütmeye yarayan bir morfolojik işlemdir. Birbirinden bağımsız bölgeleri birleştirir. Aşındırma, ikili görüntüde nesneyi küçültür ve görüntüden ilgisiz parçaları atar. İlintili bazı bölgeleri izole etmek için kullanılır [79].

Genişletme ve aşındırma diğer iki temel işlemin (açma ve kapama) biçimlendirilmesinde birleşik olarak kullanılmaktadır. Açma işlemi, aşındırma ve genişletme işlemlerinin ardışık uygulanmasıyla elde edilir. İkili imgedeki nesneyi

küçültmeye ya da inceltmeye yarayan morfolojik işlemdir. İmge üzerinde genişletme işleminin hemen ardından aşındırma işleminin uygulanması sonucu kapama işlemi elde edilir. Dolayısıyla birbirine yakın iki nesne, imgede fazla değişiklik yapılmadan birbirine bağlanmış olur. Aşağıda bu işlemlerin matematiksel gösterimi verilmiştir:

$$\text{Genişletme} \Rightarrow A \oplus B \quad (1)$$

$$\text{Aşındırma} \Rightarrow A \ominus B \quad (2)$$

$$\text{Açma} \Rightarrow A \circ B = (A \ominus B) \oplus B \quad (3)$$

$$\text{Kapama} \Rightarrow A \bullet B = (A \oplus B) \ominus B \quad (4)$$

Gri seviyeli görüntüde genişletme, maksimum işleminden dolayı orijinal görüntüden daha büyük gri seviyeli görüntü oluşturur. Karanlık bölgelerin boyutunu azaltırken parlak bölgelerin boyutunu artırır. Gri seviyeli morfolojik işlemler için bir görüntünün b yapısal elemanı ile genişletme işlemi aşağıdaki gibidir [79].

$$(f \oplus b)(x, y) = \max\{f(x - x', y - y') + b(x', y') \mid (x', y') \in D_b\} \quad (5)$$

Burada D_b , b'nin etki alanıdır. Genişletme işleminden sonra resim genelde daha parlaktır.

Gri seviyeli görüntüde aşındırma, minimum işleminden dolayı orijinal görüntüden daha küçük gri değerli görüntü oluşturur. Parlak bölgelerin boyutunu azaltırken, koyu bölgelerin boyutunu artırmaktadır. Gri seviye aşındırma işlemi aşağıdaki gibidir.

$$(f \ominus b)(x, y) = \min\{f(x - x', y - y') + b(x', y') \mid (x', y') \in D_b\} \quad (6)$$

Aşındırma işleminden sonra resim genelde daha koyudur. Gri seviye görüntüde açma ve kapama işlemine ait ifadeler aşağıdaki gibidir.

$$f \circ b = (f \ominus b) \oplus b \quad (7)$$

$$f \bullet b = (f \oplus b) \ominus b \quad (8)$$

Top-hat dönüşümü, asıl görüntü ile açma işlemi uygulanmış hali arasındaki farka karşılık gelmektedir ve orijinal görüntüde parlak bölgelerin tespitinde kullanılır. Yani, gri

seviye görüntüde tepe değerleri belirginleştirir. Bottom-hat dönüşümü, kapama görüntüden asıl görüntünün çıkarılmasıyla gerçekleştirilmektedir. Bu şekilde görüntünün alt gri seviyeleri yani karanlık bölgeler tespit edilir. Çukur bölgeleri belirginleştirir. Bu özelliklerinden dolayı, top-hat ve bottom-hat dönüşümleri mamografi üzerinde anormalliklerin diğer alanlardan ayrıştırılmasında kullanılabilir. Top-hat ve bottom-hat dönüşümüne ait ifadeler aşağıdaki gibidir [80].

$$\text{tophat}(f, b) = f - (f \circ b) \quad (9)$$

$$\text{bottomhat}(f, b) = (f \bullet b) - f \quad (10)$$

2.2. Özellik Çıkarımı

Özellik çıkarımı örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynamaktadır. Örüntü sınıfları arasında ayrımı gerçekleştirmek için, karmaşık veriden örüntü özelliklerinin çıkarılması gerekmektedir. Bu çalışmada, özellikler ve özellik vektörü çok çözünürlüklü analiz algoritması olan eğricik dönüşümü ve dalga atom dönüşümü kullanılarak elde edilmiştir. Eğricik dönüşümü, üstün yön kabiliyetine ve eğriler boyunca tekillikleri ve kenarları başarılı bir şekilde temsil yeteneğine sahip çok çözünürlüklü analiz yöntemidir. Dalga atom dönüşümü, görüntüyü daha az katsayı ile temsil etmekte ve keskin frekans yerleşimine sahiptir. Eğricik dönüşümü osilasyon doğrultusunda örüntü uyumu yakalarken, dalga atom dönüşümü hem osilasyon doğrultusunda hem de çapraz doğrultuda örüntü uyumu yakalamaktadır. Her iki yöntemde, örüntü temsilinde ve örüntü yakalamada etkin kabiliyetlere sahiptir.

2.2.1. Eğricik Dönüşümü

Son yıllarda, çok ölçek düşüncesine dayalı matematiksel ve hesapsal araçların geliştirilmesinde yoğun çalışmalar yapılmıştır. Bilişim alanında, özellikle sinyal işleme, dalgacık dönüşümü ve ilgili düşüncelerin gelişimi; sıkıştırılmış verinin hızlı transferi için, sinyal ve görüntülerdeki gürültüyü gidermek için, büyük veri setlerinin analizi için uygun araçlara yol açmıştır. Bilimsel hesaplama (bilgi işlem) alanında dalgacık dönüşümü ve ilişkili çok ölçekli yöntemler, bazen kısmi diferansiyel denklemlerin çözümünün sayısal

değerlendirmesi gibi temel bilimsel hesaplamaların hızlandırılmasına olanak sağlamıştır [81].

Sağladıkları başarıya rağmen, son birkaç yıldır yapılan yoğun araştırmalar, klasik çok çözünürlüklü yöntemlerin evrensel olarak etkili olmayacağını göstermiştir. Fourier yönteminin her türlü amaç için yeterli olmadığını anlaşılmasıyla dalgacık dönüşümü gibi yeni sistemler tanıtılmış ve sonrasında araştırmacılar dalgacık dönüşümüne de alternatif arayışına girilmiştir.

Genellikle dijital görüntü verisi, uzaysal ortamda pikseller aracılığı ile temsil edilir. Yaygın olarak Fourier dönüşümü, frekans uzayı gösterimi için kullanılmaktadır. Fourier serisi periyodik fonksiyonu, basit dalgalı fonksiyonlarının (sinüs ve kosinüs) toplamına çevirir. Ancak Fourier serisi sürekli sistemlere uygulanabilir, süreksizlik nedeniyle ayrıklık kabul edilemez. Nesne tanıma yönüyle görüntünün Fourier dönüşümü tatmin edici bilgiye sahip değildir. Çok çözünürlüklü analiz araçları, Fourier serilerinin içsel sınırlamalarını aşmak için geliştirilmiştir. Bilim ve teknolojinin birçok alanında maksimum verimlilik, etkin kaynak kullanımı ve doğruluğu için çok çözünürlüklü analiz araçlarından yararlanılır. Dalgacık, çevritcik ve sırtcık gibi dönüşümler görüntü temsilde alternatif piksel ve frekans bilgisine sahiptirler ve tanımayı kolaylaştırırlar.

Eğricik dönüşümü, genel bir eğri boyunca süreksizlikle pürüzsüz nesnelere temsil etmek için tasarlanmıştır. Eğricik dönüşümü eğriler boyunca kenarları ve diğer tekillikleri temsil etmek için mevcut çok çözünürlüklü analiz tasarımlarının eksikliklerini giderir ve gelişmiş yönsel kapasite sunar. Bir eğricik, kutupsal koordinat sisteminde tanımlanan frekans alanının da radyal ve açısal pencerenin birleşimidir. Açısal pencere, Radon dönüşümüne (yönsel analiz) karşılık gelir ve radyal dinamik pencere, bant geçiren filtreye benzer [82]. Eğricik temelleri, Gabor dönüşümü gibi diğer yönsel çok ölçek gösterimlerinin aksine frekans alanını tamamen kapsayacak şekilde tasarlanır.

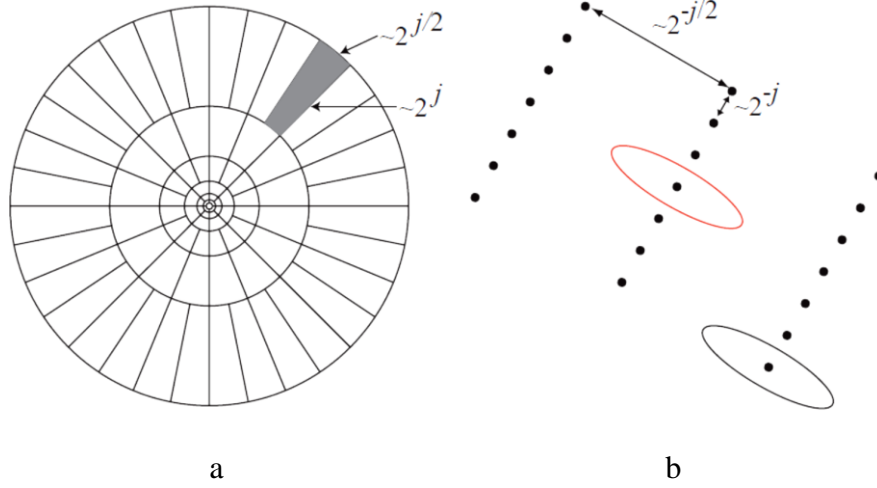
2.2.1.1. Ayrık Eğricik Dönüşümü

Eğricik dönüşümü Candes ve Donoho tarafından 1999 yılında tanıtılmıştır [83]. Yöntem, diğer geleneksel çok çözünürlüklü dönüşümlere kıyasla eğriler boyunca tekillikleri ve kenarları göstermede daha başarılıdır ve yönsel kabiliyete sahiptir. Eğricik dönüşümünün ilk tanıtımından kısa süre sonra, araştırmacılar tarafından çeşitli algoritmalar geliştirilmiştir. Bu uygulamalar, frekans ve uzayda iyi lokalize edilmiş verinin bloklarına

uygulanan sırtçık dönüşümü tarafından takip edilen faz-uzay özel bölümünü içeren, ön işleme aşamasına sahip yapının eğricik dönüşümüne dayalıdır. Ancak, takip eden iki üç yıl içinde, eğricik dönüşümü daha kolay anlaşılması ve kullanılması amacıyla yeniden tasarlanmıştır. 2006 yılında tanıtılan yeni tasarım oldukça basit ve tamamen şeffaf bir yapıya sahiptir. İlk sürümüne göre daha hızlı ve daha az tekrar fazlalığına sahiptir. Yeni matematik mimarisi, yenilikçi algoritmik stratejileri önerir ve daha önceki uygulamaları geliştirmek için bir fırsat sağlamaktadır. Bu amaç doğrultusunda, Emmanuel Candes ve arkadaşları tarafından daha hızlı, daha basit iki tane Hızlı Ayrık Eğricik Dönüşümü (FDCTs) yöntemi sunuldu [82]. Bu yöntemler sırasıyla:


- Eşitsiz aralıklanan hızlı Fourier dönüşümünü (USFFT) temel alan eğricik dönüşümü
- Sarma işlemini temel alan eğricik dönüşümüdür.

Eğricik dönüşümü çok ölçekli, çok yönlü, parabolik ölçekleme ilişkisine uyan oldukça iyi yön bağımlı biçim gösterir ve küçük ölçeklerde boyuna iğneler biçimi alır. Eğricik dönüşümünü uygulamak için ilk olarak görüntüye 2 boyutlu (2B) FFT (hızlı Fourier dönüşümü) uygulanır. Daha sonra 2B Fourier frekans düzlemi parabolik takozlara bölünür. Her bir j ölçeği ile l açısındaki eğricik katsayılarını bulmak amacıyla her bir takoz için ters FFT uygulanır. Şekil 7 bölünmüş takozları, Fourier frekans düzleminde göstermektedir. Fourier düzlemi, radyal ve açısız olarak eş merkezli daireler halinde bölümlere ayırarak takozlar elde edilmektedir. Eş merkezli daireler görüntünün çok ölçekli (bant geçişi uygulamak için) ayrıştırılmasından sorumludur ve açısız bölmeler farklı açılar veya yönelimlere karşılık gelir. Bu nedenle, belli bir takozdan bahsetmek için öncelikle ölçeğin ve açının tarif edilmesi gerekir (j, θ). Uzaysal uzayda her bir takoz, verilen o ölçek ve açıda belli bir eğriciğe karşılık gelir. Şekil 7'de sağ taraf belli bir ölçek ve açıyla ilgili uzaysal Kartezyen ızgaradaki eğricikleri temsil etmektedir. Öte yandan, dönüşüm hem uzaysal hem de frekans uzayında lokalize edilmelidir. Bir uzayda sınırlanan bir sinyal bir diğerine serilir. Bu şekilde dönüşümün her iki uzayda yaklaşık olarak sınırlandırılması beklenir. Şekil 7'nin sol tarafındaki görüntü Fourier düzleminin nasıl takozlara bölündüğünü göstermektedir. Bir takozun frekans uzayında keskin bir sınıra sahip olması halinde uzaysal uzayda yayılacağı anlamına gelir.




Şekil 7. Eğriciğin a) frekans düzlemi gösterimi, b) verilen bir ölçek ve yönelimle ilişkili uzaysal Kartezyen ızgara gösterimi.

Şekil 8'in sol tarafı frekans uzayında gerçek bir takozu ve sağ tarafı bu takozu karşılık gelen uzaysal uzayda bir eğriciği göstermektedir. Eğricik tam bir oval değildir, bir yönde yayılır ve diğer yönde dalgaya benzer. Şekil 8'nin sağ tarafında gösterildiği gibi bunun etkin desteği eliptiktir. Ovalin birincil ve ikincil eksenlerinin uzunlukları arasındaki ilişki parabolik bir ölçekleme yasasını takip eder. Eş yönlü olmaları sebebiyle dalgacıklar için karşılık gelen biçimler dairesel olur. Tüm görüntüler için eğricik biçimleri aynıdır (eliptik). Bununla birlikte eğricik katsayılarının değerleri, eğricikler ve gerçek görüntü ne kadar düzeltilirse o oranda doğru olarak bulunur.



Şekil 8. a) Fourier dönüşümü ve b) uzaysal uzayda eğricik [82].

Şekil 9, eğricik katsayılarının nasıl belirlendiğini göstermektedir. Üst sol imge, rastgele bir nesne görüntüsünü göstermektedir. Üst sağ imge, baskın kenarları olan bant geçişli ideal görüntüyü göstermektedir (Şekil 7, belli bir eş merkezli halkada). Altta ki görüntü farklı yönelimlerdeki takozlara karşılık gelen uzaysal uzaydaki eğricikleri göstermektedir (yani Şekil 7'ye ait aynı eş merkezdeki farklı takozlar). Bu durumda, kenarlara göre düzeltilmiş eğricik değerleri yüksek değerlere sahiptir, Şekil 9. Bant geçişli görüntüye (yani a ve b) göre düzeltilmeyen eğricikler çok küçük katsayılara sahiptir. Görüntü belli bir bölgede ne kadar büyük kenara (ölçek ve yönelimli) sahipse o nispete yüksek eğricik katsayıları sağlar.



Şekil 9. Eğricik katsayılarının belirlenmesi [84]

2.2.1.2. Sarma Yoluyla Ayrık Eğricik Dönüşümü


Sarma yoluyla FDCT'nin yapısı aşağıdaki işlem aşamalarını içermektedir [82]:

- 2B FFT uygulanarak görüntü matrisinin Fourier örnekleri elde edilir, $\hat{f}[n_1, n_2]$, $-n/2 \leq n_1, n_2 \leq n/2$.
- Her bir ölçek j ve açı l için pencere fonksiyonu ve Fourier örnekleri çarpımı elde edilir, $\tilde{U}_{j,l}[n_1, n_2] \hat{f}[n_1, n_2]$.
- Çarpım sonucu orjin etrafında sarmalanarak veri yeniden indekslenir, $\tilde{f}_{j,l}[n_1, n_2] = W(\tilde{U}_{j,l} \hat{f})[n_1, n_2]$. Burada n_1 ve n_2 değerleri $0 \leq n_1 \leq L_{1,j}$ ve

$0 \leq n_2 \leq L_{2,j}$ dir. $L_{1,j}$ ve $L_{2,j}$, sarma işleminde paralel yüzlüye ait ayrıtları göstermektedir.

- $c^D(j, l, k)$ ayrık eğricik katsayılarını elde etmek için her bir $\tilde{f}_{j,l}$ 'ye ters 2B FFT uygulanır.

Şekil 10, paralel kenar içindeki verinin periyodik bir şekilde bir dikdörtgene sarmalanmasını göstermektedir. θ açısı burada $(-\pi/4, \pi/4)$ alanındadır. Siyah renkli paralel kenar eğriciğin frekans desteğini içeren fayans $P_{j,l}$ dir. Gri renkli paralel kenarlar periyotlandırılmadan kaynaklanan kopyalardır. Dikdörtgenin merkezi orjindedir. Sarılmış elips parçalara bölünmüş gibi gözükür, ancak bu zıt kenarları tanımlanan periyodik dikdörtgende problem değildir.




Şekil 10. Verinin orjin etrafında sarmalanması

2.2.2. Dalga Atom Dönüşümü

Dalga atom dönüşümü Demanet and Ying tarafından 2007 yılında tanıtılan, görüntü işleme ve sayısal analiz için, çok yönlü/ölçekli dönüşüm algoritmalarından biridir [85]. Parabolik ölçekleme özelliğini sağlayan 2B dalgacık paketlerinin farklı bir hali olarak düşünülebilir. Bilinen diğer çok ölçekli yöntemlerden (eğricik, sırtçık, gabor filtre) daha seyrek genişlemeye sahiptir. Eğricik dönüşümü sadece osilasyon doğrultusunda örüntü uyumu yakalarken, dalga atomları hem osilasyon doğrultusunda hem de osilasyona çapraz doğrultuda örüntü uyumu yakalar. Dalga atom dönüşümü dalgacık paketleriyle

ulaşamayacak, keskin bir frekans lokalizasyonuna sahiptir ve salınım fonksiyonları için daha seyrek bir genişleme sunar.

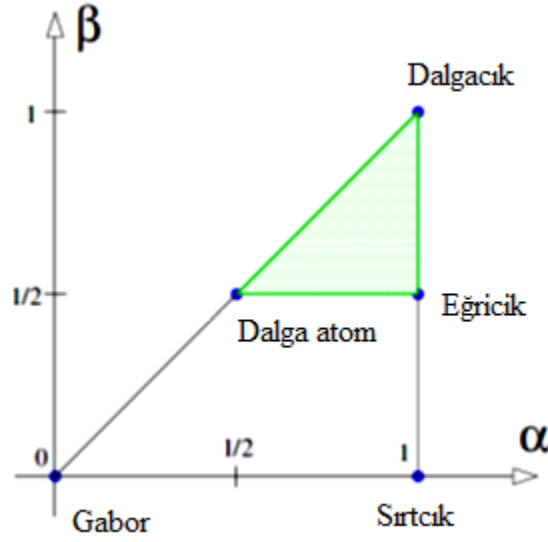
Dalga atom dönüşümünün çekirdeği Şekil 11’de gösterilmektedir. Şeklin sağ tarafı kamalara bölünmüş frekans düzlemini göstermektedir. Kamalar, frekans düzleminin açısal ve radyal parçalara bölünmesiyle oluşturulmaktadır. Radyal parçalar (konsantrik çemberler) görüntünün farklı çözünürlüklerde (ölçek) bant geçiren filtrelenmesini temsil etmektedir. Açısal parçalar, her bir bant geçiren görüntüyü farklı açılara ayırır. Her bir kama düşünüldüğünde bant geçişli görüntü, ölçek j ve açı θ ’da analiz edilebilir.



Şekil 11. (α, β) parametreleriyle bir dalga paketinin temel desteği a) uzaysal düzlemde, b) frekans düzleminde.

Şekil 11’de ölçek ve açı tanımlanarak kama tarif edilir. Ters dönüşüm kullanılarak kama uzaysal düzleme dönüştürülür (şeklin sol tarafı). Yani kamanın ters Fourier dönüşümü belirli bir ölçek ve açıda kamaya karşılık gelen dalga atomudur.

Çok ölçekli analiz yöntemlerinde iki fark parametresi vardır ve bu parametreler ayrıştırma ve yönsel kabiliyeti temsil ederler (α, β) . α ve β parametreleri dalgacık, sırtçık, eğricik, Gabor filtresi ve dalga atom yapılarının bilinen bütün formlarını indeksleme için yeterlidir. α parametresi dönüşümün çok ölçekliliğini temsil eder ve $(0-1)$ aralığındadır. β parametresi dönüşümün yönsel duyarlılığını temsil eder ve $(0-1)$ aralığındadır. Bu tanımlamaya göre dalga atom dönüşümü $\alpha = \beta = 1/2$ şeklinde tanımlanır. Yani orta yön ve ölçek ayarına sahiptir ve orta yön ve ölçekleme örüntü sınıflandırması için daha iyidir [85]. Şekil 12’de α ve β parametrelerine bağlı olarak dalga paketlerinin temsil ettiği dönüşüm yöntemleri gösterilmektedir.



Şekil 12. α ve β parametrelerine göre çok çözünürlüklü dönüşüm formları

2.2.2.1. 1B Dalga Atom Dönüşümü

Pratikte dalga atomlar 1B (boyutlulu) dalga paketlerinin tensör çarpımından oluşturulmaktadır. Frekans düzleminde $\pm\omega_{j,m} = \pm\pi 2^j m$ ve uzayda $x_{j,n} = 2^{-j}n$ etrafında merkezlenen 1B dalga paketleri $\psi_{m,n}^j(x)$ olsun. Frekans düzleminde, ψ_m^0 'ın ötelenmiş ve diyalik ölçeklenmiş versiyonlarının birleşimi olan dalga atom baz fonksiyonu aşağıdaki gibidir.

$$\psi_{m,n}^j(x) = \psi_m^j(x - 2^{-j}n) = 2^{j/2}\psi_m^0(2^j x - n) \quad (11)$$

Burada, $\psi_m^0(\omega)$ aşağıdaki gibi oluşturulmaktadır.

$$\psi_m^0(\omega) = e^{-i\omega/2} \left[e^{i\alpha_m} g \left(\epsilon_m \left(\omega - \pi \left(m + \frac{1}{2} \right) \right) \right) + e^{-i\alpha_m} g \left(\epsilon_{m+1} \left(\omega + \pi \left(m + \frac{1}{2} \right) \right) \right) \right] \quad (12)$$

$\alpha_m = \frac{\pi}{2}(m + \frac{1}{2})$, $\epsilon_m = (-1)^m$ iken, g gerçek değerli kompakt desteğe sahip c^∞ tepe fonksiyonudur. Tepe fonksiyonu, $\sum_m |\psi_m^0(\omega)|^2 = 1$ eşitliğini sağlamaktadır. 2^{-j} ölçeğinde herbir dalga $\omega_{j,m}$ için dalga atom katsayıları aşağıdaki gibi elde edilmektedir [85].

$$c_{j,m,n} = \int \psi_m^j(x - 2^{-j}n)u(x)dx = \frac{1}{2\pi} \int e^{i2^{-j}n\omega} \widehat{\psi}_m^j(\omega) \widehat{u}(\omega) d\omega \quad (13)$$

2.2.2.2. 2B Dalga Atom Dönüşümü

İki boyutlu ortonormal dört tepeli baz fonksiyonu, 1B dalga paketlerinin ayrı ayrı çarpımlarının alınmasıyla, frekans düzleminde elde edilmektedir. 2B'lu dalga atomları $\mu = (j, m, n) = (j, m_1, m_2, n_1, n_2)$ kullanılarak indekslenmektedir. Modifiye edilmiş baz fonksiyonu aşağıdaki gibidir.

$$\varphi_\mu^+(x_1, x_2) = \psi_{m_1}^j(x_1 - 2^{-j}n_1) \psi_{m_2}^j(x_2 - 2^{-j}n_2) \quad (14)$$

Dalga paketlerinin Hilbert dönüşümü alınarak ikinci bir ortonormal baz elde edilmektedir.

$$\varphi_\mu^-(x_1, x_2) = H\psi_{m_1}^j(x_1 - 2^{-j}n_1) H\psi_{m_2}^j(x_2 - 2^{-j}n_2) \quad (15)$$

Eşitlik (14) ve (15)'in birleşimiyle iki tepeli baz fonksiyonu frekans düzleminde elde edilir [85].

$$\varphi_\mu^{(1)} = \frac{\varphi_\mu^+ + \varphi_\mu^-}{2}, \quad \varphi_\mu^{(2)} = \frac{\varphi_\mu^+ - \varphi_\mu^-}{2} \quad (16)$$

$\varphi_\mu^{(1)}$ ve $\varphi_\mu^{(2)}$ birlikte dalga atom çatısını oluşturmaktadır ve φ_μ 'yi ifade eder.

2.3. Özellik Seçimi

Alt veri seçimi olarak da isimlendirilebilecek özellik seçimi aşaması özellik veri setinden en etkin veriyi bulmayı amaçlamaktadır. En iyi alt veri seti sınıflandırma doğruluğuna en çok katkıda bulunacak ve en küçük boyuttaki veri seti olmalıdır. Kalan önemsiz boyutlar göz ardı edilecektir. Özellik seçimi, sınıflandırma başarısı ve sınıflandırma zamanı üzerinde önemli etkiye sahiptir [86].

Özellik seçimi ve boyut azaltımı için literatürde çok fazla yöntem bulunmaktadır. Bunlardan temel bileşenler analizi (TBA) ve doğrusal ayırıcı analizi (DAA) algoritmaları yüksek performanslarından ötürü oldukça yaygın bir şekilde kullanılmaktadır [87]. Bu çalışmada da; özellik seçimi için, TBA ve DAA algoritmaları tercih edilmiştir.

2.3.1. Doğrusal Ayırıcı Analizi

Doğrusal ayırıcı analizi (DAA) algoritması, nesnelerin iki veya daha fazla sınıfını ayıran ya da karakterize eden özelliklerin, lineer bir kombinasyonunu bulmak için istatistikte, örüntü tanımada ve makine öğrenmesinde kullanılan bir yöntemdir. Ortaya çıkan kombinasyon doğrusal sınıflandırma ya da daha yaygın olarak sınıflandırma öncesi boyut indirgeme için kullanılabilir. DAA algoritması, özelliklerin lineer bir kombinasyonu olarak bir bağımlı değişkeni ifade etmeye çalışan, regresyon analizi ve ANOVA (varyans analizi) ile yakından ilişkilidir [88,89].

DAA sınıflar arasında maksimum ayırımı sağlamak için farklı sınıfların özelliklerini hesaplamak üzere optimum yüzey bulmak için yaygınca kullanılan bir tekniktir. Gruplar arası saçılımın toplamının, gruplar içi saçılımın toplamına oranını maksimum yaparak, özellikleri ayıracak, doğrusal bileşeni bulmayı hedeflemektedir. Başlangıçta Fisher'ın ayırma analizi olarak bilinen DAA tekniği boyut azaltımı için yaygınca kullanılmakta ve maksimum varyans ile oluşturulan öz vektörler [90] üzerine veriyi hesaplayan Temel Bileşen Analizinin (TBA) aksine DAA dönüşümü, izdüşümlerin veri kümeleri arasındaki ayrıla bilirliği maksimum edecek yönleri bulmak için girişimde bulunur. DAA algoritması, çözüm oluşturulurken öz değer ayrıştırması kullanıldığında TBA'ya benzerdir. Fakat kullanılan kovaryans matrislerinin formasyonları ve çatıları farklıdır [91]. DAA dönüşümünün bir uygulaması iki sınıf için aşağıdaki gibidir.

$$y = w^T x \quad (17)$$

Burada x veriyi, w yönü ifade etmektedir. y verisi maksimum ayırmalı veri x 'in yeni bir setini sağlayan w yönü üzerine tasarlanır. Düzlem w , Fisher'in ayırım oranı (FAO) [92] olarak bilinen maksimum bir amaç fonksiyonu olarak x 'in bir izdüşümü bulunarak elde edilir.

$$FAO = \frac{(\mu_1 - \mu_2)^2}{(\sigma_1^2 - \sigma_2^2)} \quad (18)$$

Burada her bir sınıf için μ_1, μ_2 x 'nin ortalama değerleri olarak ve σ_1^2, σ_2^2 x 'nin varyansları olarak temsil edilir. FAO eşitliği, ortalamadaki farklılık maksimum ve varyans minimum [90] olduğunda maksimum olacaktır.

$$(\mu_1 - \mu_2)^2 = E[w^T(\mu_1 - \mu_2)(\mu_1 - \mu_2)^T w] \propto w^T S_B w \quad (19)$$

Burada \propto ölçülülüğü ifade eder ve S_B sınıflar arası kovaryans matristir. Eşitlik 18'in paydası benzer bir gösterimle aşağıdaki gibi yazılabilir.

$$\sigma_1^2 = E[(x - \mu_j)^2] = E[w^T(x - \mu_j)(x - \mu_j)^T w] = w^T \Sigma_j w \quad (20)$$

Σ_j , J sınıfının her biri için kovaryans matrisini belirtir ve Σ_j 'nin toplamı aşağıdaki ifade ile orantılıdır.

$$\sum_{j=1}^J \Sigma_j \propto w^T S_w w \quad (21)$$

Burada S_w sınıflar içinde kovaryans matristir. Son olarak, uygun yönde amaç fonksiyonu maksimum yapmak için aşağıdaki gibi olur.

$$J(w) = \frac{|w^T S_B w|}{|w^T S_w w|} \quad (22)$$

Çok sınıflı durumlar için, eşitlik (17) aynı formatta uygulama ile $J - 1$ yönüne kadar, w matrisi ile temsil edilen veriyi maksimum olarak ayırmak için bulunur. J muhtemel sınıfların birine ait her bir vektörün oluşturduğu N vektör ile x verisinin verilen bir seti ile, sınıf içi S_w ve sınıf arası S_B kovaryans matrisleri hesaplanabilir. Sınıf arası, x den gelen global verinin kovaryans ortalamasına karşılık gelirken, sınıf içi matris her bireysel sınıfın kovaryansını temsil eder. İlk ihtiyaç duyulan veri her bir Σ_j sınıfı için kovaryans matrisidir.

$$\Sigma_j = \frac{1}{N_j} \sum_{i=1}^{N_j} (x_i - \mu_j)(x_i - \mu_j)^T \quad (23)$$

Burada N_j her bir sınıfa ait örneklerin sayısını ifade eder ve $\sum_{j=1}^J N_j = N$ dir. İlgili sınıf için ortalama μ_j aşağıdaki gibi hesaplanır.

$$\mu_j = \frac{1}{N_j} \sum_{i=1}^{N_j} x_i \quad (24)$$

S_w ve S_B aşağıdaki şekilde ifade edilir.

$$S_w = \frac{1}{N} \sum_{j=1}^J N_j \Sigma_j \quad (25)$$

$$S_B = \frac{1}{N} \sum_{i=1}^J N_j (\mu_i - \mu_0)(\mu_i - \mu_0)^T \quad (26)$$

μ_j her sınıf vektörünün ortalaması, μ_0 verinin genel ortalamasıdır. Son durumda Fisher'in ayırma oranı aşağıdaki gibi olmaktadır.

$$J(w) = \frac{|w^T S_B w|}{|w^T S_w w|} \quad (27)$$

Fisher [92], S_w 'nin tekil olmama şartıyla, $S_w^{-1} S_B$ 'nin öz ayrışımının $J - 1$ baskın öz vektörlerden oluşan w matrisini temsil eden sütun vektörlerini açığa vuran kapalı biçim çözüm uygulamalarını gösterir. Öz vektörler sayısı sınırlıdır, çünkü sadece $J - 1$ sıfırdan farklı öz değerleri vardır. Bu boyutun küçültülmesine olanak verir, ancak başka bir bakış açısıyla, optimum sayıda saklanabilir özellikler, mevcut toplam sınıfların sayısı ile sınırlıdır [90].

2.3.2. Temel Bileşenler Analizi

Temel bileşenler analizi (TBA) algoritması, 18. yüzyılın başında Pearson tarafından tanıtılmıştır. Daha sonra, Hotelling tarafından 1933 yılında daha da geliştirilmiştir. Temel bileşenler analizi; verideki örüntülerin belirlenmesinin ve benzerlikleri ve farklılıkları vurgulamak gibi bir şekilde, verinin ifade edilmesinin bir yoludur. Büyük boyutlu veride, örüntüyü bulmanın zorluğu ve grafiksel temsilinin zorluğu göz önünde bulundurulursa, TBA veri analizi için güçlü bir araçtır. Verideki örüntüleri bulmanın dışında TBA'nın diğer avantajları, veri sıkıştırma ve boyut sayısını azaltmadır [93, 94].

Karhunen-Loeve dönüşümü veya Hotelling dönüşümü olarak da bilinen TBA, örüntü tanımada boyut azaltımı için kullanılmaktadır. Yöntem, ilişkili değişkenleri, temel bileşenler olarak adlandırılan ilişkili olmayan değişkenlere dönüştürmektedir. Yüksek boyutlu bir veri kümesini doğrusal olarak ayrıştırarak, bu kümeyi aynı boyut (özellik) sayısında ancak farklı koordinat sistemine sahip bir uzayda tanımlamayı amaçlamaktadır. Bir başka deyişle, çok fazla sayıda ilişkili değişkenleri içeren veri kümesinin boyutunu, bilgi kaybı olmaksızın azaltmaktadır. Bu işlem, temel bileşenler olarak adlandırılan yeni değişkenler kümesine dönüştürülerek gerçekleştirilmektedir. TBA ile giriş vektörünün özelliklerinin sayısı (boyutu), yüksek varyanslı değerler korunarak düşük varyanslı değerler atılarak azaltılmaktadır [93,94]. Temel bileşen uzayı tamamen bağımsızdır ve ilişkisizdir.

$$y = w^T x \quad (28)$$

Burada x veriyi, w dönüşüm matrisini ifade etmektedir. TBA uygulanırken aşağıdaki adımlar gerçekleştirilmektedir [95].

- Veriden özellik matrisi elde edilir. Matrisin her bir satırı bir özellik vektörü tanımlamaktadır.
- Özellik matrisine ait kovaryans matrisi (Σ_X) hesaplanır. Bu matris özellikler arasındaki lineer bağımsızlık hakkında bilgi verir.
- $\det(\lambda_i \mathbf{I} - \Sigma_X) = 0$, karakteristik denklemi çözülerek öz değerler elde edilir.
- Her bir öz değer için öz vektörler elde edilerek dönüşüm matrisi elde edilir.

2.4. Sınıflandırma


Genel olarak sınıflandırma, benzer özellik taşıyan objelerin başka farklı özellikte olanlardan ayırt edilmesi şeklinde tanımlanabilir ve otomatik hedef belirleme, yapay zekâ, tıbbi tanı, istatistik gibi çeşitli alanlarda kullanılır. Bu çalışmada sınıflandırma işlemi ise görüntüden elde edilen özellik verisinin bir karar mekanizması yardımıyla hangi sınıfa ait olduğunun belirlenmesidir. Burada sınıftan kasıt mamografi görüntülerinin normal-anormal olarak veya iyi huylu-kötü huylu olarak kategorize edilmesidir.

Bu çalışmada mamogram görüntülerini sınıflandırmak için k-en yakın komşuluk (k-EK), destek vektör makineleri (DVM) ve en küçük kareli destek vektör makineleri (EK-DVM) sınıflandırıcıları kullanılmıştır. DVM algoritması, literatürde yaygınca kullanılan güçlü bir sınıflandırıcıdır. Mesafe ölçümüne göre sınıflandırma yapan k-EK ve DVM'nin yenilenmiş hali olan EK-DVM algoritmaları karşılaştırma amacıyla kullanılmıştır.

2.4.1. Destek Vektör Makineleri

DVM algoritması, örüntü tanıma, karar verme ve sınıflandırma için güçlü bir makine öğrenme aracı olarak ortaya çıkmaktadır. Veri setlerinden değerli bilgileri çıkarmak için ve büyük veriler için hızlı sınıflandırma algoritmaları oluşturmak için kullanılabilir. DVM algoritmaları yüksek boyutlu özellik uzayı içine giriş uzayını çekirdek hüneri kullanılarak haritalar. Yüksek boyutlu özellik uzayı ayırma alt düzlemine sahiptir ve ayırma alt düzlemi en yakın örüntülerin mesafesi maksimize edilerek hesaplanır. DVM hatayı en aza indirmeyi amaçlayan eğitim hatasından ziyade yapısal risk minimizasyonuna dayalı bir makine öğrenme tekniğidir. Çünkü, yapısal risk genelleme hatası üzerinde daha üst bir sınır ifade eder [96]. DVM algoritmaları birçok alanda gerçek problemlere uygulanmaktadır: örüntü tanıma, regresyon, multimedya, biyoenformatik, gibi [97].

DVM yapısal risk minimizasyonu prensibine göre Vapnik tarafından geliştirilmiştir. Temel düşünce, eğitim verisinin verilen sonlu bir miktarı ile bir öğrenme görevidir. En iyi genelleme performansına, söz konusu eğitim seti ve makine kapasitesi (hatasız herhangi bir eğitim setini öğrenmede makinenin kabiliyetidir) üzerinden elde edilen doğruluk arasında yakalanırsa ulaşılabacaktır [98]. DVM yöntemi bunu marjini maksimum yapan optimal ayırım hiper düzlemi ile gerçekleştirir. Burada marjin, ayırma hiper düzleminde en yakın veri noktasına en kısa mesafe anlamına gelir, Şekil 13.



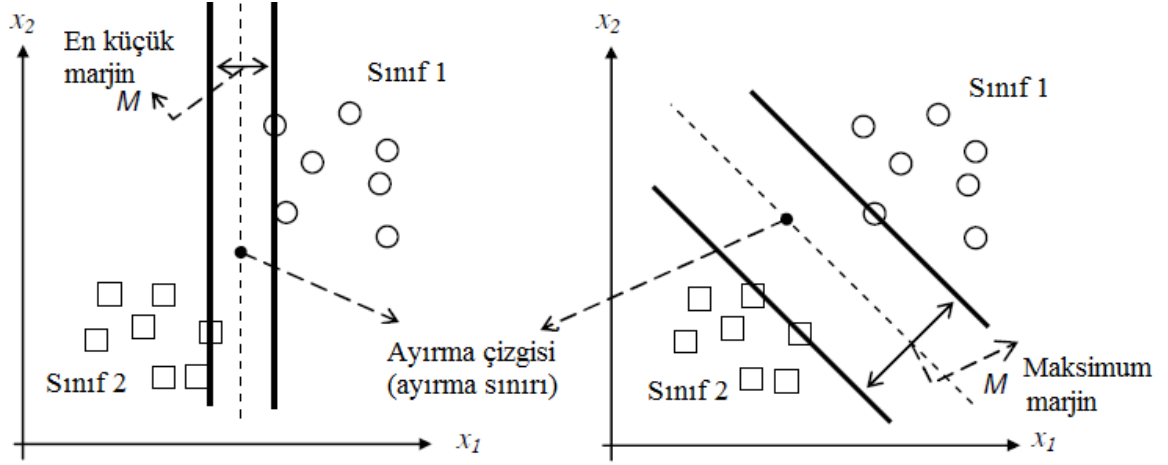
Şekil 13. Ayrılabilir durumlar için doğrusal ayıran hiper düzlem

2.4.1.1. Linear Destek Vektör Makineleri: Ayrılabilir Durum

Doğrusal şekilde ayrılabilen bir veri seti $S = \{(x_i, y_i) | i = 1, \dots, m\}$ için ikil sınıflandırma problemi göz önüne alınacak olursa; ayırma hiper düzlemi aşağıdaki gibi ifade edilebilir.

$$f(x) = w^T x + b = \sum_{i=1}^m w_i x_i + b \quad (29)$$

Burada w ağırlık vektörü ve skaler b sapmayı ifade eder ve bu değerler ayırma hiper düzleminin pozisyonunu belirler. Doğrusal olarak ayrılabilen veri setinin sınıflandırılmasında; sınıflandırmayı gerçekleştirecek birçok hiper düzlem vardır. Sezgisel olarak, eğitim örneklerine çok yakın geçen bir hiper düzlemin gürültüye duyarlı olması beklenir ve bu nedenle eğitim kümesi dışındaki veri için genelleme olasılığı daha azdır. Bunun yerine, tüm eğitim örneklerinden en uzaktaki bir hiper düzlemin daha iyi genelleme yeteneğine sahip olması umulur. Şekil 14'de gösterildiği gibi geniş marjin ile karar sınırı, daha küçük bir marjine sahip olandan daha iyi bir genelleme performansı vereceği görülür. Bu nedenle, DVM sınıflandırıcı deneysel riski minimize eden bütün hiper düzlemler arasında en geniş marjin ile hiper düzlemi bulmayı amaçlar.



Şekil 14. Maksimum ve minimum marjin gösterimi [99]

Bu durum, eğitim verisinin hepsi aşağıdaki sınırlamaları sağladığı varsayılarak formüle edilebilir.

$$w^T \cdot x_i + b \geq +1, \quad y = +1 \quad (30)$$

$$w^T \cdot x_i + b \leq -1, \quad y = -1 \quad (31)$$

veya bu sınırlamalar aşağıdaki gibi birleştirilebilir.

$$y_i(w^T \cdot x_i + b) - 1 \geq 0, \quad i = 1 \dots m \quad (32)$$

(w, b) çifti genelleştirme kaybı olmadan aşağıdaki gibi yeniden düzenlenebilir.

$$\min_{x \in X} |w^T \cdot x_i + b| = 1 \quad (33)$$

Bu sınırlama kanonik hiper düzlemlerin bir setini tanımlar. Hipotez uzayının anlamlılığını kısıtlamak amacıyla DVM marjini maksimum yaparak veriyi doğru bir şekilde sınıflandıran en basit çözümü araştırır. Hiper düzlemler arasındaki marjin türetimi [98]'de ve diğer kaynaklarda bulunabilir. İki hiper düzlem arasındaki marjin geometrik ve cebirsel yöntemlerin her ikisiyle elde edilebilir ve aşağıdaki gibi formüle edilir.

$$M = \frac{2}{\|w\|} \quad (34)$$

Maksimum marjın, ağırlık vektörü w 'nin Euclidean normunu minimize ederek bulunur. Bu nedenle marjini maksimum yapma problemi, $\|w\|$ 'yi veya $(\frac{1}{2}w^T w)$ 'yi minimize etmeye dönüştürülmüştür. Bu durum konveks karesel programlama optimizasyon problemi olarak ortaya çıkar ve bu problemin etkin bir çözümü Lagrangian optimizasyon tekniği ile gerçekleştirilir [100]. Bu durum için Lagrangian fonksiyonu aşağıdaki gibidir.

$$L(w, b, \alpha) = \frac{1}{2}w^T w - \sum_{i=1}^m \alpha_i [y_i(w^T x_i + b) - 1] \quad (35)$$

Burada $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_m)^T$ Lagrangian çarpanlarıdır. Lagrangian L, w ve b asıl değişkenlerini minimize etme ve optimum bir semer noktası bulmak için α_i ikil değişkenlerini maksimum yapmak durumundadır. Bu durum ya asıl uzayda (w ve b parametre uzayı) ya da ikil uzayda (Lagrangian çarpanları) çözülebilir [99]. Eşitsizlik sınırlamalarını ele almak zor olacağından ikili uzayda bir çözüm düşünülür. İkili yöntemin temel nedeni problemin temel bilinmeyenlerinin ikil değişkenler olmasıdır [101]. Asıl uzay, Karush-Kuhn-Tucker (KKT) şartları kullanılarak ikil uzaya dönüştürülür. Konveks optimizasyon problemi için KKT şartları sağlama gereklidir ve problemin çözümü için yeterlidir.

Optimallik şartı, eğer noktasında asıl değişkenler açısından Lagrangian türevini sıfıra eşitlemekle sağlanır.

$$\frac{\partial L}{\partial w} = 0 \quad \Rightarrow \quad w = \sum_{i=1}^m \alpha_i y_i x_i, \quad (36)$$

$$\frac{\partial L}{\partial b} = 0 \quad \Rightarrow \quad \sum_{i=1}^m \alpha_i y_i = 0, \quad (37)$$

Ayrıca, ikil değişkenler ve kısıtlamalar arasındaki ürünlerin çözüm noktasında sıfıra eşit olduğunu ifade eden tamamlayıcı koşullar aşağıdaki gibi olmalıdır.

$$y_i(w^T x_i + b) - 1 \geq 0, \quad i = 1 \dots m \quad (38)$$

$$\alpha_i \geq 0, \quad \forall i \quad (39)$$

$$\alpha_i [y_i(w^T x_i + b) - 1] = 0, \quad \forall i \quad (40)$$

Lagrangian da asıl deęişkenlerin içine, eşitlik 36 ve eşitlik 37'yi kullanarak ikil formülasyonun sonucu aşağıdaki gibi elde edilir.

$$L_D(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m y_i y_j \alpha_i \alpha_j x_i^T \cdot x_j \quad (41)$$

Bu şekilde, $L_p(w, b)$ için bir eęer noktası bulma sorunu $L_D(\alpha)$ 'yı maksimum yapmaya dönüştürülür. Optimum ayırma düzlemini bulmak için, L_D ikil Lagrangian, aşağıdaki kısıtlamalara baęlı olarak α_i 'ye göre maksimum edilmelidir.

$$\alpha_i \geq 0 \quad \forall i \quad (42)$$

$$\sum_{i=1}^m \alpha_i y_j = 0 \quad \forall i \quad (43)$$

İkili Lagrangian $L_D(\alpha)$ 'da eğitim verisi nokta ürünler $x_i^T x_j$ olarak gözükür ve bu özellik daha yüksek boyutlu bir uzayda sınıflandırmada çok kullanışlı olacaktır. Ayrıca, ikil problem eğitim verisinin miktarı ile orantılıdır ve en büyük marjinli hiper düzlemi tanımlayan eğitim örneklerini belirlemekte KKT şartları yardımcı olur. Bu örnekler destek vektörler olarak bilinecektir. Destek vektörler sıfır olmayan Lagrange çarpanlarına sahip noktalardır. Doğrusal olarak ayrılabilir durumda destek vektörler en geniş marjini tanımlayan iki hiper düzlemin biri üzerinde yer alır ve destek vektörlerin sayısı toplam eğitim örneklerinin sayısından çok daha azdır. Optimum hiper düzlem (w vektörü) eğitim seti vektörlerinin lineer bir kombinasyonudur.

$$w = \sum_{i=1}^m \alpha_i y_i x_i \quad (44)$$

Sapma terimi b destek vektörler üzerine KKT tamamlayıcı şartından bulunur.

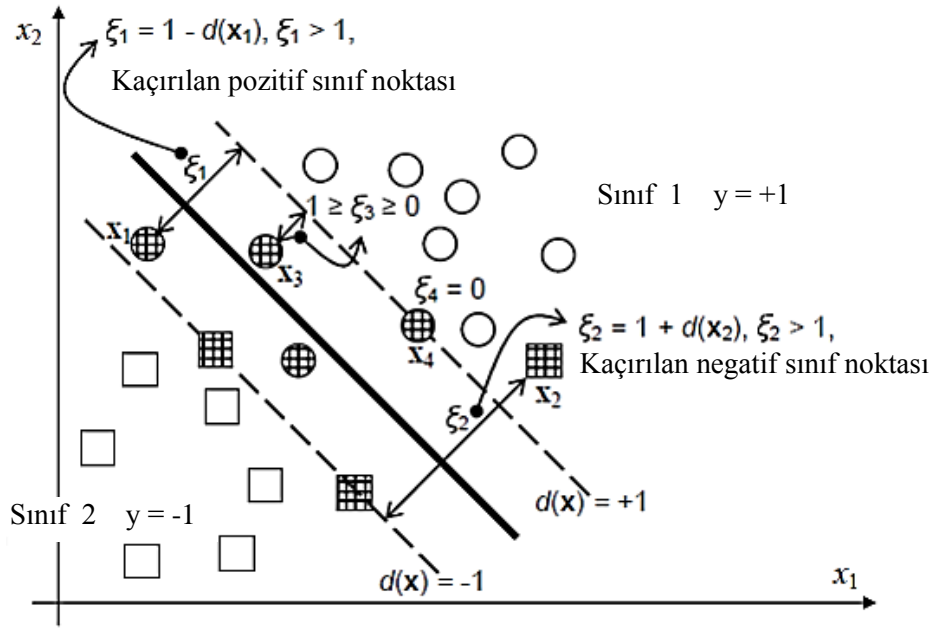
$$b = y_i - w^T x_i \quad (45)$$

Sınıflandırıcıya ait karar fonksiyonu aşağıdaki gibi elde edilir:

$$f(x) = \sum_{i=1}^m y_i \alpha_i x_i^T \cdot x + b \quad (46)$$

2.4.1.1.1. Ayrılması Zor Olan Durumlar

Yukarıda açıklanan durumlar üst üste binme olmadan iyi bir $x \rightarrow f(x, \alpha)$ haritalamasına sahip doğrusal ayrılabilir veriler için geçerlidir. Üst üste binme durumunda, doğrusal çözüm, denklem 32'deki kısıtlama sağlanmayacağı için kullanılamaz. Algoritma ayrılmayan durumlar için genişletilmelidir.



Şekil 15. Üst üste gelen veriyi birbirinden ayırma durumu için karar sınırları

Doğrusal olarak ayrılabilen durumda temel problem, sıfır eğitim hatası ile bir hipotez üretmesidir ve gürültülü veri durumunda, eğitim hatası olmadan bir hipotez kötü genelleme performansı sonucunu doğuracaktır. Dolayısıyla verilen formülasyon, sınıflandırılmayacak bazı verilere izin verecek şekilde değiştirilmelidir, Şekil 15'de gösterildiği gibi pratikte esnek marjine izin verilir ve bu marjin içindeki eğitim veri noktaları ihmal edilir. Böylece, optimum ayırma hiper düzlemi kalan eğitim veri noktaları için gerçekleştirilebilir. Düzenleme parametresi C , softmarjinin genişliğini kontrol etmekte kullanılır. Maksimum marjine sahip sınıflandırıcı, modelin VC boyutu (Vapnik ve Chervonenkis) ve kaçırılan durumlar arasında bir balans çarpanı ile bulunabilir [101]. Sınıflandırılmayan durum, aşağıdaki eşitsizliği gerektiren her eğitim örneği için negatif olmayan boşluk değişkenleri, $\xi \geq 0$, tanıtımıyla göz önünde bulundurulur.

$$w^T x_i + b \geq +1 - \xi_i, \quad \xi_i \geq 0, \quad y_i = +1 \quad (47)$$

$$w^T x_i + b \geq -1 + \xi_i, \quad \xi_i \geq 0, \quad y_i = -1 \quad (48)$$

Yukarıdaki iki denklem birleştirilirse:

$$y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (49)$$

ξ_i değeri karar sınırı ile eğitim örnekleri arasındaki mesafeyi verir ve ξ_i değerlerinin toplamı eğitim hatalarının sayısı üzerinde daha üst bir sınır verir. Bu durumda yeni denklem aşağıdaki gibi formüle edilebilir.

$$\min \frac{1}{2} w^T w + C \sum_{i=1}^m \xi_i \quad (50)$$

Daha önce ifade edildiği gibi C marjın ve eğitim hatası arasında düzenlemeyi yapar. Büyük bir C değeri seçilirse kaçırılan durumların az olmasına neden olur. Bu nedenle $C = \infty$ için, kaçırılan durum hatası, örtüşme durumu için imkânsız olan sıfır olacaktır. Bu nedenle, uygun bir çözüm sadece $C < \infty$ için bulunabilir. Kuadratik programlama problemine çözüm eşitlik 50 ile aşağıda ifade edildiği gibi $L_p(w, b, \xi, \alpha, \beta)$ asıl Lagrangianın eğer noktası ile verilir.

$$L_p(w, b, \xi, \alpha, \beta) = \frac{1}{2} w^T w + C \sum_{i=1}^m \xi_i - \sum_{i=1}^m \alpha_i [y_i(w^T x_i + b) - 1 + \xi_i] - \sum_{i=1}^m \beta_i \xi_i \quad (51)$$

Burada β_i, α_i Lagrange çoklayıcılarıdır. Optimum eğer noktası, w, b, ξ 'ye göre L_p 'nin minimumu ve β_i, α_i 'ye göre L_p 'nin maksimumu ile bulunabilir. Ayrılabilir örneğinde olduğu gibi bir çözüm göz önünde bulundurarak aşağıdaki kısıtlamalar sağlanmalıdır.

$$\frac{\partial L_p}{\partial w} = 0 \quad \Rightarrow \quad w = \sum_{i=1}^m \alpha_i y_i x_i \quad (52)$$

$$\frac{\partial L_p}{\partial b} = 0 \quad \Rightarrow \quad \sum_{i=1}^m \alpha_i y_i = 0 \quad (53)$$

$$\frac{\partial L_p}{\partial \xi} = 0 \quad \Rightarrow \quad \alpha_i + \beta_i = C \quad (54)$$

Kısıtlara göre son iki terim ikil Lagrangian probleminde kaybolur.

$$L_D(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{j=1}^m y_j y_j \alpha_i \alpha_j x_i^T \cdot x_j \quad (55)$$

Optimum hiper düzlem, α_i ye göre L_D ikil Lagrangianı maksimum yaparak bulunur.

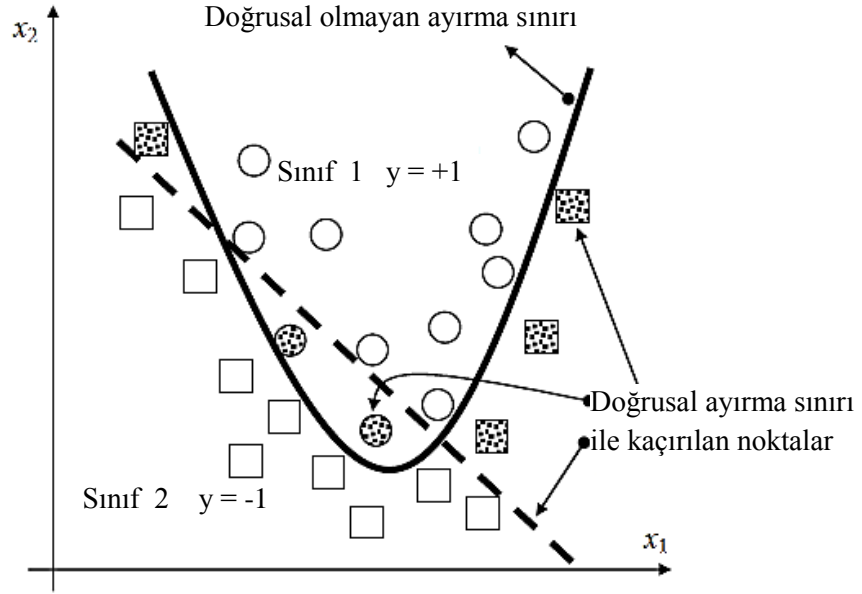
$$C \geq \alpha_i \geq 0, \quad i = 1 \dots m \quad (56)$$

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad (57)$$

Doğrusal ayrılabilir ve ayrılamaz durum çözümleri karşılaştırıldığında tek fark Lagrange çarpanları α_i 'nin modifiye sınırlarıdır. Ayrılamaz durumda C Lagrange çoklayıcının üst sınırıdır. Sonuçta, esnek marjin sınıflandırıcı için karar fonksiyonunun gösterimi doğrusal ayrılabilir durum ile aynıdır.

2.4.1.2. Doğrusal Olmayan Sınıflandırıcı


Pratikte çoğu veri üst üstedir ve sadece doğrusal olmayan karar yüzeyi ile modellenabilir (Şekil 16). Böyle durumlarda doğrusal hiper düzlemlerle modellenen yöntemler doğrusal olmayan veri işlemek için genişletilmelidir. Bu genişletme işleminde çekirdek fonksiyonları kullanılarak gerçekleştirilmektedir. Bu uygulama transfer edilen özellik uzayında veriye uygun maksimum marjinli hiper düzlem uydurmaya olanak sağlar. Veri yüksek boyutlu uzaya transfer edilmektedir.



Şekil 16. Doğrusal olmayan durum için DVM [98]

Doğrusal olmayan durumlara DVM uygulanacağı zaman temel düşünce orijinal doğrusal olmayan ayrılabilir verinin lineer şekilde ayrılabilirdiği yüksek boyutlu özellik uzayına haritalanmasıdır (Şekil 17).

$$x \in R^N \rightarrow \Phi(x) = [\phi_1(x) \phi_2(x), \dots, \phi_N(x)]^T \quad (58)$$



Şekil 17. Doğrusal olmayan giriş uzayının özellik uzayına haritalanması [102]

Optimum hiper düzlem, daha önce bahsedilen teknik kullanılarak bu özellik uzayında bulunabilir ve hiper düzlem bulunduğu orijinal giriş uzayına geri haritalanır. Özellik uzayında, ikil formda doğrusal karar fonksiyonu aşağıdaki gibi verilir.

$$f(x) = w^T \Phi(x) + b = \sum_{i=1}^m y_i \alpha_i \Phi^T(x_i) \Phi(x) + b \quad (59)$$

Daha yüksek boyutlu uzayda en uygun hiper düzlemi bulma karmaşıklığından dolayı, çekirdek fonksiyon doğrusal olmayan karar yüzeyinin oluşturulmasında kullanılır. Haritalama özellik uzayında iç çarpımı kestirmek için çekirdekler kullanılarak dolaylı yapılır. Eğitim algoritmasında çekirdek fonksiyonu kullanımında $\Phi(x)$ 'in açık hesaplamasına artık gerek yoktur. Özellik uzayında sıklık çarpım $\Phi^T(x_i)\Phi(x)$ 'nin hesaplanması yerine, çekirdek fonksiyon giriş uzayındaki verilen eğitim vektörleri için doğrudan hesaplanır.

$$K(x_i, x_j) = \Phi^T(x_i)\Phi(x) \quad (60)$$

Böylece karar fonksiyonu aşağıdaki gibi yazılabilir.

$$f(x) = \sum_{i=1}^m y_i \alpha_i K(x_i, x_j) + b \quad (61)$$

En uygun karar yüzeyi çekirdeğin uygun bir seçimi ile hesaplamada artış olmadan elde edilir.

Temel kavramlar gözden geçirilerek, özellik uzayında en uygun ayırma hiper düzlemi tasarım prosedürü, bir giriş uzayında keskin ve esnek marjinlerin tasarımı ile aynıdır. İkili Lagrangian aşağıdaki gibi verilir.

$$L_D(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m y_i y_j \alpha_i \alpha_j \Phi_i^T \cdot \Phi_j \quad (62)$$

Uygun bir çekirdek kullanarak ikili Lagrangian maksimum edilebilir.

$$L_D(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m y_i y_j \alpha_i \alpha_j K(x_i \cdot x_j) \quad (63)$$

Aşağıdaki kısıtlamalarla birlikte:

$$\alpha_i \geq 0, \quad i = 1 \dots m \quad (64)$$

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad (65)$$

Eđitim verisindeki üst üste gelme göz önünde bulundurularak, α_i için kısıtlama deđiřir. Böylece dođrusal olmayan esnek marjın sınıflandırıcı ařađıdaki kısıtlama ile denklem 63'deki durum için bir çözüml olacaktır.

$$C \geq \alpha_i \geq 0, \quad i = 1 \dots m \quad (66)$$

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad (67)$$

İkil deđiřkenlerin hesaplanmasından sonra, karar hiper düzlemi ařađıdaki gibi belirlenir.

$$f(x) = \sum_{i=1}^m y_i \alpha_i K(x, x_i) + b \quad (68)$$

2.4.2. En Küçük Kareli Destek Vektör Makineleri

DVM sınıflandırıcısının geliştirilmiş halidir. Suykens ve Vandewalle tarafından 1999 yılında sunulmuřtur [103]. DVM den ayrıldıđı kısım; eđitim için karesel programlama yerine lineer denklem seti kullanmasıdır. En Küçük Kareli Destek Vektör Makineleri (EK-DVM) için amaç fonksiyonu ařađıdaki gibi yazılabilir.

$$\min \frac{1}{2} w^T w + \frac{c}{2} \sum_{i=1}^m \xi_i^2 \quad (69)$$

Fonksiyon $y_i(w^T \phi(x_i) + b) = 1 - \xi_i$, řartına bađlıdır. α_i Lagrangian çoklayıcı vasıtasıyla ilgili amaç fonksiyonu ařađıdaki gibi yazılır.

$$L = \frac{1}{2} w^T w + \frac{c}{2} \sum_{i=1}^m \xi_i^2 - \sum_{i=1}^m \alpha_i (y_i [w^T \phi(x_i) + b] + \xi_i - 1) \quad (70)$$

formüle ait optimizasyon řartları ařađıdaki gibidir.

$$\frac{\partial L}{\partial w} = 0 \quad \rightarrow \quad w = \sum_{i=1}^m \alpha_i \phi(x_i) \quad (71)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \quad \rightarrow \quad \xi_i = \frac{\alpha_i}{c} \quad (72)$$

$$\frac{\partial L}{\partial b} = 0 \quad \rightarrow \quad \sum_{i=1}^m \alpha_i = 1 \quad (73)$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow y_i[w^T \phi(x_i) + b] + \xi_i - 1 = 0 \quad (74)$$

ξ_i, w elimine edilerek EK-DVM modeli aşağıdaki gibi elde edilir.

$$f(x) = \sum_{i=1}^m y_i \alpha_i K(x, x_i) + b \quad (75)$$

2.4.3. k En Yakın Komşuluk Sınıflandırıcı

k-en yakın komşuluk sınıflandırıcı (k-EK) en temel ifadesiyle parametrik olmayan öğrenme algoritmasıdır. Parametrik olmayan denildiğinde veri dağılımı üzerine herhangi bir varsayım yapılmadığı anlamına gelir. Bu durum pratikte oldukça kullanışlıdır, çünkü pratikte çoğu veri teorikte varsayılan tipik Gaussian karışımları ve doğrusal ayrılabilir gibi durumlara uymamaktadır. Diğer yandan k-EK algoritması herhangi bir genelleme yapmak için eğitim verisi noktalarını kullanmamaktadır. Eğitim safhası ya hiç yoktur ya da çok küçüktür. Genelleme eksikliği k-EK'nın bütün eğitim verisine test aşamasında ihtiyaç duymasındır.

k-EK mesafeyi temel alan bir sınıflandırma gerçekleştirmektedir ve k yakın komşuluğu belirlemek, test örneklerinden eğitim örneklerine olan minimum mesafesine dayanır [104]. Test örneklerinin sınıfı, en yakın komşuların çoğunluğuna göre tahmin edilir. Bütün eğitim örneklerinin test örneklerine mesafesi belirlenir ve k. minimum mesafe belirlenir.

Yakın komşu algoritması; test örneklerinin sınıfının, onun en yakın komşusunun sınıfıyla aynı olacağına karar verir. k yakın komşuluk durumunda test verisi sınıfının, k adet komşusu arasında en çok karşılaşılan sınıfla aynı olacağına karar verilir. Birbirine yakın olan gözlemlerin aynı sınıfa sahip olacağı düşüncesi uygun bir seçim olarak gözükmektedir. Eğitim verisinin geniş olması durumunda, bir tek en yakın komşuluk yerine en yakın k komşuların çoğunluk değerlerinin kullanılması daha iyi sonuç vermektedir. k sayısı, doğru kestirim elde etmek için test verisine örnekler yeterince yakın olsun diye mümkün olduğunca küçük, öte yandan yanlış sınıflandırma olasılığını en aza indirmek için yeterince büyük olmalıdır.

Yaygın olarak, k-EK algoritmasının mesafe metriği Euclidean mesafesidir. $p_1(x_1, y_1)$ ve $p_2(x_2, y_2)$ nin iki boyutlu uzayda iki nokta olduğunu farz edelim. İki nokta arasındaki Euclidean mesafesi $d(p_1, p_2)$ aşağıdaki gibidir.

$$d(p_1, p_2) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (76)$$


Şayet eşitlik N boyutlu uzaya genişletilirse.

$$d(p, q) = \sqrt{\sum_{i=1}^N (p_i - q_i)^2} \quad (77)$$

Burada p_i, q_i, i boyutundaki koordinatlardır. k-EK sınıflandırma aşamaları aşağıdaki gibi özetlenebilir:

- k parametresi belirlenir (komşuların sayısı)
- Test örneği ile bütün eğitim verisi arasındaki mesafe hesaplanır.
- k adet, en az mesafeye dayalı en yakın komşuları belirlenir ve mesafeleri sınıflandırılır.
- Test örneğinin kestirilen değeri olarak, en yakın komşuların sınıf çoğunluğu kullanılır.

k-EK uygulaması basit olan bir algoritma olmasına rağmen, k parametresinin çok iyi seçilmesi gerekir. Öğrenmeye dayalı mesafede hangi mesafenin kullanılacağı ve en iyi sonucu sağlayacak nitelikler açık değildir. İşlem yükü oldukça fazladır, çünkü bütün eğitim örneklerine her bir test örneğinin mesafesini hesaplamayı gerektirir.



Şekil 18. k parametresinin seçimi ve sınıflandırma

Örneğin Şekil 18’de kare ve yıldızlar iki farklı sınıfı temsil eden verilerdir. Eğer $k=3$ seçilirse iç çember içindeki örnekler test örneğinin komşuları olarak göz önünde bulundurulur. Bu örneklerden ikisi yıldız diğeri kare sınıfına aittir. Dolayısıyla test örneği yıldız sınıfı olarak değerlendirilecektir. Şayet $k=11$ seçilirse bu kez dış çember göz önünde bulundurulacaktır. Test verisi etrafında en yakın 6 kare ve 5 yıldız olmak üzere toplam 11 örnek bulunmaktadır. Bu durumda test örneği kare sınıfı olarak değerlendirilecektir. k değerinin seçimi için önceden tanımlanan bir kural yoktur.

2.4.4. Sınıflandırma Performans Değerlendirmesi

Bu bölümde, önerilen BDT sistemlerinde sınıflandırma sonuçlarını değerlendirmek için kullanılan performans değerlendirme yöntemleri sunulmaktadır. Performans değerlendirmesi için dört yöntem kullanılmıştır. Bu yöntemler sınıflandırma başarı oranı, duyarlılık-özgüllük analizi, ROC eğrisi analizi ve k kat çapraz doğrulama kullanılarak farklı eğitim ve test verisi için başarının değerlendirilmesidir.

2.4.4.1. Sınıflandırma Başarı Oranı

Çalışmada kullanılan DVM, k -EK ve EK-DVM sınıflandırıcıların, test verisinin sınıflandırılması sonucu doğru olarak tespit ettikleri durumların $\left(\frac{DP+DN}{DP+DN+YP+YN}\right)$ yüzde olarak değerleridir. Burada DP, DN, YP ve YN sırasıyla, gerçek pozitifler, gerçek negatif, yanlış pozitif ve yanlış negatif ifade etmektedir.

2.4.4.2. Duyarlılık ve Özgüllük

Duyarlılık ve özgüllük analizi için, aşağıdaki ifadeleri kullanılmıştır.

$$\text{Duyarlılık} = \frac{DP}{DP + YN} (\%) \quad (78)$$


$$\text{Özgüllük} = \frac{DN}{YP + DN} (\%) \quad (79)$$

Eğer bir hastanın hasta olduğu test sonuçların da görülmüşse gerçek pozitif (DP) denir. Aynı şekilde, hasta olmayan bir bireyin hasta olmadığı test sonucunda bulunmuşsa gerçek negatiflik (DN) adını alır. Diğer taraftan, eğer bir hastanın hasta olmadığı sonucuna varılmışsa bu karara yanlış negatif (YN); eğer hasta olmayan bir bireyin hasta olduğu test sonuçlarıyla belirlenmişse bu karara da yanlış pozitiflik (YP) adı verilir.

2.4.4.3. ROC Eğrileri

Alıcı işletim karakteristiği (orijinal adıyla; Receiver Operating Characteric - ROC) analizi istatistiksel karar teorisine dayanmaktadır [105]. ROC uzayında gerçek pozitif oranı (TPR, duyarlılık) y eksenini, yanlış pozitif oranı (FPR, 1-özgüllük) x eksenini belirtir. (0,0) noktası ise tüm örneklerini negatif olarak işaretleyen bir sınıflandırıcıya karşılık gelir. Tüm örneklerin pozitif olarak işaretlendiğini belirten nokta (1,1) noktasıdır. Ayrıca (0,1) noktası %100 sınıflandırma doğruluğunu ve (1,0) da %0 sınıflandırma doğruluğunu belirtmektedir. ROC eğrisinin sol alt tarafında kalan bölge sınıflandırıcının pozitif sınıf etiketi atama için daha az eğilimlidir. Bu durum düşük yanlış pozitif oranı ve düşük doğru pozitif oranına karşılık gelir.

Şekil 19'da farklı değerlere ait ROC eğrileri gösterilmektedir. Şekilde A bölgesi mükemmel test sonucu için eğriyi göstermektedir. B eğrisi iyi bir geçerliliğe ve C eğrisi orta dereceye sahiptir.




Şekil 19. Farklı durumlar için ROC eğrileri

2.4.4.4. k Kat Çapraz Doğrulama

Çapraz doğrulama veriyi parçalara bölerek öğrenme algoritmalarını karşılaştırmada ve değerlendirmede kullanılan istatistiksel bir yöntemdir. Bölümleme sonucu veri parçalarından biri öğrenme veya eğitime için kullanılır ve kalan parça veya parçalar doğrulamada kullanılır. Tipik çapraz doğrulamada eğitim ve doğrulama setleri, her verinin karşı doğrulanma şansı olsun diye aşamalarında çapraz geçmesi gerekir. Çapraz doğrulamanın temel biçimi k kat çapraz doğrulamadır [106]. Özel form olarak k kat çapraz doğrulamanın tekrarlamalı uygulamaları kullanılmaktadır. Veri eşit k parçaya bölünür ve yöntem k kez tekrarlanır. Her işlemde, k adet parçadan bir tanesi test verisi olarak ayrılır kalan k-1 parça eğitim verisi olarak kullanılır. Yöntem k kez tekrarlandıktan sonra her bir aşamada elde edilen değerlerin ortalaması alınır.

Güvenilir performans tahmini ve karşılaştırma elde etmek için, tahminlerin çok sayıda olması her zaman tercih edilir. k kat çapraz doğrulamada, sadece k tahmin (sonuç) elde edilir. Tahmin sayısını artırmak için yaygınca kullanılan yöntem k kat çapraz doğrulamayı birden fazla gerçekleştirmektir. Her tekrardan önce veri yeniden farklı içerikte parçalara ayrılır (Şekil 20). Bu çalışmada, veri setinin farklı eğitim ve test kümelerine karşılık gelen sınıflandırma başarıları ve birçok durumun ortalamasına karşılık gelen sınıflandırma başarısının belirlenmesi amacıyla kullanılmıştır.



Şekil 20. 5 kat çapraz doğrulama için test (koyu renk) ve doğrulama verisi (açık renk) prosedürü

3. BULGULAR

3.1. MIAS Veri Bankası

Bu çalışmada sunulan algoritmanın test edilmesi için mini-MIAS [107] veri bankasından elde edilen mamografi görüntüleri kullanılmıştır. MIAS veri bankası, İngiliz araştırma grubunun organizasyonu olan Mamografik Görüntü Analiz Derneği tarafından oluşturulmuştur. Bu veri bankasında 161 hastadan alınan 322 sayısal mamografi bulunmaktadır. İngiltere Ulusal Meme Taraması Programı'ndan sağlanan filmler 1024x1024 piksel olarak düzenlenmiştir. Her mamografi görüntüsü deneyimli uzman radyologlar tarafından incelenmiş ve etiketlenmiştir. Veri bankasındaki her bir görüntü için, anormalliğin tipi, anormalliğin merkez koordinatları ve anormalliği içine alan çemberin yarıçapı gibi bilgiler sunulmaktadır (Tablo 1).

Tablo 1. MIAS veri bankası görüntü ayrıntı listesi, 20 görüntü için

mdb090	G	ASYM	M	510	547	49
mdb091	F	CIRC	B	680	494	20
mdb092	F	ASYM	M	423	662	43
mdb093	G	NORM				
mdb095	F	ASYM	M	466	517	29
mdb096	F	NORM				
mdb097	F	ASYM	B	612	297	34
mdb098	F	NORM				
mdb099	D	ASYM	B	714	340	23
mdb100	D	NORM				
mdb101	D	NORM				
mdb102	D	ASYM	M	415	460	38
mdb103	D	NORM				
mdb104	D	ASYM	B	357	365	50
mdb105	D	ASYM	M	516	279	98
mdb106	D	NORM				
mdb107	D	ASYM	B	600	621	111
mdb108	D	NORM				
mdb110	D	ASYM	M	190	427	51
mdb111	D	ASYM	M	505	575	107

Görüntülere ait ayrıntı listesinde:

- I. Sütun: veri bankası referans numarasını,
- II. Sütun: dokunun karakterini,
 - F: Yağlı
 - G: Yağlı-glandüler
 - D: Yoğun-glandüler
- III. Sütun: anormalliğin sınıfını,
 - CALC: Kalsifikasyon
 - CIRC : İyi tanımlanmış / sınırlı kitleler
 - SPIC : Şüpheli kitleler
 - MISC : Kötü tanımlanmış kitleler
 - ARCH: Yapısal bozulma
 - ASYM: Asimetri
 - NORM: Normal
- IV. Sütun: anormallik türünü,
 - B : İyi huylu
 - M: Kötü huylu
- V. ve VI. Sütun: anormalliğin (x, y) koordinatlarını,
- VII. Sütun: anormalliği çevreleyen çemberin yarıçapını, temsil etmektedir.

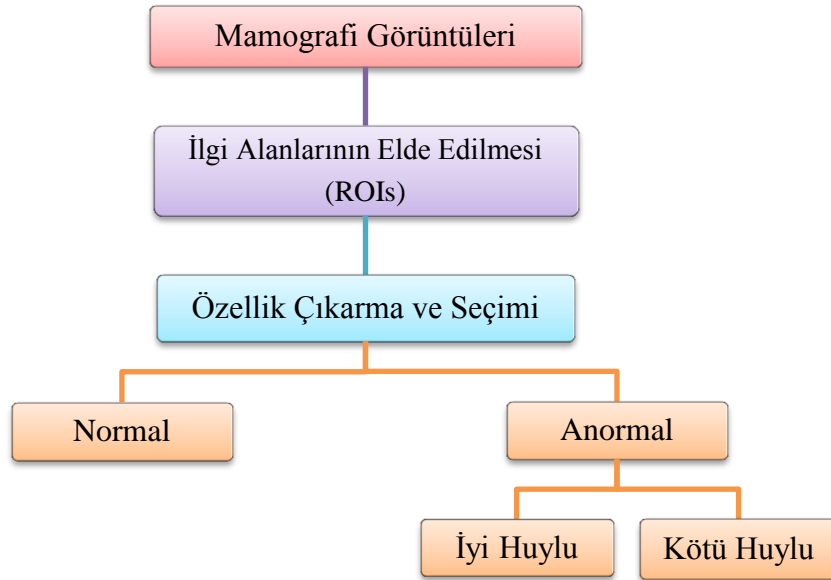
3.2. Çalışmanın Tanımı

Çalışmanın başlangıç aşamasında, MIAS veri bankasından alınan 112 anormal görüntünün, paktoral kas alanı haricinde anormal bölgeyi içine alan kırılarak çıkarılmaktadır. Kırılan görüntüler üzerinde şüpheli bölgeler (anormal alanlar ve anormal olması muhtemel ilgi alanları) ortalama filtre, top-hat ve bottom-hat dönüşümü yöntemleri kullanılarak, tespit edilip 200x200 piksel boyutunda otomatik olarak çıkarılmaktadır. Elde edilen ilgi alanı görüntülerinden, 24x24, 50x50, 128x128 ve 200x200 piksel boyutlarında farklı veri grupları oluşturulmakta daha sonra bu veri grupları ayrı ayrı özellik seçimi ve sınıflandırma işlemlerine tabi tutulmaktadır.

Oluşturulan farklı boyutlardaki veri seti görüntülerine özellik çıkarımı ve sınıflandırma işlemi uygulanarak, normal-anormal ve iyi huylu-kötü huylu ayrıştırması gerçekleştirilmektedir. Özellik seçimi için eğricik dönüşümü ve dalga atom dönüşümü

uygulanmaktadır. Dalga atom dönüşümü daha önce mamografi sınıflandırılmasında kullanılmamış bir yöntemdir. Eğricik dönüşümü için, literatürden farklı olarak, yaklaşım bandına ait katsayılar, özellikler olarak değerlendirilmiştir. Her iki algorithmadan elde edilen katsayılar üzerinden BDT sistemleri oluşturulmuştur. Eğricik dönüşümü ile yapılan sistemde yaklaşım bandı eğricik katsayılarından özellik vektörleri elde edilmekte ve DVM, k-EK ve EK-DVM sınıflandırıcılar kullanılarak mamografi görüntüleri önce normal-anormal olarak daha sonrada iyi huylu-kötü huylu olarak ayrıştırılmaktadır. Bu hibrit sistem 24x24, 50x50, 128x128 ve 200x200 piksel boyutlu veri gruplarına iki uygulama şeklinde gerçekleştirilmektedir. Sınıflandırma için k-EK algoritması kullanılan her aşamada, k değeri için 3 den 33'e kadar değerler ayrı ayrı denenerek, en iyi başarı oranını sağlayan k değeri seçilmektedir. Ayrıca çalışmada, özellik seçimi amacıyla TBA ve DAA algoritmaları kullanılarak sınıflandırma performansının artırılması hedeflenmiştir.

Dalga atom dönüşümü ile gerçekleştirilen sistemde 128x128 piksel boyutlu veri seti kullanılmaktadır. Dönüşüm katsayıları özellik vektörü olarak ele alınmakta ve DVM ile sınıflandırma gerçekleştirilmektedir. Yine sınıflandırma performansını iyileştirmek amacıyla, özellik seçimi uygulaması TBA kullanılarak gerçekleştirilmiştir. Sistemlere ait temel akış şeması Şekil 21'de gösterilmektedir.



Şekil 21. BDT sistemlerine ait temel adımlar

3.2.1. İlgili Alanlarının Elde Edilmesi

Bu bölüm meme görüntülerindeki şüpheli kısımların sınıflandırma öncesinde konumlarının otomatik belirlenmesini içermektedir. Mamografi görüntülerinin sınıflandırılmasında ilk defa gerçekleştirilen bu işlem, görüntülerin bir ön analizini gerçekleştirmekte ve görüntüde şüpheli kısımlar dışında kalan bölgelerin elenerek sadece şüpheli kısımların tek tek ele alınıp incelenmesini amaçlamaktadır. Bu şekilde meme görüntüsü üzerinde tüm alanın, anormalliğe karşı taranması sağlanmaktadır. Mamografi görüntülerinde pektoral kas alanı haricinde kalan meme alanlarına top-hat, bottom-hat ve ortalama filtre uygulanarak anormal bölgeler ve muhtemel anormal bölgeler otomatik olarak tespit edilmektedir. Şüpheli bölgelerin tespitinde, görüntülerde anormalliklerin şekilsel özellikleri ve gri seviye durumu dikkate alınarak yöntemler seçilmiştir. Mamografi görüntülerinde tüm anormallikler yüksek gri seviye değerine sahip olmakta ve görüntü dağılımında tepe kısımlarını oluşturmaktadır. Yapılan incelemelerde, kitle, asimetri ve yapısal bozukluk gibi anormalliklerin yüksek gri seviye özelliğinin yanı sıra daha büyük alana sahip olduğu görülmüştür. Yani mikrokalsifikasyonlara göre, meme yüzeyinde daha büyük alana sahiptirler. Mikrokalsifikasyonlar ise yüksek gri seviyeli ve meme yüzeyinde noktasal anormallikler olarak görülmektedir. Mikrokalsifikasyonların çok küçük boyutlu olmasından dolayı; anormallikler, mikrokalsifikasyonlar ve diğerleri şeklinde iki gruba ayrılmıştır. Şüpheli bölgelerin ön plana çıkarılmasında, iki grup için iki farklı çözüm yolu takip edilmiştir. Kitle, yapısal bozukluk, asimetri içeren mamogramlara, otomatik olarak ilgi alanı tespiti için aşağıdaki işlemler uygulanmaktadır:


- Görüntü den arka planın çıkarılması.
- Arka plan çıkarılan görüntüye top-hat ve bottom-hat dönüşümlerinin uygulanması.

$$\text{Tepe}_{\text{imge}} = (\text{asıl görüntü} + \text{tophat}(\text{asıl görüntü})) - \text{bottomhat}(\text{asıl görüntü})$$

- Elde edilen görüntülerde maksimum bölge ve maksimum tepe değerine sahip alanların, merkezlenerek görüntüden çıkarılması.


Mamogramlar üzerinde yapılan incelemeler sonucunda, anormalliklerin meme yüzeyinde tepecikler şeklinde olduğu görülmüştür. Bu tepe alanlarının ön plana çıkarılmasın da, morfolojik analiz yöntemi olan top-hat dönüşümünün yararlı olacağına,

yapılan araştırma sonucunda karar verilmiştir. Top-hat dönüşümü, görüntüde parlak bölgelerin (tepe bölgelerin) tespitinde kullanılmaktadır. Birbirine ilintili tepe halindeki anormalliklerin birbirinden ayrılması için ise bottom-hat dönüşümü kullanılmıştır. Bottom-hat dönüşümü, görüntüde karanlık bölgelerin (çukur bölgelerin) tespitinde kullanılmaktadır ve bu özelliğiyle, top-hat dönüşümüyle belirginleştirilen anormallik tepelerinin birbirinden ayrılması sağlanmaktadır. Mamografi görüntüsünün sadece şüpheli bölgelerden (tepelerden) oluşturulan yeni haline ilişkin örnek bir görüntü şekil 22’de gösterilmektedir.




Şekil 22. mdb005 görüntüsüne ait orjinal ve şüpheli bölge görünümü


Otomatik ilgi alanı belirlenmesi için yukarıda ifade edilen adımlar; veri seti mikrokalsifikasyon ve diğer anormallikler şeklinde iki gruba ayrılarak, diğer anormallikler grubuna uygulanmıştır. İşlem aşamalarına ait görüntüler; yağlı dokular için Şekil 23-24 de, yağlı-glandüler dokular için Şekil 25-26 ve yoğun-glandüler dokular için Şekil 27-28 de gösterilmektedir.




a



b




c




d


Şekil 23. MIAS veri bankası mdb134 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırpılmış görüntü.




a



b




c




d

Şekil 24. MIAS veri bankası mdb095 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.




a



b




c




d


Şekil 25. MIAS veri bankası mdb019 yağlı-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırpılmış görüntü.



a



b




c




d


Şekil 26. MIAS veri bankası mdb090 yağlı-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.




a



b




c




d

Şekil 27. MIAS veri bankası mdb198 yoğun-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.




a



b



c



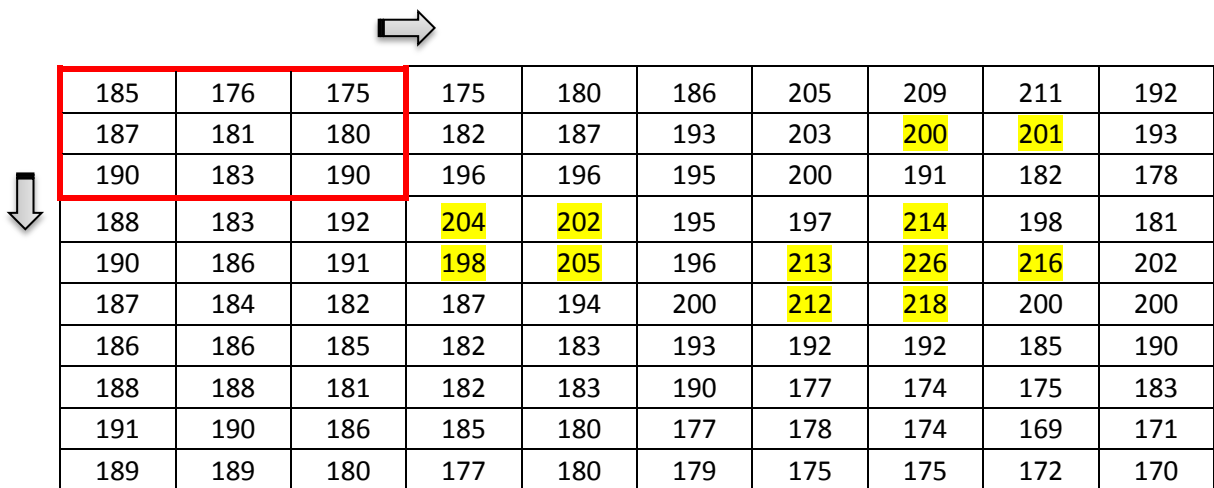
d

Şekil 28. MIAS veri bankası mdb110 yoğun-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) arka plan çıkarılmış görüntü c) tepe değerleri belirginleştirilmiş görüntü d) otomatik kırılmış görüntü.

Mikrokalsifikasyonları içeren görüntü verisi için ortalama filtre işlemi gerçekleştirilmiştir. Mikrokalsifikasyonlar görüntüde anlık pik yapan noktasal anormalliklerdir. Yani yüksek frekans özelliği gösteren anormalliklerdir. Bu alanların ön plana çıkarılması için, görüntü verisinde yüksek frekans içeriğinin korunması ve diğer kısımların atılması gerekmektedir. Alçak geçiren filtre özelliği nedeniyle ortalama filtre, bu amaç için tercih edilmiştir. Görüntünün, 3x3 lük ortalama filtreyle, görüntünün yeni hali elde edilmekte; daha sonra yeni görüntü orijinal görüntüden çıkarılarak, sadece yüksek frekanslı yapıların kalması sağlanmaktadır. Burada pencere boyutu, mamogramlar üzerinde yapılan inceleme sonucunda mikrokalsifikasyonların ortalama 9 piksel boyutunda olduğu tespit edilerek ve 3x3 olarak belirlenmiştir. 3x3'lük pencerenin görüntü üzerinde kapsadığı alan matris olarak ele alınmakta, bu matrisin ortalaması alınarak her bir pikselin değeri yeniden hesaplanmaktadır. Pencere her defasında bir piksel kaydırılarak bütün görüntü taranmaktadır. Filtreleme sonucu elde edilen yeni piksel değerlerine ait görüntü asıl görüntüden çıkarılarak mikrokalsifikasyon alanları belirlenmektedir.

Örnek bir mikrokalsifikasyon görüntü verisi Tablo 2'de gösterilmektedir. Tablodaki rakamlar görüntüye ait gri seviyeleri göstermektedir. Sarı renkle işaretlenen değerler mikrokalsifikasyon merkezini göstermektedir. Kırmızı renkli çerçeve görüntü üzerinde dolaştırılan pencereyi temsil etmektedir.

Tablo 2. Mikrokalsifikasyon içeren görüntüye ait örnek veri matrisi



185	176	175	175	180	186	205	209	211	192
187	181	180	182	187	193	203	200	201	193
190	183	190	196	196	195	200	191	182	178
188	183	192	204	202	195	197	214	198	181
190	186	191	198	205	196	213	226	216	202
187	184	182	187	194	200	212	218	200	200
186	186	185	182	183	193	192	192	185	190
188	188	181	182	183	190	177	174	175	183
191	190	186	185	180	177	178	174	169	171
189	189	180	177	180	179	175	175	172	170

Pencere görüntü verisinin tamamını tarayarak, kapsadığı alanı önce geçici bir matris haline getirilmektedir. Oluşturulan bu matris elemanları tek bir sütun haline getirilmekte ve

ortalaması alınmaktadır. Elde edilen değer, pencerenin denk geldiği merkez pikselin yeni değeri olarak atanmakta ve görüntü yeniden oluşturulmaktadır. Tablo 3, elde edilen yeni görüntü değerlerini göstermektedir. Sarı ile işaretlenen kısımlar mikrokalsifikasyon değerlerinin yeni değerlerini, kırmızı ile işaretlenen alan Tablo 3’de kırmızıyla gösterilen pencereye ait verinin oluşturduğu yeni piksel değerini göstermektedir.

Tablo 3. Filtrelenmiş görüntü verisi

81	120	119	120	123	128	133	137	134	89
122	183	182	185	188	194	198	200	195	129
124	186	188	192	194	196	199	198	193	126
124	188	191	197	199	200	203	204	199	129
124	187	190	195	198	202	208	210	206	133
124	186	187	190	193	199	205	206	203	133
124	185	184	184	188	192	194	192	191	126
125	187	185	183	184	184	183	180	179	119
126	187	184	182	181	180	178	174	174	116
84	125	123	121	120	119	118	116	115	76


Son işlem olarak, elde edilen filtre görüntü asıl görüntüden çıkarılarak anormallikler ve olası anormallikler dışında kalan kısımlar elimine edilmektedir. Aşağıdaki tabloda, asıl görüntüden filtre görüntüsünün çıkarılması sonucu elde edilen görüntü verisi gösterilmektedir.

Tablo 4. Asıl görüntüden filtre görüntüsünün çıkarılmasıyla elde edilen veri değerleri

104	56	56	55	57	58	72	72	77	103
65	0	0	0	0	0	5	0	6	64
66	0	2	4	2	0	1	0	0	52
64	0	1	7	3	0	0	10	0	52
66	0	1	3	7	0	5	16	10	69
63	0	0	0	1	1	7	12	0	67
62	1	1	0	0	1	0	0	0	64
63	1	0	0	0	6	0	0	0	64
65	3	2	3	0	0	0	0	0	55
105	64	57	56	60	60	57	59	57	94

Tablo 4’de açık turuncu bölgeler, başlangıçta kenarlara yapılan sıfır dolgusundan kaynaklanmaktadır. Pencere verisinden elde edilen değer merkez pikselin değeri olarak alınmakta, dolayısıyla kenar piksel değerleri için dolgu işlemi yapılmaktadır. Bu nedenle kenar pikselleri ilgi alanının tespitinde ihmal edilmektedir.

Mikrokalsifikasyon içeren görüntülere uygulanan filtreleme görüntüleri ve sonucunda elde edilen ilgi alanlarına ait görüntüler yağlı dokular için Şekil 29-30’da, yağlı-glandüler dokular için Şekil 31’de ve yoğun-glandüler dokular için Şekil 32’de gösterilmektedir.




a



b




c




d

Şekil 29. MIAS veri bankası mdb231 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü.




a



b




c




d


Şekil 30. MIAS veri bankası mdb248 yağlı doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü.




a



b



c




d


Şekil 31. MIAS veri bankası mdb219 yağlı-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü.



a



b



c



d

Şekil 32. MIAS veri bankası mdb239 yoğun-glandüler doku görüntüsüne ait otomatik anormal bölge tespiti a) asıl görüntü b) filtre sonucu c) eşikleme sonucu d) otomatik kırılmış görüntü.

İlgi alanlarının yani anormalliklerin veya olası anormal bölgelerin yerinin belirlenmesinde yukarıda açıklanan işlemlerle öne çıkarılan alanların koordinatları tespit edilmektedir. İlgi bölgesinin merkezi, merkez olacak şekilde bölge 200x200 piksel boyutunda asıl görüntüden çıkarılmaktadır. İlgi alanları çıkarılırken, en büyük alana sahip olandan başlayarak küçük alanlara doğru azalan sıra takip edilmektedir. MIAS veri bankasına ait anormal görüntülerle yapılan uygulama sonuçları aşağıdaki tabloda gösterilmektedir.

Tablo 5. Elde edilen ilgi alanlarının istatistiksel değerleri

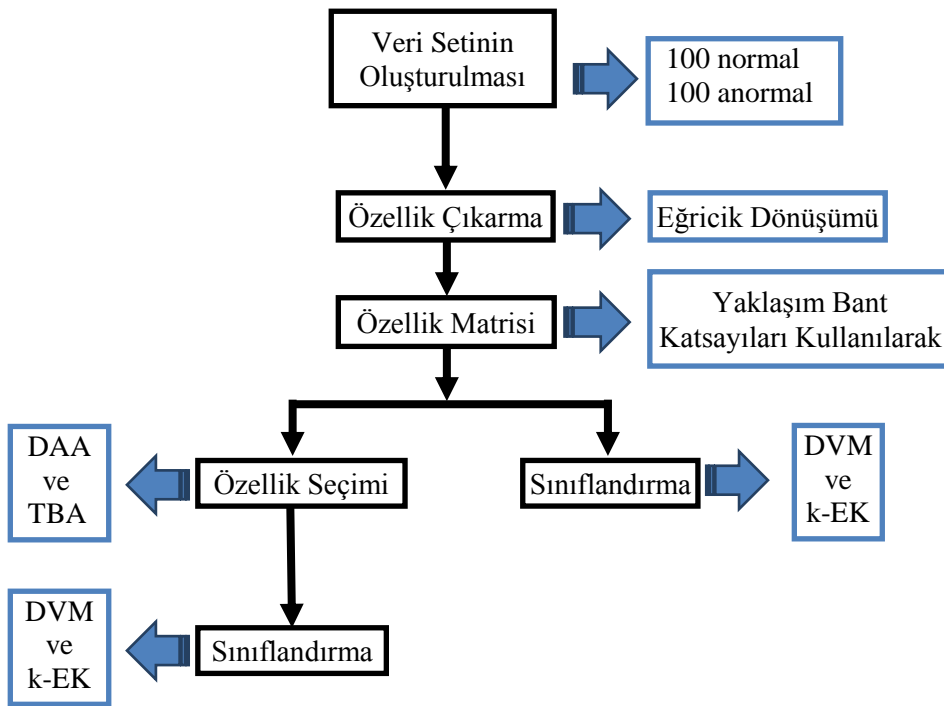
Bölge sıra numarası	1.	2.	3.	4.	5.	6.	12.
Gerçek anormal sayısı	78	11	13	2	4	3	1
% oranları	69.65	9.83	11.61	1.79	3.58	2.68	0.89
Toplam tespit (%)	100						

Uygulama sonucunda, 112 anormal görüntüden anormalliğin olduğu bölge yukarıda açıklanan yöntemler aracılığıyla 200x200 piksel boyutunda çıkarılmıştır. Anormalliklerin 78 tanesi ilk çıkarılan bölgede yer almaktadır. İlk üç bölge çıkarımında anormalliklerin %91'i alt görüntü olarak elde edilmiştir. Çıkarılan bölge sayısı 12'yle sınırlandırılmıştır. Bölge sayısı daha da artırılabilir fakat bu işlem yükünü artırmaktadır. Öte yandan, bölge sayısının artırılması daha küçük alanlı yapıların şüpheli olarak çıkarılması anlamına gelmektedir. Yapılan incelemelerde mamografi üzerinde anormallikler, mikro kalsifikasyonlar hariç, en küçük 17 piksel yarıçaplı bir çemberle çevrelendiği görülmektedir. Bundan daha küçük bölgeler memeye ait damar gibi normal yapılara karşılık gelmektedir. Bundan dolayı bölge sayısı bu çalışmada 12 olarak alınmıştır.

3.2.2. Sınıflandırma I: Eğricik Dönüşümü


Bu bölümde, eğricik dönüşümü ile özellik seçimi gerçekleştirilerek sınıflandırma yapılmaktadır. Çalışmanın ilk bölümünde otomatik olarak elde edilen alt görüntülerden, 24x24, 50x50 ve 200x200 piksel boyutlu üç farklı veri seti oluşturulmaktadır. Alt görüntü boyutunun sınıflandırma üzerindeki etkisi ve yaklaşım bant eğricik katsayılarının sınıflandırma başarısı, TBA, DAA, DVM ve k-EK algoritmalarından oluşan melez bir

sınıflandırma sistemi ile araştırılmaktadır. Sisteme ait akış şeması Şekil 33'de gösterilmektedir. Bu sistem eğricik dönüşümü kullanılarak, elde edilen veri seti görüntülerinin çok çözünürlüklü temsiline dayanmaktadır. Oluşturulan veri setine eğricik dönüşümü (ölçek 3 ve açı 8) uygulanarak her bir görüntü eğricik alt bantlarına ayrıştırılmaktadır. Eltoukhy ve ark. [75] yaptıkları çalışmada, en yüksek sınıflandırma başarısına 3'üncü ölçek eğricik katsayılarıyla ulaşmışlardır. Ölçek seçimimizde bu çalışma etkili olmuştur ancak çalışmamızda Eltoukhy ve ark.'rından farklı olarak eğricik dönüşümünün tüm bantları değil sadece yaklaşım bandı kullanılmıştır.



Şekil 33. Mamografi görüntülerinin sınıflandırması için kullanılan akış şeması

Görüntü eğricik dönüşümü ile ayrıştırıldığında 25 bileşen elde edilmektedir. Bu bileşenlerden biri yaklaşım bandı ve diğerleri detay bantlardır. MIAS veri bankasından alınan mdb028 referans numaralı görüntüye ait eğricik dönüşümü ayrıştırması Şekil 34'de, ilk sekiz detay bant için gösterilmektedir.



Şekil 34. İlk görüntü orijinal kırılmış görüntüyü, ikinci görüntü yaklaşık alt bant ve diğerleri detay alt bant katsayılarından elde edilen görüntüyü temsil etmektedir

Her bir görüntüden elde edilen yaklaşım bant katsayıları, özellik vektörlerinin ve sonrasında özellik matrisinin oluşturulmasında kullanılmaktadır. Oluşturulan özellik matrisi kullanılarak veri sınıflandırılmakta, daha sonra TBA ve DAA kullanılarak özellik seçimi gerçekleştirilip, tekrar sınıflandırılmaktadır.

Sınıflandırma işlemi iki kısımdan oluşmaktadır. İlk kısım her bir veri setinin (24x24, 50x50 ve 200x200 piksel) normal ve anormal olarak sınıflandırılmasını içermektedir. Bu doğrultuda 200 görüntüden oluşan veri seti, üç piksel boyutu içinde 100 eğitim ve 100 test verisi olarak ikiye ayrılmıştır. Eğitim verisi, 50 normal ve 50 anormal görüntüden, test verisi de yine 50 normal ve 50 anormal görüntüden oluşturulmuştur (Tablo 6).

Tablo 6. Veri seti görüntü dağılımı

		24x24	50x50	200x200
Eğitim	Normal	50	50	50
	Anormal	50	50	50
Test	Normal	50	50	50
	Anormal	50	50	50

Mamografi görüntülerinin sınıflandırılması; eğricik dönüşümü sonucu özellik matrisinin doğrudan sınıflandırıcı girişi olarak kullanılması ve özellik seçimi işleminden sonra sınıflandırıcı girişi olarak kullanılması şeklinde gerçekleştirilmektedir. Görüntüler ilk olarak eğricik katsayıları üzerinden normal ve anormal olarak sınıflandırmaya tabi

tutulmaktadır. Tablo 7, elde edilen sınıflandırma başarısını, her bir sınıflandırıcı için karşılaştırmalı olarak göstermektedir.

Tablo 7. Eğricik dönüşümü, k-EK ve DVM algoritmaları yoluyla mamografi görüntülerinin normal-anormal sınıflandırmasına ait başarı oranları

Piksel	ED		k değerleri
	Başarı oranı (%)	Sınıflandırıcı	
200×200	87	DVM	3
	81	k-EK	
50×50	85	DVM	3
	80	k-EK	
24×24	82	DVM	7
	77	k-EK	

İkinci olarak, eğricik katsayılarına özellik seçimi işlemi, sırasıyla DAA ve TBA algoritmaları ile uygulanarak sınıflandırma yeniden gerçekleştirilmiştir. Tablo 8, DAA ile gerçekleştirilen özellik seçimi sonucu elde edilen sınıflandırma başarı oranlarını, her bir sınıflandırıcı için göstermektedir.

Tablo 8. Eğricik dönüşümü, DAA, k-EK ve DVM algoritmaları yoluyla mamografi görüntülerinin normal-anormal sınıflandırmasına ait başarı oranları

Piksel	ED+DAA		k değerleri
	Başarı oranı (%)	Sınıflandırıcı	
200×200	100	DVM	3
	100	k-EK	
50×50	100	DVM	3
	100	k-EK	
24×24	93	DVM	17
	97	k-EK	

TBA algoritması uygulanarak gerçekleştirilen özellik seçimi sonucu elde edilen sınıflandırma başarı oranları ise, her bir sınıflandırıcı için Tablo 9’da göstermektedir.

Tablo 9. Eğricik dönüşümü, TBA, k-EK ve DVM algoritmaları yoluyla mamografi görüntülerinin normal-anormal sınıflandırmasına ait başarı oranları

TBA Bileşenleri	Başarı oranları (%)			Sınıflandırıcı	k değerleri		
	200×200	50×50	24×24		200×200	50×50	24×24
3	90	90	83	DVM	3	3	7
	81	75	78	k-EK			
6	90	83	90	DVM	3	3	7
	79	77	78	k-EK			
9	85	88	95	DVM	3	3	7
	86	80	77	k-EK			
12	85	88	81	DVM	3	3	7
	86	80	77	k-EK			
30	88	85	70	DVM	3	3	7
	81	80	77	k-EK			
50	86	85	61	DVM	3	3	7
	83	80	77	k-EK			

Elde edilen sonuçlardan, DAA ve TBA algoritmaları sınıflandırma başarısını artırdığı gözlenmektedir. Özellikle DAA algoritması ile elde edilen büyük başarı nedeniyle, sadece eğricik dönüşümü katsayılarının ve eğricik dönüşümü ve DAA'dan elde edilen özelliklerin sınıflandırıldığı aşamaları için duyarlılık ve özgüllük analizi gerçekleştirilmiştir. Tablo 10, doğrudan eğricik katsayıları yoluyla sınıflandırma için duyarlılık ve özgüllük değerlerini göstermektedir.

Tablo 10. Doğrudan eğricik katsayıları üzerinden gerçekleştirilen normal-anormal sınıflandırmaya ait duyarlılık ve özgüllük değerleri

Piksel	ED		Sınıflandırıcı
	Duyarlılık (%)	Özgüllük (%)	
200×200	80	94	DVM
	70	92	k-EK
50×50	82	88	DVM
	78	82	k-EK
24×24	82	82	DVM
	84	70	k-EK


DAA ile özellik seçimi sonrası gerçekleştirilen sınıflandırmaya ait duyarlılık ve özgüllük değerleri Tablo 11’de gösterilmektedir.

Tablo 11. DAA ile özellik seçimi gerçekleştirerek yapılan sınıflandırılma için duyarlılık ve özgüllük değerleri


Piksel	ED+DAA		Sınıflandırıcı
	Duyarlılık (%)	Özgüllük (%)	
200×200	100	100	DVM
	100	100	k-EK
50×50	100	100	DVM
	100	100	k-EK
24×24	92	94	DVM
	94	100	k-EK

Doğrudan eğricik katsayıları üzerinden sınıflandırma işlemi için ROC eğrileri Şekil 35’de ve DAA ile özellik seçimi yoluyla sınıflandırma işlemi için ROC eğrileri Şekil 36’da, DVM ve k-EK sınıflandırıcılar için sırasıyla gösterilmektedir.

Sınıflandırmanın ikinci aşaması, mamografi görüntülerinin iyi huylu ve kötü huylu olarak sınıflandırılmasıdır. Bu aşamada, otomatik olarak tespit edilen şüpheli bölgelere ait alt görüntülerden 100 anormal görüntü test ve eğitim verisi olarak her piksel boyutu içinde iki eşit parçaya bölünmektedir. Eğitim verisi 25 iyi huylu ve 25 kötü huylu anormallik içeren mamografi görüntülerinden ve test kümesi de yine 25 iyi huylu ve 25 kötü huylu anormallik içeren mamografi görüntülerinden oluşmaktadır (Tablo 12).



Şekil 35. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için



Şekil 36. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için

Tablo 12. İyi huylu kötü huylu sınıflandırması için veri seti görüntü sayısı dağılımı

		24x24	50x50	200x200
Eğitim	İyi huylu	25	25	25
	Kötü huylu	25	25	25
Test	İyi huylu	25	25	25
	Kötü huylu	25	25	25

İşlem aşamaları normal-anormal sınıflandırmasındaki gibi gerçekleştirilmektedir. Öncelikle eğricik dönüşümü, hazırlanan veri setine uygulanarak elde edilen yaklaşım bant katsayıları ile özellik matrisi oluşturulmakta; sonra özellik matrisi doğrudan sınıflandırıcı girişi olarak kullanılarak bir sonuç elde edilmektedir. Daha sonra, özellik matrisine DAA ve TBA algoritmaları uygulanarak özellik seçimi işlemi gerçekleştirilip tekrar sınıflandırmaya tabi tutulmaktadır. Tablo 13, eğricik katsayılarının doğrudan sınıflandırıcı girişi olarak kullanılmasıyla, mamografi görüntülerinin iyi huylu-kötü huylu olarak ayrıştırılmasına ait başarı oranlarını, her bir sınıflandırıcı için ayrı ayrı göstermektedir.

Tablo 13. Eğricik dönüşümü katsayılarının doğrudan sınıflandırıcı girişi olarak kullanılması sonucu iyi huylu-kötü huylu ayrıştırma başarı oranları

Piksel	ED		k değerleri
	Başarı oranı (%)	Sınıflandırıcı	
200x200	48	DVM	3
	58	k-EK	
50x50	42	DVM	29
	54	k-EK	
24x24	48	DVM	7
	54	k-EK	

Doğrudan sınıflandırma sonrasında DAA ve TBA kullanılarak özellik seçimi gerçekleştirilmektedir. DAA kullanılarak gerçekleştirilen özellik seçimi üzerinden iyi huylu-kötü huylu sınıflandırmasına ait başarı değerleri, Tablo 14'da gösterilmektedir. Özellik seçimi için TBA algoritması kullanılarak iyi huylu-kötü huylu sınıflandırma sonuçları, Tablo 15'de farklı TBA bileşenleri için gösterilmektedir.

Tablo 14. DAA kullanılarak özellik seçimi üzerinden iyi huylu-kötü huylu ayrıştırma başarı oranları

Piksel	ED+DAA		k değerleri
	Başarı oranı (%)	Sınıflandırıcı	
200×200	98	DVM	3
	98	k-EK	
50×50	92	DVM	9
	92	k-EK	
24×24	64	DVM	7
	66	k-EK	

Tablo 15. TBA kullanılarak özellik seçimi sonucunun iyi huylu-kötü huylu sınıflandırmasına ait başarı oranları, farklı TBA bileşenler için

TBA Bileşenleri	Başarı oranları (%)			Sınıflandırıcı	k değerleri		
	200×200	50×50	24×24		200×200	50×50	24×24
3	52	48	58	DVM	13	17	3
	60	56	58	k-EK			
6	56	54	52	DVM	7	17	3
	58	54	56	k-EK			
9	58	56	70	DVM	13	17	3
	64	54	60	k-EK			
12	50	60	72	DVM	11	9	3
	58	54	60	k-EK			
30	46	52	56	DVM	25	9	3
	60	52	58	k-EK			
50	42	52	56	DVM	19	9	3
	60	52	58	k-EK			

Normal-anormal sınıflandırma aşamasında olduğu gibi; duyarlılık, özgüllük ve ROC analizi, iyi huylu ve kötü huylu ayırım aşaması için de aynı doğrultuda uygulanmaktadır. Eğricik dönüşümü katsayılarının ve eğricik dönüşümü ve DAA'dan elde edilen özelliklerin sınıflandırıldığı aşamalara ilişkin duyarlılık ve özgüllük analizi sonuçları, sırasıyla Tablo 16 ve Tablo 17'de gösterilmektedir.

Tablo 16. Doğrudan eğricik dönüşümü katsayıları kullanılarak yapılan iyi huylu-kötü huylu sınıflandırılmaya ait duyarlılık ve özgüllük değerleri

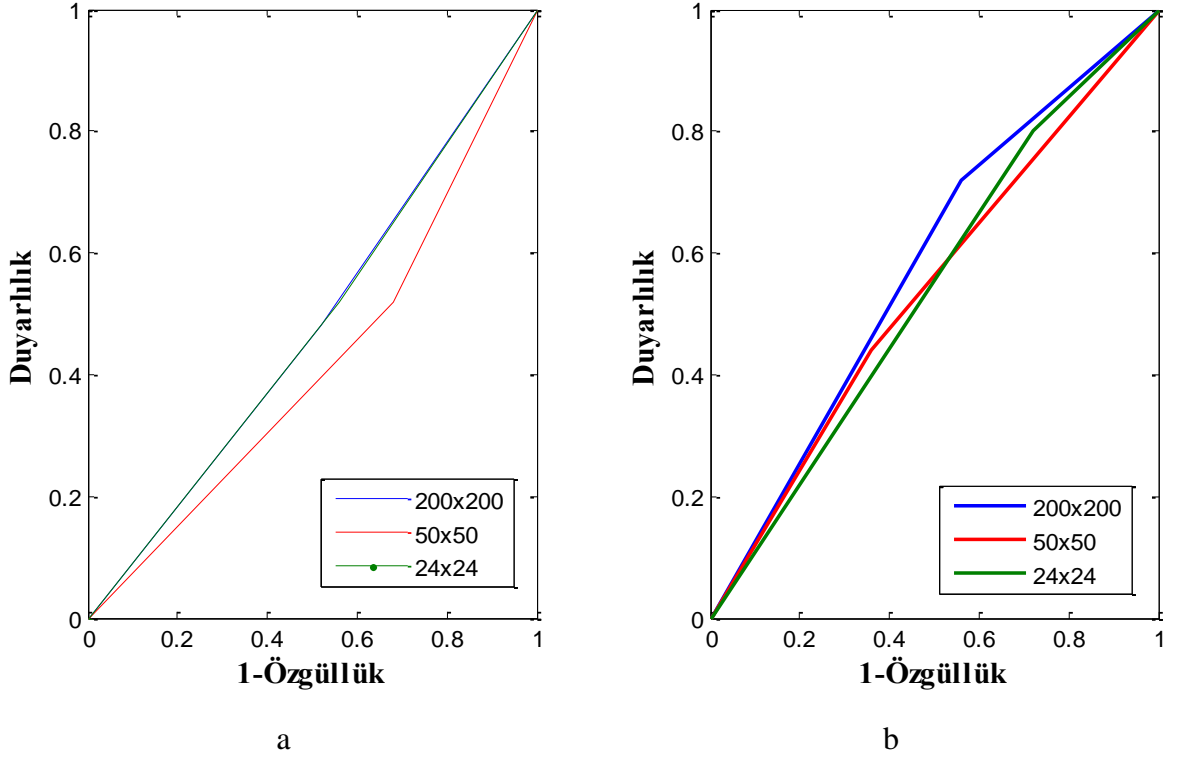
Piksel	ED		Sınıflandırıcı
	Duyarlılık (%)	Özgüllük (%)	
200×200	48	48	DVM
	72	44	k-EK
50×50	52	32	DVM
	44	64	k-EK
24×24	52	44	DVM
	80	28	k-EK

Tablo 17. Eğricik dönüşümü ardından DAA ile özellik seçimi yoluyla, iyi huylu-kötü huylu sınıflandırılmaya ait duyarlılık ve özgüllük değerleri


Piksel	ED+DAA		Sınıflandırıcı
	Duyarlılık (%)	Özgüllük (%)	
200×200	100	96	DVM
	100	96	k-EK
50×50	92	92	DVM
	96	88	k-EK
24×24	64	64	DVM
	56	76	k-EK

İyi huylu-kötü huylu sınıflandırılması için ROC eğrileri, doğrudan eğricik katsayılarının kullanılması durumu için Şekil 37’de ve DAA algoritması ile özellik seçimi gerçekleştirilmesi durumu için Şekil 38’de, DVM ve k-EK sınıflandırıcılar için sırasıyla gösterilmektedir.

Son işlem olarak, 5 kat çapraz doğrulama uygulaması, farklı eğitim ve test verisi durumları için gerçekleştirilmektedir. Bu doğrultuda veri seti 5 farklı ve eşit boyutlarda bölümlere ayrılmakta ve sınıflandırma işlemi 5 kez gerçekleştirilmektedir. Özellik seçimi işlemi olmadan gerçekleştirilen çapraz doğrulama değerleri Tablo 18’de, DAA ile gerçekleştirilen özellik seçimine göre çapraz doğrulama değerleri Tablo 19’da normal-anormal sınıflandırma için gösterilmektedir.



Şekil 37. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için



Şekil 38. ROC eğrileri: a) DVM sınıflandırıcı için b) k-EK sınıflandırıcı için

Tablo 18. Özellik seçimi yapılmadan eğricik dönüşümü ile 5 kat çapraz doğrulama başarı oranları

Piksel	Başarı oranları (%)					Ortalama (%)	Sınıflandırıcı
	ED						
	Bölüm1	Bölüm2	Bölüm3	Bölüm4	Bölüm5		
200×200	82,5	90	95	80	87,5	87	DVM
	82,5	72,5	87,5	90	85	83,5	k-EK
50×50	75	90	92,5	75	92,5	85	DVM
	72,5	80	92,5	92,5	80	83,5	k-EK
24×24	80	87,5	90	85	80	84,5	DVM
	70	85	85	90	77,5	81,5	k-EK

Tablo 19. DAA ile özellik seçimi sonucu 5 kat çapraz doğrulama başarı oranları

Piksel	Başarı oranları (%)					Ortalama (%)	Sınıflandırıcı
	ED+ DAA						
	Bölüm1	Bölüm2	Bölüm3	Bölüm4	Bölüm5		
200×200	100	100	100	100	100	100	DVM
	100	100	100	100	100	100	k-EK
50×50	100	100	100	100	100	100	DVM
	100	100	100	100	100	100	k-EK
24×24	82,5	45	87,5	97,5	52,5	73	DVM
	87,5	72,5	95	97,5	60	82,5	k-EK

5 kat çapraz doğrulama, iyi huylu-kötü huylu sınıflandırması için de gerçekleştirilmiştir. Bu doğrultuda 100 anormal görüntü 5 farklı ve eşit boyutlarda bölümlere ayrılmaktadır. Daha önce açıklanan iyi huylu-kötü huylu sınıflandırma işlemi 5 kez gerçekleştirilmektedir. Tablo 20’de özellik seçimi gerçekleştirilmeden, eğricik katsayıları üzerinden yapılan sınıflandırmaya ait değerler gösterilmektedir. DAA ile özellik seçimi gerçekleştirildikten sonra elde edilen değerler ise, Tablo 21’de gösterilmektedir.

Tablo 20. İyi huylu-kötü huylu sınıflandırmaya ait 5 kat çapraz doğrulama başarı oranları

Piksel	Başarı oranları (%)					Ortalama (%)	Sınıflandırıcı
	ED						
	Bölüm1	Bölüm2	Bölüm3	Bölüm4	Bölüm5		
200×200	30	40	40	40	25	35	DVM
	65	60	60	60	65	62	k-EK
50×50	35	45	55	35	45	43	DVM
	60	65	60	50	60	59	k-EK
24×24	45	65	60	45	55	54	DVM
	55	70	60	50	50	57	k-EK

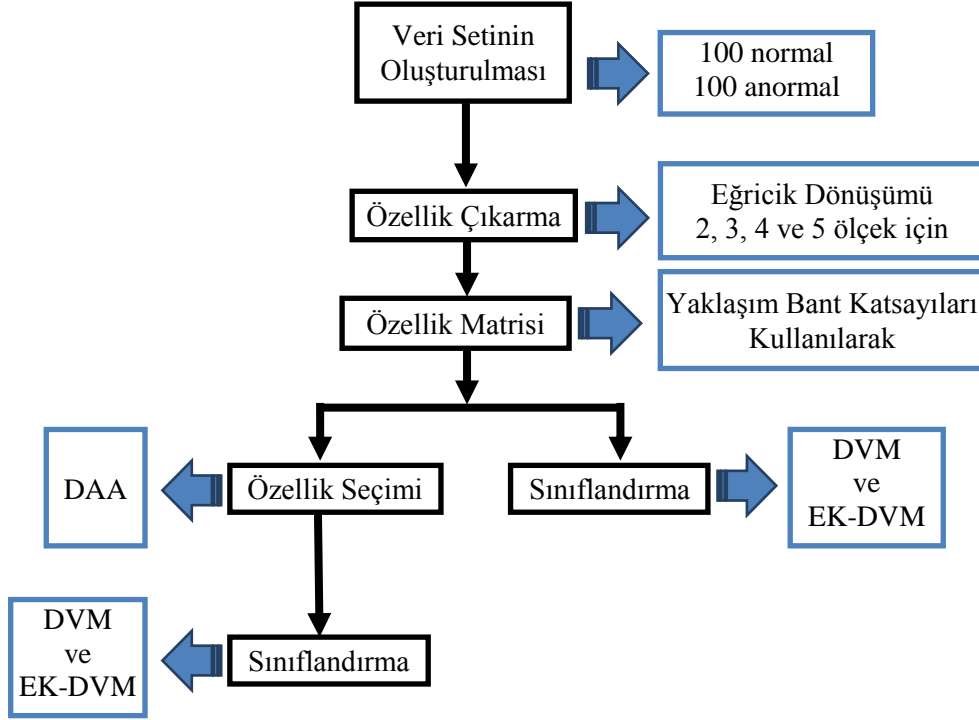
Tablo 21. DAA ile özellik seçimi ardından iyi huylu-kötü huylu sınıflandırmaya ait 5 kat çapraz doğrulama başarı oranları

Piksel	Başarı oranları (%)					Ortalama (%)	Sınıflandırıcı
	ED+DAA						
	Bölüm1	Bölüm2	Bölüm3	Bölüm4	Bölüm5		
200×200	100	75	100	100	100	95	DVM
	100	85	100	100	100	97	k-EK
50×50	100	60	70	95	95	84	DVM
	100	65	75	95	95	86	k-EK
24×24	50	55	55	60	65	57	DVM
	75	55	65	75	75	69	k-EK

3.2.3. Sınıflandırma II: Eğricik Dönüşümü

Bu bölümde, otomatik olarak elde edilen alt görüntülerden yeni bir veri seti 128x128 piksel boyutlu olarak oluşturulmaktadır. Oluşturulan yeni veri seti 100 normal ve 100 anormal görüntü olmak üzere; toplam 200 görüntüden oluşmaktadır. Yeni görüntüler ilk bölümde anlatıldığı şekilde, anormal ve normal görüntülerden elde edilmektedir. Şekil 39'da ikinci bölüme ait sınıflandırma akış şeması gösterilmektedir. Bu bölümde eğricik dönüşümü 2, 3, 4 ve 5 ölçeklerinde uygulanarak, yaklaşım bandı katsayılarının ölçeğe göre sınıflandırma değerleri analiz edilmektedir. Her ölçekte eğricik katsayıları yani özellikler elde edilmekte ve her ölçek ayrı ayrı DVM ve EK-DVM algoritmalarıyla sınıflandırılmaya tabi tutulmaktadır. Ayrıca ilk bölümde sınıflandırma başarısını oldukça iyileştiren DAA algoritmasıyla özellik seçimi işlemi gerçekleştirilmekte ve sınıflandırma işlemi tekrar

yapılmaktadır. Sınıflandırma başarı oranları, bu bölümde 2x5 kat çapraz doğrulama sonucunda elde edilen değerlerdir. Sınıflandırma yine normal-anormal ayrımı ve iyi huylu-kötü huylu ayrımı olarak gerçekleştirilmektedir.



Şekil 39. İkinci uygulamaya ait işlem aşamaları

Sınıflandırma sonuçları, 2x5 kat çapraz doğrulamada elde edilen sonuçların ortalaması olarak alınmaktadır. Oluşturulan 200 mamografi görüntüsü, 2x5 kat çapraz doğrulama işlemi için önce 5 eşit parçaya bölünmüştür. Sınıflandırma yapıldıktan sonra, veri seti farklı gruplandırma olacak şekilde yeniden 5 eşit parçaya bölünerek tekrar sınıflandırma işlemine tabi tutulmaktadır. Sınıflandırma başarısı, toplamda gerçekleştirilen 10 işlem sonucunda elde edilen başarı oranlarının ortalaması alınarak elde edilmektedir. Bu işlem, eğricik dönüşümünün 2, 3, 4 ve 5 ölçekte gerçekleştirilmesiyle dört kez tekrarlanmaktadır. Her ölçekte eğricik dönüşümü sonucuna ait sınıflandırma değerleri, DAA ile özellik seçiminden sonra elde edilen sınıflandırma değerleriyle karşılaştırılmaktadır. Tablo 22’de, özellik seçimi yapılmadan her bir ölçeğe ait sınıflandırma değerleri gösterilmektedir. DAA ile özellik seçimi gerçekleştirilerek elde edilen sınıflandırma sonuçları, her bir ölçek için Tablo 23’de gösterilmektedir.

Tablo 22. Normal-anormal sınıflandırma için, 2x5 kat çapraz doğrulama başarı oraları

Ölçek	Bölüm 1 (%)					Bölüm 2 (%)					Ortalama	Sınıflandırıcı
	Parça1	Parça2	Parça3	Parça4	Parça5	Parça1	Parça2	Parça3	Parça4	Parça5		
2	87.5	90	87.5	85	82.5	90	85	87.5	80	92.5	86.75	DVM
2	99.5	99	99.5	99.5	100	93.5	99.5	99.5	99.5	100	98.95	EK-DVM
3	90	90	87.5	85	82.5	90	87.5	87.5	80	92.5	87.25	DVM
3	98.5	99	100	100	99.5	92	99.5	99	100	100	98.75	EK-DVM
4	90	92.5	90	85	85	87.5	90	85	82.5	92.5	88	DVM
4	99	98.5	100	99.5	99.5	92	99	100	99	99	98.55	EK-DVM
5	92.5	87.5	85	85	82.5	85	90	85	70	92.5	85.5	DVM
5	98	100	98	97	100	91.5	100	98	98	100	98.05	EK-DVM

Tablo 23. DAA ile özellik seçimi yoluyla normal-anormal sınıflandırma için, 2x5 kat çapraz doğrulama başarı oraları

Ölçek	Bölüm 1 (%)					Bölüm 2 (%)					Ortalama	Sınıflandırıcı
	Parça1	Parça2	Parça3	Parça4	Parça5	Parça1	Parça2	Parça3	Parça4	Parça5		
2	100	100	100	100	100	100	100	100	100	100	100	DVM
2	100	100	100	100	100	95	100	100	100	100	99.5	EK-DVM
3	100	100	100	100	100	100	100	100	100	100	100	DVM
3	100	100	100	100	100	95	100	100	100	100	99.5	EK-DVM
4	100	100	100	100	100	62.5	100	100	100	100	96.25	DVM
4	100	100	100	100	100	94	100	100	100	100	96.4	EK-DVM
5	50	62.5	50	65	42.5	32.5	67.5	65	62.5	72.5	57	DVM
5	62	63.5	77.5	95.5	100	74.5	59	75.5	68.5	86.5	76.25	EK-DVM

Görüntülerin iyi huylu-kötü huylu olarak sınıflandırılması da, aynı işlem aşamaları kullanılarak gerçekleştirilmektedir. 50 iyi huylu ve 50 kötü huylu görüntüden oluşan toplam 100 anormal mamografi veri seti; iki kez 5 eşit parçaya ayrılarak 2x5 kat çapraz doğrulama işlemi DVM ve EK-DVM algoritmaları ile gerçekleştirilmiştir. Normal-anormal sınıflandırma aşamasında olduğu gibi; oluşturulan 5 parçadan biri test için, kalanlar eğitim için kullanılmakta ve tekrarlanan 10 işlemin sonunda ortalama alınarak başarı oranı belirlenmektedir. Tablo 24, eğricik katsayıları üzerinden iyi huylu-kötü huylu sınıflandırma sonuçlarını ve Tablo 25’de, DAA ile özellik seçimi yapıldıktan sonra iyi huylu-kötü huylu sınıflandırılma sonuçlarını göstermektedir.

Tablo 24. Eğricik katsayılarının, 2x5 kat çapraz doğrulama ile iyi huylu-kötü huylu sınıflandırılma sonuçları

Ölçek	Bölüm 1 (%)					Bölüm 2 (%)					Ortalama	Sınıflandırıcı
	Parça1	Parça2	Parça3	Parça4	Parça5	Parça1	Parça2	Parça3	Parça4	Parça5		
2	45	45	45	40	35	40	55	60	40	45	45	DVM
2	99	99	99	99	99	99	99	99	99	94	98.5	EK-DVM
3	45	45	45	40	35	40	55	70	40	45	46	DVM
3	99	99	99	99	99	99	99	99	99	94	98.5	EK-DVM
4	45	45	45	40	35	50	40	70	35	45	45	DVM
4	99	99	99	99	99	99	99	99	99	94	98.5	EK-DVM
5	45	45	45	40	35	45	40	65	40	50	45	DVM
5	99	99	99	99	99	99	99	99	99	94	98.5	EK-DVM


Tablo 25. DAA ile özellik seçimi ve 2x5 kat çapraz doğrulama ile iyi huylu-kötü huylu sınıflandırılma sonuçları

Ölçek	Bölüm 1 (%)					Bölüm 2 (%)					Ortalama	Sınıflandırıcı
	Parça1	Parça2	Parça3	Parça4	Parça5	Parça1	Parça2	Parça3	Parça4	Parça5		
2	100	100	100	95	95	100	100	95	100	70	95.5	DVM
2	99	99	99	99	99	99	99	99	99	94	98.5	EK-DVM
3	100	100	100	95	95	100	100	95	100	75	96	DVM
3	99	99	99	99	99	99	99	99	99	94	98.5	EK-DVM
4	100	100	100	95	95	95	100	95	35	65	88	DVM
4	99	99	99	99	99	98	99	99	62	84	93.7	EK-DVM
5	100	100	100	95	95	55	25	70	75	65	78	DVM
5	99	99	99	99	99	86	56	65	80	80	86.2	EK-DVM

Tablo 22 ve 21 de gösterilen normal-anormal sınıflandırma sonuçları oldukça iyi değerler içermektedir. EK-DVM algoritması tüm ölçeklerde eğricik katsayılarıyla yüksek başarı sergilemektedir. DVM algoritması ise özellik seçimi sonucunda mükemmel performans sergilemektedir. Tablo 26, sınıflandırıcıların performansını, doğrudan eğricik katsayılarını giriş olarak ve özellik seçimi sonucunu giriş olarak gerçekleştirilen normal-anormal sınıflandırma durumu için karşılaştırmalı olarak göstermektedir. Tabloya ait sınıflandırma başarısı değişimi Şekil 40'da gösterilmektedir.

Tablo 26. Normal-anormal sınıflandırma aşamasına ait bütün başarı oranları

Ölçek	ED (%)		ED+DAA (%)	
	DVM	EK-DVM	DVM	EK-DVM
2	86.75	98.95	100	99.5
3	87.25	98.75	100	99.5
4	88	98.55	96.25	96.4
5	85.5	98.05	57	76.25




Şekil 40. Normal-anormal sınıflandırma başarı oranlarının değişimi

Anormal görüntülerin iyi huylu-kötü huylu olarak sınıflandırılmasında EK-DVM algoritması yine başarılı sonuçlar verirken DVM algoritması özellik seçimi yapılmayan durumda kötü sonuçlar vermektedir. İyi huylu-kötü huylu sınıflandırma aşaması için sınıflandırıcılara ait başarı değerleri tüm sistem için Tablo 27’de gösterilmekte ve Şekil 41’de değişim karşılaştırmalı olarak verilmektedir.

Tablo 27. İyi huylu-kötü huylu sınıflandırma aşamasına ait bütün başarı oranları

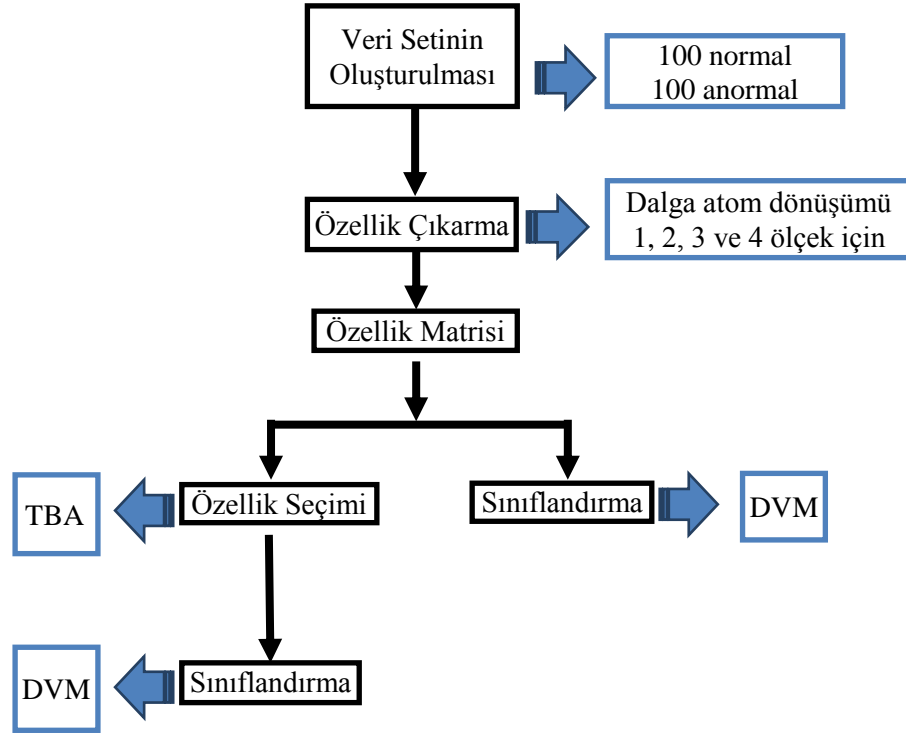
Ölçek	ED (%)		ED+DAA (%)	
	DVM	EK-DVM	DVM	EK-DVM
2	45	98.5	95.5	98.5
3	46	98.5	96	98.5
4	45	98.5	88	93.7
5	45	98.5	78	86.2



Şekil 41. İyi huylu-kötü huylu sınıflandırma başarı oranlarının değişimi

3.2.4. Sınıflandırma III: Dalga Atom Dönüşümü

Bu bölümde, otomatik olarak elde edilen ilgi alanı görüntülerinden oluşturulan 128x128 piksel boyutlu veri seti kullanılarak; dalga atom dönüşümü, TBA ve DVM'den oluşan melez bir sınıflandırma sistemi gerçekleştirilmektedir. Sisteme ait akış şeması, Şekil 42'de gösterilmektedir. Sistem dalga atom dönüşümü kullanılarak mamografi görüntülerinin çok çözünürlüklü temsiline dayanmaktadır. Veri seti görüntüleri, dalga atom dönüşümüyle 4 ölçeğe kadar ayrıştırılmaktadır. Ayrıştırma sonucunda, 4 farklı özellik matrisi elde edilmekte ve DVM sınıflandırıcısı ile önce normal-anormal daha sonra da iyi huylu-kötü huylu olarak mamografi görüntüleri sınıflandırılmaktadır. Bir sonraki aşamada, TBA ile özellik seçimi gerçekleştirilip sınıflandırma işlemi tekrar yapılmaktadır.



Şekil 42. Mamografi görüntülerinin sınıflandırılması için kullanılan akış şeması

Veri seti normal-anormal sınıflandırma için, 100 normal ve 100 anormal görüntü olmak üzere 200 görüntüden oluşturulmuştur. Sınıflandırma aşamasında eğitim verisi için, 50 normal ve 50 anormal görüntü, test verisi için 50 normal ve 50 anormal görüntü kullanılmıştır, Tablo 28.

Tablo 28. Normal-anormal sınıflandırma için veri seti dağılımı

		128x128 piksel
Eğitim	Normal	50
	Anormal	50
Test	Normal	50
	Anormal	50

Dalga atom dönüşümü katsayıları ile gerçekleştirilen normal-anormal sınıflandırma sonucu, Tablo 29’da her bir ölçek için gösterilmektedir. Tabloda ayrıca sınıflandırmaya ait duyarlılık ve özgüllük değerleri de gösterilmektedir. Kaba ölçekten, ince ölçeğe gidildikçe sınıflandırma başarısı düşmektedir. Tablo 30’da ise, TBA algoritmasıyla özellik seçimi sonucunda elde edilen başarı oranları duyarlılık ve özgüllük değerleri ile birlikte her bir

ölçek için gösterilmektedir. Özellik seçimi ile normal-anormal sınıflandırmasında, ölçek 2 ve 3 ile %100 başarı oranına ulaşmıştır.


Tablo 29. Dalga atom katsayıları ile mamografi görüntülerinin normal-anormal sınıflandırma başarı oranları

Ölçek	Dalga atom			Sınıflandırıcı
	Başarı oranı (%)	Duyarlılık (%)	Özgüllük (%)	
1	94	89	100	DVM
2	69	38	100	DVM
3	55	10	100	DVM
4	53	6	100	DVM


Tablo 30. Dalga atom ve TBA algoritmaları ile mamografi görüntülerinin normal-anormal sınıflandırma başarı oranları

Ölçek	TBA bileşenleri	Dalga atom+TBA			Sınıflandırıcı
		Başarı oranı (%)	Duyarlılık (%)	Özgüllük (%)	
1	2	98	96	100	DVM
	3	95	90	100	
	4	96	92	100	
	6	96	92	100	
	9	96	92	100	
2	2	93	86	100	DVM
	3	94	88	100	
	4	100	100	100	
	6	100	100	100	
	9	100	100	100	
3	2	95	90	100	DVM
	3	96	92	100	
	4	100	100	100	
	6	100	100	100	
	9	99	98	100	
4	2	83	66	100	DVM
	3	89	78	100	
	4	88	76	100	
	6	90	80	100	
	9	96	92	100	

TBA algoritması uygulanarak gerçekleştirilen özellik seçimi sonucu sınıflandırma ile oldukça iyi sonuçlar elde edilmektedir. Normal-anormal sınıflandırmaya ait ROC eğrileri, doğrudan dalga atom katsayıları için Şekil 43’de gösterilmektedir. TBA ile özellik seçimi gerçekleştirilerek yapılan sınıflandırma için ROC eğrileri Şekil 44’de gösterilmektedir.



Şekil 43. Dalga atom katsayıları ile yapılan doğrudan sınıflandırılma işlemine ait ROC eğrileri



Şekil 44. TBA ile özellik seçimi gerçekleştirilerek yapılan sınıflandırmaya ait ROC eğrileri

İyi huylu-kötü huylu olarak mamografi görüntülerinin sınıflandırılmasında, otomatik ilgi alanları seçimiyle elde edilen anormal görüntülerden seçilen 100 görüntü kullanılmıştır. Eğitim verisi için, 25 iyi huylu ve 25 kötü huylu anormallik içeren mamografi görüntüleri ve test kümesi için, yine 25 iyi huylu ve 25 kötü huylu anormallik içeren mamografi görüntüleri kullanılmaktadır (Tablo 31).

Tablo 31. İyi huylu-kötü huylu sınıflandırma için veri seti dağılımı

		128x128 piksel
Eğitim	İyi huylu	25
	Kötü huylu	25
Test	İyi huylu	25
	Kötü huylu	25

İşlem aşamaları, normal-anormal sınıflandırmasındaki gibi gerçekleştirilmektedir. Öncelikle dalga atom dönüşümü hazırlanan veri setine uygulanarak elde edilen katsayılarından özellik matrisi oluşturulmakta, sonra özellik matrisi doğrudan sınıflandırıcı girişi olarak kullanılarak bir sonuç elde edilmektedir. Daha sonra TBA algoritması ile özellik seçimi işlemi gerçekleştirilip, görüntüler yeniden sınıflandırmaya tabi tutulmaktadır. Tablo 32, dalga atom katsayılarının doğrudan sınıflandırıcı girişi olarak kullanılmasıyla mamografi görüntülerinin iyi huylu-kötü huylu olarak ayrıştırılması sonucunda elde edilen başarı oranlarını, her bir ölçek için ayrı ayrı göstermektedir. Tabloda ayrıca, sınıflandırmaya ait duyarlılık ve özgülük değerleri de gösterilmektedir.

Tablo 32. Dalga atom katsayılarının doğrudan sınıflandırıcı girişi olarak kullanılması sonucu, iyi huylu-kötü huylu sınıflandırma için başarı oranları


Ölçek	Dalga atom			Sınıflandırıcı
	Başarı oranı (%)	Duyarlılık (%)	Özgüllük (%)	
1	100	100	100	DVM
2	62	100	24	DVM
3	56	100	12	DVM
4	54	100	8	DVM

TBA kullanılarak özellik seçimine bağlı gerçekleştirilen iyi huylu-kötü huylu sınıflandırmanın başarısı, duyarlılık ve özgüllük değerleriyle birlikte Tablo 33'de gösterilmektedir.


Tablo 33. TBA kullanılarak özellik seçimine bağlı gerçekleştirilen iyi huylu-kötü huylu sınıflandırma için başarı oranları

Ölçek	TBA bileşenleri	Dalga atom+TBA			Sınıflandırıcı
		Başarı oranı (%)	Duyarlılık (%)	Özgüllük (%)	
1	2				DVM
	3				
	4				
	6				
	9				
2	2	52	100	4	DVM
	3	52	53	51	
	4	52	53	51	
	6	60	77	43	
	9	80	80	80	
3	2	54	100	8	DVM
	3	62	100	24	
	4	60	100	20	
	6	62	67	57	
	9	92	88	96	
4	2	46	45	47	DVM
	3	64	100	28	
	4	56	63	49	
	6	50	50	50	
	9	52	53	51	

TBA algoritması uygulanarak gerçekleştirilen özellik seçimi ile iyi huylu-kötü huylu sınıflandırma başarısında iyileşme elde edilmektedir. İyi huylu-kötü huylu sınıflandırmaya ait ROC eğrileri, doğrudan dalga atom katsayılarının kullanılması durumu için Şekil 45'de gösterilmektedir. TBA ile özellik seçimi gerçekleştirilerek yapılan iyi huylu-kötü huylu sınıflandırma için ROC eğrileri, Şekil 46'da gösterilmektedir.




Şekil 45. Dalga atom katsayıları kullanılarak gerçekleştirilen doğrudan sınıflandırmaya ait ROC eğrileri



Şekil 46. TBA algoritması kullanılarak özellik seçimi üzerinden gerçekleştirilen sınıflandırmaya ait ROC eğrileri

4. İRDELEME


Sınıflandırma I ve II’de normal-anormal sınıflandırma için her iki sınıflandırıcının alt mamografi görüntülerinin boyutu büyüdükçe daha başarılı sonuçlar verdiği gözlenmektedir. Şekil 47’de görüleceği gibi eğricik katsayılarının doğrudan sınıflandırılmasında DVM sınıflandırıcı %87 ile en iyi başarı değerine sahiptir. Öte yandan, sınıflandırma II’de eğricik katsayılarının EK-DVM sınıflandırıcı ile doğrudan sınıflandırılmasıyla, ölçek 2’de %98.95 başarı oranı elde edilmiştir.



Şekil 47. Alt görüntü boyutuna göre sınıflandırıcı başarıları


DAA ve TBA yöntemlerinin sisteme dâhil edilmesiyle, DVM ve k-EK sınıflandırıcılarının performansında iyileşme gözlenmiştir. DAA ile her iki sınıflandırıcı da en yüksek başarı oranına ulaşılmıştır. TBA ile ulaşılan en iyi sınıflandırma başarısı %95 ile DVM sınıflandırıcısına aittir. Şekil 48, TBA ve DAA algoritmalarıyla ulaşılan en yüksek sınıflandırma başarı sonuçlarını alt görüntülerin boyutuna göre vermektedir.

EK-DVM sınıflandırıcı ile birlikte sadece DAA algoritması kullanılarak sınıflandırma sonucu test edilmiştir. Bunun nedeni DAA algoritmasının diğer uygulamalarda göstermiş olduğu başarıdır. DAA ve EK-DVM sistemine ait başarı sonucu, ikinci ve üçüncü ölçek değerlerinde %99.5 olarak elde edilmiştir.




Şekil 48. DAA ve TBA algoritmaları üzerinden sınıflandırma sonuçları

İyi huylu-kötü huylu sınıflandırma işlemi için, eğricik katsayılarının doğrudan giriş olarak kullanıldığında başarı oranları düşük olarak çıkmaktadır. Şekil 49’da tüm aşamalara ve sınıflandırıcılara ait değerler gösterilmektedir. Doğrudan sınıflandırmada en yüksek başarı %98.5 olarak EK-DVM ile elde edilmiştir.




Şekil 49. Tüm alt örnekler ve sınıflandırıcılar için doğrudan sınıflandırma başarıları

Yine sınıflandırmaya DAA ve TBA algoritmalarının dahil edilmesiyle anormal görüntülerin sınıflandırılmasında da, başarı oranlarında iyileşme gözlenmiştir. Ulaşılan en yüksek başarı oranları Şekil 50’de, tüm işlemler için verilmektedir. TBA algoritması ile en yüksek başarı oranı %72 ile DVM algoritmasıyla ve DAA algoritmasıyla en yüksek başarı oranı %98 ile DVM ve k-EK sınıflandırıcılarının her ikisi ile elde edilmiştir. EK-DVM algoritmasıyla iyi huylu-kötü huylu sınıflandırma işleminde en yüksek başarı oranı, ikinci ve üçüncü ölçeklerde %98.5 olarak elde edilmiştir.




Şekil 50. DAA ve TBA algoritmaları üzerinden iyi huylu-kötü huylu sınıflandırma sonuçları

Sınıflandırma III'de yani dalga atom dönüşümü kullanılarak yapılan sınıflandırma da; normal-anormal sınıflandırma için ölçek 1'de ve iyi huylu-kötü huylu sınıflandırma için yine ölçek 1'de iyi sonuçlar elde edilmiştir. Diğer ölçeklerde başarı gittikçe kötüleşmektedir. Şekil 51'de her iki sınıflandırma durumu için her bir ölçekteki başarı oranları gösterilmektedir. En başarılı sonuçlar normal-anormal için %94, iyi huylu-kötü huylu için %100 dür.



Şekil 51. Bütün ölçekler için dalga atomu katsayıları üzerinden normal-anormal (N-A) ve iyi huylu-kötü huylu (IH-KH) sınıflandırma sonuçları

Dalga atomu katsayılarının TBA algoritması kullanılarak seçilmesi ile bütün ölçeklerde başarı oranı artmaktadır. Normal-anormal sınıflandırmada ölçek 2 ve 3'de %100 başarı elde edilmiştir. İyi huylu-kötü huylu sınıflandırmada ölçek 3'de %92 başarı elde edilmiştir. Şekil 52'de her durum için TBA algoritması ile elde edilen en yüksek başarı oranları her ölçek için gösterilmektedir.



Şekil 52. Bütün ölçekler için, dalga atomu katsayıları üzerinden normal-anormal (N-A) ve iyi huylu-kötü huylu (IH-KH) sınıflandırma sonuçları

Oluşturulan sistemlerin işlem süreleri tablo 34’de, elde edilen en yüksek sınıflandırma başarısına sahip sınıflandırmalar için gösterilmektedir. Yapılan uygulamalar sonucunda elde edilen sonuçların literatürde yapılan diğer çalışmalarla olan karşılaştırması ise, Tablo 35’de gösterilmektedir. Tablodaki değerlerden de görüleceği üzere, bu çalışmada daha yüksek sınıflandırma değerlerine ulaşılmıştır.

Tablo 34. En yüksek sınıflandırma başarısına sahip sistemlerin işlem süreleri

	Görüntü boyutu (piksel)	Özellik çıkarımı	Özellik seçimi	Sınıflandırıcı	Sınıflandırma türü	Sınıflandırma başarısı (%)	Süre (saniye)
Sınıflandırma I	200x200	ED	DAA	DVM	Normal-anormal	100	760
			DAA	DVM	İyi huylu-kötü huylu	98	375
Sınıflandırma II	128x128	ED	DAA	DVM	Normal-anormal	100	543
			DAA	DVM	İyi huylu-kötü huylu	95,5	203
		ED	DAA	EK-DVM	Normal-anormal	99,5	534
			DAA	EK-DVM	İyi huylu-kötü huylu	98,5	188
Sınıflandırma III	128x128	DAD	TBA	DVM	Normal-anormal	100	46
			-----	DVM	İyi huylu-kötü huylu	100	27

Tablo 35. Daha önce yapılan çalışmalarla elde edilen sonuçların karşılaştırılması

	Tarih	Veri seti görüntü boyutu (piksel)	Veri seti görüntü sayısı	Özellik çıkarım yöntemleri	Sınıflandırma doğruluğu (%)	Sınıflandırıcı
Christoyianni ve ark. [63]	2002	35 x 35	119	BBA	88.23 [*] 79.31 ^{**}	RBFNN
Mousa ve ark. [67]	2005	800x800	132	Dalgacık Dönüşümü	81.40 [*]	ANFIS
Campos ve ark. [62]	2005	24x24	200	Hızlı BBA	97.30 [*]	PNN
Abu-Amara ve ark. [61]	2007	35x35 45x45	119	BBA, TBA	79 [*] 71.20 ^{**}	Euclidean Distance
Eltoukhy ve ark. [76]	2010	128x128	142	Eğricik Dönüşümü Dalgacık Dönüşümü	94.07 [*] 94.28 ^{**}	Euclidean Distance
Eltoukhy ve ark. [75]	2010	128x128	142	Eğricik Dönüşümü	98.59 [*]	Euclidean Distance
Eltoukhy ve ark. [77]	2012	128x128	142	Eğricik Dönüşümü + t-Test Algoritması	95.98 [*] 97.30 ^{**}	DVM
Bu çalışma: sınıflandırma I	2012	200x200	200	Eğricik Dönüşümü + DAA	100[*] 98^{**}	DVM k-EK
Bu çalışma: sınıflandırma II	2012	128x128	200	Eğricik Dönüşümü	98.95[*] 98.50^{**}	EK-DVM
Bu çalışma: sınıflandırma III	2012	128x128	200	Dalga atom dönüşümü	94[*] 100^{**}	DVM
Bu çalışma: sınıflandırma III	2012	128x128	200	Dalga atom dönüşümü + TBA	100[*] 92^{**}	DVM

* Normal-anormal sınıflandırma

** İyi huylu- kötü huylu sınıflandırma

5. SONUÇ VE ÖNERİLER

Bilgisayar destekli teşhis sistemleri çeşitli nedenlere bağlı olarak, meme kanserinin gözden kaçırılmasını önlemek ve/veya meme kanserinin erken evrede tespit edilememesi gibi durumların minimum seviyeye çekilmesi için radyoloğa destek amacıyla geliştirilmektedir. Kansere karşı en etkin mücadele hastalığın erken dönemde tespiti ile mümkün olmaktadır. Yapılan teknolojik çalışmalar meme kanserinin erken tespitinde önemli bir rol oynamaktadır. Meme kanserlerinin yaklaşık olarak %85-90'nının tespiti mamografi görüntülerinin incelenmesi ile gerçekleştirilmekte ve bu aşamada radyologlar bilgisayar destekli teşhis sistemleriyle desteklenmektedir. Meme kanserinin tespitinde iki temel unsur etkili olarak rol oynamaktadır. Bunlar; mamografinin taranmasında radyolog performansı ve kullanılan BDT sistemin performansıdır. Radyolog performansına etki eden nedenler; incelenecek mamografi görüntü sayısının çokluğu ve tespiti zor vakalar olarak özetlenebilir. Radyoloğun incelediği yüzlerce görüntüden sadece bir kaç tanesi hastalıklı çıkmaktadır. Bu durumda, radyoloğun performansının artırılması anormal mamografi görüntülerinden normal görüntülerin ayrıştırılması ve böylece anormal görüntülere daha iyi odaklanılmasının sağlanması ile çözümlenebilir.

Bu tez çalışmasının ilk aşamasında, mamografi görüntülerindeki anormalliklerin, otomatik olarak tespit edilip alt görüntü haline getirilmesini içeren farklı bir yaklaşım gerçekleştirilmiştir. Meme yüzeyi taranarak şüpheli kısımlara ait bölgeler, sınıflandırılmak üzere alt görüntü haline getirilmektedir. Alt görüntüler, top-hat, bottom-hat ve ortalama filtre uygulanarak otomatik olarak tespit edilip, 200x200 piksel boyutunda oluşturulmaktadır. Bu şekilde, meme görüntüsünde tarama alanı daraltılmakta ve şüpheli alanlar ön plana çıkarılmaktadır. Top-hat ve bottom-hat dönüşümleri kitle, yapısal bozukluk, asimetri içeren mamogramlara uygulanmış ve görüntülerde şüpheli alanlar büyük bölgeden küçük bölgeye doğru çıkarılmıştır. Ortalama filtre ise mikrokalsifikasyon alanlarının tespit edilmesinde kullanılmıştır. Uygulanan yöntemler ile otomatik olarak çıkarılan şüpheli alanlar, MIAS veri bankasına ait anormal görüntülerin bütün anormalliklerini içermektedir. Diğer bir deyişle, otomatik şüpheli bölgeler tespitiyle bütün anormallikler tespit edilmekte, alt görüntüsü elde edilemeyen hiçbir anormal bölge bulunmamaktadır. Her iki yöntem de, uygulamada anormal alanların yerinin belirlenmesinde başarılıdır.

Şüpheli bölgelerin otomatik tespitiyle elde edilen alt mamografi görüntülerinden oluşturulan veri setlerinin, önce normal-anormal olarak daha sonrada iyi huylu-kötü huylu olarak sınıflandırılması amacıyla, dalga atom dönüşümü, eğricik dönüşümü, doğrusal ayırıcı analiz, temel bileşen analizi, destek vektör makineleri, k-en yakın komşuluk ve en küçük kareli destek vektör makineleri algoritmalarından oluşan melez bilgisayar destekli teşhis sistemleri tasarlanmıştır. Çalışma üç uygulama aşamasıyla ve mamografi görüntülerinin dört farklı alt görüntü boyutuyla gerçekleştirilmiştir. Hem dalga atom dönüşümü hem de eğricik dönüşümü ile elde edilen özelliklerle sınıflandırma sonucu yüksek başarı oranlarına ulaşılmıştır. TBA ve DAA algoritmalarıyla yapılan özellik seçimi işlemiyle sınıflandırma başarısında büyük ölçüde iyileşme sağlanmıştır.

Çalışmanın ikinci aşamasında eğricik dönüşümü katsayılarından elde edilen özellikler, DAA, TBA, DVM ve k-EK algoritmalarının değişik kombinasyonları ile karşılaştırmalı olarak test edilmiştir. Literatürden farklı olarak eğricik dönüşümünün yaklaşım bandı kullanılmıştır. Görüntülerin normal-anormal olarak sınıflandırılmasında %100 başarı 200x200 ve 50x50 piksel alt örneklerde, hem k-EK hem de DVM sınıflandırıcılarıyla DAA uygulanarak elde edilmiştir. İyi huylu-kötü huylu sınıflandırma için en iyi sonuç 200x200 piksel alt örneklerde k-EK ve DVM sınıflandırıcıları için %98 olarak yine DAA uygulanarak sağlanmıştır. Bu sonuçlara dayanarak; büyük piksel boyutlarında mamografi görüntülerinin, eğricik dönüşümü yaklaşım bant katsayıları ve DAA algoritması yoluyla sınıflandırılmalarının uygulamada kullanılabilirliği ortaya çıkarılmıştır.

Çalışmanın üçüncü aşamasında DAA, EK-DVM ve DVM algoritmaları kullanılarak eğricik dönüşümünün farklı ölçekleri için sınıflandırma başarısı araştırılmıştır. Çalışmanın sonucunda eğricik dönüşümünün ikinci ve üçüncü ölçeklerinde yüksel başarılar elde edilmiştir. Mamografi görüntülerinin normal-anormal olarak sınıflandırılmasında EK-DVM algoritmasıyla elde edilen en yüksek başarı oranı %98.95 ile ikinci ölçektir. Bu değer DAA algoritmasının eklenmesiyle %99.5 değerine yükselmektedir. İyi huylu-kötü huylu olarak sınıflandırmada ise, EK-DVM algoritması %98.5 başarı göstermektedir. Bu aşamada DAA algoritmasıyla herhangi bir iyileşme elde edilememiştir. Sonuçlar eğricik dönüşümü ve EK-DVM sınıflandırıcısının uygulamada kullanılabilir bir başarı sergilediğini göstermektedir.

Çalışmanın dördüncü aşamasında dalga atom dönüşümü, TBA ve SVM algoritmalarından oluşan bir sistem oluşturulmuştur. Dalga atom dönüşümüyle mamogram

görüntüleri üzerinde, daha önce yapılan bir çalışma bulunmamaktadır. Dalga atom dönüşümü katsayıları üzerinden yapılan sınıflandırmada normal-anormal ayrımında %94, iyi huylu-kötü huylu ayrımında %100 başarı elde edilmiştir. Sisteme TBA algoritmasının dâhil edilmesiyle normal-anormal sınıflandırmasında %100 başarıya ulaşılmıştır.

Yapılan tüm uygulama sonuçlarına göre; bu sistem ile mamogram görüntülerinden, başarılı bir normal-anormal ayrımı yapılacak ve radyoloğun sadece anormal yapılarla odaklanmasını sağlayacaktır. Yine, bu sistem görüntülerin iyi huylu-kötü huylu olarak kategorize edilmesinde de başarılı bir sınıflandırma gerçekleştirerek radyologlara destek olacaktır. Oluşturulan sistemler, mamografi görüntülerinin analizindeki gelişmelere ayak uydurarak daha yüksek duyarlığa sahip olma amacına ulaşmıştır. Bununla birlikte, dalga atom dönüşümü ile oluşturulan sistem hem daha yüksek hıza ve hem de daha yüksek duyarlığa sahip olduğundan daha kullanışlı bir sistem olma özelliğini sağlamaktadır.

Bu çalışmanın katkılarını kısaca aşağıdaki gibi özetleyebiliriz:

- Bilgisayar programı yardımıyla mamogram görüntüleri üzerindeki ilgi alanlarının otomatik olarak bulunması konusunda bir yenilik sağlanmıştır.
- Ayrıca, ilgi alanları belirlenen mamogram görüntülerinin; önce normal-anormal, daha sonra da anormal görüntülerden iyi huylu-kötü huylu olarak sınıflandırılmaları; eğricik dönüşümü ve şu ana kadar bu alanda hiç kullanılmamış olan, dalga atom dönüşümü algoritmaları ile gerçekleştirilmiştir.
- Bu metodlarla elde edilen sınıflandırmalar sonucunda, var olan diğer çalışmalara göre daha yüksek performanslar elde edilmiş ve literatüre yönetsel açıdan katkılar sağlanmıştır.
- Bu alanda ilk defa kullanılmış olan, dalga atom dönüşümü ile oluşturulan sistem, diğer algoritmalarla yapılan sistemlere göre, daha az işlem süresine sahip olduğundan, bu çalışma zaman açısından da üstünlük göstermektedir.

İleri çalışmalarda farklı mamografi veri tabanları kullanılarak sistemlerin başarısının değerlendirilmesi önerilmektedir. Sistem tasarlanırken kullanılan yöntemler farklı medikal görüntülerin sınıflandırılması için kullanılabilir. Özellik seçimi ve sınıflandırma için farklı algoritmalar kullanılarak bunların başarısı test edilebilir. Ayrıca; algoritmaların başka mühendislik alanlarına uygulanarak geliştirilmesi ve disiplinler arası işbirliği alanlarının inşası, uygulamaya açık alanlardan biri olarak göz önünde bulundurulmalıdır.

6. KAYNAKLAR

1. Özmen, V., Dünya’da ve Türkiye’de meme kanseri, Meme Sağlığı Dergisi, (2010).
2. Alpteker, H., Gümüş, D., Doğan, S., Bilir, S. ve Önal, M., Kız öğrencilerin meme kanseri ve kendi kendine meme muayenesi bilgi ve uygulamalarının incelenmesi, The Journal of Breast Health, 37, 3 (2011).
3. Gölbaşı, Z., Çetin, R., Kalkan, S. ve Durmuş, T., Üniversite öğrencisi kızların meme kanseri ve kendi kendine meme muayenesi ile ilgili bilgi ve davranışları, Meme Sağlığı Dergisi, 6, 2 (2010) 69-73.
4. Ponraj, D. N., Evangelin Jenifer, M. ve Manoharan, J.S., A survey on the preprocessing techniques of mammogram for the detection of breast cancer” International Journal of Computer Science and Security (IJCSS), 1, 3 (2011).
5. [http: //www.uthscsa.edu/hscnews/pdf/BreastCancerFacts.pdf](http://www.uthscsa.edu/hscnews/pdf/BreastCancerFacts.pdf)Breast cancer facts, 1 Nisan 2012.
6. Bouyahia, S., Mbainabeye, J. ve Ellouze, N., Computer aided diagnosis of mammographic images, Control, Communications and Signal Processing, IEEE (2004) 259-262.
7. Jemal, R., Siegel, E., Ward, Y., Hao, J. X. ve Thun, M., Cancer statistics, 2009, CA: a cancer journal for clinicians, 59, 4(2009) 225.
8. Zorukoş, S., Birinci Derece Yakınlarında Meme Kanseri Olan Kadınlar İçin Bilgiye Destek Gereksinimleri Ölçeğinin Türkçe ’ye Uyarlanması, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sağlık Bilimleri Enstitüsü, İzmir, 2008.
9. Milli Eğitim Bakanlığı Bireysel Öğrenme Materyali, Radyoloji-Mamografi, 2011.
10. Somunoğlu, S., Meme Kanseri: Belirtileri Ve Erken Tanıda Kullanılan Tarama Yöntemleri, Fırat Sağlık Hizmetleri Dergisi, 4, 10 (2009).
11. Gülsün, M., Demirkazık, B. F., Köksal, A. ve Arıyürek, M., Meme mikrokalsifikasyonlarının BI-RADS kriterlerine göre değerlendirilmesi ve yorumcular arasındaki uyumun araştırılması, Tanıs ve Girişimsel Radyoloji, 8 (2002) 358-363.
12. Martin, J., Moskowitz, M. ve Milbrath, J., Breast cancer missed by mammography, American Journal of Roentgenology, 132, 5 (1979) 737.
13. Brown, J., Bryan, S. ve Warren, R., Mammography screening: An incremental cost effectiveness analysis of double versus single reading of mammograms, BMJ, 312, 7034 (1996) 809–812.

14. Giger, M., Computer aided diagnosis of breast lesions in medical images, Computing in Science & Engineering, 2, 5 (2000) 39–45.
15. Blanks, R.G., Wallis, M.G. ve Moss, S.M., A comparison of cancer detection rates achieved by breast cancer screening programs by number of readers, for one and two 187 view mammography: Results from the UK National Health Service Breast Screening Program, Journal of Medical Screening, 5, 4(1998)195–201.
16. Brem, R., Baum, J., Lechner, M., Kaplan, S., Souders, S., Naul, L. ve Hoffmeister, J., Improvement in sensitivity of screening mammography with computer aided detection: A multi institutional trial, Amer. J. Roentgenol., 181, 3 (2003) 687–693.
17. Baeg, S. ve Kehtarnavaz, N., Classification of breast mass abnormalities using denseness and architectural distortion, Electronic Letters on Computer Vision and Image Analysis, 1, 1(2002)1–20.
18. Pisano, E.D., Gatsonis, C., Hendrick, E., Yaffe, M., Baum, J., Acharyya, S., Conant, E., Fajardo, L., Bassett, L., D’Orsi, C., Jong, R. ve Rebner, M., Diagnostic performance of digital versus film mammography for breast cancer screening, New England J. Med., 353, 17 (2005) 1773–1783.
19. Ciatto, S., Houssami, N., Gur, D., Nishikawa, R., Schmidt, R., Metz, C., Ruiz, J., Feig, S., Birdwell, R., Linver, M., Fenton, J., Barlow, W. ve Elmore, J., Computer-aided screening mammography, New England J. Med., 357,1 (2007) 83–85.
20. Hadjiiski, L., Sahiner, B. ve Chan, H.P., Advances in computer-aided diagnosis for breast cancer, Current Opinion in Obstetrics and Gynecology, 18 (2006) 64–70.
21. Birdwell, R.L., Bندوقkar, P. ve Ikeda, D.M., Computer aided detection with screening mammography in a university hospital setting, Radiology, 236, 2 (2005)451–457.
22. Freer, T.W. ve Ulissey, M.J., Screening mammography with computer-aided detection: prospective study of 12,860 patients in a community breast center, Radiology, 220, 3 (2001).
23. Zhang, Y., Tomuro, N., Furst, J. ve Raicu, D.S., Image enhancement and edge-based mass segmentation in mammogram, SPIE Digital Library, 7623 (2010) 76234.
24. Li, L., Wu, Z., Salem, A., Chen, L., George, F., Kallergi, M. ve Berman, C., Computerized analysis of tissue density effect on missed cancer detection in digital mammography, Computerized Medical Imaging and Graphics, 30, (2006) 291-297.
25. Mariate Brake, G., Computer aided detection of masses in digital mammograms, Grant KUN 96-1343 from the Dutch Cancer Society, 2000.
26. Heine, J.J., Deans, S.R., Cullers, D.K., Stauduhar, R. ve Clarke, L.P., Multi resolution statistical analysis of high-resolution digital mammograms, IEEE Transaction on Medical Imaging, vol., 16, 5 (1997) 503-515.

27. Mini, M.G. ve Thomas, T., A neural network method for mammogram analysis based on statistical features, TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region, 4, (2003) 1489-1492.
28. Liu, S., The Analysis Of Digital Mammograms: Speculated Tumor Detection And Normal Mammogram Characterization, PhD Thesis, School of Electrical and Computer Engineering, Purdue University, May 1999.
29. Sun, Y., Babbs, C. ve Delp, E.J., Full-field mammogram analysis based on the identification of normal regions, IEEE International Symposium on Biomedical Imaging Nano to Macro, (2004) 1131-1134.
30. Sun, Y., Normal Mammogram Analysis, PhD Thesis, School of Electrical and Computer Engineering, Purdue University, August 2004.
31. Chiracharit, W., Sun, Y., Kumhom, P., Chamnongthai, K., Babbs, C.F. ve Delp, E.J., Normal mammogram classification based on a support vector machine utilizing crossed distribution features, IEEE 26th International Conference of the Engineering in Medicine and Biology Society (EMBS'04), 1, (2004) 1581-1584.
32. Kom, G., Tiedeu, A. ve Kom, M., Automated detection of masses in mammograms by local adaptive thresholding, Comput. Biol. Med., 37, 1 (2007) 37-48.
33. Eltonsy, N.H., Tourassi, G.D. ve Elmaghraby, A.S., A concentric morphology model for the detection of masses in mammography, IEEE Trans. Med. Imag., 26, 6 (2007) 880-889.
34. Timp, S., Varela, C., Karssemeijer, N. ve Dacolian, B., Temporal change analysis for characterization of mass lesions in mammography, IEEE Trans. Med. Imag., 26, 7 (2007) 945-953.
35. Tourassi, G.D. ve Vargas-Voracek, R., Computer-assisted detection of mammographic masses: A template matching scheme based on mutual information, Medical Phys., 30, 8 (2003) 2123-2130.
36. Lai, S.M., Li, X. ve Biscof, W.F., On techniques for detecting circumscribed masses in mammograms, IEEE Trans. Med. Imag., 18, 4 (1989) 377-386.
37. Moayedi, F., Boostani, R., Azimifar, Z. ve Katebi, S., A support vector based fuzzy neural network approach for mass classification in mammography, 15th Int. Conf. Digit. Signal Process, 1, 4 (2007) 240-243.
38. Tourassi, G.D., Harrawood, B. ve Floyd, C.E.Jr., Cross-digitizer robustness of a knowledge-based CAD system for mass detection in mammograms, SPIE Med. Imag.: Computer-Aided Diagnosis, 6514, (2007) 65141Y-1-65141Y-8.

39. Broeders, M.J.M., Onland-Moret, N.C., Rijken, H.J.T.M., Hendriks, J.H.C.L., Verbeek, A.L.M. ve Holland, R., Use of previous screening mammograms to identify features indicating cases that would have a possible gain in prognosis following earlier detection, Eur. J. Cancer, 39, 12 (2003) 1770–1775.
40. Ayres, F.J. ve Rangayyan, R.M., Characterization of architectural distortion in mammograms, IEEE Eng. Med. Biol. Mag., 24, 1(2005) 59–67.
41. Ayres, F.J. ve Rangayyan, R.M., Reduction of false positives in the detection of architectural distortion in mammograms by using a geometrically constrained phase portrait model, Int. J. Comput. Assist. Radiol. Surg., 1, 6 (2007) 361–369.
42. Rangayyan, R.M. ve Ayres, F.J., Gabor filters and phase portraits for the detection of architectural distortion in mammograms, Med. Biol. Eng. Comput., 44, 10 (2006) 883–894.
43. Guo, Q., Shao, J. ve Ruiz, V., Investigation of support vector machine for the detection of architectural distortion in mammographic images, J. Phys.: Conf. Series, 15, (2005) 88–94.
44. Tourassi, G.D., Delong, D.M. ve Floyd, C.E.J., A study on the computerized fractal analysis of architectural distortion in screening mammograms, Phys. Med. Biol., 51, 5 (2006) 1299–1312.
45. Matsubara, T., Ichikawa, T., Hara, T., Fujita, H., Kasai, S., Endo, T. ve Iwase, T., Automated detection methods for architectural distortions around skin line and within mammary gland on mammograms, 17th Int. Congr. Exhib. Comput. Assist. Radiol. Surg. Elsevier, (2003) 950–955.
46. Ichikawa, T., Matsubara, T., Hara, T., Fujita, H., Endo, T., ve Iwasem, T., Automated detection method for architectural distortion areas on mammograms based on morphological processing and surface analysis, SPIE Med. Imag.: Image Process., 5374, (2004) 920–925.
47. Rangayyan, R.M., Ayres, F.J. ve Desautels, J.E.L., A review of computer-aided diagnosis of breast cancer: Toward the detection of early signs, J. Franklin Inst., 344, ¾ (2007) 312–348.
48. Rangayyan, R.M., Ferrari, R.J. ve Fr`ere, A.F., Analysis of bilateral asymmetry in mammograms using directional, morphological, and density features, J. Electron. Imag., 16, 1 (2007) 1–12.
49. Ferrari, R.J., Rangayyan, R.M., Desautels, J.E.L. ve Fr`ere, A.F., Analysis of asymmetry in mammograms via directional filtering with Gabor wavelets, IEEE Trans. Med. Imag., 20, 9 (2001) 953–964.
50. Scutt, D., Lancaster, G.A. ve Manning, J.T., Breast asymmetry and predisposition to breast cancer, Breast Cancer Res., 8, 2 (2006) 14.

51. Miller, P. ve Astley, S., Automated detection of breast asymmetry using anatomical features, State of the Art in Digital Mammographic Image Analysis, 9, (1994) 247–261.
52. Lau, T.K. ve Bischof, W.F., Automated detection of breast tumors using the asymmetry approach, Comput. Biomed. Res., 24, (1991) 273–295.
53. Yu, S. ve Guan, L., A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films, IEEE Transactions on Medical Imaging, 19, 2 (2000) 115-126.
54. Verma, B. ve Zakos, J., A computer-aided diagnosis system for digital mammograms based on fuzzy-neural and feature extraction techniques, IEEE Transactions on Information Technology in Biomedicine, 5, 1 (2001) 46-54.
55. De Santo, M., Molinara, M., Tortorella, F. ve Vento, M., Automatic classification of clustered microcalcifications by a multiple expert system, Pattern Recognition, 36, (2003) 1467-1477.
56. Soltanian-Zadeh, H., Rafiee-Rad, F. ve Pourabdollah-Nejad D.S., Comparison of multi wavelet, wavelet, haralick, and shape features for microcalcification classification in mammograms, Pattern Recognition, 37, (2004) 1973-1986.
57. Fu, J.C., Lee, S.K., Wong, S.T.C., Yeh, J.Y., Wang, A.H. ve Wu, H.K., Image segmentation feature selection and pattern classification for mammographic microcalcifications, Computerized Medical Imaging and Graphics, 29, (2005) 419-429.
58. Zhang, X., Gao, X. ve Wang, Y., MCs detection with combined image features and twin support vector machines, Journal of Computers, 4, 3 (2009) 215-221.
59. Ferrari, R.J., Rangayyan, R.M., Desautels, J.E.L. ve Frere, A.F., Analysis of asymmetry in mammograms via directional filtering with Gabor wavelets, IEEE Transactions on Medical Imaging, 20, 9 (2001) 953–964.
60. Bocchi, L., Coppini, G., Nori, J. ve Valli, G., Detection of single and clustered microcalcifications in mammograms using fractal models and neural networks, Medical Engineering & Physics, 26, (2004) 303 – 312.
61. Abu-Amara, F., Abdel-Qader, I., Detection of breast cancer using independent component analysis, Electro/Information Technology IEEE International Conference, (2007) 428-431.
62. Campos, L.F.A., Silva, A.C. ve Barros, A.K., Diagnosis of breast cancer in digital mammograms using independent component analysis and neural networks, Springer, CIARP 2005, LNCS 3773, (2005) 460-469.
63. Christoyianni, A., Koutras, E.D. ve Kokkinakis, G., Computer aided diagnosis of breast cancer in digitized mammograms, Computerized Medical Imaging and Graphics, 26, (2002) 309–319.

64. Anna, N., Ioannis, S., Spyros, G. ve Filippou, N., Breast cancer diagnosis: analyzing texture of tissue surrounding microcalcifications, IEEE Trans. Inform. Tech. Biomed., 12,6(2008)731–738.
65. Costa, D.D., Campos, L.F. ve Barros, A.K., Classification of breast tissue in mammograms using efficient coding, BioMedical Engineering OnLine, 10, 55 (2011).
66. Mallat, S.G., A theory for multi resolution signal decomposition: the wavelet representation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 7, 11(1989) 674–93.
67. Mousa, R., Munib, Q. ve Moussa, A., Breast cancer diagnosis system based on wavelet analysis and fuzzy-neural, Expert Systems with Applications, 28, (2005) 713–723.
68. Liu, S., Babbs, C.F. ve Delp, E.J., Multi resolution detection of spiculated lesions in digital mammograms, IEEE Transactions on Image Processing, 10,6(2001) 874–884.
69. Yang, J.C., Shin, J.W. ve Park, D.S., Comparing study for detecting microcalcifications in digital mammogram using wavelets, Lecture Notes in Computer Science, 3177, (2004) 409–415.
70. Moayedi, F., Azimifar, Z., Boostani, R. ve Katebi, S., Contourlet based mammography mass classification, Lecture Notes in Computer Science, 4633, (2007) 923–934.
71. Soman, K.P., Ramachandran, K.I., Insight into Wavelets: From Theory to Practice, Second Edition, Prentice-Hall, 2006.
72. Ali, F.E., El-Dokany, I.M., Saad, A.A. ve Abd El-Samie, F.E., Curvelet fusion of MR and CT images, Progress in Electromagnetics Research C, 3 (2008) 215-224.
73. Binh, N.T. ve Thanh, N.C., Object detection of speckle image base on curvelet transform, ARPN Journal of Engineering and Applied Sciences, 2, 3 (2007) 14-16.
74. Murtagh, F. ve Starck, J., Wavelet and curvelet moments for image classification: Application to aggregate mixture grading, Pattern Recognition Letters, 29, (2008) 1557–1564.
75. Eltoukhy, M.M., Faye, I. ve Samir, B.B., Breast cancer diagnosis in digital mammogram using multi scale curvelet transform, Computerized Medical Imaging and Graphics, 34, (2010) 269–276.
76. Eltoukhy, M.M., Faye, I. ve Samir, B.B., A comparison of wavelet and curvelet for breast cancer diagnosis in digital mammogram, Computers in Biology and Medicine, 40, 4 (2010) 384-391.
77. Eltoukhy, M.M., Faye, I. ve Samir, B.B., A statistical based feature extraction method for breast cancer diagnosis in digital mammogram using multi resolution representation, Computers in Biology and Medicine, 42, (2012) 123-128.

78. Huo, H., Song, E., Face recognition using curvelet and selective PCA, *International Conference on Intelligent Control and Information Processing*, 978, 1 (2010) 4244-7050.
79. Gonzalez R. C., Woods R.E., *Digital Image Processing*, 2nd Edition, Prentice Hall, 792s, USA, 2002.
80. Yang, X., Enhancement for road sign images and its performance evaluation, *Optic - Int. J. Light Electron Opt.* (2012).
81. Beylkin, G., Coifman, R. ve Rokhlin, V., Fast wavelet transforms and numerical algorithms, *Comm. on Pure and Appl. Math.*, 44, (1991) 141–183.
82. Candes, E.J., Demanet, L., Donoho, D.L. ve Ying, L., Fast discrete curvelet transforms, *Multiscale Modeling and Simulation*, 5, 3 (2006) 861-899.
83. Candes, E.J., Demanet, L. ve Donoho, D.L., Curvelets – a surprisingly effective nonadaptive representation for objects with edges, *Vanderbilt University Press*, Nashville, TN, (2000) 1-10.
84. Candes, E.J., Demanet, L. ve Donoho, D.L., New tight frames of curvelets and optimal representations of objects with smooth singularities, *Technical Report*, Stanford University, 2002.
85. Demanety L. ve Ying L., Wave atoms and sparsely of oscillatory patterns, appear in *Appl. Comput. Harm. Anal.* , February, 2007.
86. Costaridou, L., *Medical Image Analysis Methods*. CRC Pres, USA, 2005.
87. Liu, H. ve Motoda, H., *Computational methods of feature selection*, Chapman & Hall/CRC, USA, 2008.
88. Fisher, R., The use of multiple measurements in taxonomic problems, *Annals of Human Genetics*, 7, 2 (1936) 179-188.
89. McLachlan, G.J., *Discriminant analysis and statistical pattern recognition*, A John Wiley & Sons, 2004.
90. Theodoridis, S. ve Koutroumbas, K., *Pattern Recognition*, 4th Edition Burlington, USA: Elsevier Inc., 2009.
91. Burget, L., *Complementarity of Speech Recognition Systems and System Combination*, Brno University of Technology, PhD Thesis 2004.
92. Fisher R.A., The statistical utilization of multiple measurements, *Annals of Human Genetics*, 8, (1938) 376-386.
93. Jackson, J.E., *A User's Guide to Principal Components*, Wiley, 2003.

94. Jolliffe, I.T., *Principal Component Analysis*, Springer, New York, 2002.
95. Nixon, M.S., Aguado, A.S., *Feature Extraction and Image Processing*, Academic Press, London. 2008.
96. Barakat, N., Rule-extraction from support vector machines for medical diagnosis-prediction and explanation, ITEE Seminar, The University of Queensland, Australia, 2005.
97. Awad, M. ve Khan, L., *Applications and limitations of support vector machines*, University of Texas at Dallas, 2004.
98. Burges, C.J.C., A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery*, 2, 2 (1998) 1-47.
99. Kecman, V., *Support Vector Machine Basics*, The University of Auckland, School of Engineering Report 616, 2004.
100. Cristianini, N. ve John, S., *An Introduction To Support Vector Machines And Other Kernel-Based Learning Methods*, Cambridge University Press, 2000.
101. Vapnik, V., *The Nature Of Statistical Learning Theory*, Springer, 2000.
102. Sarlak, M. ve Shahrtash, S.M., SVM-based method for high-impedance faults detection in distribution networks, *The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 30, 2 (2011) 431-450.
103. Suykens, J.A.K. ve Vandewalle, J., Least squares support vector machine classifiers, *Neural Processing Letters*, 9, (1999) 293–300.
104. <http://people.revoledu.com/kardi/tutorial/KNN/index.html> Tenomo, K., k-Nearest Neighbor Tutorial, 05 Şubat 2012.
105. Zou, K.H., Hall, W.J. ve Shapiro, D.E., Smooth nonparametric receiver operating characteristic ROC curves for continuous diagnostic tests. *Statistics in Medicine*, 16, (1997) 2143-2156.
106. <http://www.public.asu.edu/~ltang9/papers/ency-cross-validation.pdf> Refaeilzadeh, P., Tang, L., Liu, H., *Cross-Validation*, Arizona State University, 15 Nisan 2008.
107. <http://peipa.essex.ac.uk/info/mias.html> MIAS Data Base, 12 Nisan 2012.

ÖZGEÇMİŞ

Nebi GEDİK, Erzurum doğumludur. İlk, orta ve lise eğitimini Erzurum'da tamamlamıştır. 1994 yılında Atatürk Endüstri Meslek lisesinden, 2001 yılında Fırat üniversitesi Elektrik-Elektronik Mühendisliğinden, 2005 yılında Atatürk Üniversitesi Fen Bilimleri Enstitüsünden mezun olmuştur. 2003-2008 yılları arasında Atatürk Üniversitesinde Öğretim Görevlisi olarak çalışmıştır. 2008 yılından itibaren Karadeniz Teknik Üniversitesi Deniz Ulaştırma İşletme Mühendisliğinde Öğretim Görevlisi olarak çalışmaktadır.

YAYINLAR (Sci)

Gedik N., Atasoy A., "A computer aided diagnosis system for breast cancer detection by using curvelet transform." Turkish Journal of Electrical Engineering & Computer Sciences, 2012