



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

**PULMONER NODÜLLER İÇİN
BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ**

Ahmet TARTAR

Biyomedikal Mühendisliği Anabilim Dalı

Danışman

Prof. Dr. Aydın AKAN

II. Danışman

Yrd. Doç. Dr. Niyazi KILIÇ

Haziran, 2013

İSTANBUL



**İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

**PULMONER NODÜLLER İÇİN
BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ**

Ahmet TARTAR

Biyomedikal Mühendisliği Anabilim Dalı

Danışman

Prof. Dr. Aydın AKAN

II. Danışman

Yrd. Doç. Dr. Niyazi KILIÇ

Haziran, 2013

İSTANBUL

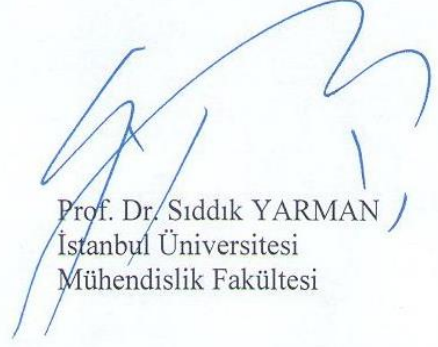
Bu çalışma 24/07/2013 tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği programında Doktora Tezi olarak kabul edilmiştir.

Tez Jürisi

Prof. Dr. Aydın AKAN (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi



Prof. Dr. Sıddık YARMAN
İstanbul Üniversitesi
Mühendislik Fakültesi



Prof. Dr. Osman Nuri UÇAN
İstanbul Aydın Üniversitesi
Mühendislik Mimarlık Fakültesi



Prof. Dr. Sadık KARA
Fatih Üniversitesi
Biyomedikal Mühendislik Enstitüsü



Doç. Dr. Olcay KURŞUN
İstanbul Üniversitesi
Mühendislik Fakültesi



Bu alıřma İstanbul Üniversitesi Bilimsel Arařtırma Projeleri Yürütücü Sekreterliđinin Tez-24014 numaralı projesi ile desteklenmiřtir.

ÖNSÖZ

Bu tezin hazırlanması aşamasında değerli bilgi ve tecrübelerini esirgemeyen ve doktora tez çalışmam boyunca gösterdiği her türlü destek ve yardımlarından dolayı çok değerli danışman hocam Sayın Prof. Dr. Aydın AKAN'a en içten dileklerle teşekkür ederim.

Doktora tez çalışmam sırasında bilgi ve tecrübesini esirgemeyen, yoğun işleri arasında bana her zaman vakit ayıran Sayın Yrd. Doç. Dr. Niyazi KILIÇ'a ve tez izleme komitesinde yer alarak tezime katkıda bulunan Sayın Prof. Dr. Sıddık YARMAN'a ve Sayın Prof. Dr. Osman Nuri UÇAN'a teşekkürlerimi sunarım. Ayrıca her zaman desteklerini yanımda hissettiğim Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Bilimleri Bölümü tüm öğretim üyelerine ve tez sürecinde her daim destek olan İÜ Biyomedikal ve Klinik Mühendisliği Birimi'nde çalışan tüm arkadaşlarıma şükranlarımı sunarım.

Medikal görüntülerin temini ve değerlendirilmesi hususunda yoğun klinik temposu arasında bana vakit ayıran ve tez çalışması sırasında desteğini hiç esirgemeyen İÜ Cerrahpaşa Tıp Fakültesi Radyoloji Bölümü Öğretim Üyesi Sayın Yrd. Doç. Dr. Deniz Çebi OLGUN'a ve doktora tezimde vermiş olduğu maddi destekten ötürü İÜ Bilimsel Araştırma Projeleri Koordinatörlüğü'ne teşekkür ederim.

Eğitim yaşamım boyunca bana hayatta destek olan başta ailemin tüm fertleri olmak üzere, özellikle hayatta tüm sıkıntılara katlanan ve her daim bana destek ve sabır gösteren eşim Yasemin TARTAR'a ve aramıza yeni katılan kızım Neva Nesrin hanımefendiye sonsuz şükranlarımı sunarım.

Haziran, 2013

Ahmet TARTAR

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	i
İÇİNDEKİLER	ii
ŞEKİL LİSTESİ.....	vi
TABLO LİSTESİ	viii
SEMBOL LİSTESİ.....	x
ÖZET.....	xii
SUMMARY	xiv
1. GİRİŞ.....	1
2. GENEL KISIMLAR	3
2.1 KANSER.....	3
2.2 AKCİĞER KANSERİ.....	4
2.2.1 Pulmoner Nodüller.....	5
2.2.2 Akciğer Kanseri Nedenleri	7
2.2.3 Akciğer Kanseri Belirtileri	9
2.2.4 Akciğer Kanserinde Tanı ve Tedavi Yöntemleri.....	10
2.2.4.1 Tanı Yöntemleri.....	10
2.2.4.2 Tedavi Yöntemleri	15
2.2.5 Türkiye’de ve Dünyada Akciğer Kanseri	17
2.3 BİLGİSAYAR TOMOGRAFİ VE GÖRÜNTÜLEME YÖNTEMİ.....	20

2.3.1 Bilgisayar Tomografide Görüntü Oluşumu	23
2.4 BİLGİSAYAR DESTEKLİ TESPİT/TEŞHİS SİSTEMİ	24
2.5 BDT SİSTEMİNE İLİŞKİN LİTERATÜRDE YAPILAN ARAŞTIRMALAR..	26
3. MALZEME VE YÖNTEM	29
3.1 MALZEME	29
3.1.1 Hasta Popülasyonu.....	29
3.1.2 Görüntüleme Protokolü	35
3.2 PULMONER NODÜLLERİN TESPİT EDİLMESİ.....	37
3.3 DALGACIK DÖNÜŞÜMÜ.....	37
3.3.1 Sürekli Dalgacık Dönüşümü	40
3.3.1.1 İki Boyutlu Sürekli Dalgacık Dönüşümü.....	41
3.3.2 Dalgacık Serileri Açılımı.....	42
3.3.3 Ayrık Dalgacık Dönüşümü.....	43
3.3.3.1 İki Boyutlu Ayrık Dalgacık Dönüşümü.....	44
3.3.3.2 Daubechies Dalgacık Dönüşümü.....	48
3.4 TEMEL BİLEŞEN ANALİZİ.....	50
3.5 MORFOLOJİK GÖRÜNTÜ İŞLEME	55
3.6 EN ETKİLİ ÖZNİTELİKLERİN SEÇİMİ	59
3.6.1 mRMR Yöntemi	59
3.7 DESTEK VEKTÖR MAKİNELERİ	61
3.7.1 Doğrusal Destek Vektör Makineleri.....	62
3.7.1.1 Doğrusal olarak Ayrılabilen Durumlar	62
3.7.1.2 Doğrusal olarak Ayrılamayan Durumlar.....	66
3.7.2 Doğrusal Olmayan Destek Vektör Makineleri	68
3.8 PULMONER NODÜLLERİN MALİGN-BENİGN AYRIMININ YAPILMASI	72

3.9 MEDİKAL GÖRÜNTÜLEMEDE KULLANILAN PERFORMANS ÖLÇÜMLERİ.....	76
4. BULGULAR	79
4.1 ÖZNİTELİK ÇIKARMA.....	82
4.1.1 Ayırık Dalgacık Dönüşümü.....	83
4.1.2 Temel Bileşen Analizi	84
4.1.3 Temel Bileşen Analizi İstatistiksel Değerleri.....	86
4.1.4 Morfolojik Görüntü İşleme.....	86
4.2 ÖZNİTELİK SEÇME	86
4.2.1 Ayırık Dalgacık Dönüşümü.....	87
4.2.2 Temel Bileşen Analizi	88
4.2.3 Temel Bileşen Analizi İstatistiksel Değerleri.....	89
4.2.4 Morfolojik Görüntü İşleme.....	89
4.2.5 Öznitelik Seçiminde Yeni Bir Yaklaşım: Hibrid Yaklaşım	90
4.3 SINIFLANDIRMA SONUÇLARI	91
4.3.1 Ayırık Dalgacık Dönüşümü.....	92
4.3.2 Temel Bileşen Analizi	102
4.3.3 Temel Bileşen Analizi İstatistiksel Değerleri.....	108
4.3.4 Morfolojik Görüntü İşleme.....	113
4.3.5 Hibrid Yaklaşım Sonuçları	119
4.3.6 Literatürde Yapılan Çalışmalarla Performans Karşılaştırması	122
4.4. MALİGN- BENİGN SINIFLANDIRMA SONUÇLARI.....	124
5. TARTIŞMA VE SONUÇ	127
5.1 PULMONER NODÜL TESPİT SONUÇLARININ DEĞERLENDİRİLMESİ	127
5.2 MALİGN BENİGN AYRIM SONUÇLARININ DEĞERLENDİRİLMESİ.....	130

KAYNAKLAR	132
ÖZGEÇMİŞ.....	141

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Akciğerdeki temel yapılar [10].	4
Şekil 2.2: BT görüntüsünde soliter pulmoner nodül örüntüsü.	6
Şekil 2.3: BT görüntüsünde multipl pulmoner nodüller.	7
Şekil 2.4: Bilgisayar Tomografi Cihazı.	12
Şekil 2.5: Bronkoskopik Görüntüleme [24].	13
Şekil 2.6: Türkiye’de yıllara ve cinsiyete göre toplam kanser insidansı [32].	18
Şekil 2.7: Türkiye’de erkeklerde en sık görülen 10 kanser türünün insidansı [32].	19
Şekil 2.8: Kadınlarda en sık görülen 10 kanser türünün insidansı [32].	19
Şekil 2.9: Bilgisayar Tomografi cihazı içyapısı [41].	21
Şekil 2.10: BT cihazında Xenon gazlı detektörlerin şematik gösterimi [40].	21
Şekil 2.11: BT’de spiral görüntüleme [41].	22
Şekil 2.12: Bir BDT sistemi temel yapısı.	25
Şekil 3.1: BT görüntülerinden elde edilen 2D pulmoner nodüllerin elde edilmesi.	30
Şekil 3.2: BT görüntülerinden elde edilen gerçek nodül örüntüsü örnekleri.	30
Şekil 3.3: BT görüntülerinden elde edilen nodül olmayan örüntü örnekleri.	31
Şekil 3.4: Veri setindeki hastaların cinsiyete göre yaş dağılımlarını gösteren histogram.	32
Şekil 3.5: Sağ ve sol akciğerin 3 farklı bölgeye ayrımı ve nodül sayıları dağılımı.	33
Şekil 3.6: Veri kümesindeki kullanılan pulmoner nodüllerin çap dağılımını gösteren histogram.	34
Şekil 3.7: CODONICS arayüz yazılımı.	36
Şekil 3.8: Dalgacık Dönüşümünde kullanılan pencere ve çözünürlük hücreleri [87].	39
Şekil 3.9: Dalgacık dönüşümünde bir işaretin altbandlara ayrışımı [88].	44
Şekil 3.10: İki boyutlu ADD kullanarak Tek Seviyeli görüntü ayrıştırma işlemi [90].	47
Şekil 3.11: ADD ile 2 seviyeli görüntü ayrıştırma işlemi [93].	47
Şekil 3.12: ADD’de ayrıştırma ve birleştirme süreçleri şematik gösterimi [88].	48
Şekil 3.13: Daubechies dalgacık tipleri [93].	50
Şekil 3.14: İki boyutlu pulmoner nodül örüntüsü.	56
Şekil 3.15: İki boyutlu uzayda iki sınıfa ait ayırıcı düzlem [107].	64
Şekil 3.16: Doğrusal olarak ayrılamayan durum örneği [107].	66
Şekil 3.17: Giriş uzayının çok boyutlu Öznitelik uzayına dönüşümü [107].	68
Şekil 3.18: Akciğerde nodül lokalizasyonu için ayrıştırılan bölgeler.	74
Şekil 3.19: Benign ve Malign huylu tümör örnekleri.	74
Şekil 4.1: Pulmoner nodüllerin tespiti için önerilen BDT sistemi.	81
Şekil 4.2: Malign ve Benign ayrımı için önerilen BDT sistemi.	82
Şekil 4.3: Ayrık dalgacık dönüşümü ile pulmoner nodül örüntüsünün alt bölgelere bölünmesi.	84
Şekil 4.4: TBA sonucu elde edilen sonuç matrisi.	85
Şekil 4.5: Haar dalgacık tipi için tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.	97
Şekil 4.6: db4 dalgacık tipi için tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.	102
Şekil 4.7: TBA’da tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.	108

Şekil 4.8: TBA istatistiksel değerlerde tüm çekirdek fonksiyonlarının öznelik sayısına göre AUROC değeri eğrileri.....	113
Şekil 4.9: TBA istatistiksel değerlerde tüm çekirdek fonksiyonlarının öznelik sayısına göre AUROC değeri eğrileri.....	119
Şekil 4.10: Malign Benign sınıflandırmasında Sınıflandırıcılara ait ROC eğrileri.	126

TABLO LİSTESİ

Sayfa No

Tablo 3.1: Pulmoner nodüllerin çap aralığına göre frekans dağılımı.....	34
Tablo 3.2: Malign, benign ve takip teşhisli örüntülerin dağılımı.....	35
Tablo 3.3: Sensation-16 Bilgisayar Tomografi cihazı görüntüleme protokolü.....	36
Tablo 3.4: Morfolojik şekil bilgisine dayalı iki boyutlu geometrik özellikler.....	58
Tablo 3.5: DVM’de kullanılan temel kernel fonksiyonları ve parametreleri [111].....	70
Tablo 3.6: Malign ve benign nodüllerin sınıflandırılması için oluşturulan öznelikler.....	73
Tablo 3.7: BT cihazında Hounsfield Unit (HU) cinsinden yoğunluk değerleri [113].....	75
Tablo 3.8: Bir BDT sisteminde hata matrisi.....	76
Tablo 4.1: Dalgacık dönüşümünde kullanılan istatistik değerler.....	87
Tablo 4.2: a) Örüntüden alınan 7x7 piksel boyutlu öznelik matrisi, b) mRMR sonucu en iyi özneliklerin sıralaması.....	88
Tablo 4.3: mRMR metodu ile en iyi özneliklerin sıralaması.....	89
Tablo 4.4: Haar dalgacık tipi kullanılarak tüm öznelikler (24 öznelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	93
Tablo 4.5: Haar dalgacık tipi kullanılarak 20 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	94
Tablo 4.6: Haar dalgacık tipi kullanılarak 15 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	95
Tablo 4.7: Haar dalgacık tipi kullanılarak 10 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	96
Tablo 4.8: db4 dalgacık tipi kullanılarak tüm öznelikler (24 Öznelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	98
Tablo 4.9: db4 dalgacık tipi kullanılarak 20 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	99
Tablo 4.10: db4 dalgacık tipi kullanılarak 15 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	100
Tablo 4.11: db4 dalgacık tipi kullanılarak 10 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	101
Tablo 4.12: TBA’da tüm öznelikler (49 öznelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	103
Tablo 4.13: TBA’da 45 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	104
Tablo 4.14: TBA’da 30 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	105
Tablo 4.15: TBA’da 20 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	106
Tablo 4.16: TBA’da 10 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	107
Tablo 4.17: TBA istatistiksel 6 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	109

Tablo 4.18: TBA istatistiksel 5 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	110
Tablo 4.19: TBA istatistiksel 4 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	111
Tablo 4.20: TBA istatistiksel 3 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	112
Tablo 4.21: Morfolojik görüntü işleme ile 10 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	114
Tablo 4.22: Morfolojik görüntü işleme ile 9 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	115
Tablo 4.23: Morfolojik görüntü işleme ile 8 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	116
Tablo 4.24: Morfolojik görüntü işleme ile 6 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	117
Tablo 4.25: Morfolojik görüntü işleme ile 5 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	118
Tablo 4.26: Hibrid yaklaşım (en iyi 40 adet öznitelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	120
Tablo 4.27: Hibrid yaklaşım (en iyi 30 adet öznitelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.....	121
Tablo 4.28: Literatürdeki BDT sistemlerinin performans karşılaştırması.	122
Tablo 4.29: Malign Benign sınıflandırma performans sonuçları.	125
Tablo 4.30: Bagging Rastgele Orman Topluluk Sınıflandırıcısına ait malign benign sınıflandırma performans sonuçları.	126

SEMBOL LİSTESİ

$\psi(t)$: Bir işaretin örnek fonksiyonu
$f(x)$: Dalgacık dönüşümü alınacak işaret
$\Psi_{a,b}(x)$: Dalgacık taban fonksiyonu
$W_f(a,b)$: $f(x)$ 'in dalgacık dönüşümünü
$\Psi(x)$: Ana dalgacık fonksiyonunu
$W_f(a,b_x, b_y)$: İki boyutlu sürekli dalgacık dönüşümü
$\Psi_{a,b_x,b_y}(x,y)$: Dalgacık taban fonksiyonu
$C_{j,k}$: Seri katsayıları
$h[.]$: Alçak geçiren süzgeç
$g[.]$: Yüksek geçiren süzgeç
$\Phi(x,y)$: İki boyutlu ölçekleme fonksiyonunu
$\psi^H(x,y)$: İki boyutlu Yatay dalgacık fonksiyonu
$\psi^V(x,y)$: İki boyutlu Dikey dalgacık fonksiyonu
$\psi^D(x,y)$: İki boyutlu Köşegen dalgacık fonksiyonu
$db4$: 8 adet ölçekleme katsayılı daubechies dalgacığı
C_k^{N-1+k}	: Binominal katsayıları
N	: Gözlem sayısı
P	: Değişken sayısı
X	: Gözlem matrisi
\bar{X}	: Veri matrisinin ortalama değeri
σ	: Standart sapma
σ^2	: Varyans
S	: Kovaryans matris
λ	: Özdeğer
E	: Özvektörler matrisi
I	: Birim matris
Λ	: Özdeğerler köşegen matrisi
A	: Alan
P	: Çevre
$p(x,y)$: Birleşik olasılık dağılım fonksiyonu
$p_1(x)$: X değişkenine ait marjinal olasılık dağılım fonksiyonu
$p_2(x)$: Y değişkenine ait marjinal olasılık dağılım fonksiyonu
$I(x,c)$: Öznitelik x ve c sınıf arasındaki benzerlik
w	: Ağırlık vektörü
b	: Eşik değeri
d	: En uygun sınır uzunluğu mesafesi
$\ w\ $: w 'nin normu
α_i	: Langrange çarpanları
ξ_i	: Gevşek değişkenler
C	: Düzenleyici parametre
$\phi(x)$: Yüksek dereceli öznitelik uzayındaki eğitim kümesi
K	: Çekirdek fonksiyonu

γ ,	: Kernel Boyutu
y	: Gerçek deęer
\hat{y}	: Kestirilen deęer
n	: Toplam veri sayısı
BT	: Bilgisayar Tomografi
BDT	: Bilgisayar Destekli Tespit/Teşhis
CAD	: Computer Aided Detection/Diagnosis
SPN	: Soliter Pulmoner Nodül
PET	: Pozitron Emisyon Tomografisi
ATS	: American Thoracic Society
ERS	: European Respiratory Society
MR	: Manyetik Rezonans görüntüleme
ROI	: Region of Interest (ilgili alan)
2D	: İki boyutlu
DICOM	: Digital Imaging and Communications in Medicine
KZFD	: Kısa Zamanlı Fourier Dönüşümü
ADD	: Ayrık Dalgacık Dönüşümü
PCA	: Principal Component Analysis
TBA	: Temel Bileşen Analizi
mRMR	: Asgari Artıklık Azami İlişkisellik (Minimum Redundancy Maximum Relevance)
DVM	: Destek Vektör Makinesi
ERM	: Deneysel Risk Minimizasyonu (Empirical risc minimization)
SRM	: Yapısal Risk Minimizasyonu (Structural risc minimization)
RBF	: Radyal Tabanlı Fonksiyon
HU	: Hounsfield Unit
DP	: Doğru pozitif
YP	: Yanlış Pozitif
YN	: Yanlış Negatif
DN	: Doğru Negatif
RMSE	: Ortalama Kare hata Kökü (Root mean squared error)

ÖZET

PULMONER NODÜLLER İÇİN BİLGİSAYAR DESTEKLİ TEŞHİS SİSTEMİ

Pulmoner nodüllerin erken teşhisi, akciğer kanserinin teşhis ve tedavisi için oldukça büyük önem arz etmektedir. Son yıllarda teknolojinin hızlı gelişmesi ile birlikte küçük boyuttaki pulmoner nodüllerin yüksek çözünürlükle görüntülenmesine olanak sağlayan çok detektörlü bilgisayar tomografi (BT) sistemleri kullanılmaktadır. Bu durum radyologlara uzun ve yorucu bir değerlendirme aşamasını beraberinde getirmektedir. Bu amaçla son yıllarda tıp alanında verimli kullanım alanına sahip olan Bilgisayar Destekli Tespit (BDT) sistemleri, tıbbi görüntüler üzerindeki anormalliklerin tespitinde oldukça sık kullanılmaktadır. Bu açıdan BDT sistemleri, hastalığın teşhisi aşamasında medikal görüntüler üzerinde ileri görüntü işleme ve örüntü tanıma teknikleri kullanılarak hekime ikinci bir gözden geçirme olanağı sunması, hızlı karar verme yeteneğine sahip olması ve insan hatasının teşhisteki rolünü azaltması açısından son derece önemlidir.

Tez çalışmasında literatüre alternatif olabilecek BT görüntülerinden pulmoner nodüllerin tespitine yönelik yeni iki farklı BDT sistemi önerilmiştir. Biri, BT görüntülerinden pulmoner nodül örüntülerinin tespitine yönelik bir sistemdir. Diğeri ise BT görüntülerinden pulmoner nodül örüntülerinin teşhis açısından malign ve benign olduğuna karar veren yeni bir bilgisayar destekli teşhis sistemidir. Çalışmada BT görüntülerinden pulmoner nodüllerin teşhisi için hibrid öznitelikler kullanılarak yeni bir sınıflandırma yaklaşımı sunulmaktadır. Pulmoner nodüllerin tespitinde dört farklı öznitelik çıkarma yöntemi kullanılmıştır. Nodül örüntülerinin malign ve benign ayrımı, hastaların risk faktörleri ve morfolojik görüntü işleme yaklaşımları kullanılarak gerçekleştirilmiştir. Destek vektör makineleri çekirdek fonksiyonları kullanılarak her bir yöntemin sınıflandırma performans ölçümleri elde edilmiştir.

Pulmoner nodüllerin tespiti için önerilen hibrid yaklaşım ile % 78.7 sınıflandırma doğruluğu, % 78.8 duyarlılık ve % 76.4 seçicilik değerleri elde edilmiştir. Malign ve

benign huylu nodüllerin ayrımı için önerilen sistemde, % 86.8 sınıflandırma doğruluğu olmak üzere benign sınıf için % 94.7 duyarlılık ve 0.975 AUROC; malign sınıf için % 80.0 duyarlılık ve 0.889 AUROC; takibi gereken belirsiz sınıf için % 77.8 duyarlılık ve 0.862 AUROC olarak performans değerleri hesaplanmıştır.

SUMMARY

COMPUTER AIDED DIAGNOSIS SYSTEM FOR PULMONARY NODULES

Early detection of pulmonary nodules is extremely important for the diagnosis and treatment of lung cancer. With the rapid improvement of technology in recent years, Multi-detector computer tomography (CT) systems, providing to be viewed the small pulmonary nodules by high resolution, have been used. This case is long and tiring process for radiologists. Recently, Computer-Aided Detection (CAD) systems that having an efficient usage area in the medicine have widely been utilized for the detection of abnormalities on medical images. In this respect, CAD systems are extremely important in the diagnosis of disease in terms of offering a second interpretation opportunity for physician, to be a quick decision making ability and to reduce the diagnosis role of human error by using advanced image processing and pattern recognition techniques on the medical images.

In this thesis study, two different CAD systems have newly been proposed for pulmonary nodule detection from computer tomography images as an alternative system for the literature. One is a system aiming at the detection of pulmonary nodule patterns on CT images. The other is a novel computer-aided diagnosis system that deciding the type of the pulmonary nodule patterns as malign or benign from the CT images. In the study, a new classification approach for pulmonary nodules from CT imagery is presented by using hybrid features. Four different feature extraction methods are used on the detection of pulmonary nodules. The overall detection performance is evaluated using various classifiers. The results are compared to similar techniques in the literature by using standard measures. Malign and benign differentiation of pulmonary nodules has been provided by using the risk factors of the patients and morphological image processing approaches. Classification performance measurements are obtained for each method proposed by using the kernel functions of support vector machines.

For pulmonary nodule detection, the proposed approach gives 78.7 % classification accuracy, 78.8 % sensitivity and 76.4 % specificity values with the hybrid features. On the differentiating of malign and benign nodules, classification performance values are calculated as 94.7 % sensitivity and 0.975 AUROC for benign class; 80.0 % sensitivity and 0.889 AUROC for malign class; 77.8 % sensitivity and 0.862 AUROC for uncertain class by 86.8 % accuracy of the classifier.

1. GİRİŞ

Akciğer kanseri bugün dünyada kanser ölümlerinin başlıca nedenlerinden biri olarak kabul edilmektedir. Özellikle gelişmiş endüstriyel ülkelerde hızlı bir şekilde akciğer kanser vakaları artış göstermektedir [1, 2]. Bu durum kanser hastalıklarına karşı savaşmada akciğer kanseri tedavisini oldukça önemli kılmaktadır.

Akciğer kanserine neden olan pulmoner nodüllerin erken teşhisi hastanın hayatta kalma şansını artırması açısından son derece önemlidir [3]. Günümüzde pulmoner nodüllerin tespiti için kullanılan çok detektörlü bilgisayar tomografi sistemleri ile küçük boyutlardaki şüpheli kanser lezyonları görüntülenebilmektedir. Hastalığın teşhisi için bilgisayar tomografi (BT)'den alınan her bir görüntü üzerinde uzman radyologlar tarafından ayrıntılı bir inceleme yapılması gerekmektedir. Ancak her bir görüntünün değerlendirilmesi oldukça uzun zaman harcanmasına ve dolayısıyla radyologların yorum performansının olumsuz bir şekilde etkilenmesine neden olmaktadır. Bazı klinik değerlendirmelerde bir uzman hekimin aynı hastaya yaptığı teşhis ile başka bir uzman hekimin teşhisi arasında farklılıklara sıklıkla rastlanmaktadır [3].

Son yıllarda teknolojinin hızla ilerlemesiyle birlikte tıp alanında verimli kullanım alanına sahip olan Bilgisayar Destekli Tespit (BDT) (*Computer Aided Detection, CAD*) sistemleri, tıbbi görüntüler üzerindeki anormalliklerin tespitinde oldukça sık kullanım alanına sahiptir. Özellikle akciğer göğüs BT görüntülerinden pulmoner nodüllerin tespit edilmesine yönelik araştırmalar son yıllarda hızla devam etmektedir [4]. Klinik alanda birçok BDT sistemleri kullanılmaktadır [5]. Tıbbi uygulamalarda hekimler için yardımcı bir sistem olarak tanımlanan BDT sistemleri, meme kanseri teşhisinde mamografi görüntülerinden kalsifikasyonların saptanması amacıyla kullanılmaktadır. Bu açıdan daha güvenilir ve doğru teşhis sağlayabilmek için BDT sistemlerinin geliştirilmesi son yıllarda büyük önem kazanmıştır [6, 7, 8, 44]. BDT sistemleri radyologlara doğru pozitif bulgularının bulunmasında ve pulmoner nodüllerin erken aşamada tespit edilmesinde önemli katkı sağlamaktadır. Biyomedikal mühendisliği

açısından BDT sistemleri, hastalık teşhisine ait karar verme sürecinde medikal görüntüler üzerinde ileri görüntü işleme ve örüntü tanıma teknikleri kullanılarak hekime ikinci bir gözden geçirme olanağı sunması, hızlı karar verme yeteneğine sahip olması ve insan hatasının teşhisteki rolünü azaltması açısından son derece önemlidir [43, 68].

Tez çalışmasında literatüre alternatif olabilecek BT görüntülerinden pulmoner nodüllerin tespitine yönelik yeni iki farklı BDT sistemi önerilmiştir. Biri, BT görüntülerinden pulmoner nodül örüntülerinin tespitine yönelik bir sistemdir. Diğeri, BT görüntülerinden nodül olduğuna karar verilen pulmoner nodül örüntülerinin teşhis açısından malign ve benign huylu olduğuna karar veren yeni bir bilgisayar destekli teşhis sistemidir.

Sunulan tez çalışması ile ilgili olarak Bölüm 2’de akciğer kanseri, belirtileri, nedenleri, tanı ve tedavi yöntemlerinin yanı sıra Türkiye’de ve dünyada akciğer kanseri dağılımı ile genel bir BDT sistemi yapısı ve literatürde yapılan araştırmalar ile ilgili bilgilere yer verilmiştir. Bölüm 3’te, veri setinde kullanılan hastaların yaş ve cinsiyet dağılımına, hastaların BT görüntülerine ait istatistiksel bilgilere ve önerilen BDT sisteminde kullanılan yöntemler hakkında ayrıntılı bilgilere yer verilmektedir. Bölüm 4’te ise her bir yöntem için önerilen BDT sistemlerine ait sonuçlar incelenmektedir. Son olarak Bölüm 5’te elde edilen sonuçlara ilişkin değerlendirme ve önerilerde bulunmaktadır.

2. GENEL KISIMLAR

2.1 KANSER

Kanser, vücudun belli bir bölgesindeki hücrelerin kontrolsüz veya anormal bir şekilde çoğalıp, o bölgenin de dışına yayılmasından ileri gelen hastalıkların genel adı olarak tanımlanmaktadır. Kanser kelimesi belli bir hastalığı değil, aşırı hücre çoğalmaları ve doku büyümeleri şeklinde kendini belli eden çeşitli bozuklukları ifade etmektedir.

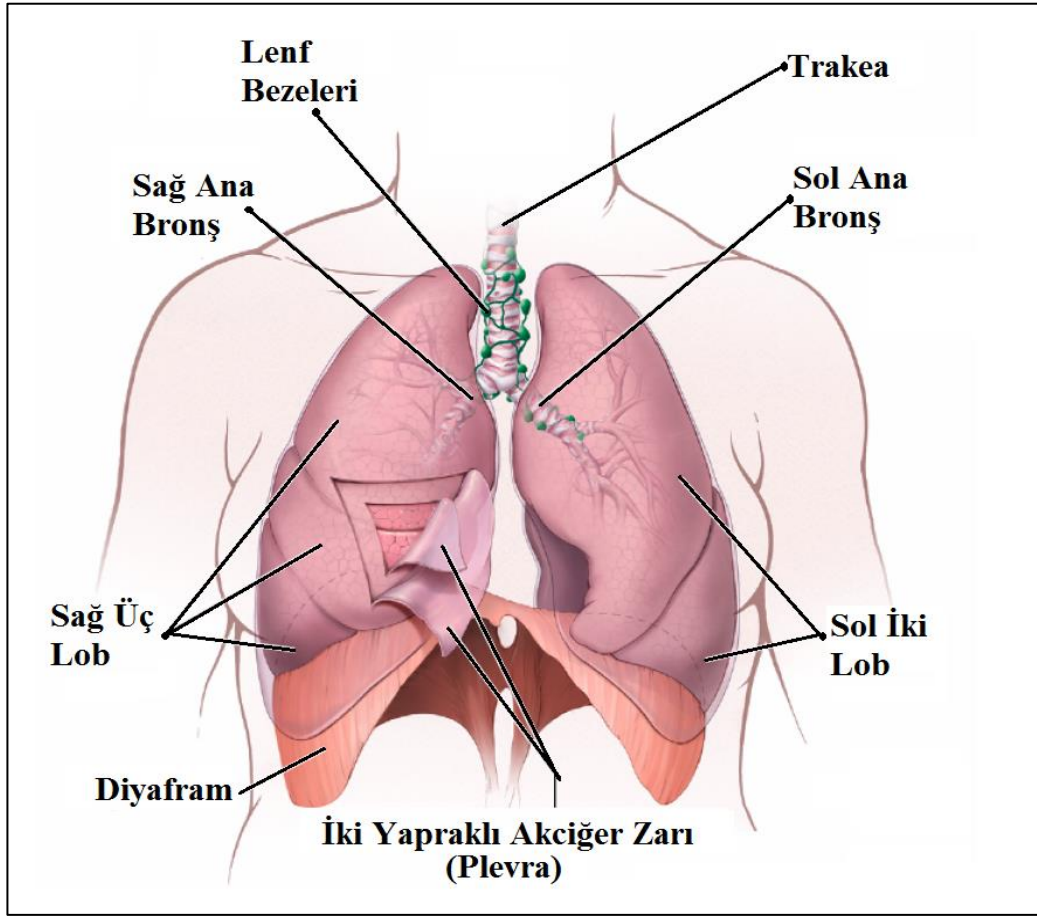
Vücudun tüm organları hücrelerden oluşmaktadır. Sağlıklı vücut hücreleri (kas ve sinir hücreleri hariç) bölünebilme yeteneğine sahiptirler. Hücreler bu yeteneklerini ölen hücrelerin yenilenmesi ve vücut içinde veya vücut dışında yaralanan dokuların onarılmasında kullanırlar. Ancak hücrelerin bu yetenekleri sınırlıdır ve sonsuz sayıda bölünebilme yeteneğine sahip değildirler. Her hücrenin hayatı boyunca belli bir bölünebilme sayısı vardır. Sağlıklı bir hücre gerektiği yerde ne kadar bölüneceğini bilmektedir. Bu durum bireyin yaşamını devam ettirirken sağlıklı kalmasını sağlamaktadır. Eğer bu hücreler gereksiz olarak bölünmeye başlar ise, yeni bir doku kitlesi oluştururlar. Bu normal dışı kitleye *tümör* denmektedir. Tümörler, *benign* (iyi huylu) ve *malign* (kötü huylu) olmak üzere temelde iki sınıfta değerlendirilmektedir.

Benign tümörler kanser değildir. Eğer ameliyatla tümör çıkartılırsa hastaların çoğunda tekrarlanmazlar. Aynı zamanda benign tümörlerindeki hücreler vücudun diğer bölgelerine yayılmazlar. Bu tür tümörler nadiren hayatı tehdit edici nitelik taşımaktadır.

Malign tümörler ise kanser hücreleridir. Bu kanser hücreleri yakındaki doku ve organlara yayılabilir niteliktedir. Ayrıca bu hücreler kan dolaşımına ve lenf sistemine girerek *metastaz* adı verilen vücudun diğer bölgelerine yayılma özelliği göstermektedir [3, 9].

2.2 AKCİĞER KANSERİ

Kanserler, genel olarak ortaya çıktığı dokuya göre adlandırılmaktadır. Akciğer kanseri, akciğer dokularındaki hücrelerin kontrolsüz bir şekilde çoğaldığı bir hastalıktır. Akciğerlerin başlıca görevi, vücut hücrelerinin atık maddesi olan karbondioksiti vücuttan atma ve yaşamın temel gereksinimi oksijenin vücuda alınmasını sağlamaktır. Solunum sisteminin bir parçası olan akciğerler, koni şeklinde süngerimsi yapıya sahip bir organdır. Şekil 2.1’de görüldüğü üzere, sağ akciğerde (sol akciğere göre daha büyük olup) 3 (üç) kısım (lob), sol akciğerde ise 2 (iki) lob bulunmaktadır. Akciğer başlıca *bronş* denen hava içeren tüplerden, *alveol* denen hava keseciklerinden, *kan damarları* ve *lenf (akkan) bezeleri*’nden oluşmaktadır. Ayrıca akciğerler, karın boşluğundan *diyafram* ile ayrılmakta olup, üzerini çevreleyen *plevra* adlı bir zar bulunmaktadır.



Şekil 2.1: Akciğerdeki temel yapılar [10].

Akciğeri meydana getiren hücrelerden biri kanserleştiğinde, bu hücre kontrolsüz bir şekilde çoğalmaya başlamakta ve vücut bu çoğalmayı önleyememektedir. Hücrenin kanserleşmesi, mutasyon adı verilen genetik şifrenin (DNA) bozulması sonucunda oluşmaktadır. Hücrenin mutasyona uğradıktan sonra kanserleşmesi için önce akciğerin iç yüzeyini döşeyen hücreler (epitelyum hücreleri) normal olmayan bir şekilde çoğalmaya başlamaktadır. Ardından hücre normalin dışında büyüme (displazi) özelliği göstererek hücrenin kanserleşmesine neden olmaktadır. Hücrede kanserleşme olduktan sonra bile, hücrenin özelliklerinde değişme ve mutasyon devam etmektedir. Bu durum hastalığın kötüleşerek daha ileri düzeylere çıkmasına neden olmaktadır. Akciğer kanserlerinin erken teşhis ve tedavisi önemli ölçüde hayatta kalma olasılığını artırmaktadır [10, 11].

2.2.1 Pulmoner Nodüller

Pulmoner nodüller, genellikle çapı 3 cm'den küçük, akciğer parankimi ile çevrili, beraberinde herhangi patolojinin eşlik etmediği, tek, yuvarlak veya oval görünüme sahip lezyonlar olarak tanımlanmaktadır. Nodülde büyüme gerçekleşirse pulmoner nodül, kitle olarak adlandırılmaktadır. Bir kitle, pulmoner nodüle göre daha yüksek kanser olasılığını ifade etmektedir [12].

Pulmoner nodüller, soliter pulmoner nodüller ve multipl pulmoner nodüller olmak üzere iki kısımda değerlendirilmektedir. Soliter Pulmoner Nodüller (SPN), uzun zamandan beri klinisyen ve radyologların ilgi odağı haline gelmiştir. Soliter pulmoner nodül, göğüs grafilerinde rastlantısal olarak tespit edilebilmektedir. Tüm göğüs grafilerinin % 0.09-0.2'sinde veya 1000'de 1-2 oranında SPN'ye rastlanmaktadır (Şekil 2.2).




Şekil 2.2: BT görüntüsünde soliter pulmoner nodül örüntüsü.

Soliter pulmoner nodül, göreceli olarak ileri yaş hastalarda primer bir akciğer karsinomasını işaret edebilmektedir. Genel popülasyonda rutin radyolojik araştırmalarda tespit edilen SPN'lerin % 5'i karsinom olarak rapor edilse de, 50 yaş üzeri hastalarda tespit edilen SPN'lerin % 50'den fazlası karsinoma olduğu belirtilmiştir [12].

Multipl pulmoner nodüller ise, akciğer parankiminde birden çok sayıda lezyonun bulunması durumudur (Şekil 2.3). Hastanın tedavisi sürecinde balgam örneklerinin incelenmesi, radyolojik görüntüleme yöntemleri (BT, PET) gibi noninvaziv tanı yöntemleri uygulanmaktadır. Bunun yanında bronkoskopi, perkütan iğne biyopsisi ve video yardımcı torakoskopik cerrahi (vats) gibi invaziv tanı yöntemlerine de başvurulmaktadır.

Elde edilen görüntülerde lezyonun yerinin tespit edilebilmesi ilk aşamada büyük önem arz etmektedir. Ayrıca radyologlar tarafından tespit edilen pulmoner nodüllerin, malign-benign ayrımının yapılabilmesi klinik anlamda teşhis ve tedavide büyük ölçüde kolaylıklar sağlamaktadır.



Şekil 2.3: BT görüntüsünde multipl pulmoner nodüller.

2.2.2 Akciğer Kanseri Nedenleri

Kanserin nedeni tam olarak bilinmemekle beraber akciğer kanseri oluşumunu tetikleyen bazı etkenler bulunmaktadır. Bunların arasında yaş, cinsiyet ve aile öyküsü gibi nedenler kanserin oluşumu aşamasında doğal faktörler olarak tanımlanmaktadır [13]. Tüm kanser türlerinde olduğu gibi akciğer kanserinin başlıca nedeni çevresel faktörler olarak kaydedilmektedir [14]. Akciğer kanseri oluşumunda aşağıdaki faktörler yer almaktadır:

- Sigara ve alkol kullanımı
- Radon
- Radyasyon (radyoizotoplar, X-ışını, güneş ışığı vb.)
- Beslenme
- Endüstriyel Ürünler (Asbest, arsenik, uranyum vb.)
- Genetik Yatkınlık
- Meslek
- Diğer Faktörler (Hava kirliliği, ağır metaller, virüsler vb.)

Sigara, akciğer kanserinin en sık görülen nedenlerinden biridir. Bunun yanı sıra sigara içmeyen bireylerde de akciğer kanseri görülebilmektedir [15]. Özellikle gelişmiş ülkelerde akciğer kanserinden sonuçlanan ölümlerin erkeklerde % 92-94'ünün, kadınlarda % 78-80'inin sigaradan kaynaklanmaktadır. Bu kapsamda ülkelerin tükettiği sigara miktarı ile akciğer kanseri ölüm oranı arasında doğrusal bir ilinti olduğu bildirilmiştir [16]. Aynı zamanda sigara içilen ortamda bulunarak sigara dumanına maruz kalma olarak tanımlanan pasif sigara içiciliği, sigara kullanmak gibi akciğer kanseri açısından risk oluşturmaktadır. Sigara ve tütün ürünlerinin bırakılması ile akciğer kanseri oluşma riski azalmakta, akciğer kanseri gelişme riski sigarayı bıraktıktan yaklaşık 15-20 yıl sonrasında hiç içmeyenlerin düzeyine yaklaşmaktadır [16].

Radon gazı, kimyasal bir gaz olup uranyumun parçalanma ürünüdür. Solunum yolu ile alındığında akciğer epitel hücreleri ile etkileşerek kansere neden olmaktadır. Toprakta doğal olarak bulunan radon gazı, iyi havalandırılmayan ev ve işyerlerinin altındaki topraktaki miktarına bağlı olarak kapalı mekânlarda daha yüksek seviyelerde olmaktadır. Radon gazı, Amerika Birleşik Devletleri'nde akciğer kanserinin en sık (%10) rastlanan nedeni olup, her yıl 6 000 ile 360 000 akciğer kanserli kişinin ölümüne sebep olduğu belirtilmiştir [16].

Uzun süre cildin güneş ışığında kalması, doğrudan X-ışınlarına ve radyoizotoplara (kobalt, amerisyum vb.) maruz kalınması akciğer kanseri riskini artırmaktadır.

Kötü beslenme alışkanlıkları, doğal olmayan veya genetiği değiştirilmiş gıdaların tüketilmesi akciğer kanserine yakalanma olasılığını artırmaktadır.

Akciğer kanseri etiyolojisinde önemli rol oynayan kanserojenlerden biri de “ak toprak” olarak da bilinen *asbest*'tir. Özellikle gemi, izolasyon ve otomotiv sanayisinde sıklıkla kullanılmaktadır. Asbestin kullanıldığı bazı meslek gruplarında (gemi yapımı, yapı malzemeleri çıkarımı, çanak-çömlek imalatı, matbaa işleri ve madencilik vb.) çalışan kişilerde akciğer kanseri daha sık görülmektedir [17]. Genel olarak akciğer kanseri riskini artıran en önemli faktör, kanserojen maddelerin uzun süre boyunca vücutta solunumundan kaynaklanmaktadır.

Akciğer kanserinde kalıtsal yatkınlık oluşturan faktörlerin varlığı ileri sürülmektedir. Kronik karsinojen maruziyeti sonucunda hücrenin genetik yapısında hasar oluşmaktadır. Ancak hücrenin kanserleşmesinin temelinde hücre çoğalmasını kontrol eden genlerdeki değişiklik yatmaktadır [17].

2.2.3 Akciğer Kanseri Belirtileri

Akciğer ve bronş sisteminin ağrı duyusu içermemesi ve ilk belirti (*sempptom*) olan öksürüğün sigara içenler tarafından bir hastalık semptomu olarak görülmemesi nedeniyle akciğer kanseri tanısı çoğunlukla ileri evrelerde konulabilmektedir. Genel olarak semptomlar, tümörün lokal büyümesine, diğer organlara metastatik durumuna veya metastatik olmayan kanserli hücrelerin vücudun diğer dokularına dolaylı etkilerine (*paraneoplastik sendromlar*) bağlıdır [18]. Akciğer kanserinin başlıca belirtileri aşağıda verilmektedir [19]:

- Öksürük
- Nefes darlığı, Hırıltılı solunum
- Kanlı balgam çıkarma ve kan tükürme
- Egzersiz yapmada zorlanma
- Ses kısıklığı
- Kol ve omuz ağrısı

- Kemik ağrısı
- Yutarken zorlanma ve takıntı hissi
- Anemi (Kansızlık)
- Baş ağrısı
- Boyunda ve yüzde şişlik oluşumu
- Cilt ve cilt-altı nodülleri
- İştahsızlık, halsizlik ve kilo kaybı
- Göğüs kafesi içinde lenf sıvısı birikimi
- Ateş, çarpıntı ve bayılma (senkop)
- Göz kapağında düşme ve gözün içine çökmesi vb.

Kanser dokusunun göğüs boşluğunda aşırı büyümesi ile vücuttaki diğer hayati organlara bası yapabilir ve yutma güçlüğü, kalp yetmezliği gibi semptomlar verebilmektedir. Aynı şekilde oluşan kanser hücreleri vücudun diğer organ veya dokusuna yayılabilmektedir. Özellikle beyin, karaciğer, kemik ve böbrek üstü bezleri başta olmak üzere kanser, bulunduğu yere göre farklı semptomlar verebilmektedir. Hatta kanser hücreleri göze bile yayılım göstererek görme kayıplarına sebep olabilmektedir [20, 21].

American Thoracic Society (ATS) ve European Respiratory Society (ERS) verilerine göre, akciğer kanserinde öksürük % 8-75, kilo kaybı % 0-68, nefes darlığı (*dispne*) % 3-60, göğüs ağrısı % 20-49 ve öksürük yoluyla kan tükürme (*hemoptizi*) % 6-35 oranlarında semptomlar görülmektedir [22].

2.2.4 Akciğer Kanseri Tanı ve Tedavi Yöntemleri

2.2.4.1 Tanı Yöntemleri

Akciğer kanseri yönünden hastaların semptom ve bulguları hastalığın teşhis ve tedavisi için son derece önemlidir. Öksürük ve balgam kronik sigara içicilerinde oldukça sık görülmektedir. Balgamda kan olması, göğüste ağrılar, nefes darlığı gibi şikâyetleri bulunmaktadır. Aynı şekilde hastada iştahsızlık, yorgunluk, kilo kaybı gibi sistemik semptomlar gözlemlenebilmektedir. Bazen hastalığın farklı organlara erken yayılımından ötürü semptomlar gözlemlenebilmektedir. Hekim tarafından yapılan fizik muayenede

herhangi bir bulguya rastlanamaya bilmektedir. Vena kava sendromunda yüzde ve göz kapaklarında ödem, boyunda iki taraflı şişlik, göğüs duvarlarında periferik damarların belirginleşmesi şeklinde ortaya çıkmaktadır. Benzer şekilde uzak metastazlarla ilgili metastazın olduğu bölgede hepatomegali (karaciğer büyümesi); kraniyal metastaz varsa baş ağrısı, baş dönmesi, kafa sinir çifti felçleri; kemik metastazından lokal kemik ağrıları görülebilmektedir. Bu nedenle hastalığın tanısında akciğer bölgesinin görüntülenmesi son derece önemlidir [23]. Bu amaçla kullanılan genel tanı yöntemleri hakkındaki bilgilere bu bölümde yer verilecektir.

Genel olarak kullanılan tanı yöntemleri aşağıda verilmektedir:

- Radyografi
- Bilgisayar Tomografi (BT)
- Manyetik Rezonans Görüntüleme (MR)
- Pozitron Emisyon Tomografisi (PET CT)
- Bronkoskopi
- Transtorasik İğne Aspirasyonu
- Biyopsi
- Plevral Aspirasyon
- Torakoskopi
- Mediastinoskopi

Radyografi: Hekimler tarafından ilk olarak istenen görüntüleme metodudur. Konvansiyonel röntgenler kullanılarak elde edilen görüntüde hastaya ait tümör izlenebilir, ancak boyutları küçük ise nodülün yerinin kalp veya kaburga yapısının arkasında kalmasından ötürü daha ileri görüntüleme tekniği olan bilgisayar tomografi görüntülerine ihtiyaç duyulabilmektedir.

Bilgisayar Tomografi: Akciğer tomografisi ile tüm akciğer ve göğüs boşluğu bir veya birkaç santimetre aralıklarla taranmakta ve böylece akciğerlerle ilgili ayrıntılı bir görüntüleme sağlanabilmektedir (Şekil 2.4). BT görüntüsü ile parankim içinde oldukça küçük boyuta sahip pulmoner nodüller, lezyon, kitlelerin görüntülenmesi sağlanmaktadır. Bu tetkik ile tümörün çevre yapılarla özellikle karaciğer ve böbreküstü

bezlerinde tutulup tutulmadığı da incelenmektedir. Ayrıca damardan verilen kontrast madde ile venöz çekimleri de yapılabilmektedir. Bilgisayar tomografi ile ilgili görüntü oluşumu ve çalışma prensibi hakkında ayrıntılı bilgiler bir sonraki kısımda verilmektedir.



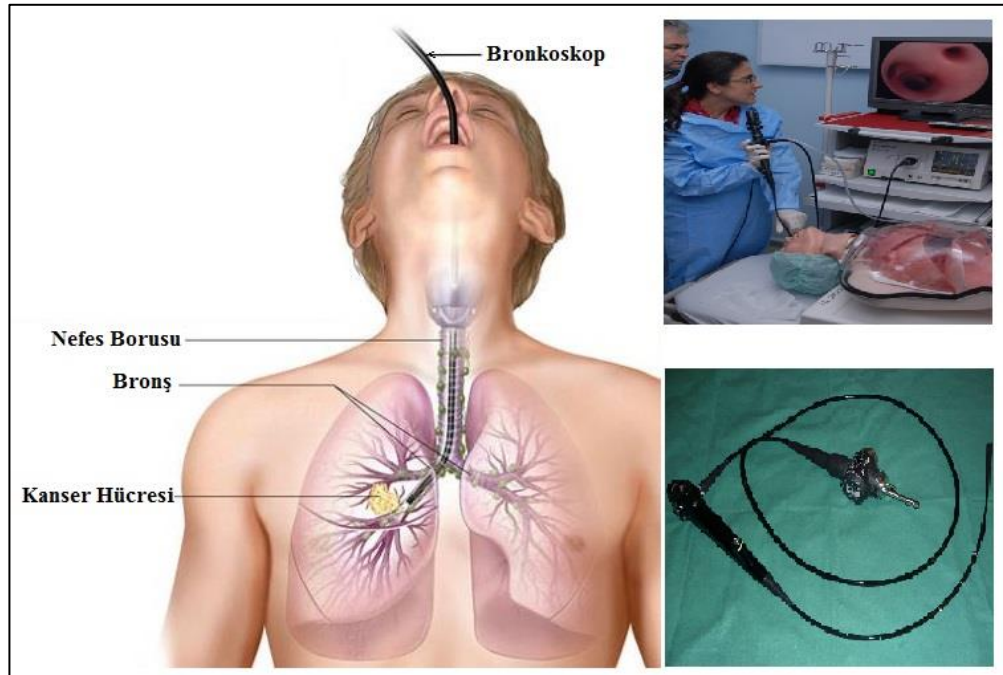
Şekil 2.4: Bilgisayar Tomografi Cihazı.

Manyetik Rezonans Görüntüleme: Son yıllarda BT cihazı kadar kullanımı yaygınlaşan MR cihazı bazı durumlarda BT görüntülerine göre üstünlüğü olan bir görüntüleme yöntemidir. Özellikle yumuşak dokularda daha iyi görüntüleme sağlaması, birçok planda kesit özelliği sunması, kalp ve büyük damarların ayrıntılı sınır özelliklerinin seçilebilmesi ve kalbin pulzasyon defektlerini ortadan kaldırması gibi görüntülemedeki üstünlüklerinden dolayı tercih edilmektedir.

Pozitron Emisyon Tomografisi: Pozitron emisyon tomografisi ve bilgisayar tomografi sistemlerindeki görüntülerin aynı anda çakıştırılması ile elde edilen tüm insan vücudunun özellikle tümör volümü görüntülenmesinde oldukça etkili olan bir tetkiktir. Görüntüleme esnasında hastaya radyo-izotoplu şeker (*FDG, Fluore Deoxy Glucose*) verilmektedir. Şeker, dışarıya ışınım yaparak sintilasyon detektörü üzerinde sinyaller üreten radyo-izotoplarla bağlanmakta ve kullanımının yüksek olduğu kanser hücrelerinin bulunduğu bölgede tutulumu sağlanmaktadır. Böylece kanser hücresi

küçük boyutta iken tespit edilebilmekte ve kanser hücrelerinin vücuttaki dağılımı hakkında bir haritalama yapma imkanı sağlamaktadır. Benzer şekilde BT görüntülerinde rastlanan kanser hücrelerinin malign veya benign olduğu yönündeki değerlendirmelerde yardımcı olmaktadır [24].

Bronkoskopi: Bronkoskopi, hava yollarının optikli, ışıklı boru şeklindeki katı veya fleksibl bir sistem ile görüntülenmesidir. İlk olarak katı bronkoskopi sistemleri kullanılmış olup, daha sonra fleksibl özellikte fiber-optiklerin kullanılmasıyla hastalığın tanı aşamasında önemli kullanım alanları bulmuştur. Daha sonra optik tarafından alınan görüntünün bir video sayesinde görüntülenmesi ile *Video Bronkoskopi* sistemleri hızlı bir şekilde klinik kullanımda yerini almıştır. Hasta açısından riski az olup invaziv bir yöntem olan bronkoskopi, tomografide saptanan normal dışı bulgular tümöral lezyonlarda hava yollarındaki değişikliklerin ve tümörlerin gözlemlenmesini sağlamaktadır. Lokal anestezi veya genel anestezi içinde yapılabilmektedir. Tanı yöntemi olan bronkoskopi, aynı zamanda hastalığın takibinde de sıklıkla uygulanmaktadır [24]. Hekim tarafından monitorize edilen hastanın bronkoskopi uygulaması ve prob yerleşimi Şekil 2.5’te görülmektedir.



Şekil 2.5: Bronkoskopik Görüntüleme [24].

Transtorasik İğne Aspirasyonu: Bronkoskopiden daha az invaziv yöntem olarak kabul edilmektedir. Özellikle periferik nodüllerde sıklıkla tercih edilmektedir. Tomografi eşliğinde göğüs duvarından ince bir iğne ile kitlenin içine girip örnek alınması ile gerçekleştirilmektedir. Lokal anestezi ile gerçekleştirilip özellikle 2-3 cm üzerindeki periferik lezyonlarda % 70-100 arasında duyarlılık elde edilmektedir [23].

Biyopsi: Hastalığın teşhisinde kanser tanısının tam olarak konulabilmesi için mutlaka yapılması gereken bir işlemdir. Kanserli dokudan bir iğne yardımıyla örnek alınması işlemidir. Alınan örnekler patolojik inceleme yapıldıktan sonra nodül/lezyon hakkında daha kesin bilgilere ulaşılabilmektedir.

Plevral Aspirasyon: Akciğer kanserinde akciğer ile plevra arasında sıvı birikimi görülebilmektedir. Kaburga aralıklarından bir iğne ile girilip bölge uyuşturulduktan sonra içerisindeki sıvı çekilerek sıvının kanser hücresi açısından incelenmesine olanak sağlamaktadır.

Torakoskopi: Plevrada sıvı birikimi esnasında sitoloji, biyopsi ve diğer incelemelere rağmen yetersiz kalabilmektedir. Bu durumda genel anestezi altında plevra boşluğunun real time olarak monitorize edilmesi tanı olasılığını % 95'e kadar yükselttiği belirtilmiştir [23].

Mediastinoskopi: Genel anestezi altında kalp ile akciğerler arasında kalan boşluğun izlenmesi yöntemidir. Göğüs cerrahları tarafından uygulanarak bu bölgede tümör tarafından tutulan bezelerden örnek alınması sağlanmaktadır.

Özellikle tanı aşamasında tespit edilen nodülün veya kitlenin hastalığın hangi evresine karşılık geldiğinin bilinmesi teşhis ve tedavi için son derece önemlidir. Akciğer kanseri, 4 (dört) farklı evreden oluşmaktadır [25]:

- **Evre I:** Nodülün akciğerin sadece küçük bir bölümünde yer almasıdır.

Evre IA: Sadece bir akciğer bölgesindedir.

Evre IB: Nodülün akciğer içinde büyümesi veya ana bronşa yayılması ya da akciğeri kaplayan plevranın iç tabakasına yayılım göstermesi halidir.

- **Evre 2:** Kanser hücresi, en yakın lenf bezelerine atlamış durumdadır.
Evre 2A: Kanser, lenf bezlerine yayılır.
Evre 2B: Kanser akciğerin bir bölgesindedir ve bulunduğu yerdeki lenf bezlerine yayılmıştır. Lenf bezlerine yayılmasa da göğüs duvarına, diyaframa, plevraya, kalp zarına (*perikardium*) veya ana bronşlardan birine yayılma ihtimali bulunmaktadır.
- **Evre 3:** Kanser hücresi (nodül, kitle, tümör), plevraya veya mediastene (iki akciğer arasındaki boşluğa) veya buradaki bezelere yayılması durumudur.
Evre 3A: Kanser hücresi lenf bezlerine yayılmıştır. Ayrıca göğüs duvarına, diyaframa, plevraya, kalp zarına (*perikardium*) veya ana bronşlardan birine yayılma ihtimali bulunmaktadır.
Evre 3B: Kanser hücresi köprücük kemiğindeki lenf bezlerine veya göğüsteki lenf bezlerine yayılmış durumdadır. Aynı zamanda kalbe, aşağı vena kava ve aorta, göğüs duvarına, diyaframa, nefes borusuna, sternuma (sağ ve sol kaburga kemikleri arasında bulunan göğüs kafesi kemiği), yutağa veya plevra tabakaları arasındaki sıvıya yayılma ihtimali bulunmaktadır.
- **Evre 4:** Karaciğer, kemik, böbrek üstü bezi gibi uzak organlara yayılması sonucu oluşan durumdur.

2.2.4.2 Tedavi Yöntemleri

Akciğer kanseri tedavisinde kanserin histopatolojik tipi, mevcut evresi ve hastanın performans durumu göz önüne alınarak tedavi için uygulanabilecek yöntem belirlenmelidir. Akciğer kanserinde ölümlerin başlıca nedeni metastazik durumlardır. Bu nedenle erken tanı büyük önem arz etmektedir [25].

Akciğer kanseri tedavisinde sıklıkla uygulanan tedavi yöntemleri [26, 27];

- Cerrahi
- Kemoterapi
- Radyoterapi
- Fotodinamik

tedavileri kullanılmaktadır.

- **Cerrahi Tedavi:** Öncelikle akciğer kanseri tanısı konmuş hastaların sıklıkla BT görüntüleri ve PET görüntüleri kullanılarak kanserin yerleşimi, cerrahiye uygun olup olmadığı karar verildikten sonra bu yöntem uygulanmaktadır. Ayrıca karar aşamasında kan testleri ve spirometre (akciğer fonksiyon testi) de gerekli olan testler arasındadır. Evre 3A'ya kadar tek akciğerde yerleşik küçük hücreli dışı kanserlerde sıklıkla cerrahi yöntem tercih edilmektedir. Kullanılan cerrahi yöntemler arasında *dilim (wedge) rezeksiyon*, akciğer lobunun bir parçasını çıkarma; *segmentektomi*, akciğer loblarının parçalarından birinin çıkartılması; *lobektomi*, bir akciğer lobunun tamamen çıkartılması; *bilobektomi* veya *pnömonektomi*, iki akciğer lobunun tamamen çıkartılması işlemleri bulunmaktadır. Yeterli solunum kapasitesi olan hastalarda lobektomi, yeterli olmayan hastalarda ise dilim rezeksiyon gibi cerrahi yöntemler sıklıkla tercih edilmektedir [28].
- **Kemoterapi Tedavisi:** Küçük hücreli akciğer kanserinin tüm evrelerinde kullanılabilen bir tedavi yöntemidir. Hap şeklinde veya iğne aracılığı ile ilaç, damar veya kaslara verilerek uygulanmaktadır. Kemoterapi, verilen ilacın kan dolaşımına girerek tüm vücudu dolaşması ve böylece akciğerler dışındaki kanser hücrelerini (beyindeki kanser hücreleri gibi) öldürmesinden ötürü sistemik bir tedavi olarak adlandırılmaktadır [24].
- **Radyoterapi (Işın Tedavisi):** Kanser hücrelerini öldürmek için x-ışınlarının veya yüksek enerjili elektronların kullanılmasıdır. Bu amaçlı Kobalt-60 teleterapi cihazları, klinik lineer hızlandırıcılar ve son olarak robotik kol özellikli

cihazlar kullanılarak tedavi gerçekleştirilmektedir. Radyoterapide amaç kanser volümüne önerilen maksimum dozu verirken sağlam olan diğer dokuların korumaktır. Palyatif tedaviler için de sıklıkla radyasyon tedavisi kullanılmaktadır.

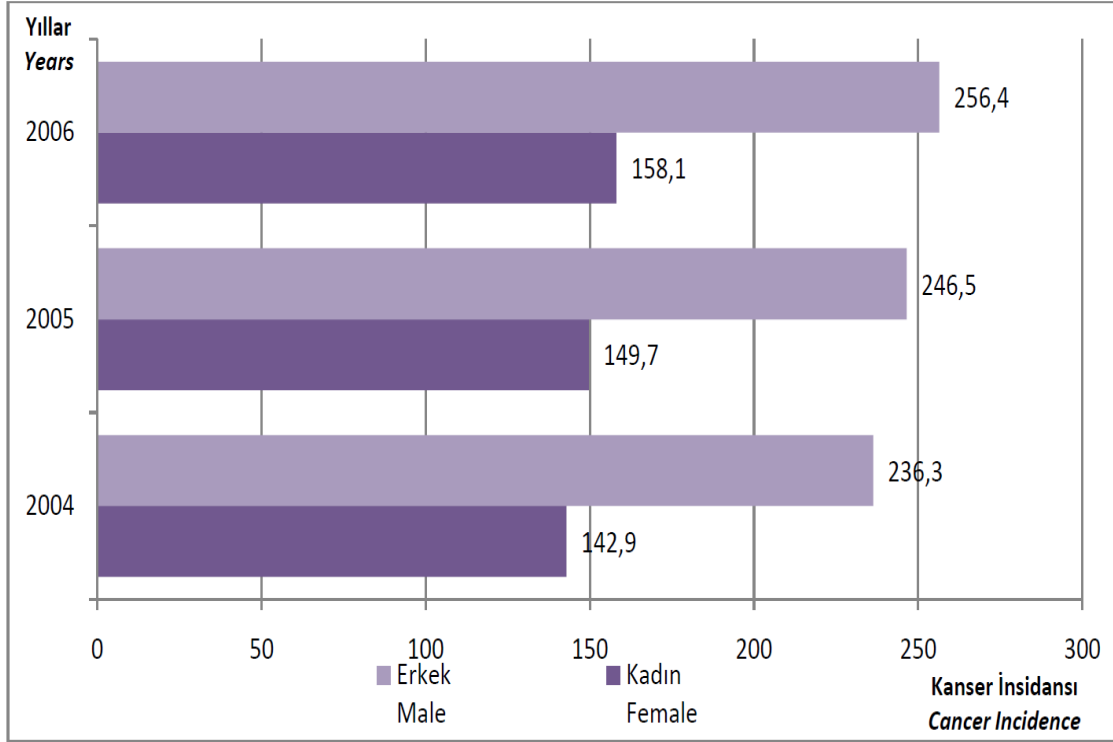
- **Fotodinamik Tedavi:** Özel hazırlanmış kimyasal bir sıvının kana enjeksiyon edilerek vücuttaki hücreler tarafından emilmesini içeren bir tür lazer tedavisidir. Kimyasal sıvının kanser hücrelerinde tutulumu yüksek olup uzun süre kalmaktadır. Daha sonra bu hücreyi hedef alan lazer ışığı kimyasal sıvıyı aktifleştirerek sıvıyı emmiş olan kanser hücrelerinin ölmesi sağlanmaktadır. Fotodinamik tedavi, normal tedavilere uygun olmayan akciğer kanserli hastaların küçük boyutlu tümör tedavilerinde kullanılabilir [29].

2.2.5 Türkiye’de ve Dünyada Akciğer Kanseri

Akciğer kanseri günümüzde dünyada en çok ölüme neden olan kanser türü arasında sayılmaktadır. Amerikan Kanser Topluluğu istatistik verilerine göre akciğer kanseri Amerika Birleşik Devletleri’nde birinci ölüm nedeni olduğu rapor edilmektedir. 2010 yılında Amerika Birleşik Devletleri’nde tüm kanser ölümlerinin % 28’ini oluşturan yaklaşık 157 300 ölümlü akciğer kanseri vakası görülmüştür. Akciğer kanserlerinin teşhis ve tedavisindeki ilerlemelere rağmen, 5 yıllık periyotta hayatta kalma oranı şuan % 16’lardadır. Eğer hastalık erken aşamada teşhis ve tedavi edilebilirse, bu oranın %53’lere yükselebileceği kaydedilmiştir. Ancak henüz, akciğer kanserlerinin % 15’i erken aşamada teşhis edilebilmektedir [30]. Yine Japonya’da ölen tüm erkeklerin % 21.4’ü akciğer kanserinden neden olduğu belirtilmiştir. Genel olarak dünyadaki kanser vakalarının % 13’ünde ve kanser ölümlerinin % 18’inde akciğer kanseri görülmektedir [31].


Ülkemizde 2009 yılına ait Sağlık Bakanlığı’nın verilerinde tüm kanser türleri arasında akciğer kanserinin erkeklerde kaydedildiği rapor edilmiştir [32]. Genel anlamda akciğer kanseri gelişmiş ülkelerde başlıca sağlık sorunlarından biridir. Son 5 yıl içinde hayatta

kalma oranı % 10-15 civarındadır [33] ve son 20 yıl içerisinde önemli bir gelişme kaydedilememiştir [34]. Yaklaşık olarak akciğer kanserlerinin % 70'i çok ileri seviyelerde teşhis edilebilmiştir [35]. Sağlık bakanlığı 2009 yılı verilerine göre yıllara ve cinsiyete göre kanser insidansına bakıldığında her yıl artış göstermektedir (Şekil 2.6).




Şekil 2.6: Türkiye’de yıllara ve cinsiyete göre toplam kanser insidansı [32].

Bu verilere göre ülkemizde erkelerde ve kadınlarda en sık görülen 10 (on) kanser türünün insidans değerleri Şekil 2.7-2.8’de verilmiştir. Akciğer kanseri tüm dünyada olduğu gibi ülkemizde de erkeklerde en sık görülen hastalıktır. Kadınlarda ise giderek akciğer kanseri görülme sıklığındaki yükselme, son yıllarda kadınlarda sigara kullanım alışkanlığının artış göstermesinden kaynaklanmaktadır [36, 37, 38].



Şekil 2.7: Türkiye’de erkeklerde en sık görülen 10 kanser türünün insidansı [32].



Şekil 2.8: Kadınlarda en sık görülen 10 kanser türünün insidansı [32].

2.3 BİLGİSAYAR TOMOGRAFİ VE GÖRÜNTÜLEME YÖNTEMİ


Tomografi vücuttan kesit şeklinde görüntü alma işlemini tanımlamaktadır. Anlam itibari ile *Tomo* (Kesit) ve *Graphy* (Görüntü) şeklinde iki eski Yunanca kelimenin birleşiminden oluşmaktadır [39]. X-ışını görüntüleme tekniği ilk olarak 1963 yılında Tıp Nobel ödülü alan Allan Cormak tarafından teorisi geliştirilmiştir. Bilgisayar tomografi (BT) cihazı, 1972 yılında Godfrey Hounsfield tarafından icat edilmiştir [40]. Temeli röntgen cihazına dayanmakta olan BT Cihazı bir kesitsel görüntüleme yöntemidir. Bir nesnenin değişik açılardan çok sayıda iki boyutlu X-ışını görüntüleri alınarak o nesnenin içyapısının üç boyutlu olarak görüntüsünün elde edilmesidir.

Genel olarak bir BT sistemi 3 (üç) ana kısımdan oluşmaktadır [41]:

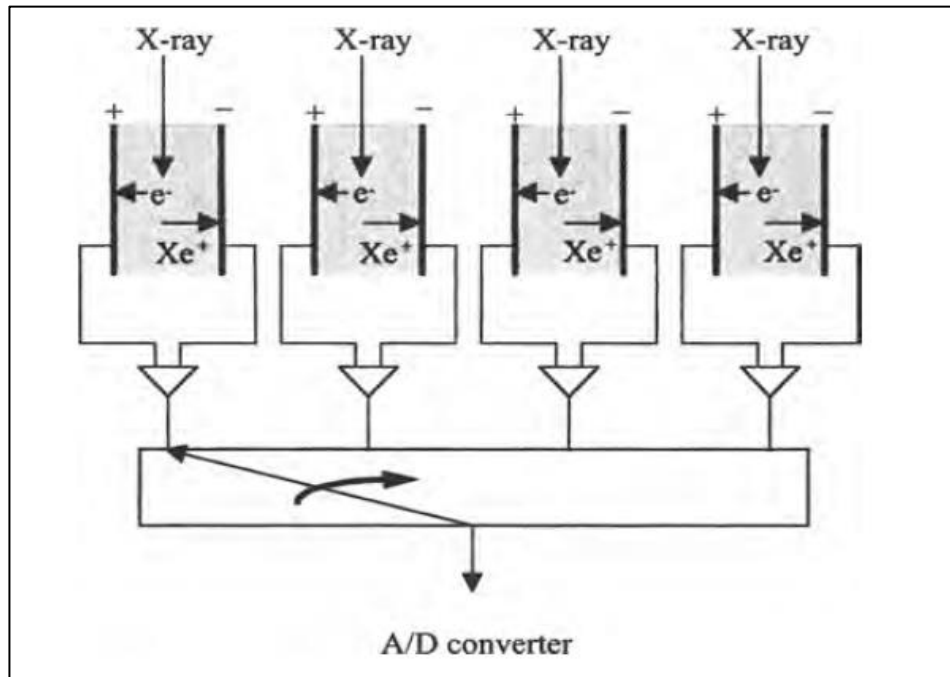
- Tarama Ünitesi
- Bilgisayar Sistemi
- Görüntüleme Ünitesi

Tarama Ünitesi: Tarama ünitesi, cihazın gövde kısmı olan gantri ve hasta masasından oluşmaktadır. Şekil 2.9'da görüldüğü gibi gantri, X-ışını tüpü ve detektör sistemi içine alan kısımdır. Orta kısımda hasta masasının girdiği gantri açıklığı bulunmaktadır. Tüp ve detektör sistemi birlikte hareket edip hastanın etrafından dönüş yaparak görüntüleme sağlanır. X-ışınları hasta kalınlığını geçerken ortamın zayıflatma katsayısına göre vücut içerisinde soğrulurlar. Hasta kalınlığını geçen X-ışınları, detektör üzerine düşerek zayıflama oranları nispetinde ölçülmekte ve elektronik bir sinyale dönüştürülerek dijitalize edilmektedir.

Bilgisayar tomografide tüm detektör sistemleri, Xenon gazı ile doldurulmuş iyonizasyon odalarından oluşmaktadır (Şekil 2.10). Xenon gazı yüksek atom numarasına (66) sahip olduğu için gaz ve gelen X-ışınları arasında fotoelektrik etkileşme olayı gerçekleşme olasılığı çok yüksektir. Xenon gazı, gaz ve X-ışınları arasındaki etkileşmelerin sayısını artırmak için yaklaşık 20 atmosfer basınç altında (atm) tutulmaktadır. Oluşan elektron çığı akımı güçlendirilerek bir analog-dijital çevrimi sayesinde elektriksel sinyal elde edilmektedir [40].



Şekil 2.9: Bilgisayar Tomografi cihazı içyapısı [41].




Şekil 2.10: BT cihazında Xenon gazlı detektörlerin şematik gösterimi [40].

Bilgisayar Sistemi: Tarama ünitesinden gelen bilgilerin birçok matematiksel işlem ve algoritmalarla değerlendirildiği bir bilgi işlem ünitesidir. İşlemlerden elde edilen sonuçlar tarama alanını temsil edecek şekilde sayılardan oluşan bir haritalamaya dönüştürülmektedir. Bu işleme *rekonstrüksiyon* denmektedir. Kısacası bilgisayar sistemi, elde edilen dijital verileri kesiti oluşturan voksel değerlerine dönüştürmektedir.

Görüntüleme Ünitesi: Sayısal değerlerden oluşan ham görüntünün ortaya çıktığı ve işlendiği bir ünedir. Yüksek çözünürlüğe sahip bir monitör ve kayıt sisteminden oluşmaktadır.

Günümüzdeki modern aygıtlar, vücudu kesit değil bir blok halinde ve çok hızlı bir şekilde tarama yapmaktadırlar. Sabit sistemlerde tüp ve detektör birbirine karşı olup



Şekil 2.11: BT’de spiral görüntüleme [41].

tek detektör halkası veya yan yana sıralanan çoklu detektör halkaları ile bir detektör bloğu şeklinde tasarlanmaktadır [41]. Spiral veya helikal BT sistemlerinde ise tüp ve detektör bir bütün olarak hastanın etrafında dönerek tüm vücudun görüntülenmesine olanak sağlamaktadır (Şekil 2.11). 16, 32 veya 64 halkalı detektör sistemleri bulunmaktadır. Daha ileri görüntü işleme algoritmalarında çift detektör (128 detektörlü) sistemi ile görüntüleme yapılmaktadır. BT teknolojisindeki ilerleme, elde edilen görüntülerin en iyi ve hızlı bir şekilde işlenmesini sağlayan algoritmaların geliştirilmesi yönündedir.

2.3.1 Bilgisayar Tomografide Görüntü Oluşumu

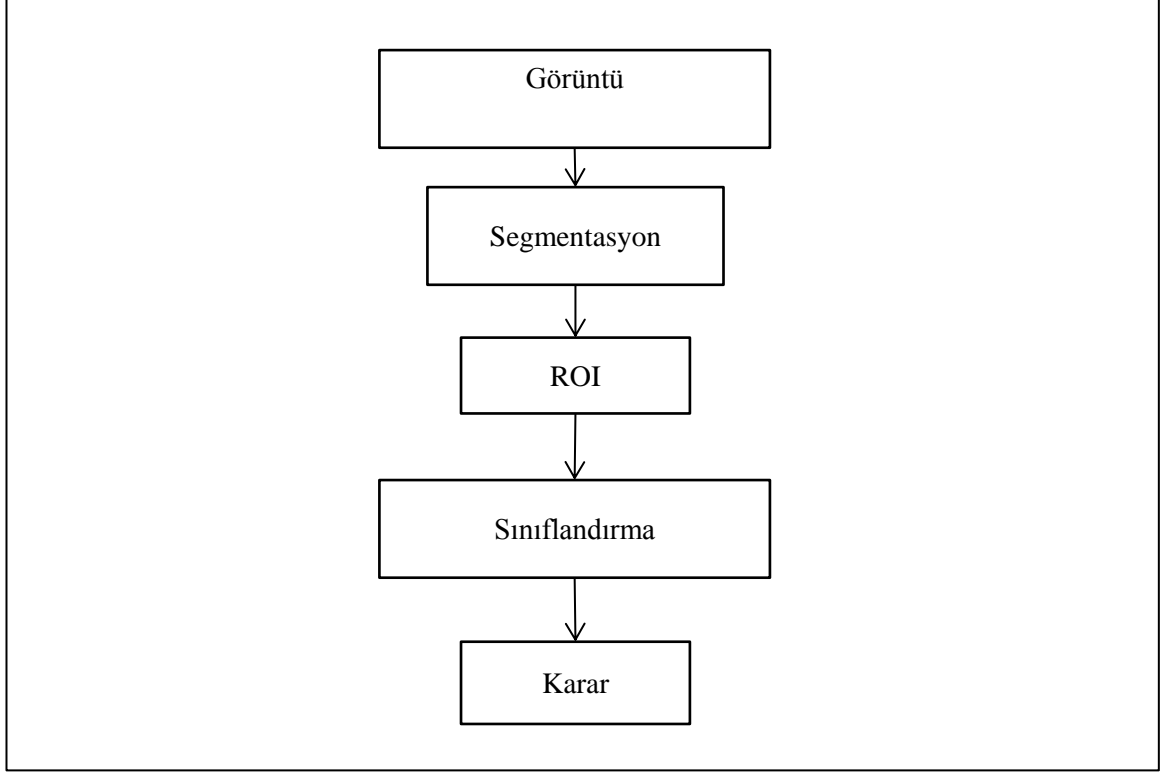
BT'de elde edilen görüntüler aynı zamanda belirli bir kalınlık değerleri vardır. Bu açıdan ölçüm yapılan pikseller değil, tabanını pikselin, yüksekliğini kesit kalınlığının oluşturduğu dikdörtgen prizmalardır. Bu prizmalara hacim elementi anlamına gelen *Voksel* adı verilmektedir.

BT taramasında X-ışını tüpü hastanın etrafında 360 derece döndürülerek vücuda ışınların girişim yapması sağlanmaktadır. Vücuda giren ve vücudu geçtikten sonraki X-ışınlarının şiddeti detektörlerle ölçülerek zayıflama miktarları ölçülmektedir. Her BT kesiti 512x512 voksel boyutunda matrislerle temsil edilmektedir. Detektörün ölçtüğü ve dijitalize ettiği değerler her vokselin X-ışınlarını tutma değerlerine dönüştürülmektedir. Bu dönüşüm işlemi suyun X-ışınlarını tutma değerini 0 kabul ederek İngiliz Fizikçi Hounsfield tarafından bir Hounsfield Cetveli oluşturulmuştur. Cetveldeki sayılar, Hounsfield Ünitesi veya BT Ünitesi olarak adlandırılmaktadır. Böylece sayısal voksel değerleri aldıkları sayılara göre Gri Sakal cetvelinde siyah-beyaz aralığındaki gri tonlara boyama işlemi gerçekleştirilmektedir [40].

2.4 BİLGİSAYAR DESTEKLİ TESPİT/TEŞHİS SİSTEMİ

Son yıllarda teknolojinin hızla ilerlemesiyle birlikte tıp alanında verimli kullanım alanına sahip olan Bilgisayar Destekli Tespit/Teşhis Sistemleri (BDT, *Computer-Aided Detection/Diagnosis Systems*, CAD) giderek büyük önem kazanmaktadır. Birçok alanda BDT sistemleri kullanılmaktadır [42, 43]. Tıbbi uygulamalarda hekimler için yardımcı bir sistem olarak tanımlanan meme kanseri teşhisinde BDT sistemi, mamografi görüntülerinden kalsifikasyonların saptanması amacıyla klinik olarak kullanılmaktadır. Benzer şekilde son yıllarda akciğer göğüs BT görüntülerinden pulmoner nodüllerin tespit edilmesine yönelik olarak araştırmalar devam etmektedir [42, 44]. Medikal anlamda bir BDT sistemi, özellikle radyologlara hastalığın teşhisi aşamasında ileri görüntü işleme ve görüntü tanıma teknikleri kullanılarak bilgisayarlı tomografi görüntüleri üzerinde ikinci bir gözden geçirme fırsatı vererek yeniden inceleme olanağı sunması, hızlı karar verme yeteneğinin bulunması ve insan hatasının teşhisteki rolünü azaltması açısından son derece önemlidir [45, 46].

Bir BDT sistemi genel olarak Şekil 2.12’de verilen yapılardan oluşmaktadır. Medikal görüntüler kullanılarak önce *Segmentasyon* denilen ilgili bölgenin bölütlenmesi sağlanarak her bir görüntüde ilgisiz alanların çıkartılması ile görüntülerin daha hızlı değerlendirilmesi sağlanmaktadır. Bu aşamadan sonra ROI denilen elde edilen ilgi alanların belirlenmesi hedeflenmektedir. Böylece BDT sisteminin yapısına yönelik olan görüntü kümesinin elde edilmesi amaçlanmaktadır. Bu iki süreç BDT sisteminin ön işleme aşamasını oluşturmaktadır.



Şekil 2.12: Bir BDT sistemi temel yapısı.

Bir BDT sisteminin ana kaburgasını oluşturan ise alınan her bir ROI görüntüsünün doğru bir şekilde ayrıştırılmasını sağlayan *Sınıflandırma* işlemidir. Medikal karar verme sürecinde görüntünün nodül olup olmadığı noktasında iyi geliştirilmiş bir sınıflandırma algoritması ile BDT sisteminin verimi yükseltilebilmektedir [68, 69, 70]. BDT sistemleri, otomatik veya yarı otomatik olmak üzere sistemim verimli karar vermesini sağlayacak farklı algoritmalar kullanılarak geliştirilmektedir [71-79].

2.5 BDT SİSTEMİNE İLİŞKİN LİTERATÜRDE YAPILAN ARAŞTIRMALAR

Pulmoner nodüllerin tespitine yönelik otomatik veya yarı otomatik BDT sistemlerinin geliştirilmesi için son zamanlarda birçok araştırma yapılmaktadır. Teknolojinin ilerlemesi ile beraber daha hızlı doğru karar veren ve insan hatasını minimize etmeye yönelik teknolojilerin geliştirilmesi son derece önemlidir.

Pulmoner nodüllerin tespitine yönelik literatürde birçok farklı algoritma geliştirilmiştir. Retico A. ve arkadaşları tarafından yapılan çalışmada ince kesit BT görüntülerinden 75 adet iç kısımda ve 27 adet akciğer zarına yapışık şekilde bulunan 39 adet hasta verisi küçük boyutlu pulmoner nodüllerin tespiti için kullanılmıştır. %80-85 oranında duyarlılık ve hasta başına 10-13 yanlış pozitif oranı değeri elde edilmiştir [47]. İnce kesit helikal bilgisayar tomografi [48] veya çok detektörlü bilgisayar tomografi [49] görüntülerinden pulmoner nodüllerin tespiti için bir BDT sistemi geliştirilmiştir. Şüpheli nodül görüntüleri, BT görüntülerinden çıkartılan iris filtreleme çıktısına, gri seviye ve morfolojik özniteliklere bağlı olarak karakterize edilmiştir. Çalışmada 77 adet pulmoner nodül içeren veri seti kullanılmış, %80 duyarlılık ve 7.7 yanlış pozitif oranı elde edilmiştir [50].

Özekes S. tarafından yapılan doktora tez çalışmasında LIDC (Lung Image Database Consortium) veri tabanından alınan 23 hastaya ait akciğer bilgisayar tomografi verileri kullanılmıştır [51]. Lee M.C. ve arkadaşları tarafından yapılan çalışma 63 kadın 62 erkek veriden oluşan 125 hastadan alınan akciğer tomografi görüntüleri ile yapılmıştır [52].

D. T. Lin yapmış olduğu pulmoner nodüllerin tespitine yönelik 29 hasta üzerindeki çalışmada % 89.3 duyarlılık ve 0.2'den daha az yanlış pozitif değeri elde etmiştir [53]. Messay T. ve arkadaşları tarafından yapılan çalışma toplam 143 nodül içeren LIDC veri setinden alınan 84 hasta üzerinde yapılmıştır. Her bir görüntü için toplam 245 tane öznitelik tanımlanmıştır. Önerilen BDT sistemi için Fisher doğrusal ayrıştırıcı sınıflandırıcısı kullanılmıştır. En etkili 40 öznitelik kullanılarak % 80.4 duyarlılık ve 3 yanlış pozitif oranı elde edilmiştir. Sistemin performansını gözlemlemek için LIDC veri setinde 7 katlı çapraz doğrulamada ile 3-30 mm boyutlu pulmoner nodüller % 86.66 duyarlılık ve 3 yanlış pozitif oranı ile tespit edilmiştir [54].

W.J. Choi ve arkadaşları pulmoner nodüllerin tespiti için genetik algoritma tabanlı sınıflandırıcı önermişlerdir. LIDC veri seti kullanılarak % 94.1 duyarlılık ve 5.45 yanlış pozitif oranı elde etmişlerdir [55]. Bağcı ve arkadaşları tarafından birçok farklı sınıflandırıcının pulmoner nodüllerin tespitinde sınıflandırma başarımları karşılaştırılmıştır [56]. Murphy K. ve arkadaşları tarafından toraks BT görüntülerinden nodüllerin otomatik tespiti [57] için k-NN sınıflandırıcısı kullanılarak bir BDT sistemi önerilmiştir. Gelişigüzel seçilen 813 adet tarama görüntüsü ile % 80 duyarlılık ve 4.2 yanlış pozitif oranı elde edilmiştir [58]. Iwano S. Ve arkadaşları pulmoner nodülleri şekillerine göre sınıflandırılma yaklaşımı önermişlerdir [59]. Jose M. F-F. ve arkadaşları 63 adet akciğer kanserli hastanın nodüllerinin tespiti için 12 farklı serum biyolojik belirteci (*biomarker*) kullanmışlardır. Temel bileşen analizi ve yapay zeka modellemesi ile en etkili biyolojik belirteçler belirlenmiştir. En iyi Cyfra biyolojik belirteci ile % 95.4 duyarlık ve % 80 seçicilik değeri ile tespit edilmiştir [60].

Kubota T. ve arkadaşları dışbükey modelleme ve morfolojik yaklaşımlarla pulmoner nodüllerin katı, katı olmayan, kısmı katı, tek, damara ve akciğer zarına yapışık özellikte olan örüntüleri için bir bölütleme (*segmentation*) algoritması önermişlerdir [61]. S.L.A. Lee ve arkadaşları Rastgele Orman Sınıflandırıcısı (*Random Forest Classifier*) otomatik akciğer nodül tespit sistemi önermişlerdir. 5721 görüntü içeren 32 farklı hastanın BT görüntüleri kullanılmıştır. Önerilen sistemle % 98.33 duyarlılık ve %97.11 seçicilik değeri bulunmuştur [62]. Pulmoner nodüllerin tespitinde örüntülerin aktif kontör yapılarına göre sınıflandırma [63] ve morfolojik yapılarına göre sınıflandırmaya [64] yer verilmiştir. Pulmoner nodüllerin tespiti için BDT sistemlerinde destek vektör makineleri [65, 66, 67, 68] ve topluluk öğrenme algoritmaları karşılaştırmalı olarak sınıflandırmadaki başarımları test edilmektedir [69]. BDT sistemlerinde karar ağaçları kullanılarak pulmoner nodüllerin sınıflandırılmasında yüksek başarımlar elde edilmiştir [70].

Pulmoner nodüllerin BT görüntülerinden tespitinden sonra nodüllerin malign veya benign olduğunun belirlenmesi klinik anlamda teşhise büyük katkı sağlamaktadır. Malign ve benign ayrımının yapılmasına yönelik çalışmalar bir başlangıç niteliği taşımaktadır. BDT sistemlerinde güvenilir ve doğru bir teşhis verimi sağlayabilmek için

çok fazla sayıda hasta görüntüsünün ve malign-benign nodül örüntülerinin kullanıldığı veri setleri oluşturulması gereklidir [71, 72, 73, 74, 75]. M.C. Lee ve ark. tarafından malign ve benign ayrımı için önerilen BDT sisteminde Gelişigüzel Altuzay Yöntemi (*Random Subspace Method, RSM*) ile Genetik Algoritma (GA) birleştirilerek danışmanlı bir öğrenme sistemi kullanılmıştır. 63 adet benign ve 62 adet malign huylu olmak üzere 125 adet pulmoner nodül ile veri seti oluşturulmuştur [76]. Hanamiya ve ark. tarafından 308 hastanın görüntüsü değerlendirilmiştir. Malign-benign nodül karakteristikleri biyopsi veya nodül takibi sonuçlarına dayalı olarak ayırt edilmiştir. 10 mm'den daha küçük olan nodüller benign; 10 mm'den daha büyük olanlar ise malignite olasılıkları oldukça yüksek olduğu belirtilmiştir [77]. Hardie ve ark. 167 radyografi görüntüsünden 181 adet nodül görüntüsünü eğitim algoritmasında; 154 adet nodülü (100 adet malign ve 54 adet benign) test veri setinde kullanarak yeni bir BDT sistemi önermişlerdir. Her bir örüntü için 114 tane öznitelik elde edilmiş, daha sonra en iyi 46 adet öznitelikle Fisher doğrusal ayrıştırıcı sınıflandırıcısı kullanılarak sınıflandırma performans ölçümleri elde edilmiştir. Hardie tarafından önerilen BDT sistemi ile % 78.1 duyarlılık ve 4 yanlış pozitif oranı elde edilmiştir [78]. Iwano S. Ve arkadaşları pulmoner nodüllerin şekillerine dayalı bir sınıflandırma yapmışlardır. 107 adet yüksek rezüstasyonlu BT görüntülerinden 55 tanesi benign, 52 tanesi malign nitelik taşımaktadır. Pulmoner nodül örüntüleri, dairesellik ve ikinci derece merkezi moment değerleri öznitelik olarak kullanılmıştır. Sınıflandırma sonucunda % 76.9 duyarlılık ve % 80 seçicilik değerleri bulunmuştur [79].

3. MALZEME VE YÖNTEM

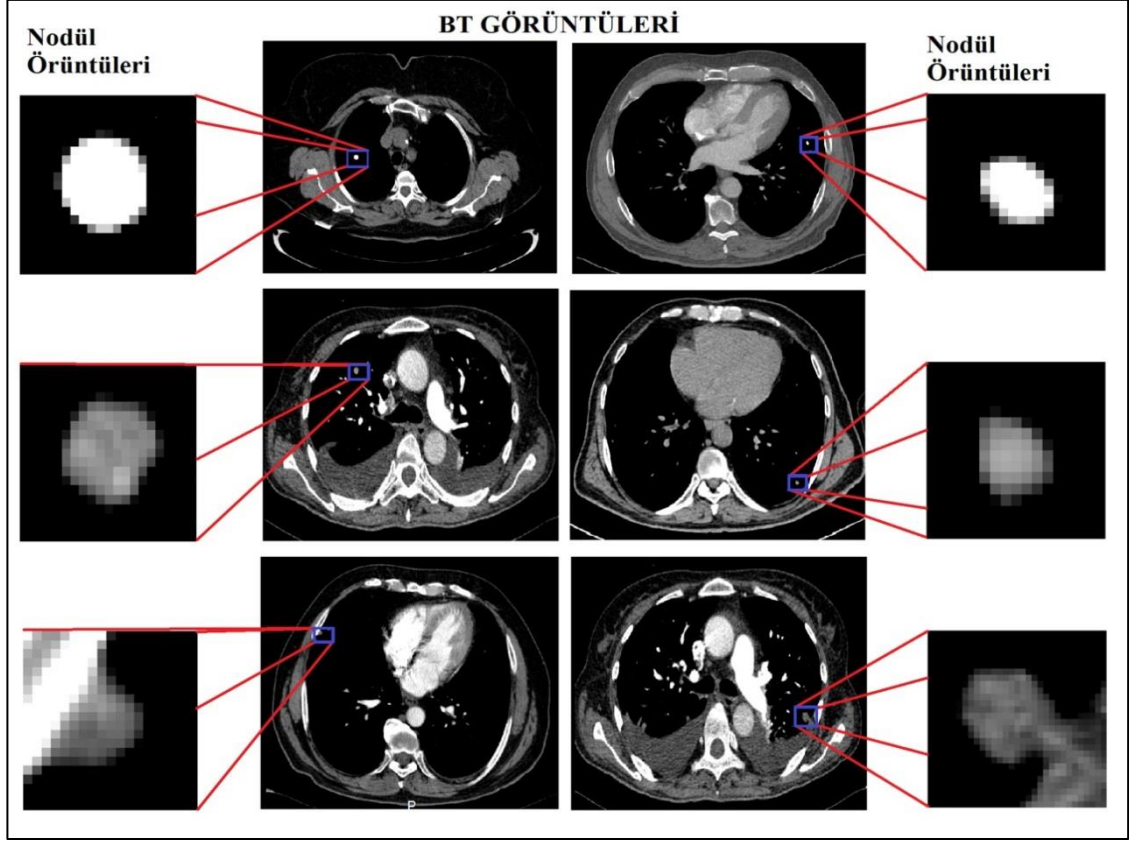
3.1 MALZEME

Bu kısımda tez çalışması kapsamında kullanılan akciğer BT görüntülerinin elde edilmiş biçimleri, veri setindeki hastaların ve pulmoner nodül örüntülerinin istatistik bilgileri ve görüntüleme protokolü hakkında ayrıntılı bilgiler verilecektir.

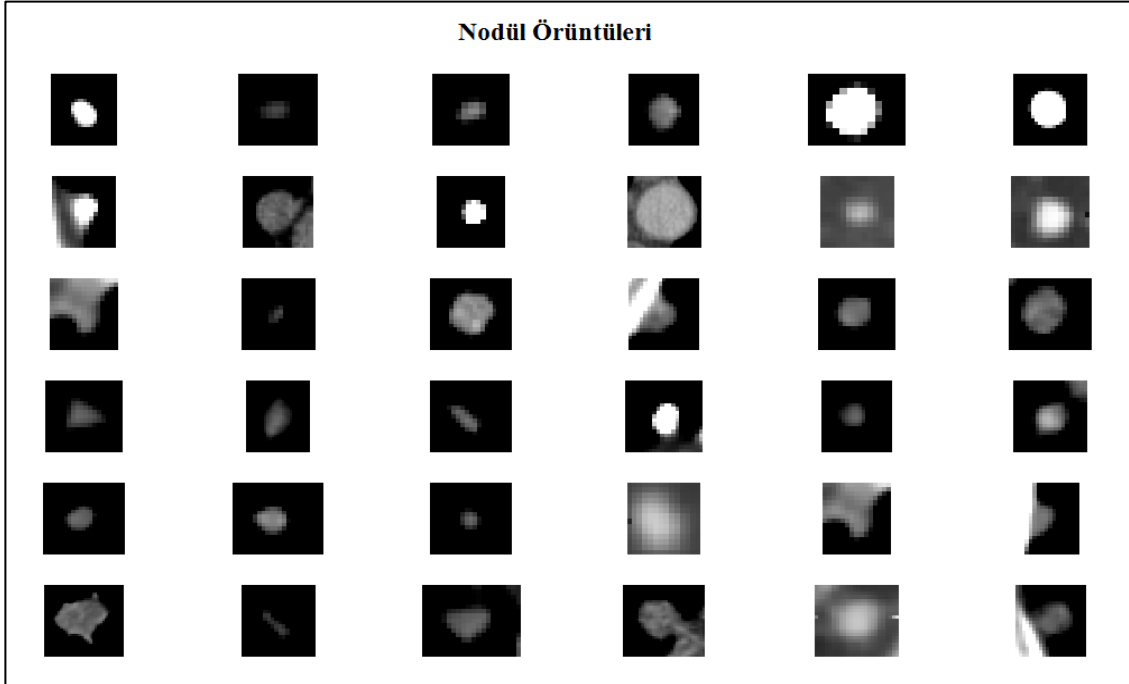
3.1.1 Hasta Popülasyonu

İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Radyoloji Anabilim Dalı'nda bulunan Siemens marka Sensation-16 model bilgisayar tomografi cihazından alınan akciğer BT görüntüleri çalışmada kullanılmıştır. 2010-2013 yılları arasında akciğer kanser hastası olan toplam 103 adet hastaya ait akciğer BT görüntüleri bölümdeki uzman radyologlar tarafından değerlendirilmiştir.


Çalışmada değerlendirilen 103 farklı hastadan toplam 159 adet pulmoner nodül ve 141 adet nodül olmayan örüntü elde edilmiştir. Aynı şekilde BT görüntüleri üzerinde akciğer parankiminde yer alan nodüle benzer ama nodül olmayan yapılar seçilerek nodül-olmayan örüntü kümesi oluşturulmuştur. Böylece çalışmada toplam 300 adet örüntü veri setinde kullanılmıştır. Her hastanın BT görüntülerindeki iki boyutlu (2D) pulmoner nodül örüntüleri uzman radyologlar tarafından Şekil 3.1'de görüldüğü gibi elle işaretlenmiştir. Veri setinde kullanılan pulmoner nodül ve nodül olmayan örüntü örnekleri Şekil 3.2-3.3'de görülmektedir.



Şekil 3.1: BT görüntülerinden elde edilen 2D pulmoner nodüllerin elde edilmesi.

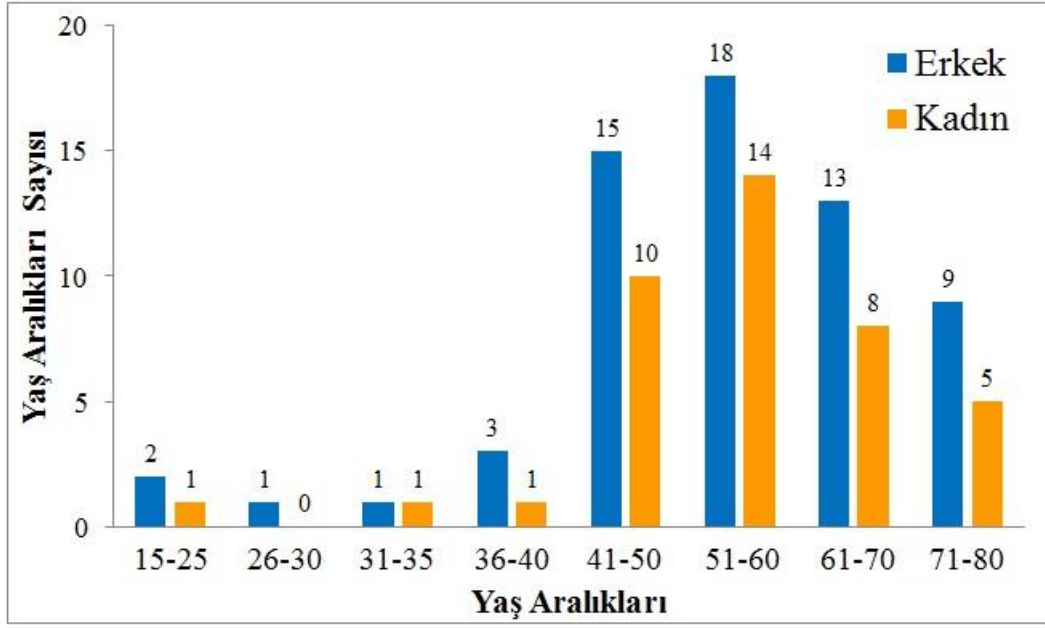


Şekil 3.2: BT görüntülerinden elde edilen gerçek nodül örüntüsü örnekleri.



Şekil 3.3: BT görüntülerinden elde edilen nodül olmayan örüntü örnekleri.


Hazırlanan veri seti, yaşları 19 ile 80 arasında değişen 63 erkek ve 40 kadın hastadan oluşmaktadır. Hastaların genel yaş ortalaması 55.5 ± 13.0 yıl olarak hesaplanmıştır. Veri setinde kullanılan kadın hastaların yaş ortalaması 55.0 ± 12.4 yıl; erkek hastalar için 55.8 ± 13.4 yıl olarak hesaplanmıştır. Veri setinde kullanılan hastaların cinsiyete göre yaş dağılım histogramı Şekil 3.4’de verilmiştir.



Şekil 3.4: Veri setindeki hastaların cinsiyete göre yaş dağılımlarını gösteren histogram.

Hastaların BT görüntülerinden elde edilen pulmoner nodüller Şekil 3.5'te görüldüğü gibi altı farklı bölgeden alınmıştır. Veri setinde kullanılan pulmoner nodül örüntüleri, sağ ve sol akciğer parankiminde alt kısım, üst kısım ve akciğer zarına yapışık olarak üç farklı bölgede görülmektedir.

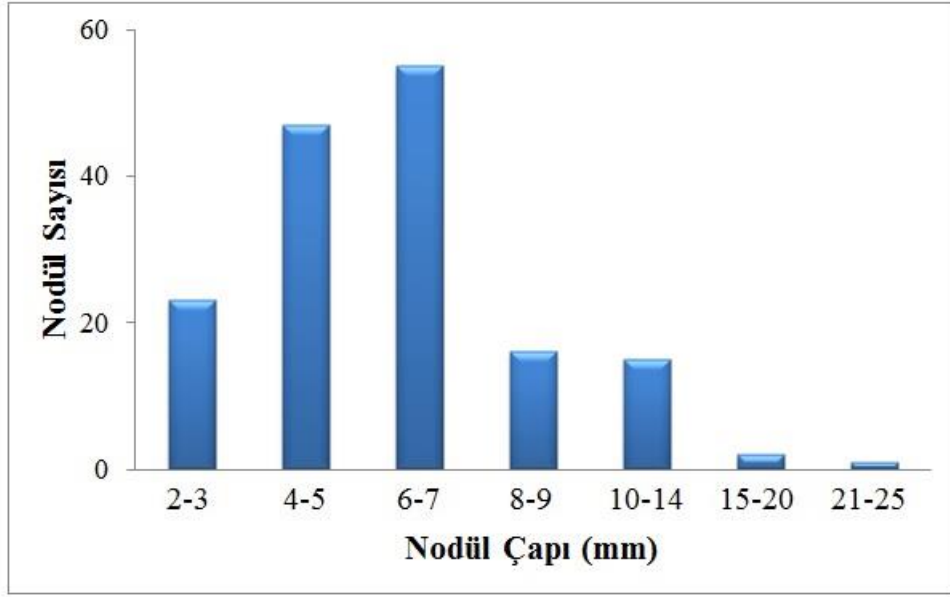
Şekil 3.5'ten görüldüğü üzere sağ akciğerde toplam 114 pulmoner nodül olup bunların 36 tanesi alt kısımda, 43 tanesi üst kısımda ve 35 tanesi akciğer zarına yapışık durumda tespit edilmiştir. Sol akciğerde ise toplam 45 pulmoner nodül olup bunların 18 tanesi alt kısımda, 15 tanesi üst kısımda ve 12 tanesi akciğer zarına yapışık olarak tespit edilmiştir. Veri setinde kullanılan pulmoner nodüllerin ortalama çapı 6.69 ± 3.17 mm olarak elde edilmiştir. Veri setindeki pulmoner nodüllerin çap dağılımı, Şekil 3.6'da gösterilmiştir. Ayrıca pulmoner nodüllerin çap aralığına göre frekans dağılımı Tablo 3.1'de görülmektedir.



Şekil 3.5: Sağ ve sol akciğerin 3 farklı bölgeye ayrımı ve nodül sayıları dağılımı.

Çalışmada ayrıca veri setinde kullanılan hastaların pulmoner nodülleri ile ilgili olarak malign, benign ve takibi gereken hastaların örüntüleri yeni bir teşhis sistemi önerilerek sınıflandırılmıştır. Malign, benign ve takibi gerekli hastaların örüntü sayıları ve cinsiyete göre dağılımları Tablo 3.2’de verilmektedir.

Malign benign ayrımı için toplam 28 adet örüntü bulunmaktadır. Benign nodüller için 13 adet erkek ve 4 adet kadın hastadan olmak üzere 19 adet örüntü, malign nodüller için 6 adet erkek ve 3 adet kadın hastadan olmak üzere 10 adet örüntü ve takibi gereken vakalar için 5 adet erkek ve 4 adet kadın hastadan olmak üzere 9 adet nodül örüntüsü veri setinde kullanılmıştır.



Şekil 3.6: Veri kümesindeki kullanılan pulmoner nodüllerin çap dağılımını gösteren histogram.

Tablo 3.1: Pulmoner nodüllerin çap aralığına göre frekans dağılımı.

Nodül Çap Aralığı (mm)	Nodül Sayısı
2-3	23
4-5	47
6-7	55
8-9	16
10-14	15
15-20	2
21-25	1
Yaş Ortalaması (Yıl)	55.5 ± 13.0
Nodül Çap Ortalaması (mm)	6.69 ± 3.17

Tablo 3.2: Malign, benign ve takip teşhisli örüntülerin dağılımı.

	Örüntü Sayısı	Erkek	Kadın
<i>Benign</i>	19	13 Hasta 15 Örüntü	4 Hasta 4 Örüntü
<i>Malign</i>	10	6 Hasta 7 Örüntü	3 Hasta 3 Örüntü
<i>Takip</i>	9	5 Hasta 5 Örüntü	4 Hasta 4 Örüntü

3.1.2 Görüntüleme Protokolü

Bu tez çalışmasında İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Radyoloji Bölümü'nde bulunan Siemens marka Sensation 16 model bilgisayar tomografi (BT) tarayıcısı verileri kullanılmıştır. Çalışmada kullanılan veri kümesi, 2010-2013 yılları arasında BT tarayıcısından çekilen göğüs BT görüntülerinden oluşturulmuştur. Tüm BT taramaları, 120 kVp tüp potansiyel altında alınmıştır. Görüntüler 512x512 piksel boyutunda ve BT'den doğrudan DICOM (*Digital Imaging and Communications in Medicine*) formatlı dosya olarak kaydedilmiştir. Siemens Sensation-16 ile ilgili toraks görüntüleme protokolü Tablo 3.4'de verilmektedir [80].

Bilgisayar tomografi tarayıcısından alınan DICOM formatlı dosyaları görüntülemek için CODONICS adlı arayüz yazılımı kullanılmaktadır. Arayüz programı, alınan görüntüler üzerinde mesafe, açılama, ölçekleme, kontrast ölçümü gibi bir çok işlemin yapılmasına olanak sağlamaktadır. CODONICS v3.2.1 versiyon arayüz yazılımı kullanılmış olup, ekran görüntüsü Şekil 3.7'de görülmektedir. Şekilde bir hastanın topogramı, hasta ışın bilgisi protokolü, abdomen arterial ve abdomen arterial geç faz çekim görüntüleri ve pulmoner nodül görüntüsünün işaretlenmiş olduğu ayrıca bir BT kesiti görülmektedir.

Tablo 3.3: Sensation-16 Bilgisayar Tomografi cihazı görüntüleme protokolü.

BT Cihazı	Parametre	İkinci /Üçüncü/ Dördüncü Rekonstrüksiyon
Enerji (kV)	120	5.00 mm/5.00 mm/5.00 mm
Efektif mAs	100	
Rotasyon Süresi	0.5 s	
Kesit Kolimasyonu	0.75 mm	
Kesit Genişliği	5.0 mm	
Aralık	5.0 mm	
CTDI _{VOL}	7.8 mGy	
Efektif Doz	Erkek: 3.86 mSv	
	Kadın: 4.98 mSv	

**Şekil 3.7:** CODONICS arayüz yazılımı.

3.2 PULMONER NODÜLLERİN TESPİT EDİLMESİ

Tez çalışmasında önerilen bilgisayar destekli tespit sistemine ait pulmoner nodüllerin tespiti için kullanılan öznetelik çıkarma ve öznetelik seçme yöntemleri ayrıntılı olarak bu bölümde verilmektedir.

3.3 DALGACIK DÖNÜŞÜMÜ

Dalgacık dönüşümü, birçok alanda olduğu gibi sinyal işleme ve görüntü işleme alanlarında da çok geniş kullanım alanına sahip olmuştur. Durağan olmayan sinyalleri işleme olanağını dalgacık dönüşümleri sağlamaktadır. Son zamanlarda dalgacık dönüşümü, birçok farklı türde görüntülerin analiz, iletim ve sıkıştırılması işlemlerinde önemli kolaylıklar sağlamıştır [81, 82].

Pratik olarak birçok sinyal zaman domeninde yani sinyal zamanın fonksiyonu olarak ifade edilmektedir. Genel anlamda bu matematiksel dönüşümler, zaman domeninde elde edilemeyen bilgilere ulaşılmasını sağlamaktadır. Bu durum, sinyal işleme açısından çok büyük bir öneme sahiptir.

Günümüzde geliştirilmiş birçok dalgacık tipi mevcuttur. Başlıca dalgacık tipleri aşağıda verilmiştir:

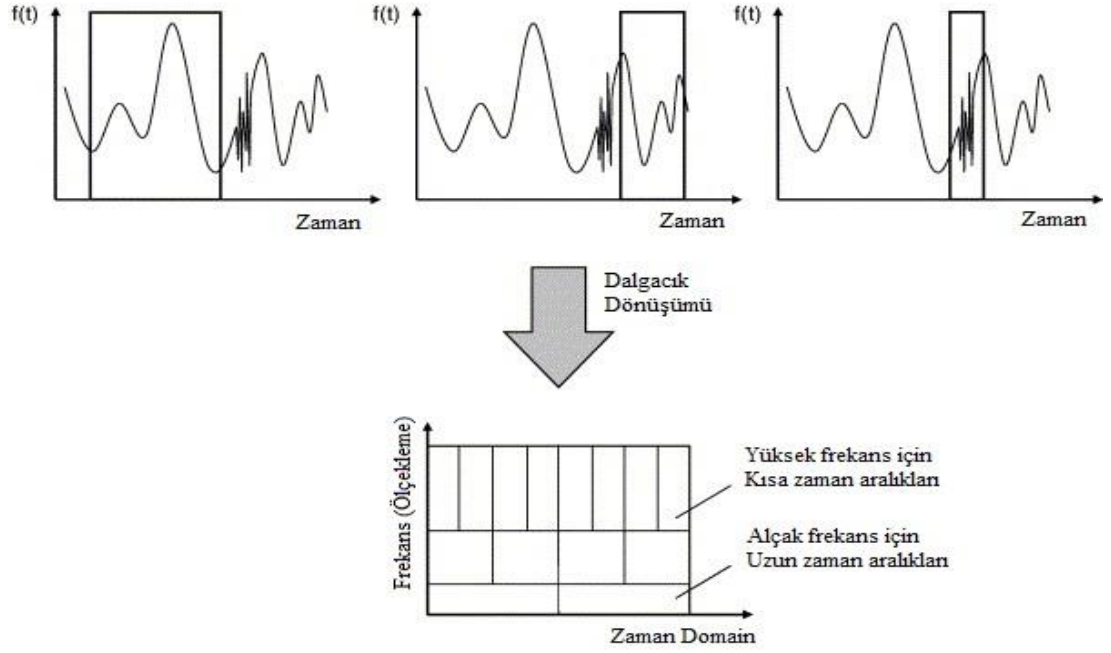
- Haar dalgacık
- Daubechies dalgacık
- Coiflet dalgacık
- Symlet Dalgacık
- Biortogonal dalgacık
- Gaussian dalgacık

Son yıllarda pek çok uygulamada en yaygın kullanılan Haar ve Daubechies ana dalgacık tipleridir [83].

Dalgacık dönüşümü, bir işaretin $\Psi(t)$ örnek fonksiyonunun ölçekleme ve ötelemeleri ile oluşturulan taban fonksiyonu ile analizi şeklinde ifade edilmektedir. Bu taban fonksiyonları sonlu süreli ve titreşimli dalga özelliklerine sahip olup, bu dalgalara dalgacık denir. İlk kez 1900'lü yılların başlarında Haar tarafından dalgacıklar kullanılmıştır [84].

Fourier dönüşümü, işaretin tamamı üzerinden bir dönüşüm yaparak işarete ait bilgileri vermektedir. Fourier dönüşümü, frekansı zamana göre değişmeyen işaretlerin analizinde iyi bir yaklaşım verirken durağan olmayan sinyallerin analizinde istenilen netice elde edilememektedir. Sabit aralıklı zaman pencereci sinyaller üzerine uygulanan Fourier dönüşümü ile belirli bir frekansa ait zaman bilgisi elde edilememektedir. Bu anlamda sadece mevcut zaman aralığındaki frekans bileşenleri hesaplanabilmektedir. Fourier dönüşümündeki bu eksiklikler 1946 yılında Gabor tarafından pencere fonksiyonu olarak tanımlanan bir sabit fonksiyonun zamanda ötelenmesi ile taranan herhangi bir işaretin Fourier dönüşümü alınarak giderilmeye ve bölgesel frekans analizinin yapılmasına olanak sağlamıştır. Gabor dönüşümü adı verilen bu dönüşüm daha sonra oluşturulan yeni bir algoritma ile değişik pencere fonksiyonlarının kullanıldığı "Kısa Zamanlı Fourier Dönüşümü, Short Time Fourier Analysis" (KZFD) olarak yenilenmiştir. KZFD'lerde kullanılan pencerelerin sabit büyüklükte olmasından ötürü zaman-frekans alanında elde edilen bilgiler sınırlı bir hassasiyetle elde edilebilmektedir.

Dalgacık dönüşümü, durağan olmayan ve anlık değişimlere sahip işaretlerin analizinde kullanılan önemli bir yöntemdir. Bu durum dalgacık dönüşümünün farklı ölçeklerde yeniden çözüm özelliğinden kaynaklanmaktadır. Dalgacık dönüşümü, KZFD'deki sınırlılığı ortadan kaldırmak için sabit genişlikteki pencereler yerine işaret üzerinde düşük frekansları yakalamak için geniş pencere fonksiyonlarını, yüksek frekansları yakalamak için dar pencere fonksiyonlarını kullanan bir pencereleme tekniğidir [84, 85, 86].



Şekil 3.8: Dalgacık Dönüşümünde kullanılan pencere ve çözünürlük hücreleri [87].

Dalgacık, zamanda belirli bir aralıkta osilasyon yapan bir dalgayı göstermektedir. Dolayısıyla hem zamanda hem frekans alanında sınırlı bir yapıya sahiptir. Dalgacık dönüşümü, ses ve imge sıkıştırma, çoklu çözünürlüklü işaret işleme ve iki boyutlu işaret işlemedeki imge analizinde sağladığı avantajlardan dolayı önemli bir kullanım alanı bulmuştur[87].

Son yıllarda dalgacık dönüşümünün başlıca uygulama alanları,

- Veri sıkıştırma
- Görüntü süzme
- Biyomedikal mühendisliği uygulamaları
- Kısmi diferansiyel denklemlerin sayısal çözümü
- Uzay çalışmaları
- Yapay sinir ağları

olarak sayılabilir[88].

3.3.1 Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümünde (SDD) sinyal, kısa zamanlı fourier dönüşümündeki pencere fonksiyonuna benzeyen dalgacık fonksiyonu ile çarpılır ve zaman domeninde farklı zaman aralıkları için dönüşüm hesaplanmış olur. Bir başka deyişle dalgacık dönüşümü, bir işaretin veya sinyalin, $\Psi(x)$ örnek fonksiyonunun ölçekleme (scaling) ve öteleme (translation) ile oluşturulan taban fonksiyonları ile analizine dayanmaktadır. Herhangi bir $f(x)$ fonksiyonunun sürekli dalgacık dönüşümü;

$$W_f(a, b) = \langle f, \Psi_{a,b} \rangle = \int_{-\infty}^{\infty} f(x) \Psi_{a,b}(x) dx \quad (3.1)$$

ifadesi ile verilir. Burada,

$f(x)$: Dalgacık dönüşümü alınacak işaret/sinyali,

$\Psi_{a,b}(x)$: Dalgacık taban fonksiyonu

$W_f(a,b)$: $f(x)$ 'in dalgacık dönüşümünü

göstermektedir. Sürekli dalgacık dönüşümündeki taban fonksiyonu $\Psi_{a,b}(x)$, $\Psi(x)$ ana fonksiyonun ölçekleme ve öteleme terimleri dikkate alındığında aşağıdaki gibi tanımlanır:

$$\Psi_{a,b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (3.2)$$

Denklem (3.2)'de, a ölçekleme (scale), b ise öteleme (translation) parametrelerini göstermektedir. Fourier dönüşümü $\Psi(s)$ olan $\Psi(x)$ ana dalgacık fonksiyonunun gerçek değerli olabilmesi için aşağıda belirtilen onarırılık (*admissibility*) şartını sağlamalıdır:

$$C_\Psi = \int_{-\infty}^{\infty} \frac{|\Psi(s)|^2}{|s|} ds \quad (3.3)$$

Burada $C_\Psi < \infty$ şartını sağlar ve bu durum DC kazancın sıfır olması anlamına gelmektedir [89].

$$\Psi(0) = \int_{-\infty}^{\infty} \Psi(x) dx = 0 \quad (3.4)$$

Denklem (3.4)'te $\Psi(0) = 0$ ise $\Psi(\infty) = 0$ olması anlamına gelmektedir. Bu durum, dalgacığın genlik cevabının band geçiren bir süzgecin transfer fonksiyonuna benzediğini belirtmektedir. $\Psi(x)$ ana dalgacık fonksiyonu, dürtü cevabı sıfır olan herhangi bir bandgeçiren süzgeç gibi artan frekanslarla sıfıra yeteri kadar hızlı bir şekilde azalmasını mümkün kılmaktadır [90].

Verilen bir $W_f(a,b)$ dalgacık dönüşümünden ters sürekli dalgacık dönüşümü kullanarak $f(x)$ işaret fonksiyonu tekrar elde edilebilmektedir. Ters sürekli dalgacık dönüşümü,

$$f(x) = \frac{1}{C_\Psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_f(a,b) \frac{\Psi_{a,b}(x)}{a^2} db da \quad (3.5)$$

şeklinde ifade edilmektedir.

3.3.1.1 İki Boyutlu Sürekli Dalgacık Dönüşümü

İki boyutlu $f(x,y)$ fonksiyonunun sürekli dalgacık dönüşümü,

$$W_f(a, b_x, b_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x,y) \frac{\Psi_{a,b_x,b_y}(x,y)}{a^3} db_x db_y da \quad (3.6)$$

şeklinde ifade edilmektedir. Denklem (3.6)'da bulunan $\Psi_{a,b_x,b_y}(x,y)$ dalgacık taban fonksiyonu aşağıdaki şekilde tanımlanmaktadır.

$$\Psi_{a,b_x,b_y}(x,y) = \frac{1}{|a|} \Psi\left(\frac{x-b_x}{a}, \frac{y-b_y}{a}\right) \quad (3.7)$$

3.3.2 Dalgacık Serileri Açılımı

$\Psi_{j,k}(x)$ ana dalgacık fonksiyonu ölçekleme ve öteleme gibi iki özellik tarafından yapılandırılır [91].

$$\Psi_{j,k}(x) = 2^{-\frac{j}{2}} \Psi(2^{-j}x - k) \quad (3.8)$$

Denklem (3.8)'de j,k ifadeleri $(-\infty, \infty)$ aralığında tam sayı değeri alırlar. Burada j tamsayısı ölçekleme, k tamsayısı öteleme parametrelerini göstermektedir. Basitçe bir dalgacığın ölçeklendirilmesi, işaretin genişletilmesi veya sıkıştırılması anlamına gelmektedir. Benzer şekilde işaretin ötelenmesi ise işareti başlangıcından geciktirme veya öncesine alma işlemidir. Denklem (3.8)'deki $\Psi_{j,k}(x)$ bir fonksiyonu ifade ettiğinden $\Psi(x)$ ana dalgacık fonksiyonu ortogonal bir dalgacık özelliğine sahiptir. $f(x)$ fonksiyonunun dalgacık serileri açılımı,

$$f(x) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} c_{j,k} \Psi_{j,k}(x) \quad (3.9)$$

olarak tanımlanmaktadır. $C_{j,k}$ seri katsayıları, işaret fonksiyonu $f(x)$ ile dalgacık fonksiyonu $\Psi_{j,k}(x)$ arasındaki iç çarpım ile hesaplanabilir.

$$\begin{aligned} c_{j,k} &= \langle f(x), \Psi_{j,k}(x) \rangle \\ &= 2^{-j/2} \int_{-\infty}^{\infty} f(x) \Psi(2^{-j}x - k) dx \end{aligned} \quad (3.10)$$

3.3.3 Ayrık Dalgacık Dönüşümü

Sürekli dalgacık dönüşümünde tüm dalgacık katsayılarının ölçekleme ile hesaplanması sonucu fazla sayıda katsayı elde edilmektedir. Bu durum çok sayıda veri ve işlem yükü meydana getirmektedir. Bu dezavantajı ortadan kaldırmak için ayrık dalgacık dönüşümü geliştirilmiştir. Dalgacık katsayılarının sadece seçilen ölçek ve zaman aralığında hesap edilmesi önemli bir avantaj sağlayacaktır [85]. Ayrık dalgacık dönüşümünde (*Discrete Wavelet Transform, ADD*), ölçek değerleri dyadic (2 'nin kuvvetleri) şeklinde seçilerek yalnızca belirli noktalarda dalgacık katsayıları hesaplanmakta ve böylece işlem sayısında ciddi bir azalma sağlanmaktadır. Öteleme ve ölçekleme parametreleri ayrık değerler olmak üzere seçilen yeni ölçek değerleri ile ayrık dalgacık dönüşümü aşağıdaki ifade ile verilir:

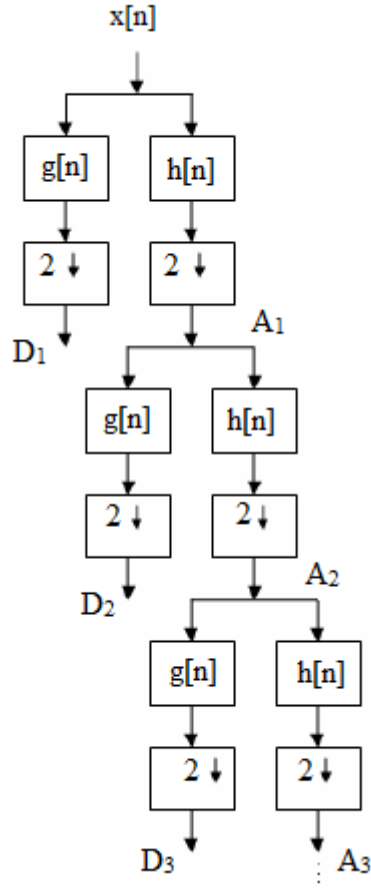
$$W[a, b] = \sum_x f[x] \Psi_{a,b}[x] \quad (3.11)$$

a ve b ayrık değerler $a=2^j$ ve $b=k2^j$ ($j, k \in Z$) olmak üzere, dalgacık taban fonksiyonu,

$$\Psi_{j,k}[x] = 2^{-\frac{j}{2}} \Psi(2^j x - k) \quad (3.12)$$

olarak şeklinde yeniden yazılabilir.

Ayrık değerli $x[n]$ işareti dalgacık dönüşümünde, yaklaşık (*approximation*) A ve ayrıntı (*detail*) D olarak altbandlara ayrılmaktadır. Bu şekilde orijinal işaret, alçak geçiren $h[.]$ ve yüksek geçiren $g[.]$ süzgeçlerden geçirilerek yaklaşık altbandında belirli sayıda ölçeklere ayrılmış olur. Çoklu çözünürlük olarak da bilinen bu işlem Şekil 3.9'da ayrıntılı olarak gösterilmiştir.



Şekil 3.9: Dalgacık dönüşümünde bir işaretin altbandlara ayrışımı [88].

Şekil 4'te görüldüğü üzere, yaklaşık altbandı A, işaretin yüksek ölçekli ve düşük frekans bileşenlerini, ayrıntı altbandı D ise işaretin düşük ölçekli ve yüksek frekans bileşenlerini temsil etmektedir.

3.3.3.1 İki Boyutlu Ayrık Dalgacık Dönüşümü

Tek boyutlu ayrık dalgacık dönüşümü, görüntü gibi iki boyutlu fonksiyonlar için kolaylıkla ifade edilebilir. $\Phi(x,y)$ iki boyutlu ölçekleme fonksiyonunu ve $\psi^H(x,y)$, $\psi^V(x,y)$ ve $\psi^D(x,y)$ gibi yatay, dikey ve köşegen iki boyutlu dalgacık fonksiyonlarını kullanarak iki boyutlu ayrık dalgacık fonksiyonunu ifade edilebilir. Burada iki boyutlu

ölçekleme fonksiyonları ve iki boyutlu dalgacık fonksiyonları aşağıdaki şekilde tanımlanmaktadır:

$$\varphi(x, y) = \varphi(x)\varphi(y) \quad (3.13)$$

$$\Psi^H(x, y) = \Psi(x)\varphi(y) \quad (3.14)$$

$$\Psi^V(x, y) = \varphi(x)\Psi(y) \quad (3.15)$$

$$\Psi^D(x, y) = \Psi(x)\Psi(y) \quad (3.16)$$

Denklem 3.14-3.16'daki iki boyutlu dalgacık fonksiyonları, bir görüntüdeki yoğunluk değişimlerinin belirlenmesini sağlarlar [90]. Burada $\Psi^H(x, y)$, görüntü üzerinde satır boyunca oluşan değişimleri; $\Psi^V(x, y)$, görüntüdeki sütun boyunca meydana gelen değişimleri; $\Psi^D(x, y)$ ise görüntünün köşegeni boyunca oluşan değişimleri göstermektedir. Ele alınan bu iki boyutlu ölçekleme ve iki boyutlu yönlü dalgacık fonksiyonlarını genel olarak aşağıdaki şekilde ifade edebiliriz.

$$\varphi_{j,k,l}(x, y) = 2^{-\frac{j}{2}}\varphi(2^{-j}x - k, 2^{-j}y - l) \quad (3.17)$$

$$\Psi_{j,k,l}^i(x, y) = 2^{-\frac{j}{2}}\Psi^i(2^{-j}x - k, 2^{-j}y - l) \quad (3.18)$$

Denklem (3.36)'daki i indisi, iki boyutlu dalgacık fonksiyonlarının H, V, D yönlerindeki değişimlerini göstermektedir. Bu ifadelerden sonra $M \times N$ boyutuna sahip $f(x, y)$ fonksiyonunun ayrık dalgacık dönüşümünü aşağıdaki şekilde tanımlanmaktadır:

$$W_\varphi(j_0, k, l) = 2^{-j} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \varphi_{j_0, k, l}(x, y) \quad (3.19)$$

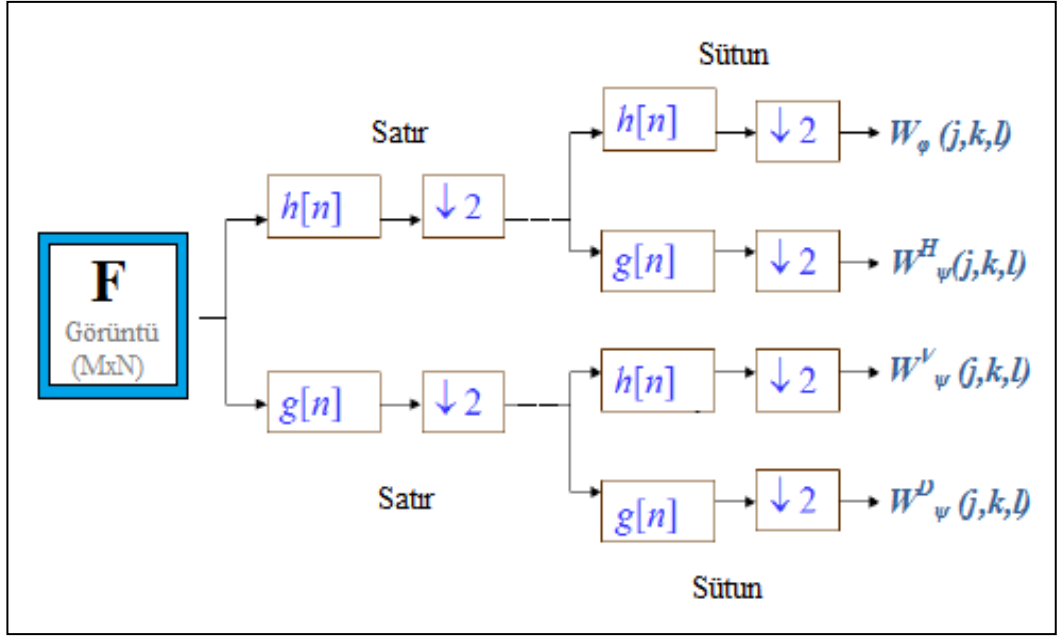
$$W_{\psi}^i(j, k, l) = 2^{-j} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \Psi_{j,k,l}^i(x, y) \quad (3.20)$$

$$j = 0, 1, 2, \dots, j-1 \text{ ve } k, l = 0, 1, 2, \dots, 2^j - 1$$


Burada Denklem (3.19), j_0 ölçeğinde $f(x, y)$ fonksiyonunun yaklaşık katsayılarını (*approximation coefficients*) vermektedir. Genellikle j_0 keyfi bir ölçekleme değeri olup ekseriyetle 0 (sıfır) alınır. Denklem (3.20)'deki denklem ise j ölçeği için yatay (H), dikey (V) ve köşegen (D) yönleri için ayrıştırma katsayılarını (*detail coefficients*) vermektedir. Analitik olarak eğer W_{ϕ} ve W_{ψ}^i katsayıları verilmiş ise kolayca ters dalgacık dönüşümü kullanılarak $f(x, y)$ fonksiyonu elde edilebilir.

$$f(x, y) = 2^{-j} \sum_k \sum_l W_{\phi}(j_0, k, l) \phi_{j_0, k, l}(x, y) + 2^{-j} \sum_{i=H, V, D} \sum_{j=j_0}^{\infty} \sum_k \sum_l W_{\psi}^i(j, k, l) \Psi_{j, k, l}^i(x, y) \quad (3.21)$$

Sayısal süzgeçler ve veri azaltma (*downsampling*) işlemleri iki boyutlu ayrık dalgacık dönüşümlerinde de kullanılabilir. Burada her bir seviyede önce yatay olarak (sıra), ardından dikey olarak (sütun) alt-geçiren ve üst-geçiren süzgeçleme işlemi yapılmaktadır. $M \times N$ boyutunda bir görüntü üzerine iki boyutlu ayrık dalgacık dönüşümü uygulanarak tek seviyeli görüntü ayrıştırma işlemi Şekil 3.10'da şematik olarak gösterilmiştir. Aynı şekilde Şekil 3.11'de iki boyutlu ayrık dalgacık dönüşümü ile 2 (iki) seviyeli görüntü ayrıştırması gösterilmiştir.



Şekil 3.10: İki boyutlu ADD kullanarak Tek Seviyeli görüntü ayrıştırma işlemi [90].

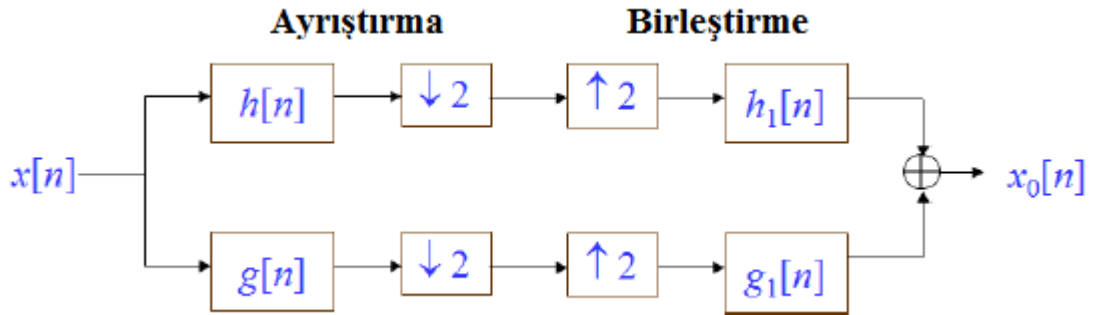


Şekil 3.11: ADD ile 2 seviyeli görüntü ayrıştırma işlemi [93].

Şekil 3.10'da verilen şematik gösterim, iki boyutlu ayırık dalgacık dönüşümlerinin genel formunu ifade etmektedir. Burada $h[.]$ alçak geçiren, $g[.]$ yüksek geçiren süzgeçleri

ifade ederken (2↓) ise görüntüdeki veri azaltma işlemlerini temsil etmektedir. Verilen $M \times N$ boyutlu görüntüde, ilk yatay, daha sonra dikey olarak süzgeçleme işlemi yapılmaktadır. Bu işlemlerin sonunda $M \times N$ boyutlu görüntü, $\frac{M}{2} \times \frac{N}{2}$ boyutuna sahip dört farklı alt-görüntüye ayrılmıştır. $W_\varphi(j,k,l)$ düşük frekans bileşenine sahip yaklaşık görüntüyü; $W^D_\psi(j,k,l)$, $W^V_\psi(j,k,l)$ ve $W^H_\psi(j,k,l)$ alt görüntüleri sırasıyla köşegen, dikey ve yatay ayrıntı görüntülerini temsil etmektedir.

Ayrıştırma (*decomposition*) işlemi sonucunda elde edilen yüksek frekanslı ve alçak frekanslı alt-görüntüler kullanılarak tekrar başlangıçtaki orijinal görüntü elde edilebilir. Bu işleme Birleştirme (*synthesis*) adı verilir. Basit olarak birleştirme işleminde ayrıştırma işleminde yapılan işlemlerin simetrisi bir işlem takip edilir. Şekil 3.12’de bu algoritma ile ilgili şematik bir gösterim verilmiştir.



Şekil 3.12: ADD’de ayrıştırma ve birleştirme süreçleri şematik gösterimi [88].

3.3.3.2 Daubechies Dalgacık Dönüşümü

Dalgacık dönüşümünde katsayılar, bir taraftan veri düzleştirici bir filtre gibi davranırken diğer yandan her ölçekteki işaret detaylarını içermektedir. Daubechies dalgacık fonksiyonu, ortogonal temel dalgacık fonksiyonu olup, içerisinde Haar dalgacık fonksiyonunu da içerir. İki ölçekleme katsayısı bulunan ve her birinin bire eşit olduğu Haar dalgacığı, dalgacık tipleri arasında en basit özellikte olanıdır. Haar dalgacığı sadece iki ölçekleme katsayısına sahip olup Daubechies dalgacığı gibi *db1* ile temsil

edilebilir. Daubechies dalgacığında $db2$ dalgacığı 4 (dört) adet, $db3$ dalgacığı 6 (altı), dbN dalgacığı ise $2N$ adet ölçekleme katsayısına sahiptir [92].

Bir dalgacığın düzgünlüğü, ölçekleme katsayıları ve bir moment ile ilgilidir. Daubechies dalgacığı kısaca aşağıdaki şekilde tanımlanmaktadır:

$$p(y) = \sum_{k=1}^{N-1} C_k^{N-1+k} y^k \quad (3.22)$$

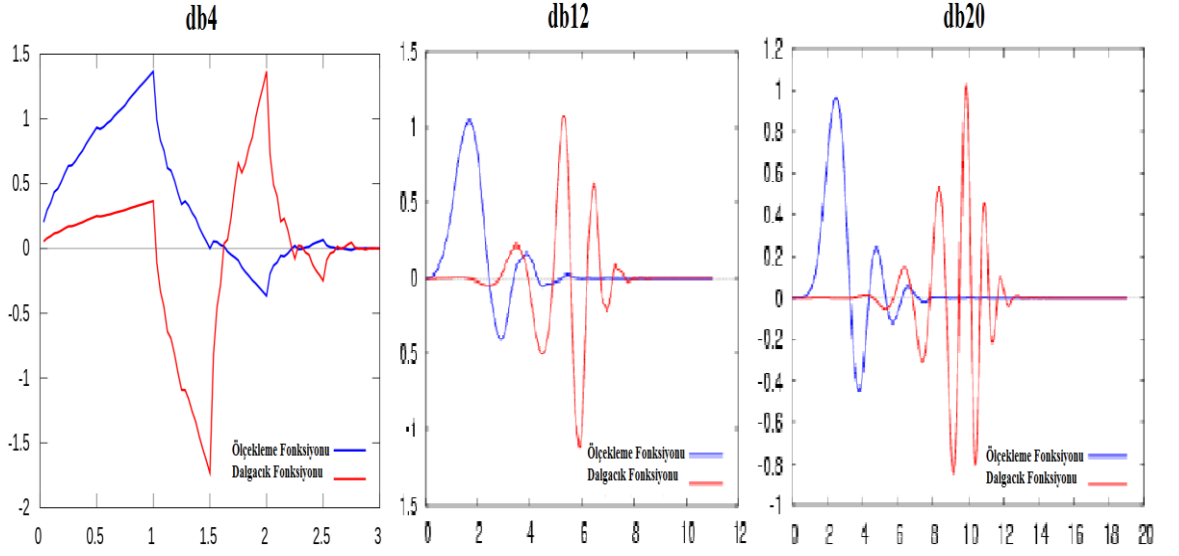
Burada C_k^{N-1+k} binominal katsayılardır. Fonksiyonun mutlak değeri karesi,

$$|m_0(w)|^2 = \left(\cos^2 \left(\frac{w}{2} \right) \right)^N p \left(\sin^2 \left(\frac{w}{2} \right) \right) \quad (3.23)$$

Denklem (3.23)'teki $m_0(w)$ ifadesi,

$$m_0(w) = \frac{1}{\sqrt{2}} \sum_{k=0}^{2N-1} h_k e^{-kw} \quad (3.24)$$

şeklinde tanımlanmaktadır. Daubechies dalgacıkları $db1$, $db2$, $db4$, $db6$, $db8$, $db10$, $db12$, $db16$, $db18$ ve $db20$ gibi dalgacık tipleri vardır. Şekil 3.13'te daubechies dalgacıklarına ait dalga tipleri görülmektedir [93].



Şekil 3.13: Daubechies dalgacık tipleri [93].

3.4 TEMEL BİLEŞEN ANALİZİ

Temel Bileşen Analizi (*Principal Component Analysis*, TBA), ilk defa 1900'lü yılların başında Karl Pearson tarafından ortaya atılmıştır. Daha sonra 1933 yılında Hotelling, ardından 1964 yılında Rao tarafından uygulama alanları önemli ölçüde geliştirilmiştir [94]. Temel Bileşen Analizi, değişkenler arasındaki bağımlılık yapısının yok edilmesi veya boyut indirgeme ve şekil sıkıştırmak gibi uygulamalarda kullanılan önemli bir tekniktir. Temel bileşenler analizi, bir değişken setinin varyans-kovaryans yapısını bu değişkenlerin doğrusal birleşimleri yardımı ile ortaya koyarak boyut indirgemesini ve yorumlanmasını sağlayan çok değişkenli bir istatistik yöntem olarak tanımlanmaktadır [95]. TBA genellikle bilgi kaybı olmaksızın değişkenlerin sayısını azaltmak için kullanılan bir teknik olarak sunulmaktadır. TBA, daha çok değişkenler arasında bir bağımlılığın bulunduğu veya bağımsız olmadığı istatistik sonuçların yorumlanmasının zor olduğu durumlarda kullanılan tekniklerin başında gelmektedir.

Temel bileşenler analizinde N birey (gözlem) ve P değişkenden oluşan veri matrisi X 'in P boyutlu uzaydaki durumunu ele alınırsa, veri matrisi (her gözlem bir noktayı temsil etmek üzere) çok sayıda noktadan oluşan bir topluluğu ifade etmektedir. Bu matriste

ham veri kullanılıyor ise varyans-kovaryans matrisinden, standartlaştırılmış veri kullanılıyor ise korelasyon matrisinden yararlanılmaktadır. Orijinal verilerin oluşturduğu $N \times P$ boyutlu X matrisi aşağıda verilmiştir.

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_i \\ \vdots \\ X_N \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1j} & \dots & x_{1P} \\ x_{21} & x_{22} & \dots & x_{2j} & \dots & x_{2P} \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots \\ x_{i1} & x_{i2} & \dots & x_{ij} & \dots & x_{iP} \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{N3} & \dots & x_{NP} \end{bmatrix} \quad (3.25)$$

P adet tesadüfi değişken,

$$X_1 = \begin{bmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{i1} \\ \vdots \\ x_{N1} \end{bmatrix}, X_2 = \begin{bmatrix} x_{12} \\ x_{22} \\ \vdots \\ x_{i2} \\ \vdots \\ x_{N2} \end{bmatrix}, \dots, X_j = \begin{bmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{ij} \\ \vdots \\ x_{Nj} \end{bmatrix}, \dots, X_P = \begin{bmatrix} x_{1P} \\ x_{2P} \\ \vdots \\ x_{iP} \\ \vdots \\ x_{NP} \end{bmatrix} \quad (3.26)$$

şeklinde gösterilir. Burada temel bileşenler, X_1, X_2, \dots, X_P değişkenlerinin doğrusal kombinasyonlarıdır. Bu doğrusal bileşenler birbiri ile ilişkili koordinat eksenlerine X_1, X_2, \dots, X_P sahip orijinal sistemi döndürerek birbirinden bağımsız yeni koordinat sisteminin oluşturulması hedeflenmektedir. Yeni değişkenler maksimum değişkenliği içerir ve birlikte değişimin daha basit ve daha az sayıda değişken ile açıklanmasına olanak sağlamaktadır. t' ler standartlaştırılmış özvektörleri göstermek üzere, X gözlem matrisinin birinci temel bileşenine ait denklem,

$$Y_1 = t_{11}X_1 + t_{21}X_2 + t_{31}X_3 + \dots + t_{P1}X_P \quad (3.27)$$

$$Y_1 = t_1'X \quad (3.28)$$

şeklinde yazılabilir. Burada $t_1' = (t_{11}, t_{21}, \dots, t_{P1})$ ve $X' = (X_1, X_2, \dots, X_P)$ olmak üzere,

$$\begin{aligned}
t'X &= (t_{11}, t_{21}, \dots, t_{p1}) \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{bmatrix} \\
&= t_{11}X_1 + t_{21}X_2 + t_{31}X_3 + \dots + t_{p1}X_p
\end{aligned} \tag{3.29}$$

olarak yazılabilir. X matrisinde yer alan P değişkenin doğrusal bileşenleri için varyans-kovaryans matrisinin özdeğerleri ve özvektörleri kullanılır [96]. Özdeğerlere karşılık gelen özvektörler birbirine dik yani birbirinden bağımsızdırlar. Bu özellikten dolayı ana bileşenler özdeğerlerin büyüklük sırası izlenerek önem sırasına göre hesaplanır.

X veri matrisinin ortalama değeri,

$$\begin{aligned}
\bar{X} &= [M_1 M_2 M_3 \dots M_p] \\
&= \left[\frac{\sum_{i=1}^N x_{i1}}{N} \quad \frac{\sum_{i=1}^N x_{i2}}{N} \quad \frac{\sum_{i=1}^N x_{i3}}{N} \quad \dots \quad \frac{\sum_{i=1}^N x_{ip}}{N} \right]
\end{aligned} \tag{3.30}$$

X veri kümesindeki her bir veriden ortalama değer çıkartılarak öznitelik vektörü veya matrisi oluşturulur:

$$X_M = \begin{bmatrix} x_{11} - M_1 & x_{12} - M_2 & \dots & \dots & x_{1p} - M_p \\ x_{21} - M_1 & x_{22} - M_2 & \dots & \dots & x_{2p} - M_p \\ x_{31} - M_1 & x_{32} - M_2 & \dots & \dots & \vdots \\ \vdots & \vdots & \dots & \dots & \vdots \\ x_{N1} - M_1 & x_{N2} - M_2 & \dots & \dots & x_{Np} - M_p \end{bmatrix} \tag{3.31}$$

Kovaryans ve korelasyon matrislerini hesaplamak için standart sapma (σ) ve varyans (σ^2) değerleri hesap edilir. X veri kümesinin standart sapması,

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (X_i - \bar{X})^2}{(N - 1)}} \tag{3.32}$$

bir veri içerisindeki yayılımın ölçüsü olarak tanımlanan varyans ise,

$$\sigma^2 = \frac{\sum_{i=1}^N (X_i - \bar{X})^2}{(N - 1)} \quad (3.33)$$

ifadelerinden hesaplanır. X_M matrisinin her bir elemanı, X_M 'nin standart sapmasına bölünerek öznelik vektörü oluşturulur. Kovaryans, iki değişken arasındaki bağımlılık hakkında bilgi verir. Genellikle istatistik analizlerin amacı boyutlar arasında ilişki olup olmadığını ortaya çıkarmaktır. Standart sapma ve varyans diğer boyutlardan bağımsız olarak sadece bir boyuttaki verinin ortalama değere göre dağılımını verirken, kovaryans ise bir boyutun diğer boyutlara bağlı olarak nasıl bir değişim gösterdiğini ortaya koyan bir ölçüm tekniğidir. S kovaryans matrisi ise,

$$S = \frac{\sum_{i=1}^N ((X_i - \bar{X})^T (X_i - \bar{X}))}{(N - 1)} \quad (3.34)$$

ifadesi ile hesaplanır. S kovaryans matrisine ait her bir eleman aşağıdaki şekilde hesaplanır.

$$\begin{aligned} S(i, j) &= S(j, i) \\ &= \frac{\sum_{k=1}^N (X_M(k, i) \cdot X_M(k, j))}{(N - 1)} \end{aligned} \quad (3.35)$$

Kovaryans matrisin özdeğerleri (*eigenvalue*) ve özvektörleri (*eigenvector*) elde edilir. S matrisinin özdeğerleri,

$$|S - \lambda I| = 0 \quad (3.36)$$

yaklaşımı ile hesaplanır. Denklem (3.36)'dan $\lambda_1, \lambda_2, \dots, \lambda_p$ özdeğerleri bulunur. Bulunan λ_i özdeğerleri büyüklük sırasına göre sırandıktan sonra özvektörler matrisi E hesap edilir. Özvektörler matrisi ise,

$$(S - \Lambda)E = 0 \quad (3.37)$$

olarak ifade edilir. Burada Λ özdeğerler köşegen matrisini göstermektedir. Dolayısıyla E matrisinin vektörleri sırasıyla temel bileşenleri vermektedir.

Toplam varyans ifadesi $\lambda_T = \lambda_1 + \lambda_2 + \dots + \lambda_P$ olduğundan k . temel bileşen tarafından toplam varyansın açıklanma oranı aşağıdaki gibi hesaplanmaktadır.

$$\text{Varyans Oranı } k\text{-inci bileşen} = \frac{\lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_P} \quad (3.38)$$

Bu şekilde temel bileşenlerin varyans oranları hesaplanır.

Temel bileşen analizinde bileşenler bulunduktan sonra kaç tane temel bileşenin alınacağına karar vermek oldukça önemlidir. Genel olarak basit ve en çok kullanılan yöntem, toplam varyasyonun $2/3$ 'ünü geçinceye kadar λ değerlerini toplama işlemidir. Bir başka deyişle kaç tane temel bileşenin varyans oranı % 67'den büyük ise o kadar tane temel bileşen var demektir [97, 98]. Yeni temel bileşen sayısı k olmak üzere temel bileşen varyasyon oranı aşağıdaki şekilde verilir.

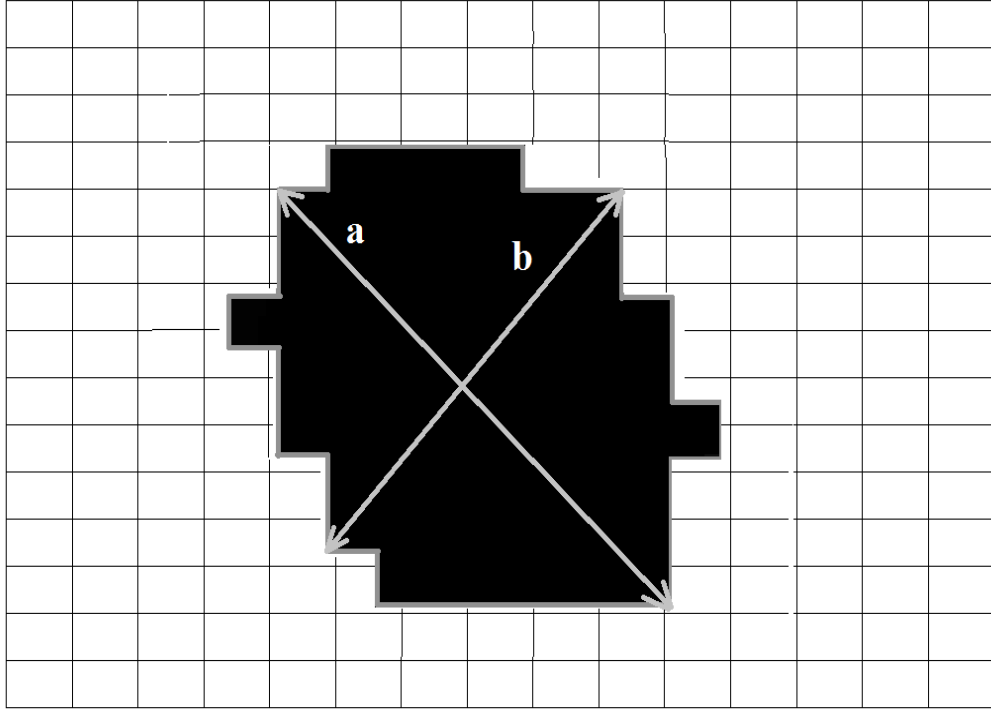
$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^P \lambda_i} > \frac{2}{3}, \quad k = 1, 2, 3, \dots, P \quad (3.39)$$

Sonuç olarak P değişken yerine ilk olarak k tane temel bileşen fazla bilgi kaybına neden olmadan orijinal oluşumu açıklamak üzere kullanılabilir [99, 100].

3.5 MORFOLOJİK GÖRÜNTÜ İŞLEME

Morfoloji, bir görüntü üzerinden anlamlı özniteliklerin çıkarımını sağlayan başlıca matematiksel araçları kullanan oldukça önemli tekniklerden biridir [101]. Üç boyutlu morfolojik görüntü işlemenin yanı sıra 2D morfolojik görüntü işleme ile medikal görüntülerde oldukça başarılı sonuçlar elde edilmektedir.

Çalışmada 2D pulmoner nodül ve nodül olmayan görüntülerin özniteliklerini çıkarmak için, temel morfolojik şekil bilgisine dayalı görüntülere ait bölgesel tanımlayıcılar kullanılarak geometrik öznitelikler kullanılmıştır. Literatürde en sık kullanılan geometrik öznitelikler, iki boyutlu görüntüden elde edilen alan, çevre, çap, katılık (*solidity*), eksantriklik (*eccentricity*), en-boy oranı (*aspect ratio*), kompaktlık (*compactness*), yuvarlaklık (*roundness*), dairesellik (*circularity*) ve eliptisite (*ellipticity*) değerleridir. Veri kümesinde kullanılan örnek bir iki boyutlu pulmoner nodül örneği Şekil 3.14'te gösterilmiştir. Böylece görüntülerdeki özniteliklerin çıkarımı için toplam 10 adet öznitelik kullanılmıştır. Ayrıca kullanılan öznitelikler ile ilgili ayrıntılı açıklamalar ve matematiksel ifadeler aşağıda verilmektedir.



Şekil 3.14: İki boyutlu pulmoner nodül örüntüsü.

BDT sisteminde kullanılan temel morfolojik şekil bilgisine dayalı geometrik öznitelikler şunlardır [102]:

- **Alan** (*Area, A*): Şekil-1’de görüldüğü üzere iki boyutlu örüntüyü oluşturan bölgenin piksel cinsinden değerini ifade etmektedir.
- **Çevre** (*Perimeter, P*): İki boyutlu örüntüyü çevreleyen uzunluk olarak tarif edilir.
- **Çap** (*Diameter, D*): Şekil-1’de görüldüğü gibi alınan nodül örüntülerinde en büyük değere sahip uzunluk (*a*) olarak ifade edilmektedir.
- **Katılık** (*Solidity*): Örüntü üzerindeki dışbükey durumdaki piksellerin oranını göstermektedir. Görüntü açısından renk ölçeğindeki koyuluğu ifade eden bir parametredir.

- **Eksantriklik** (*Eccentricity*): Örüntü bölgesine ait aynı ikinci derece moment değerine sahip olan elipsin yapısı hakkında bilgi vermektedir. Aynı zamanda elipsin odağı ile ana eksen uzunluğu arasındaki mesafenin oranı olarak ifade edilmektedir. Eksantriklik değeri, 0 ile 1 arasında değişmektedir. Eksantrikliğin 1 (bir) olması örüntünün çizgi, 0 (sıfır) olması ise örüntünün daire olduğu anlamına gelmektedir.
- **En-Boy Oranı** (*Aspect Ratio*): Şekil-1'de görüldüğü üzere alınan iki boyutlu örüntüdeki en büyük (boy) ve en küçük (en) uzunlukların oranı olarak tanımlanmaktadır.

$$\text{En Boy Oranı} = \frac{\text{En Küçük Çap (b)}}{\text{En Büyük Çap (a)}} \quad (3.40)$$

- **Kompaktlık** (*Compactness*): Örüntüdeki piksellerin bütünlüğünün bir ölçüsüdür. Karşılaştırma yapmak amacıyla kompaktlık, örüntü daire şeklinde ise 1 değerine, kare şeklinde ise $4/\pi$ değerine yakınsamaktadır.

$$\text{Kompaktlık} = \frac{P^2}{4\pi A} \quad (3.41)$$

- **Yuvarlaklık** (*Roundness*): Örüntünün yuvarlaklık ölçüsünü göstermektedir. Yuvarlaklık, örüntü daire şeklinde ise 1 değerine, kare şeklinde ise 2 değerine eşit olmaktadır.

$$\text{Yuvarlaklık} = \frac{4A}{\pi a^2} \quad (3.42)$$

- **Dairesellik** (*Circularity*): Ele alınan örüntünün dairesel yapısına ilişkin yakınsaklığını göstermektedir. Örüntü daire şeklinde ise dairesellik değeri 1, kare ise $\pi/4$ değerine eşittir.

$$\text{Dairesellik} = \frac{4\pi A}{P^2} \quad (3.43)$$

- **Eliptisite** (*Ellipticity*): Örüntünün elips yapısına olan yakınlığını ifade etmektedir. Eliptisite, örüntü daire şeklinde ise 2 değerine, kare ise π değerine yakınsamaktadır.

$$Eliptisite = \frac{\pi a^2}{2A} \quad (3.44)$$

Kullanılan geometrik özniteliklere ait matematiksel ifadeler ve belirli şekil yapıları için elde edilen değerler Tablo 3.4'te özet olarak görülmektedir. Kullanılan özniteliklerin daire ve kare gibi iki boyutlu şekiller için hesaplanan değerleri, kullanılan özniteliklerin değişim aralığı konusunda bir fikir oluşturması amacıyla verilmiştir.

İki boyutlu örüntülerin şekil bilgisine dayalı morfolojik görüntü işleme ile elde edilen geometrik öznitelikler, pulmoner nodüllerin özniteliklerinin elde edilmesinde son derece kullanışlıdır. Tez çalışmasında geometrik özniteliklerin kullanılmasıyla pulmoner nodül örüntülerinin sınıflandırılmasında oldukça yüksek başarımlı değerleri elde edilmiştir [70].

Tablo 3.4: Morfolojik şekil bilgisine dayalı iki boyutlu geometrik özellikler.

Öznitelikler	Matematiksel İfadesi	Daire	Kare
Alan	A	-	-
Çevre	P	-	-
Çap	D	-	-
Katılık	-	-	-
Eksantriklik	-	0	-
En-boy Oranı	$\frac{En\ küçük\ çap\ (b)}{En\ büyük\ çap\ (a)}$	1	$\frac{1}{\sqrt{2}}$
Kompaktlık	$\frac{P^2}{4\pi A}$	1	$\frac{4}{\pi}$
Yuvarlaklık	$\frac{4A}{\pi a^2}$	1	2
Dairesellik	$\frac{4\pi A}{P^2}$	1	$\frac{\pi}{4}$
Eliptisite	$\frac{\pi a^2}{2A}$	2	π

3.6 EN ETKİLİ ÖZNETELİKLERİN SEÇİMİ

3.6.1 mRMR Yöntemi

Sınıflandırma algoritmalarında daha yüksek doğruluk oranı ve daha kısa hesaplama zamanına olanak sağlayan öznitelik seçme metotlarından mRMR (*Asgari Artıklık Azami İlişkiselik, Minimum Redundancy Maximum Relevance*) Yöntemi, Hanchuan Peng tarafından önerilmiştir [103]. mRMR yöntemi, veri kümesindeki özniteliklerin arasından sınıf bilgisiyle en ilişkilerini seçerek ilişkisellik değerini en yüksek yapmayı, öznitelikler arasındaki bağımlılığı ölçen artıklık değerini en küçük değerde tutmayı hedeflemektedir.

mRMR yönteminde kullanılan her bir öznitelik, birbirinden bağımsız rastgele değişken olarak kabul edilmektedir. mRMR yönteminde ilişkisellik ve artıklık değerleri, benzerlik bilgisi (*mutual information*) değerleri hesap edilerek elde edilmektedir.

X ve Y ayrık değişkenleri dikkate alınır, benzerlik bilgisi aşağıdaki şekilde ifade edilir:

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p_1(x)p_2(y)} \right) \quad (3.45)$$

Burada $p(x, y)$, X ve Y rastgele değişkenlerine ait birleşik olasılık dağılım fonksiyonunu; $p_1(x)$ ve $p_2(y)$, X ve Y değişkenlerine ait marjinal olasılık dağılım fonksiyonlarını göstermektedir.

mRMR yöntemi, bir sınıf ve bir öznitelik arasında veya bir öznitelik ve diğer öznitelik arasındaki benzerlik bilgisini kullanmaktadır. c sınıf için bir S öznitelik kümesinin ilişkiselliği, tek öznitelik x_i ve c sınıfı arasındaki tüm benzerlik bilgisi değerlerinin ortalaması olarak tanımlanmaktadır.

$$\max D(S, c), \quad D = \frac{1}{|S|} \sum_{x_i \in S} I(x_i; c) \quad (3.46)$$

Burada $I(x_i, c)$, öznitelik x_i ve c sınıf arasındaki benzerlik bilgisidir. S kümesindeki tüm özniteliklerin artıklığı, x_i ve x_j öznitelikleri arasındaki tüm benzerlik bilgisi değerlerinin ortalaması olarak ifade edilmektedir.

$$\min R(S), R = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \quad (3.47)$$

Burada $I(x_i, x_j)$, öznitelik x_i ve x_j arasındaki benzerlik bilgisidir. mRMR yönteminde, Denklem (3.46) ve Denklem (3.47) ifadeleri aynı anda optimize edilerek en uygun öznitelik kümesi elde edilir.

$$\text{Fark Kriteri: } \max(D - R) \quad (3.48)$$

$$\text{Oran Kriteri: } \max(D/R) \quad (3.49)$$

Özniteliklere ait en uygunluk hesabı, yukarıdaki *Fark Kriteri* veya *Oran Kriteri*'ne göre gerçekleştirilmektedir.

3.7 DESTEK VEKTÖR MAKİNELERİ

Destek Vektör Makineleri (*Support Vector Machines*, DVM), istatistiksel öğrenme teorisine dayalı bir kontrollü sınıflandırma algoritmasıdır. 1960'lı yılların sonlarında Vapnik tarafından teorik temelleri atılmış ve Vapnik, 1995 yılında ilk defa bir sınıflandırma probleminin çözümünde kullanmıştır [104, 105]. DVM algoritması iki sınıfa ait örnekleri birbirinden ayırma esasına dayanmaktadır. DVM başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmışken, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırma problemlerinin çözümü için de geliştirilmiştir. DVM, örnek uzayında örnekleri mümkün olduğu kadar sınıflandıran en uygun ayırıcı düzlemi (*hyperplane*) bulmaya çalışır. Böylece DVM, iki sınıfa ait örnekler arasındaki mesafenin maksimum olmasını sağlamaya çalışmaktadır. Bu tür iki sınıfa ait örnekleri birbirinden ayırma probleminde birçok ayırıcı düzlem bulunabilir. Bu anlamda en uygun ayırıcı düzlem ise iki sınıfa ait ve sınıra en yakın iki örnek arasındaki mesafenin en büyük olmasını sağlayan aşırı düzlemdir. Optimum ayırıcı düzlemin sınırlarına (*margin*) en yakın örnek vektörlere, *destek vektörü* adı verilir [105].

DVM algoritması sınıflandırma işlemi yaparken, diğer makine öğrenme algoritmalarının kullanmış olduğu Deneysel Risk Minimizasyonu (*Empirical Risk Minimization*, ERM) ve Yapısal Risk Minimizasyonu (*Structural Risk Minimization*, SRM) yapılarını kullanmaktadır. Burada ERM, örnekler arasındaki hata oranını en aza indirmeye çalışırken, SRM ise bütün örnekler üzerinden kaynaklanan hata oranı üst sınırının en küçük olmasını sağlamaktadır.

Bir sınıflandırma işleminde iki örnek arasındaki optimum ayırıcı düzlemin bulunması son derece önemlidir. DVM ile bu düzlem bulunurken, önce ortaya çıkan optimizasyon problemi formüle edilir ve ardından problem ikinci derece programlama ile çözülür. Eğer örnek (eğitim) vektörler doğrusal olarak bir ayırıcı düzlem ile ayrılamıyorsa, bu örnekler giriş uzayından çok boyutlu öznitelik uzayına haritalanır. Böylece öznitelik uzayında en uygun ayırıcı düzlem bulunmaya çalışılır. Tüm bu işlemlerde hesap yükü ve süresinin az olması sınıflandırıcının performansı açısından son derece önemlidir. Bu amaçla öznitelik uzayında yüksek dereceli işlem yükünden kurtulmak

için Çekirdek (*Kernel*) Fonksiyonları kullanılır ve en uygun ayırt edici düzlem çekirdek fonksiyonları yardımıyla bulunur.

Destek vektör makineleri, sinir ağları, radyal tabanlı fonksiyon ağları ve polinom sınıflandırıcıları kendi yapısında bulunmaktadır. Doğrusal olmayan girişleri yüksek boyutlu öznitelik uzayına dönüştürüp, öznitelik uzayında doğrusal yöntemleri kullandığı için DVM'lerin matematiksel analizi son derece basittir [106].

Destek vektör makineleri, karakter tanıma, ses tanıma ve örüntü tanıma gibi alanlarda son yıllarda bir çok uygulama alanı bulmuştur [107].

3.7.1 Doğrusal Destek Vektör Makineleri

3.7.1.1 Doğrusal olarak Ayrılabilen Durumlar

Doğrusal olarak ayrılabilen durumlar için en uygun ayırt edici düzlemin elde edilmesi Vapnik tarafından sağlanmıştır [104]. Amaç, veri kümesini verilen sınıflara göre bir alt düzlem ile ayırıp, aynı sınıfa ait bütün veri noktalarını alt düzlemin kendi tarafında bırakmaktır.

l tane örnekten oluşan bir eğitim kümesini ele alalım.

$$(x_1, y_1), \dots, (x_n, y_n), x_i \in R^d, y_i \in \{-1, +1\} \quad (3.50)$$

w ağırlık vektörü ve b eşik değerleri uygun olarak seçilip aşağıdaki eşitsizlikleri sağlıyorsa o zaman Denklem (3.50)'deki eğitim kümesi doğrusal olarak ayrılabilir demektir.

$$w \cdot x_i + b \geq 1, y_i = 1 \quad (3.51)$$

$$w \cdot x_i + b \leq -1, y_i = -1 \quad (3.52)$$

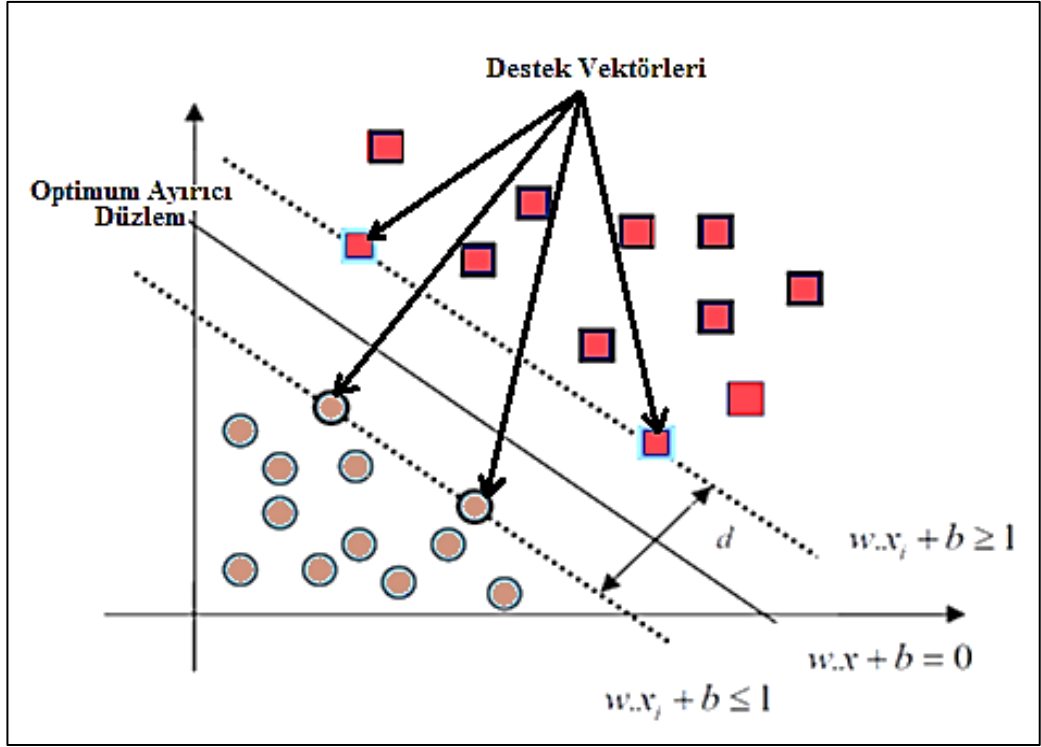
Bu denklemler aşağıdaki şekilde genelleştirilebilir.

$$y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, l \quad (3.53)$$

Bu durumda en uygun ayırıcı düzlem ise karar sınırı Denklem (3.54) ile verilmektedir.

$$w \cdot x + b = 0 \quad (3.54)$$

Bir eğitim verisinde en uygun ayırıcı düzlem tektir ve verileri en büyük sınır ile ayırmaktadır. Sınır, ayırıcı düzlem ile eğitim verileri arasındaki en kısa mesafe olarak tanımlanmaktadır. Şayet sınır maksimum mesafeye sahipse ayırıcı düzlem en uygun (optimum) düzlem olarak adlandırılır. Şekil 3.15, iki boyutlu bir uzayda iki sınıfa ait verileri ayıran bir ayırıcı düzlemi temsil etmektedir. Şekilde noktalı doğrular, ayırıcı düzleme ait karar sınırlarını göstermektedir. Bu yüzeye en yakın vektörler destek vektörleri olarak adlandırılır. Karar sınırları bu vektörlerle belirlenmektedir.



Şekil 3.15: İki boyutlu uzayda iki sınıfa ait ayırıcı düzlem [107].

En uygun sınır uzunluğu olan d mesafesi aşağıdaki şekilde ifade edilir.

$$d = \frac{2}{\|w\|} \quad (3.55)$$

Burada $\|w\|$, w 'nin normudur. d mesafesinin en büyüklenmesi için $\|w\|$ 'nin en küçüklenmesi ile sağlanmaktadır. En uygun ayırıcı düzlem Denklem (3.51) ve Denklem (3.52)'deki koşulları sağlayan ve $\|w\|$ 'yi en küçüklenmesi en iyileme problemi olarak ele alınmaktadır. Bu en iyileme problemini çözmek için Langrange Çarpanları Yöntemi'nden yararlanılabilir.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i [y_i(w \cdot x + b) - 1] \quad (3.56)$$

Burada $\alpha_i \geq 0$ olmak üzere, Langrange çarpanlarını ifade etmektedir. $L(w, b, \alpha)$ fonksiyonu, α_i değerleri için en büyük, w ve b değerleri için en küçük alınarak çözüm

sağlanabilir. $L(w,b,\alpha)$ fonksiyonunun w ve b değerlerindeki en küçük noktaları bulmak için kısmi türevlerinin alınıp sıfır değerine eşitlenmesi gerekmektedir.

$$\frac{\partial L(w,b,\alpha)}{\partial w} = 0 \quad (3.57)$$

$$\frac{\partial L(w,b,\alpha)}{\partial b} = 0 \quad (3.58)$$

Bu ifadeleri türevleri, Denklem (3.59)'daki şart dikkate alınarak çözümlenirse, en uygun ayırıcı düzlemin çözümü,

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad \alpha_i \geq 0, \quad i = 1, \dots, l \quad (3.59)$$

$$w = \sum_{i=1}^l \alpha_i y_i x_i \quad \alpha_i \geq 0, \quad i = 1, \dots, l \quad (3.60)$$

şeklinde eğitim vektörünün (x_i) kombinasyonu ifade edilir. Böylece Denklem (3.56), fazla değişkenli bir ifade olmak yerine, α_i Langrange çarpanlarına bağlı olarak yazılabilir.

Destek vektörlerinin (karar sınırları) bulunduğu noktalarda Denklem (3.53) eşitsizliği, Khun-Tucker Teoremi kullanılarak $\alpha \neq 0$ noktalarında aşağıdaki yapıya dönüşmektedir.

$$\alpha_i [y_i (w \cdot x_i + b) - 1] = 0, \quad i = 1, \dots, l \quad (3.61)$$

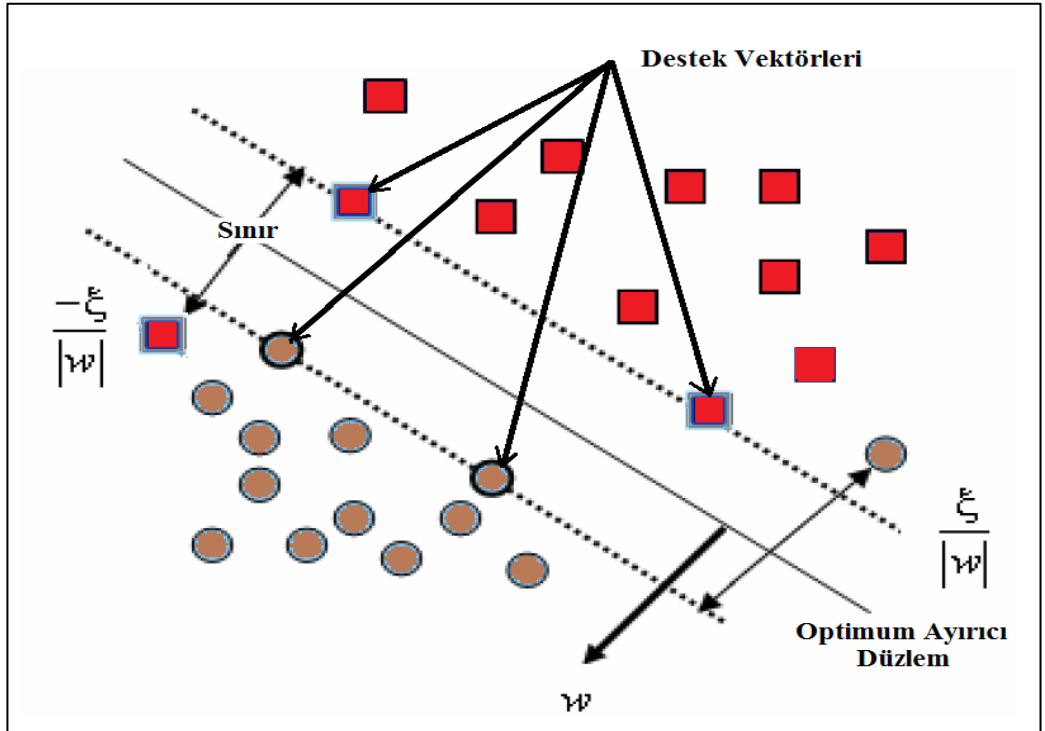
Bu denklemi sağlayan noktalar destek vektörleridir. Denklem (3.59) ve Denklem (3.60) ifadeleri kullanılarak Denklem (3.56) yeniden yazılırsa,

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (3.62)$$

şeklinde ifade edilir. Denklem (3.62)'de görüldüğü üzere, $L(\alpha)$ fonksiyonu, Denklem (3.59) verilen şarta bağlı olup Langrange çarpanlarına göre en çoklama işlemi yapılarak çözülmektedir [105, 108].

3.7.1.2 Doğrusal olarak Ayrılamayan Durumlar

Burada amaç, iki sınıflı veriyi, aynı sınıfa ait verinin mümkün olan en büyük kısmını altdüzlemin aynı tarafında bırakacak şekilde ayrılabilen alt düzlemi bulmaya çalışmaktır. Sınıflandırma problemlerinin çözümünde eğitim verilerini daima hatasız bir şekilde ayırmak mümkün olmadığından, bu verilerin ayrılmasında en az hata ile ayrılması istenilmektedir. Doğrusal olarak ayrılamayan durum, Şekil 3.16'da gösterilmiştir.



Şekil 3.16: Doğrusal olarak ayrılamayan durum örneği [107].

Bir önceki kısımda sınıflandırmada eğitim verilerinin doğrusal olarak ayrılabilirdiği ve optimum ayırıcı düzlem, $\|w\|$ 'nin en azlanarak elde edildiği belirtilmişti. Böylece tek bir destek vektörünün en iyi ayırt edici düzlemi tanımlamada yeterli olduğu ifade edilmişti. Doğrusal olarak ayrılamayan durumlar için Şekil 3.16'da gösterildiği gibi en iyi ayırt edici düzlem, ξ_i gevşek değişkenler tanımlanarak elde edilir [105].

ξ_i gevşek değişkeni, herhangi bir eğitim verisi için uygun sınıfın sınırdan olan sapma miktarı olarak tanımlanmaktadır. Ayırt edici düzlemde sınırın içine düşen veya karar sınırın yanlış sınıfa ait olduğu tarafta bulunan eğitim verileri için genelleme yapılırsa ayırt edici düzlem, Denklem (3.53)'teki şart ifadesine ξ_i pozitif gevşek değerleri eklenmektedir.

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i \text{ ve } \xi_i \geq 0, \quad i = 1, \dots, l \quad (3.63)$$

Hatanın meydana gelmesi ξ_i ifadesinin 1 (bir) değerini aşmasıyla oluşmaktadır. $\sum_i \xi_i$ değeri, tüm eğitim hataları sayısının toplamı olup, üst sınırı göstermektedir. Genel olarak en büyük sınır ile en iyi ayırt edici düzlem,

$$P = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (3.64)$$

denklem (3.63)'teki şartlara bağlı olarak, P eşitliğini en küçük yapan w ve b parametreleri ile tanımlanmaktadır. Buradaki C , düzenleyici parametre olarak tanımlanır ve herhangi bir sabit bir değer seçilebilmektedir. Denklem (3.64)'ün çözümü için ifadenin Langrange çarpanları ile ikili probleme dönüştürülmesi gerekmektedir [108].


$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (3.65)$$

$$\sum_{i=1}^l \alpha_i y_i \text{ ve } 0 \leq \alpha_i \leq C \quad i = 1, \dots, l \quad (3.66)$$

Denklem (3.65) ifadesi en büyük yapılmak suretiyle sınıflandırma için gerekli olan parametreler hesaplanır.

3.7.2 Doğrusal Olmayan Destek Vektör Makineleri

Destek vektör makinelerinin uygulamalarına bakıldığında doğrusal DVM yerine çoğu zaman doğrusal olmayan DVM algoritmaları kullanılmaktadır. Doğrusal DVM algoritmaları, Doğrusal olmayan DVM algoritmalarına dönüştürülebilmektedir. Bunu gerçekleştirmek için giriş uzayındaki eğitim verileri, daha yüksek boyutlu bir uzaya dönüştürülmelidir [106, 109]. Bu şekilde yüksek boyutlu uzayda doğrusal yaklaşımlar uygulanarak sınıflandırma problemi çözülebilmektedir.



Şekil 3.17: Giriş uzayının çok boyutlu Öznitelik uzayına dönüşümü [107].

Şekil 3.17’de, giriş uzayında doğrusal olmayan eğitim verilerinin yüksek dereceli öznitelik uzayına dönüştürüldüğünde doğrusal olarak ayırt edilebileceği görülmektedir.

$\phi: R^d \rightarrow R^N$ olmak üzere,

$$\phi(x_i) = \phi_1(x_i), \phi_2(x_i), \dots, \phi_N(x_N), \quad i = 1, \dots, l \quad (3.67)$$

böylece x bilinmeyen vektörün sınıflandırılması, x vektörünün $\phi(x)$ ayırıcı uzayına dönüştürülmesi ve fonksiyonun işaretini alması ile gerçekleştirilir.

$$f(x) = w \cdot \phi(x) + b \quad (3.68)$$

Daha önce belirtildiği üzere w vektörü, destek vektörlerinin doğrusal kombinasyonu olarak ifade edilir.

$$w = \sum_{i=1}^l y_i \alpha_i \phi(x_i) \quad (3.69)$$

Denklem (3.69), Denklem (3.68) ifadesinde yerine konulursa bilinmeyen x vektörü, sadece iç çarpıma bağlı olarak elde edilir.

$$f(x) = \sum_{i=1}^l y_i \alpha_i (\phi(x) \cdot \phi(x_i)) + b \quad (3.70)$$

Yüksek boyuta sahip öznitelik uzayının $(\phi(x) \cdot \phi(x_i))$ iç çarpımının hesap edilmesi oldukça zordur. Bunun yerine düşük boyuta sahip giriş uzayında Çekirdek (*Kernel*) fonksiyonlarının kullanılması daha hesaplama imkânı sağlamaktadır [110, 68].

Çekirdek fonksiyonu K ,

$$K = (\phi(x) \cdot \phi(x_i)) \quad (3.71)$$

şeklinde ifade edilir. Langrange çarpanları doğrusal olmayan durumlar için kullanıldığında,

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j \phi(x_i) \phi(x_j) \quad (3.72)$$

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) \quad (3.73)$$

olarak elde edilir. Burada Denklem (3.73) ifadesi aşağıdaki şartlara bağlıdır.

$$\sum_{i=1}^l y_i \alpha_i = 0 \quad \text{ve} \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, l \quad (3.74)$$

Literatürde en sık kullanılan Polinom, Radyal Tabanlı Fonksiyon (*RBF*) ve normalleştirilmiş polinom çekirdek fonksiyonlarıdır. Tablo 3.5'te bu çekirdek fonksiyonlarına ait matematiksel ifadeler ve kullanılan parametreler ayrıntılı olarak verilmiştir. Tablodan görüldüğü üzere bazı parametrelerin kullanıcı tarafından belirlenmesi gerekmektedir. Polinom çekirdek fonksiyonlarında p değeri,

$p = 1$ ise Doğrusal Çekirdek Fonksiyonu

$p = 2$ ise Karesel Çekirdek Fonksiyonu

olarak adlandırılmaktadır.

Tablo 3.5: DVM'de kullanılan temel kernel fonksiyonları ve parametreleri [111].

Kernel Türü	Matematiksel İfadesi	Parametreler
<i>Polinom Kerneli</i>	$K(x, x_i) = (x \cdot x_i + 1)^p$	p: Polinom Derecesi
<i>Normalleştirilmiş Polinom Kerneli</i>	$K(x, x_i) = \frac{(x \cdot x_i + 1)^d}{\sqrt{(x \cdot x + 1)^d + (x_i \cdot x_i + 1)^d}}$	d: Polinom Derecesi
<i>Radyal Tabanlı Fonksiyon Kerneli</i>	$K(x, x_i) = e^{-\gamma \ x - x_i\ ^2}$	γ : Kernel Boyutu

Kernel fonksiyonların matematiksel ifadeleri dikkate alındığında polinom ve Radyal Tabanlı çekirdek fonksiyonlarının daha sade ve anlaşılabilir olduğu görülmektedir. Burada matematiksel olarak basit görünse de, polinomun derecesindeki artış, algoritmanın karmaşık bir hal almasının yanı sıra hem işlem süresinde artışa hem de sınıflandırma başarımının ciddi bir şekilde düşmesine neden olmaktadır. RBF'de kernel boyutu parametresindeki değişimler sınıflandırma performansına daha az etki ettiği belirtilmiştir [111]. Normalleştirilmiş polinom fonksiyonu, veri setinin

normalleştirilmesi yerine polinom çekirdek fonksiyonunun matematiksel ifadesinin normalleştirilmesi amacıyla Arnulf tarafından ortaya atılmıştır [112]. Yani, normalleştirilmiş polinom çekirdek fonksiyonu polinom kernelinin genelleştirilmiş durumu olduğu söylenebilir.

Çekirdek fonksiyonlarına ait parametrelerin seçiminin yanı sıra destek vektör makineleri için *düzenleyici parametre* C 'nin kullanıcı tarafından belirlenmesi son derece önemlidir. Düzenleme parametresinin çok küçük veya çok büyük değerler seçildiğinde en uygun ayırıcı düzlem doğru bir şekilde belirlenemeyeceğinden sınıflandırma doğruluğunda önemli düşüş olmaktadır. Diğer taraftan $C = \infty$ olması durumunda DVM algoritması sadece doğrusal olarak ayrılabilen veri kümesi için kullanılabilir olmasını sağlayacaktır. Bu açıdan parametrelerin seçimi, DVM'nin sınıflandırma performansını doğrudan etkileyen bir faktördür. Genel olarak deneme ve hata yaklaşımı kullanılmasına karşın çapraz doğrulama yaklaşımı başarılı sonuçlara ulaşılmasına olanak sağlamaktadır. Çapraz doğrulamada amaç oluşturulan sınıflandırma modelinin performansının belirlenmesidir. Burada veri kümesi iki kısma bölünür. Birinci kısım sınıflandırmanın yapılandırılmasında eğitim verisi olarak kullanılır. İkinci kısım ise oluşturulan modelin performansını belirlemede test verisi olarak değerlendirilmektedir. Böylece eğitim verisi ile yapılandırılan modelin test verisine uygulanmasıyla elde edilen doğru sınıflandırılan örneklerin sayısı, sınıflandırıcının performansını belirlemektedir [69].

3.8 PULMONER NODÜLLERİN MALİGN-BENİGN AYRIMININ YAPILMASI

Akciğer kanseri tedavisinde pulmoner nodüllerin bir BDT sistemi ile tespit edilmesinin yanı sıra pulmoner nodüller ile ilgili malign (*kötü huylu, kötücül*), benign (*iyi huylu, iyicil*) gibi teşhis ve tedavi sürecine katkı sağlayabilecek bilgisayar destekli teşhis sistemlerinin geliştirilmesi oldukça önemli bir yeniliği beraberinde getirecektir. Şimdiye kadar yapılan çalışmalarda genellikle farklı sınıflandırma algoritmaları kullanılarak medikal görüntüler üzerinde nodül olup olmadığının tespiti edilmesi yönünde olmuştur [47-79]. Dolayısıyla bir bilgisayar destekli teşhis sisteminin birinci basamağını oluşturan pulmoner nodül tespiti adımından sonra hekime hastalığın teşhisi hakkında yardımcı olabilecek sistemlerin geliştirilmesi büyük önem arz etmektedir.


Bu amaçla, çalışmada kullanılan hastaların BT görüntüleri tıbbi teşhis aşamasında radyoloji ve patoloji raporları neticesinde hastadaki nodülün malignite veya benign özellikte olduğu değerlendirilen BT görüntüleri pulmoner nodüllerin sınıflandırılması için incelenmiştir.

Çalışmada pulmoner nodül örüntülerinden özniteliklerin çıkartılması için iki farklı öznitelik yapısı önerilmektedir. Biri; yaş, cinsiyet, nodül lokalizasyonu, kontrast ve nodül çapı niceliklerini içine alan *Risk Faktörleri*; diğeri, kullanılan iki boyutlu pulmoner nodül örüntüleri için Eksantriklik, Kompaktlık, Yuvarlaklık, Dairesellik ve Eliptisite gibi şekillerine dayalı geometrik özelliklerini tanımlayan *Morfolojik Özellikler* kullanılarak Tablo 3.6'da verildiği gibi bir öznitelik kümesi oluşturulmuştur.


Tablo 3.6: Malign ve benign nodüllerin sınıflandırılması için oluşturulan öznitelikler.

Sıra	Nicelik	Öznitelik
1	Risk Faktörleri	<i>Yaş</i>
2		<i>Cinsiyet</i>
3		<i>Nodül Lokalizasyonu</i>
4		<i>Kontrast</i>
5		<i>Nodül Çapı</i>
6	Morfolojik Özellikler	<i>Eksantriklik</i>
7		<i>Kompaktlık</i>
8		<i>Yuvarlaklık</i>
9		<i>Dairesellik</i>
10		<i>Elipsite</i>

Pulmoner nodüllerin sınıflandırılması için oluşturulan öznitelikler ile ilgili olarak nodül lokalizasyonu sağ ve sol akciğer parankim yapılarında alt, üst ve akciğer zarına yapışık olmak üzere 6 (altı) farklı bölgeye ayrılmıştır (Şekil 3.18). Ayrıca veri setinde kullanılan BT görüntülerinden alınan benign ve malign huylu tümör örnekleri Şekil 3.19’da verilmektedir.



Şekil 3.18: Akciğerde nodül lokalizasyonu için ayrıştırılan bölgeler.



Şekil 3.19: Benign ve Malign huylu tümör örnekleri.

Pulmoner nodül örüntülerinin çapı ölçülerek malign-benign ayrımında risk faktörü olarak kullanılmıştır. Bilgisayar tomografi görüntüleri üzerinde doku, kitle ve

lezyonların görüntü yoğunluk ölçümleri Hounsfield Unit (*HU*) değeri ile ifade edilmektedir [113]. Çalışmada ilgili pulmoner nodül örüntüleri için Hounsfield Unit değerleri ölçülmüş ve pulmoner nodüllerin sınıflandırılmasında risk faktörü olarak değerlendirilmiştir. Ayrıca Tablo 3.7’de BT cihazında kullanılan Hounsfield Unit cinsinden ortam yoğunluk değerleri verilmektedir.

Tablo 3.7: BT cihazında Hounsfield Unit (HU) cinsinden yoğunluk değerleri [113].

Ortam	HU Değeri
Hava	-1000
Yağ	-50 ile -100
Su	0
Kist	0-20
Taze Kan- Pıhtı	40-60
Nonkalsifiye Nodül	40-160
Kalsifiye Nodül	>200
Kemik	1000

Pulmoner nodül örüntülerine ait iki boyutlu şekil özelliklerine dayalı morfolojik görüntü işleme yapılarak örüntüleri en iyi tanımlayan öznitelikler elde edilmiştir. Kullanılan öznitelikler ile ilgili ayrıntılı bilgiler Bölüm 3.5’te verilmektedir.

3.9 MEDİKAL GÖRÜNTÜLEMEDE KULLANILAN PERFORMANS ÖLÇÜMLERİ

Son yıllarda teknolojinin hızla gelişmesine paralel olarak medikal görüntüleme tekniklerinde de hızlı bir ilerleyiş meydana gelmiştir. Özellikle kullanılan son teknoloji görüntüleme cihazlarının elde edilen görüntülerin yorumlanması son derece önemlidir. Bu kapsamda uzman hekimlere teşhis ve tedavi aşamasında çok ciddi bir katkı sağlayan Bilgisayar Destekli Tespit sistemlerinin kullanımı rutin klinik çalışmalarda sıklıkla rastlanmaktadır.

Geliştirilen BDT sistemlerinin tıbbi karar verme performansını ve klinik anlamda kullanılabilirliğini belirlemek için, literatürde çeşitli istatistiksel ölçüm parametreleri kullanılmaktadır. Bir BDT sistemine ait örnek bir hata matrisi Tablo 3.8’de verilmektedir. Burada “gerçek durum” veya “kestirilen durum”, pozitif ve negatif olarak ifade edilir. Pozitif, BT görüntüsünde “pulmoner nodül”ün var olduğunu, negatif ise BT görüntüsünde “nodül olmayan” bir örüntünün mevcut olduğunu göstermektedir.

Tablo 3.8: Bir BDT sisteminde hata matrisi.

Gerçek Durum	Kestirilen Durum	
	Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Pozitif (Pulmoner Nodül)	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
Negatif (Nodül olmayan örüntü)	Yanlış Negatif (YN)	Doğru Negatif (DN)

Tablo 3.8’de sırasıyla, Doğru Pozitif (DP), gerçekte nodül olan bir yapının BDT sistemi tarafından da nodül olarak tespit edilenlerin sayısını; Yanlış Pozitif (YP), gerçekte nodül olan bir yapının BDT sistemi tarafından nodül olmadığı şeklinde tespit edilenlerin sayısını; Yanlış Negatif (YN), gerçekte nodül olmayan bir yapının BDT sistemi

tarafından nodül olarak etiketlenenlerin sayısını; Doğru Negatif (DN) ise gerçekte nodül olmayan bir yapının aynı şekilde BDT sistemi tarafından da etiketlenenlerin sayısını göstermektedir. Bir BDT sisteminin başarımını, DP ve DN değerlerinin en yüksek, YP ve YN değerlerinin sıfır veya en düşük seviyede olması artırmaktadır.

Bir BDT sisteminin performans başarımını tanımlayabilmek için başlıca aşağıdaki performans ölçütleri kullanılmaktadır [114]:

- **Duyarlılık** (*Sensitivity / Recall*): Gerçek durum değerlendirmesinde pulmoner nodül olan yapıların (DP), BDT sistemi tarafından da pulmoner nodül olarak saptanan (DP+YN) yapılara oranını ifade etmektedir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} * 100 \quad (3.75)$$

- **Seçicilik** (*Specificity*): Gerçek durum değerlendirmesinde pulmoner nodül olmayan yapıların (DN), BDT sistemi tarafından da pulmoner nodül olmayan olarak saptanan (DN+YP) yapılara oranını göstermektedir.

$$\text{Seçicilik} = \frac{DN}{DN+YP} * 100 \quad (3.76)$$

- **Toplam Sınıflandırma Doğruluğu** (*Total Classification Accuracy*): Bir BDT sisteminin değerlendirmesi sonucunda verdiği tüm doğru kararların, toplam veri kümesine oranı olarak ifade edilmektedir. Duyarlılık ve seçicilik tek bir sınıfa ait bilgileri verirken, doğruluk tüm sınıflandırma ile ilgili bilgiyi içermektedir.

$$\text{Toplam Sınıflandırma Doğruluğu} = \frac{DP+DN}{(DP+DN+YP+YN)} * 100 \quad (3.77)$$

- **Kappa İstatistiği**: Kappa istatistiği, sınıflandırma oranları arasındaki uyum derecesini karşılaştırmak için kullanılmaktadır. Bir bakıma sınıflandırmanın kalitesini ölçmek için kullanılır. Kappa istatistiği [1,-1] aralığında değer almaktadır.

1 değeri, mükemmel sınıflandırmayı, -1 değeri ise sistematik olarak yanlış karar veren bir sınıflandırıcıyı göstermektedir.

- **RMSE** (*Root Mean Squared Error*): Ortalama kare hatanın kökü olarak ifade edilmektedir. RMSE ifadesi,

$$RMSE = \sqrt{\frac{\sum(y' - y)^2}{n}} \quad (3.78)$$

olarak verilmektedir. Burada y' , gerçek değeri; y , kestirilen değeri ve n kullanılan toplam veri sayısını göstermektedir. RMSE değerinin sıfır veya bu değere yakın olması, sistemin başarımının mükemmel olduğunu göstermektedir.

- **ROC Eğrileri** (*Receiver Operating Characteristics Curves*): Bir ROC eğrisi, genellikle sınıflandırıcıların performansını görselleştirmek için kullanılan bir tekniktir. Ayrıca tıbbi karar verme sistemlerinde farklı sınıflandırıcıların performansını karşılaştırmada son derece kullanışlıdır. ROC eğrisi, doğru pozitif ve yanlış pozitif arasındaki dengeyi göstermektedir. Bir ROC eğrisinde, x -ekseni YP oranını, y -ekseni ise DP oranını göstermektedir. ROC eğrisi altında kalan alan, *AUROC* olarak tanımlanmaktadır. *AUROC* değeri ne kadar büyükse, yani, eğri altında kalan alan ne kadar fazla ise yapılan sınıflandırma o ölçüde başarılıdır [115].

Bir BDT sisteminin başarımı için tüm bu parametrelerin birlikte ele alınıp değerlendirilmesi gerekmektedir. Bu ölçümler arasında, duyarlılık, seçicilik ve doğruluk ölçüm değerlerinin yüksek olması arzu edilmektedir.

Yine Yanlış Pozitif (YP), oranının düşük olması son derece önemlidir. Çünkü bir BDT sistemi için, gerçek durumda pozitif olan bir yapının negatif olarak tanımlanması, hekimlerin hastalığın teşhisi ve tedavisi sürecinde yanlışlarına ve ilgili tıbbi görüntüde herhangi bir hastalık bulgusu olmadığı yönünde kanaat vermelerine neden olacaktır.

4. BULGULAR

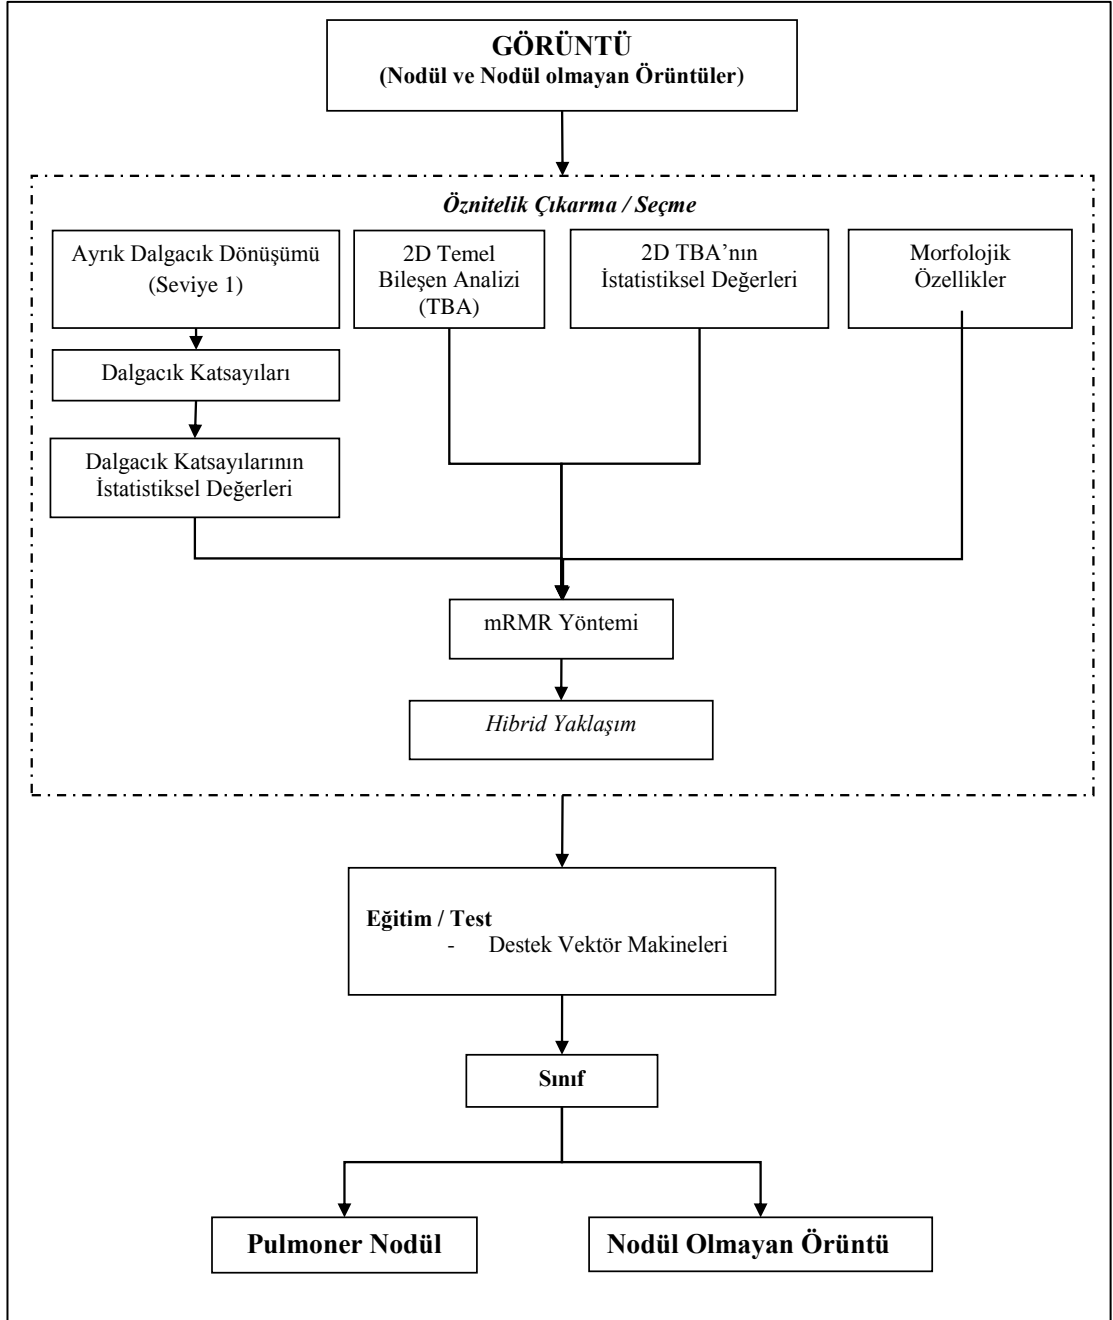
Bilgisayar destekli tespit/teşhis sistemlerinin (BDT) son yıllarda klinik anlamda oldukça sık kullanım alanı bulunmaktadır. Özellikle akciğer kanserli hastaların teşhis ve tedavi sürecinde hekimlere yardımcı olan ve onlara görüntüler üzerinde ikinci bir değerlendirme fırsatı sağlayan BDT sistemlerinin geliştirilmesi oldukça büyük önem arz etmektedir. Tez çalışması, akciğer kanseri tanı ve teşhis sürecinde pulmoner nodül örüntülerinin bilgisayar destekli bir sistemle tespit/teşhis edilmesini hedeflemektedir. Bu amaçla İÜ Cerrahpaşa Tıp Fakültesi Radyoloji Bölümü'nden elde edilen BT görüntüleri kullanılmıştır.

Tez çalışmasında literatüre alternatif olabilecek BT görüntülerinden pulmoner nodüllerin tespit ve teşhisine yönelik yeni iki farklı BDT sistemi önerilerek yeni sınıflandırma işlemleri gerçekleştirilmiştir. Öncelikle BT görüntülerinden pulmoner nodül örüntülerinin tespitine yönelik bir sistem; ardından BT görüntülerinden pulmoner nodül örüntülerinin teşhis açısından malign ve benign olduğuna karar veren yeni bir bilgisayar destekli teşhis sistemi önerilmiştir. Bu açıdan çalışmadaki malign ve benign sınıflandırması literatüre önemli bir yenilik kazandırmaktadır. Çalışmada ayrıca hastalığın klinik değerlendirmesinde malign veya benign olduğuna karar verilemeyen ancak tedavisi uzun süreli takibi gerektiren pulmoner nodüllerin tespitine yönelik *Belirsiz* adlı üçüncü bir sınıfa yer verilmiştir.

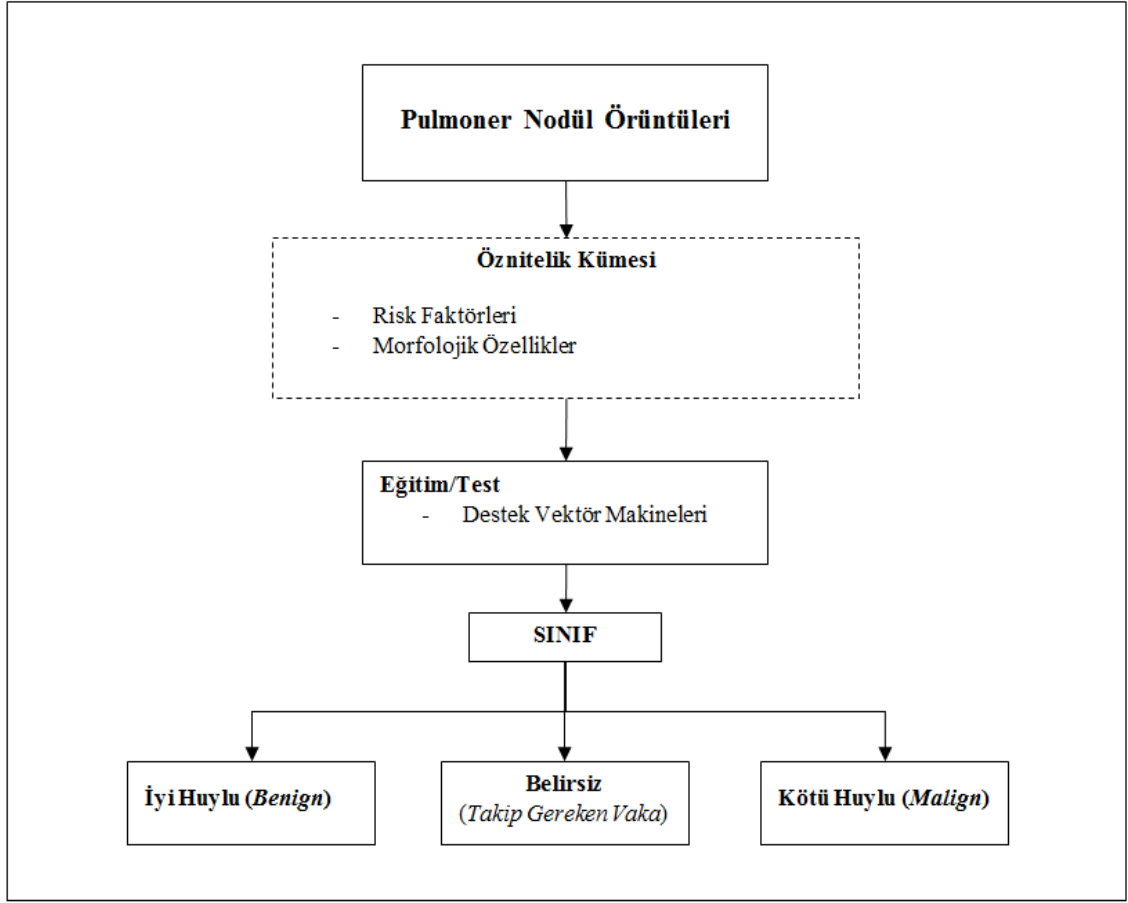
Çalışmada önerilen genel BDT sistemi, iki ana sınıflandırma blok diyagramından oluşmaktadır. Birinci kısımda önerilen BDT sistemi, görüntüler üzerinde nodül ve nodül olmayan yapılardan pulmoner nodül örüntülerinin tespit edilmesi sağlanmaktadır. Pulmoner nodüllerin tespiti için önerilen BDT sistemi blok diyagramı Şekil 4.1'de verilmektedir. İkinci kısımda ise birinci kısımda tespit edilen pulmoner nodül örüntülerinin teşhis açısından malign ve benign ayrımı yapılmaktadır. Malign ve benign ayrımı için önerilen BDT sistemi blok diyagramı Şekil 4.2'de görülmektedir.

Çalışmada 103 farklı hastadan 159 adet pulmoner nodül ve 141 adet nodül olmayan örüntü olmak üzere toplam 300 adet örüntü kullanılmıştır. Örüntü veri seti, eğitim ve test veri seti olmak üzere ikiye ayrılmıştır. Eğitim veri setinde 79 adet pulmoner nodül ve 71 adet nodül olmayan örüntü; test veri setinde 80 adet pulmoner nodül ve 70 adet nodül olmayan örüntü olmak üzere toplam 150'şer adet örüntü kullanılmıştır.

Pulmoner nodül ve nodül olmayan örüntülere ait çalışmada önerilen yöntemlerle öznelikler çıkartılmıştır. Her bir yöntemde elde edilen öznelikler arasından en etkili ve örüntüyü en iyi karakterize eden özneliklerin belirlenmesinde mRMR yöntemi kullanılmıştır. Son olarak önerilen her bir yöntemde ait sınıflandırma performans sonuçları elde edilmiştir.



Şekil 4.1: Pulmoner nodüllerin tespiti için önerilen BDT sistemi.



Şekil 4.2: Malign ve Benign ayrımı için önerilen BDT sistemi.

4.1 ÖZİNTELİK ÇIKARMA

Eğitim veri seti kullanılarak eğitilen bir sınıflandırıcının nodül ve nodül olmayan örüntüler üzerinden iki boyutlu bir sınıflandırma yapması amaçlanmaktadır. Bu kapsamda iki boyutlu bir sınıflandırmanın yapılabilmesi için görüntülere ait özniteliklerin çıkartılıp *öznitelik vektörleri* oluşturulmuştur.

Öznitelik çıkarma, görüntüyü tanımlama ve görüntüyü en iyi şekilde karakterize edebilecek özniteliklerin çıkartılarak bir öznitelik vektörünün elde edilmesi işlemidir. Tez çalışması kapsamında, elde edilen nodül ve nodül olmayan görüntülerin özniteliklerinin çıkartılması için *Ayrık dalgacık dönüşümü*, *Temel Bileşen Analizi Yöntemleri* ve *Morfolojik Görüntü İşleme* algoritmaları kullanılmıştır.

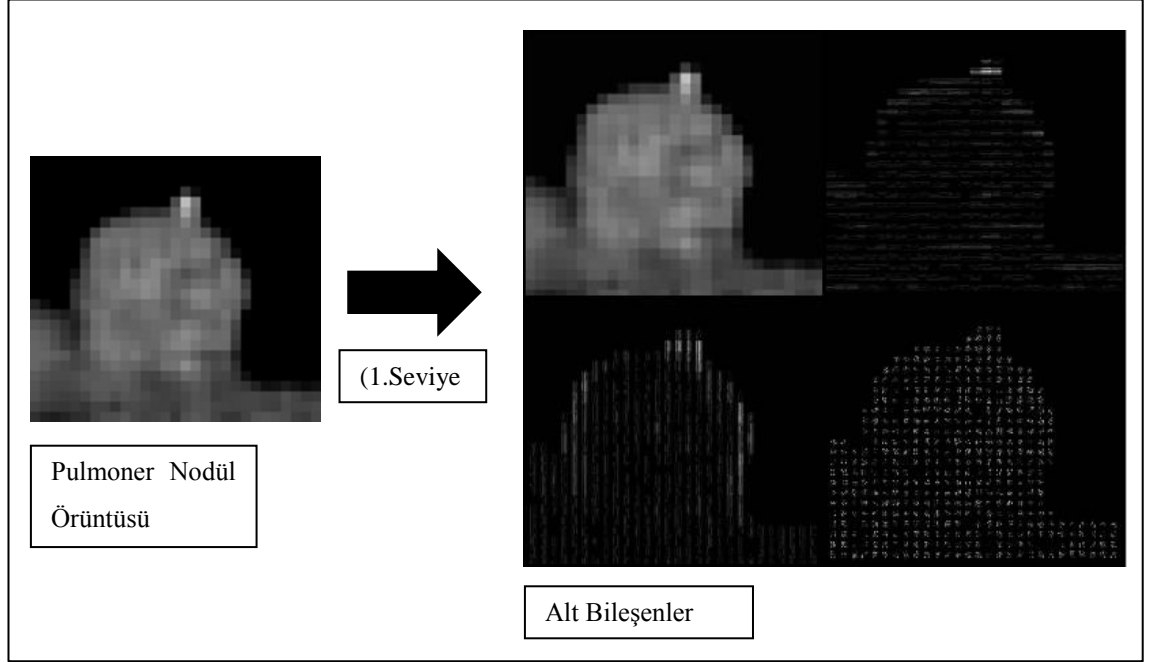
4.1.1 Ayrık Dalgacık Dönüşümü

Öznelik çıkarma işleminde giriş görüntüleri olan eğitim veri setindeki nodül ve nodül olmayan örüntülere ayrık dalgacık dönüşümü uygulanarak her bir giriş görüntüsü 4 (*dört*) alt görüntüye ayrıştırılmıştır. Burada alt görüntüler, orijinal görüntünün düşük frekans bileşeni olan *yaklaşık* ve yüksek frekans bileşenleri olan *ayrıntı* (*yatay, dikey ve köşegen*) katsayılarından oluşmaktadır. Her bir giriş görüntüsüne HAAR ve Daubechies dalgacık tipi kullanılarak ayrık dalgacık dönüşümüne ait *Birinci Seviye (Level 1)* dalgacık katsayıları elde edilmiştir. Tez çalışmasında kullanılan BT görüntülerinden alınan nodül ve nodül olmayan örüntüler aynı boyutta olmadığından örüntülere ait öznelik vektörleri aynı uzunluğa sahip değildirler. Genel olarak sınıflandırma işleminde sınıflandırmada kullanılacak giriş vektörlerinin eşit uzunlukta ve hesap kolaylığı açısından kısa olması gerekmektedir. Bu amaçla çalışmada öznelik vektörü için hesaplanan dalgacık katsayılarının bazı istatistik değerleri dikkate alınarak oluşturulmuştur. Öznelik vektörü için kullanılan istatistik parametreler aşağıda belirtilmiştir:

- Dalgacık yöntemi ile bulunan yaklaşık ve yatay, dikey ve köşegen yönlerine ait ayrıntı katsayılarının en büyük değerleri,
- Dalgacık yöntemi ile bulunan yaklaşık ve yatay, dikey ve köşegen yönlerine ait ayrıntı katsayılarının en küçük değerleri,
- Dalgacık yöntemi ile bulunan yaklaşık ve yatay, dikey ve köşegen yönlerine ait ayrıntı katsayılarının ortalama değerleri,
- Dalgacık yöntemi ile bulunan yaklaşık ve yatay, dikey ve köşegen yönlerine ait ayrıntı katsayılarının standart sapma değerleri,
- Dalgacık yöntemi ile bulunan yaklaşık ve yatay, dikey ve köşegen yönlerine ait ayrıntı katsayılarının varyans değerleri,
- Dalgacık yöntemi ile bulunan yaklaşık ve yatay, dikey ve köşegen yönlerine ait ayrıntı katsayılarının 3. moment değerleri.

Sonuç olarak bu parametre değerleri ile nodül ve nodül olmayan örüntüleri tanımlayan ve 24 değişken içeren öznelik vektörü ayrık dalgacık dönüşümü kullanılarak

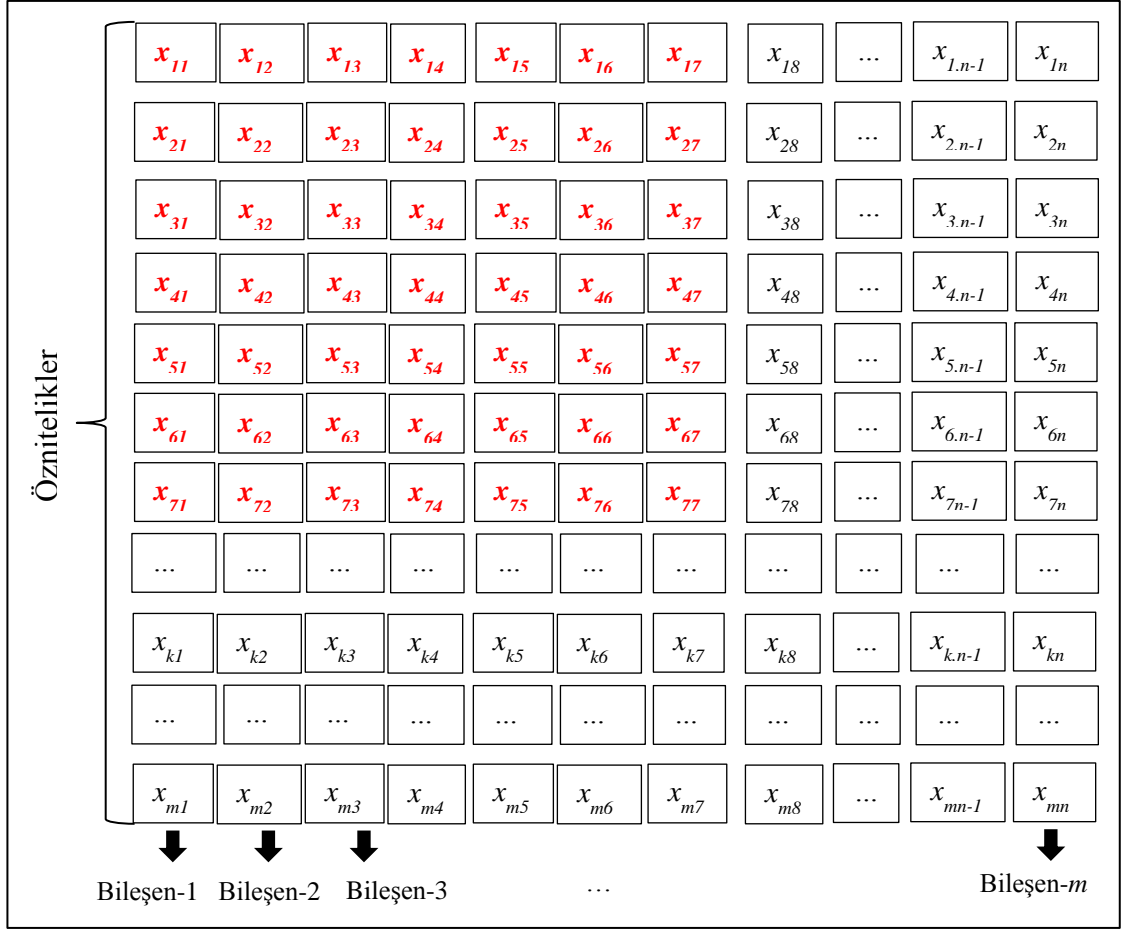
oluşturulmuştur. Pulmoner nodül örüntülerinin ayrık dalgacık dönüşümü kullanılarak alt bileşenlere ayrışımı Şekil 4.3'te görülmektedir.



Şekil 4.3: Ayrık dalgacık dönüşümü ile pulmoner nodül örüntüsünün alt bölgelere bölünmesi.

4.1.2 Temel Bileşen Analizi

Pulmoner nodül ve nodül olmayan örüntülere ait özniteliklerin çıkartımı için Temel Bileşen Analizi (TBA) uygulanmıştır. Veri setinde kullanılan iki boyutlu örüntülerin boyutları farklı olduğundan uygulama sonucunda elde edilen sonuç matrisinde her bir örüntüye ait Şekil 4.4'teki gibi 7X7 piksel boyutlu matris alınarak her bir örüntü için 1x49 boyutlu *Öznitelik Vektörü* oluşturulmuştur. Şekil 4.4'te $m \times n$ boyuta sahip bir örüntü için alınan 7x7 piksel boyutlu öznitelik matrisi görülmektedir.



Şekil 4.4: TBA sonucu elde edilen sonuç matrisi.

Temel bileşen analizi uygulanırken her bir bileşen için en yüksek değere sahip olan öznitelikler sıralanarak 7x7 boyutlu öznitelik matrisi dikkate alınmıştır. Böylece ilk 7 temel bileşen ile toplam varyansın en az % 99.9x yüzdeline değeri hesaba katılması sağlanmıştır. 7x7 boyutlu öznitelik matrisi, 1x49 boyutlu öznitelik vektörüne dönüştürülmüştür.

4.1.3 Temel Bileşen Analizi İstatistiksel Değerleri

Her bir pulmoner nodül ve nodül olmayan örüntüden temel bileşen analizi kullanılarak elde edilen 1x49 boyutlu öznitelik vektörünün *en küçük, en büyük, ortalama, standart sapma, varyans* ve *3.derece moment* gibi istatistiksel değerlerinden oluşan 1x6 boyutlu yeni bir öznitelik vektörü oluşturulmuştur. Böylece her bir örüntü için sınıflandırma algoritmasındaki hesap yükü ve işlem karmaşıklığının azaltılması amaçlanmaktadır.

4.1.4 Morfolojik Görüntü İşleme

Pulmoner nodül ve nodül olmayan iki boyutlu örüntülerin şekil bilgisine dayalı morfolojik görüntü işleme ile elde edilen geometrik öznitelikler görüntü işleme uygulamalarında son derece önemlidir. Tez çalışmasında geometrik özniteliklerin kullanılarak her bir örüntü için öznitelik değerleri elde edilmiştir. Çalışmada morfolojik görüntü işlemeye dayalı *Alan, Çap, Çevre, En-boy oranı, Eliptisite, Katılık, Eksantriklik, Kompaktlık, Dairesellik* ve *Yuvarlaklık* olmak üzere toplam 10 (on) adet öznitelik kullanılmıştır.

4.2 ÖZİNİTELİK SEÇME

Öznitelik seçme, sınıflandırma işlemi açısından örüntüyü tanımlamada en yüksek katkı sağlayan özniteliklerin seçilmesi işlemidir. Öznitelik seçme işlemi, bir sınıflandırıcının karar verme sürecini hızlandırması ve işlem yükünün azaltılması açısından son derece önemli bir adımdır. Çalışma kapsamında elde edilen öznitelik vektöründe en yüksek değişime sahip ve görüntüyü karakterize etmede en fazla belirleyici nitelikteki parametrelerin seçilmesi için mRMR yöntemi kullanılmıştır. Böylece oluşturulan öznitelik vektörü boyutunun azaltılması ve daha yüksek sınıflandırma başarımı elde edilmesi hedeflenmiştir.

Çalışmada kullanılan her bir yöntem için elde edilen öznitelikler ve mRMR yöntemi kullanılarak bulunan sonuçlar ayrıntılı aşağıda verilmektedir.

4.2.1 Ayrık Dalgacık Dönüşümü

Ayrık dalgacık dönüşümü kullanılarak elde edilen öznitelik vektörünü oluşturan istatistik parametreler Tablo 4.1’de verilmektedir.

Tablo 4.1: Dalgacık dönüşümünde kullanılan istatistik değerler.

Sıra	Öznitelik	Sıra	Öznitelik
1	Yaklaşık- En Küçük	13	Dikey- En Küçük
2	Yaklaşık- En Büyük	14	Dikey- En Büyük
3	Yaklaşık- Ortalama	15	Dikey- Ortalama
4	Yaklaşık- Std. Sapma	16	Dikey- Std. Sapma
5	Yaklaşık- Varyans	17	Dikey- Varyans
6	Yaklaşık- Moment	18	Dikey- Moment
7	Yatay- En Küçük	19	Köşegen- En Küçük
8	Yatay- En Büyük	20	Köşegen- En Büyük
9	Yatay- Ortalama	21	Köşegen- Ortalama
10	Yatay- Standart Sapma	22	Köşegen- Standart Sapma
11	Yatay- Varyans	23	Köşegen- Varyans
12	Yatay- Moment	24	Köşegen- Moment

Ayrık dalgacık dönüşümünden elde edilen katsayılara mRMR yöntemi uygulanarak Haar ve db4 (daubechies) dalgacık tipleri için en iyi özniteliklerin önem sıralaması Tablo 4.1’deki numaralandırmaya göre aşağıda verilmektedir:

Haar =[1; 9; 24; 4; 15; 12; 2; 18; 21; 7; 3; 11; 13; 6; 14; 8; 23; 17; 5; 19; 10; 20; 16; 22]

db4 = [18; 12; 3; 24; 9; 5; 11; 15; 21; 1; 2; 23; 6; 17; 7; 4; 13; 10; 20; 19; 14; 8; 16; 22]

4.2.2 Temel Bileşen Analizi

Eğitim setindeki pulmoner nodül ve nodül olmayan örüntülere temel bileşen analizi uygulanarak elde edilen öznitelik matrisinden en iyi ve en etkili özniteliklerin seçimi için mRMR yöntemi uygulanmıştır. Her bir örüntüden alınan öznitelik matrisi değerleri Tablo 4.2a'da verildiği gibi numaralandırılmıştır. mRMR yöntemi sonucu elde edilen en iyi özniteliklerin sıralaması Tablo 4.2b'de verilmektedir.

Tablo 4.2: a) Örüntüden alınan 7x7 piksel boyutlu öznitelik matrisi, b) mRMR sonucu en iyi özniteliklerin sıralaması.

a)

1	2	3	4	5	6	7
8	9	10	11	12	13	14
15	16	17	18	19	20	21
22	23	24	25	26	27	28
29	30	31	32	33	34	35
36	37	38	39	40	41	42
43	44	45	46	47	48	49

b)

30	2	8	14	15	7	44
1	9	21	29	4	17	10
28	22	3	42	16	6	37
11	47	18	23	5	34	43
20	12	36	27	13	24	31
26	46	49	19	35	38	45
25	48	40	33	41	32	39

4.2.3 Temel Bileşen Analizi İstatistiksel Değerleri

Temel bileşen analizinde her bir örüntüden elde edilen 1x49 boyutlu öznitelik vektörünün istatistik değerleri ile oluşturulan 1x6 boyutlu öznitelik vektöründen en iyi özniteliklerin seçimi için mRMR yöntemi uygulanmıştır. Her bir örüntüyü en iyi karakterize eden öznitelikler seçilmiş ve önem sırasına göre aşağıda verilmektedir:

Öznitelik Vektörü= [*en küçük; en büyük; ortalama; standart sapma; varyans; 3. derece moment*]

Öznitelik sıralaması = [*3. derece moment; en küçük; varyans; ortalama; en büyük; standart sapma*]

4.2.4 Morfolojik Görüntü İşleme

Morfolojik görüntü işleme ile pulmoner nodül ve nodül olmayan örüntülere ait en iyi özniteliklerin seçimi için eğitim veri setine mRMR metodu uygulanmıştır. mRMR metodu sonucu elde edilen özniteliklerin önem sırasına göre dizilimi Tablo 4.3'te verilmektedir.

Tablo 4.3: mRMR metodu ile en iyi özniteliklerin sıralaması.

Önem Sırası	Öznitelik
1	Kompaktlık
2	En-boy Oranı
3	Katılık
4	Çap
5	Eliptisite
6	Çevre
7	Eksantriklik
8	Alan
9	Dairesellik
10	Yuvarlaklık

4.2.5 Öznitelik Seçiminde Yeni Bir Yaklaşım: Hibrid Yaklaşım

Bir sınıflandırma probleminin çözümünde en önemli faktörlerden biri ilgili örüntüyü tanımlayan özniteliklerin iyi belirlenmesine bağlıdır. Çalışmada kullanılan yöntemlerdeki öznitelik sayısını düşürmek ve yüksek sınıflandırma doğruluğu elde etmek için her yöntemde mRMR yöntemi ile belirlenen en iyi öznitelikler kullanılarak *Hibrid Yaklaşım* olarak tanımlanan yeni bir öznitelik seçme yaklaşımı önerilmiştir. Böylece sınıflandırıcının verimi yükseltilmesi amaçlanmıştır [68-70, 116].

Önerilen Hibrid Yaklaşım, ayrık dalgacık dönüşümünden (Haar dalgacık tipi) en iyi 20 adet öznitelik; temel bileşen analizinden en iyi 10 adet öznitelik; temel bileşen analizi istatistiksel değerlerinden en iyi 4 adet öznitelik; morfolojik görüntü işlemeden en iyi 6 adet öznitelik olmak üzere toplam 40 adet öznitelik kullanılarak gerçekleştirilmiştir.

4.3 SINIFLANDIRMA SONUÇLARI

Çalışmada 159 adet pulmoner nodül ve 141 adet nodül olmayan örüntü olmak üzere toplam 300 örüntü kullanılmıştır. Veri setinde kullanılan 159 adet pulmoner nodül örüntüsünün 79 tanesi eğitim setinde, 80 tanesi test setinde olmak üzere iki kısma bölütlenmiştir. Benzer şekilde 141 adet nodül olmayan örüntüsünün 71 tanesi eğitim setinde, 70 tanesi test setinde olmak üzere ikiye ayrılmıştır. Eğitim setindeki örüntüler kullanılarak her bir örüntüye ait öznitelikler çıkartılmış, daha sonra en iyi özniteliklerin seçimi için mRMR yöntemi uygulanmıştır. Kullanılan her bir yöntemin sınıflandırma başarımını ölçmek için bağımsız bir şekilde oluşturulan test veri seti kullanılarak sınıflandırma başarımları elde edilmiştir. Çalışmada her bir yöntem için mRMR yöntemi ile elde edilen farklı öznitelik sayılarına göre sınıflandırıcıların performans değerleri ölçülmüştür.

Destek vektör makinelerinin çekirdek fonksiyonları kullanılarak sınıflandırma yapılmıştır. Sınıflandırma algoritmasında 5-katlı çapraz doğrulama yapılmıştır. Destek vektör makinelerine ait Doğrusal, Karesel, Normalleştirilmiş polinom ve Radyal tabanlı çekirdek fonksiyonları sınıflandırmada kullanılmıştır. Sınıflandırma başarımlarını değerlendirmek için duyarlılık, seçicilik, doğruluk, kappa istatistiği, kök ortalama kare hata (RMSE), AUROC (ROC Eğrisi altında kalan alan) ve hata matrisi değerleri ölçülmüştür. Her bir yöntem için performans ölçüm sonuçları tablo halinde verilmektedir. Sistemin performansını gözlemlemek için her bir yöntemde öznitelik sayısına göre AUROC değeri değişimi eğrileri ve en iyi başarımın sağlandığı öznitelik sayısı ve çekirdek fonksiyonuna ait ROC eğrisi grafik halinde sunulmaktadır.

Çalışmada ayırık dalgacık dönüşümü, temel bileşen analizi ve morfolojik görüntü işleme algoritmaları Matlab programı aracılığıyla gerçekleştirilmiştir. Ayrıca tüm sınıflandırma işlemleri için Weka Veri Madenciliği yazılımı (<http://www.cs.waikato.ac.nz/~ml/weka>) kullanılmıştır. Çalışmada gerçekleştirilen tüm uygulamalar, Intel Core i7, 1.90 GHz CPU ve 4.00 GB RAM özellikli kişisel bilgisayarda yapılmıştır.

4.3.1 Ayrık Dalgacık Dönüşümü

Pulmoner nodül ve nodül olmayan test setindeki örüntülere ayrık dalgacık dönüşümü uygulanarak elde edilen öznitelikler kullanılarak sınıflandırma performans ölçümleri elde edilmiştir. Destek vektör makinelerinin çekirdek fonksiyonları Haar ve Daubechies (db4) dalgacık tiplerine ait doğrusal ve karesel çekirdek fonksiyonu için düzenleyici parametre $C=1$, normalleştirilmiş çekirdek fonksiyonu için düzenleyici parametre $C=1$ ve radyal tabanlı çekirdek fonksiyonu için düzenleyici parametre $C=250$ ve kernel boyutu $\gamma=0.1$ olarak alınmıştır.

Destek vektör makinelerinin çekirdek fonksiyonları kullanılarak elde edilen sınıflandırıcının performans ölçüm sonuçları sırasıyla en etkili 24, 20, 15 ve 10 adet öznitelik sayılarına göre Haar dalgacık tipi için Tablo 4.4-7'de ve db4 dalgacık tipi için Tablo 4.8-11'de verilmektedir. Haar ve db4 dalgacık tipleri için öznitelik sayısına göre AUROC değeri değişimi eğrileri Şekil 4.5-6'da görülmektedir.

Tablo 4.4: Haar dalgacık tipi kullanılarak tüm öznelilikler (24 öznelilik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	60	20
	Negatif (Nodül olmayan örüntü)	32	38
	Duyarlılık	75.0 %	Kappa 0.296
	Seçicilik	65.5 %	RMSE 0.589
	Doğruluk	65.3 %	AUROC 0.646
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	49	31
	Negatif (Nodül olmayan örüntü)	22	48
	Duyarlılık	61.3 %	Kappa 0.296
	Seçicilik	60.8 %	RMSE 0.594
	Doğruluk	64.7 %	AUROC 0.649
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	59	21
	Negatif (Nodül olmayan örüntü)	32	38
	Duyarlılık	73.8 %	Kappa 0.283
	Seçicilik	64.4 %	RMSE 0.594
	Doğruluk	64.7 %	AUROC 0.640
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	58	22
	Negatif (Nodül olmayan örüntü)	22	48
	Duyarlılık	72.5 %	Kappa 0.411
	Seçicilik	68.6 %	RMSE 0.542
	Doğruluk	70.7 %	AUROC 0.705

Tablo 4.5: Haar dalgacık tipi kullanılarak 20 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

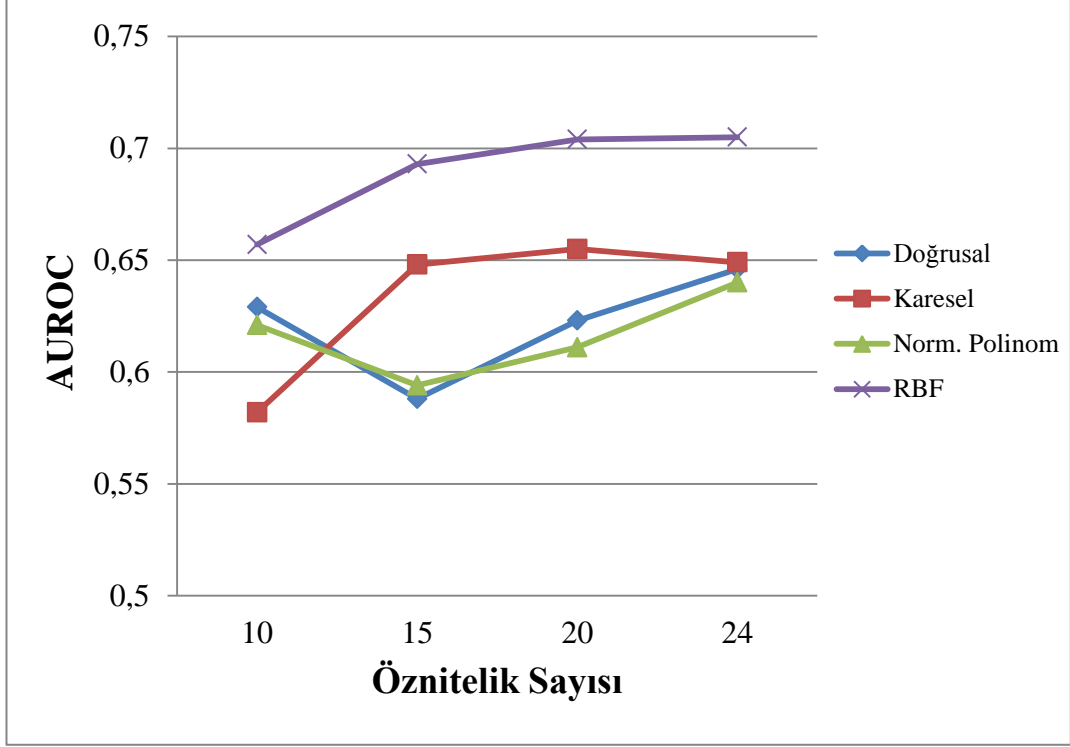
Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	62	18
	Negatif (Nodül olmayan örüntü)	37	33
	Duyarlılık	77.5 %	Kappa 0.251
	Seçicilik	64.7 %	RMSE 0.606
	Doğruluk	63.3 %	AUROC 0.623
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	50	30
	Negatif (Nodül olmayan örüntü)	22	48
	Duyarlılık	62.5 %	Kappa 0.309
	Seçicilik	61.5 %	RMSE 0.589
	Doğruluk	65.3 %	AUROC 0.655
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	58	22
	Negatif (Nodül olmayan örüntü)	34	36
	Duyarlılık	72.5 %	Kappa 0.242
	Seçicilik	62.1 %	RMSE 0.611
	Doğruluk	62.7 %	AUROC 0.620
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	59	21
	Negatif (Nodül olmayan örüntü)	23	47
	Duyarlılık	73.8 %	Kappa 0.410
	Seçicilik	69.1 %	RMSE 0.542
	Doğruluk	70.7 %	AUROC 0.704

Tablo 4.6: Haar dalgacık tipi kullanılarak 15 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	61	19	
	Negatif (Nodül olmayan örüntü)	41	29	
	Duyarlılık	76.3 %	Kappa	0.180
	Seçicilik	60.4 %	RMSE	0.633
	Doğruluk	60.0 %	AUROC	0.588
	Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	50	30
Negatif (Nodül olmayan örüntü)		23	47	
Duyarlılık		62.5 %	Kappa	0.295
Seçicilik		61.0 %	RMSE	0.594
Doğruluk		64.7 %	AUROC	0.648
Normalleştirilmiş Polinom Çekirdek Fonksiyonu		Pozitif (Pulmoner Nodül)	55	25
	Negatif (Nodül olmayan örüntü)	35	35	
	Duyarlılık	68.8 %	Kappa	0.189
	Seçicilik	58.3 %	RMSE	0.633
	Doğruluk	60.0 %	AUROC	0.594
	Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	56	24
Negatif (Nodül olmayan örüntü)		22	48	
Duyarlılık		70.0 %	Kappa	0.385
Seçicilik		66.7 %	RMSE	0.554
Doğruluk		69.3 %	AUROC	0.693

Tablo 4.7: Haar dalgacık tipi kullanılarak 10 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	56	24
	Negatif (Nodül olmayan örüntü)	31	39
	Duyarlılık	70.0 %	Kappa 0.259
	Seçicilik	61.9 %	RMSE 0.606
	Doğruluk	63.3 %	AUROC 0.629
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	60	20
	Negatif (Nodül olmayan örüntü)	41	29
	Duyarlılık	75.0 %	Kappa 0.167
	Seçicilik	59.2 %	RMSE 0.638
	Doğruluk	59.3 %	AUROC 0.582
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	48	32
	Negatif (Nodül olmayan örüntü)	25	45
	Duyarlılık	60.0 %	Kappa 0.241
	Seçicilik	58.4 %	RMSE 0.616
	Doğruluk	62.0 %	AUROC 0.621
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	48	32
	Negatif (Nodül olmayan örüntü)	20	50
	Duyarlılık	60.0 %	Kappa 0.311
	Seçicilik	61.0 %	RMSE 0.589
	Doğruluk	65.3 %	AUROC 0.657



Şekil 4.5: Haar dalgacık tipi için tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.

Tablo 4.8: db4 dalgacık tipi kullanılarak tüm öznelikler (24 Öznelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	53	27
	Negatif (Nodül olmayan örüntü)	41	29
	Duyarlılık	66.3 %	Kappa 0.078
	Seçicilik	51.8 %	RMSE 0.673
	Doğruluk	54.7 %	AUROC 0.538
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	46	34
	Negatif (Nodül olmayan örüntü)	21	49
	Duyarlılık	57.5 %	Kappa 0.272
	Seçicilik	59.0 %	RMSE 0.606
	Doğruluk	63.3 %	AUROC 0.638
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	58	22
	Negatif (Nodül olmayan örüntü)	39	31
	Duyarlılık	72.5 %	Kappa 0.170
	Seçicilik	58.5 %	RMSE 0.638
	Doğruluk	59.3 %	AUROC 0.584
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	48	32
	Negatif (Nodül olmayan örüntü)	18	52
	Duyarlılık	60.0 %	Kappa 0.339
	Seçicilik	61.9 %	RMSE 0.577
	Doğruluk	66.7 %	AUROC 0.671

Tablo 4.9: db4 dalgacık tipi kullanılarak 20 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.


Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	54	26	
	Negatif (Nodül olmayan örüntü)	40	30	
	Duyarlılık	67.5 %	Kappa 0.105	
	Seçicilik	53.6 %	RMSE 0.663	
	Doğruluk	56.0 %	AUROC 0.552	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	45	35	
	Negatif (Nodül olmayan örüntü)	20	50	
	Duyarlılık	56.3 %	Kappa 0.273	
	Seçicilik	58.8 %	RMSE 0.606	
	Doğruluk	63.3 %	AUROC 0.638	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	58	22	
	Negatif (Nodül olmayan örüntü)	39	31	
	Duyarlılık	72.5 %	Kappa 0.170	
	Seçicilik	58.5 %	RMSE 0.638	
	Doğruluk	59.3 %	AUROC 0.584	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	53	27	
	Negatif (Nodül olmayan örüntü)	18	52	
	Duyarlılık	66.3 %	Kappa 0.402	
	Seçicilik	65.8 %	RMSE 0.545	
	Doğruluk	70.0 %	AUROC 0.703	

Tablo 4.10: db4 dalgacık tipi kullanılarak 15 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	56	24	
	Negatif (Nodül olmayan örüntü)	38	32	
	Duyarlılık	70.0 %	Kappa	0.159
	Seçicilik	57.1 %	RMSE	0.643
	Doğruluk	58.7 %	AUROC	0.579
	Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	55	25
Negatif (Nodül olmayan örüntü)		20	50	
Duyarlılık		68.8 %	Kappa	0.400
Seçicilik		66.7 %	RMSE	0.548
Doğruluk		70.0 %	AUROC	0.701
Normalleştirilmiş Polinom Çekirdek Fonksiyonu		Pozitif (Pulmoner Nodül)	60	20
	Negatif (Nodül olmayan örüntü)	35	35	
	Duyarlılık	75.0 %	Kappa	0.253
	Seçicilik	63.6 %	RMSE	0.606
	Doğruluk	63.3 %	AUROC	0.625
	Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	54	26
Negatif (Nodül olmayan örüntü)		21	49	
Duyarlılık		67.5 %	Kappa	0.373
Seçicilik		65.3 %	RMSE	0.560
Doğruluk		68.7 %	AUROC	0.688

Tablo 4.11: db4 dalgacık tipi kullanılarak 10 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	52	28	
Negatif (Nodül olmayan örüntü)	45	25		
Duyarlılık	65.0 %	Kappa	0.007	
Seçicilik	47.2 %	RMSE	0.698	
Doğruluk	51.3 %	AUROC	0.504	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	52	28	
Negatif (Nodül olmayan örüntü)	47	23		
Duyarlılık	65.0 %	Kappa	-0.022	
Seçicilik	45.1 %	RMSE	0.707	
Doğruluk	50.0 %	AUROC	0.489	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	57	23	
Negatif (Nodül olmayan örüntü)	48	22		
Duyarlılık	71.3 %	Kappa	0.027	
Seçicilik	48.9 %	RMSE	0.688	
Doğruluk	52.7 %	AUROC	0.513	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	51	29	
Negatif (Nodül olmayan örüntü)	31	39		
Duyarlılık	63.8 %	Kappa	0.195	
Seçicilik	57.4 %	RMSE	0.633	
Doğruluk	60.0 %	AUROC	0.597	



Şekil 4.6: db4 dalgacık tipi için tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.

4.3.2 Temel Bileşen Analizi

Test setindeki pulmoner nodül ve nodül olmayan örüntülere temel bileşen analizi uygulanarak elde edilen öznitelikler kullanılarak sınıflandırma performans ölçümleri elde edilmiştir. Destek vektör makinelerinin çekirdek fonksiyonlarında doğrusal ve karesel çekirdek fonksiyonu için düzenleyici parametre $C=1$, normalleştirilmiş çekirdek fonksiyonu için düzenleyici parametre $C=20$ ve radyal tabanlı çekirdek fonksiyonu için düzenleyici parametre $C=50$ ve kernel boyutu $\gamma=0.1$ olarak alınmıştır.

Destek vektör makinelerinin çekirdek fonksiyonları kullanılarak elde edilen sınıflandırıcının sırasıyla en etkili 49, 45, 30, 20 ve 10 adet öznitelik sayılarına göre performans ölçüm sonuçları Tablo 4.12-16'da verilmektedir. Ayrıca öznitelik sayılarına göre AUROC değeri değişimi eğrileri Şekil 4.7'de görülmektedir.

Tablo 4.12: TBA’da tüm öznelikler (49 öznelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	58	22	
Negatif (Nodül olmayan örüntü)	40	30		
	Duyarlılık	72.5 %	Kappa	0.156
	Seçicilik	57.7 %	RMSE	0.643
	Doğruluk	58.7 %	AUROC	0.577
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	60	20	
Negatif (Nodül olmayan örüntü)	43	27		
	Duyarlılık	75.0 %	Kappa	0.139
	Seçicilik	57.4 %	RMSE	0.648
	Doğruluk	58.0 %	AUROC	0.568
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	49	31	
Negatif (Nodül olmayan örüntü)	34	36		
	Duyarlılık	61.3 %	Kappa	0.127
	Seçicilik	53.7 %	RMSE	0.658
	Doğruluk	56.7 %	AUROC	0.563
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	55	25	
Negatif (Nodül olmayan örüntü)	35	35		
	Duyarlılık	68.8 %	Kappa	0.189
	Seçicilik	58.3 %	RMSE	0.633
	Doğruluk	60.0 %	AUROC	0.594

Tablo 4.13: TBA’da 45 öz nitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	59	21	
Negatif (Nodül olmayan örüntü)	39	31		
Duyarlılık	73.8 %	Kappa	0.183	
Seçicilik	59.6 %	RMSE	0.633	
Doğruluk	60.0 %	AUROC	0.590	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	60	20	
Negatif (Nodül olmayan örüntü)	43	27		
Duyarlılık	75.0 %	Kappa	0.139	
Seçicilik	57.4 %	RMSE	0.648	
Doğruluk	58.0 %	AUROC	0.568	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	49	31	
Negatif (Nodül olmayan örüntü)	35	35		
Duyarlılık	61.3 %	Kappa	0.113	
Seçicilik	53.0 %	RMSE	0.663	
Doğruluk	56.0 %	AUROC	0.556	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	54	26	
Negatif (Nodül olmayan örüntü)	37	33		
Duyarlılık	67.5 %	Kappa	0.148	
Seçicilik	55.9 %	RMSE	0.648	
Doğruluk	58.0 %	AUROC	0.573	

Tablo 4.14: TBA’da 30 öz nitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.


Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	62	18	
Negatif (Nodül olmayan örüntü)	35	35		
Duyarlılık	77.5 %	Kappa	0.279	
Seçicilik	66.0 %	RMSE	0.594	
Doğruluk	64.7 %	AUROC	0.638	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	58	22	
Negatif (Nodül olmayan örüntü)	45	25		
Duyarlılık	72.5 %	Kappa	0.084	
Seçicilik	53.2 %	RMSE	0.668	
Doğruluk	55.3 %	AUROC	0.541	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	48	32	
Negatif (Nodül olmayan örüntü)	34	36		
Duyarlılık	60.0 %	Kappa	0.115	
Seçicilik	52.9 %	RMSE	0.663	
Doğruluk	56.0 %	AUROC	0.557	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	55	25	
Negatif (Nodül olmayan örüntü)	36	34		
Duyarlılık	68.8 %	Kappa	0.175	
Seçicilik	57.6 %	RMSE	0.634	
Doğruluk	59.3 %	AUROC	0.587	

Tablo 4.15: TBA’da 20 öz nitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	58	22	
Negatif (Nodül olmayan örüntü)	35	35		
Duyarlılık	72.5 %	Kappa	0.228	
Seçicilik	61.4 %	RMSE	0.616	
Doğruluk	62.0 %	AUROC	0.613	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	59	21	
Negatif (Nodül olmayan örüntü)	41	29		
Duyarlılık	73.8 %	Kappa	0.155	
Seçicilik	58.0 %	RMSE	0.643	
Doğruluk	58.7 %	AUROC	0.576	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	52	28	
Negatif (Nodül olmayan örüntü)	35	35		
Duyarlılık	65.0 %	Kappa	0.151	
Seçicilik	55.6 %	RMSE	0.648	
Doğruluk	58.0 %	AUROC	0.575	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	54	26	
Negatif (Nodül olmayan örüntü)	40	30		
Duyarlılık	67.5 %	Kappa	0.105	
Seçicilik	53.6 %	RMSE	0.663	
Doğruluk	56.0 %	AUROC	0.552	

Tablo 4.16: TBA’da 10 öz nitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	60	20	
Negatif (Nodül olmayan örüntü)	34	36		
Duyarlılık	75.0 %	Kappa	0.268	
Seçicilik	64.3 %	RMSE	0.600	
Doğruluk	64.0 %	AUROC	0.632	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	65	15	
Negatif (Nodül olmayan örüntü)	50	20		
Duyarlılık	81.3 %	Kappa	0.101	
Seçicilik	57.1 %	RMSE	0.658	
Doğruluk	56.7 %	AUROC	0.549	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	48	32	
Negatif (Nodül olmayan örüntü)	38	32		
Duyarlılık	60.0 %	Kappa	0.058	
Seçicilik	50.0 %	RMSE	0.683	
Doğruluk	53.3 %	AUROC	0.529	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	52	28	
Negatif (Nodül olmayan örüntü)	36	34		
Duyarlılık	65.0 %	Kappa	0.137	
Seçicilik	54.8 %	RMSE	0.653	
Doğruluk	57.3 %	AUROC	0.568	



Şekil 4.7: TBA’da tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.

4.3.3 Temel Bileşen Analizi İstatistiksel Değerleri

Pulmoner nodül ve nodül olmayan örüntülere ait test setindeki Temel bileşen analizi istatistiksel değerlerinden elde edilen öznitelikler test setindeki bağımsız örüntü datasına uygulanarak sınıflandırma performans ölçümleri elde edilmiştir. Destek vektör makinelerinin çekirdek fonksiyonlarında doğrusal ve karesel çekirdek fonksiyonu için düzenleyici parametre $C=30$, normalleştirilmiş çekirdek fonksiyonu için düzenleyici parametre $C=50$ ve radyal tabanlı çekirdek fonksiyonu için düzenleyici parametre $C=1000$ ve kernel boyutu $\gamma=0.1$ olarak alınmıştır.

En iyi 6, 5, 4 ve 3 adet öznitelik sayılarına göre performans ölçüm sonuçları Tablo 4.17 -20’de verilmektedir. Ayrıca öznitelik sayılarına göre AUROC değeri değişimi eğrileri Şekil 4.8’de görülmektedir.

Tablo 4.17: TBA istatistiksel 6 öznelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	52	28	
Negatif (Nodül olmayan örüntü)	44	26		
Duyarlılık	65.0 %	Kappa	0.022	
Seçicilik	48.1 %	RMSE	0.693	
Doğruluk	52.0 %	AUROC	0.511	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	50	30	
Negatif (Nodül olmayan örüntü)	39	31		
Duyarlılık	62.5 %	Kappa	0.068	
Seçicilik	50.8 %	RMSE	0.678	
Doğruluk	54.0 %	AUROC	0.534	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	38	42	
Negatif (Nodül olmayan örüntü)	22	48		
Duyarlılık	47.5 %	Kappa	0.158	
Seçicilik	68.6 %	RMSE	0.653	
Doğruluk	57.3 %	AUROC	0.580	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	41	39	
Negatif (Nodül olmayan örüntü)	30	40		
Duyarlılık	51.3 %	Kappa	0.083	
Seçicilik	50.6 %	RMSE	0.678	
Doğruluk	54.0 %	AUROC	0.542	

Tablo 4.18: TBA istatistiksel 5 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.


Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	53	27	
Negatif (Nodül olmayan örüntü)	44	26		
Duyarlılık	66.3 %	Kappa	0.035	
Seçicilik	49.1 %	RMSE	0.688	
Doğruluk	52.7 %	AUROC	0.517	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	52	28	
Negatif (Nodül olmayan örüntü)	41	29		
Duyarlılık	65.0 %	Kappa	0.065	
Seçicilik	50.9 %	RMSE	0.678	
Doğruluk	54.0 %	AUROC	0.532	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	39	41	
Negatif (Nodül olmayan örüntü)	24	46		
Duyarlılık	48.8 %	Kappa	0.143	
Seçicilik	52.9 %	RMSE	0.658	
Doğruluk	56.7 %	AUROC	0.572	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	41	39	
Negatif (Nodül olmayan örüntü)	28	42		
Duyarlılık	51.3 %	Kappa	0.111	
Seçicilik	51.9 %	RMSE	0.668	
Doğruluk	55.3 %	AUROC	0.556	

Tablo 4.19: TBA istatistiksel 4 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	55	25
	Negatif (Nodül olmayan örüntü)	42	28
	Duyarlılık	68.8 %	Kappa 0.089
	Seçicilik	52.8 %	RMSE 0.668
	Doğruluk	55.3 %	AUROC 0.544
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	52	28
	Negatif (Nodül olmayan örüntü)	45	25
	Duyarlılık	65.0 %	Kappa 0.007
	Seçicilik	47.2 %	RMSE 0.698
	Doğruluk	51.3 %	AUROC 0.504
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	38	42
	Negatif (Nodül olmayan örüntü)	22	48
	Duyarlılık	47.5 %	Kappa 0.158
	Seçicilik	53.3 %	RMSE 0.653
	Doğruluk	57.3 %	AUROC 0.580
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	42	38
	Negatif (Nodül olmayan örüntü)	29	41
	Duyarlılık	52.5 %	Kappa 0.110
	Seçicilik	51.9 %	RMSE 0.668
	Doğruluk	55.3 %	AUROC 0.555

Tablo 4.20: TBA istatistiksel 3 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	60	20	
Negatif (Nodül olmayan örüntü)	53	17		
Duyarlılık	75.0 %	Kappa	-0.007	
Seçicilik	45.9 %	RMSE	0.698	
Doğruluk	51.3 %	AUROC	0.496	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	67	13	
Negatif (Nodül olmayan örüntü)	56	14		
Duyarlılık	83.8 %	Kappa	0.039	
Seçicilik	51.9 %	RMSE	0.678	
Doğruluk	54.0 %	AUROC	0.519	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	59	21	
Negatif (Nodül olmayan örüntü)	46	24		
Duyarlılık	73.8 %	Kappa	0.082	
Seçicilik	53.3 %	RMSE	0.668	
Doğruluk	55.3 %	AUROC	0.540	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	60	20	
Negatif (Nodül olmayan örüntü)	51	19		
Duyarlılık	75.0 %	Kappa	0.022	
Seçicilik	48.7 %	RMSE	0.688	
Doğruluk	52.7 %	AUROC	0.511	



Şekil 4.8: TBA istatistiksel değerlerde tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.

4.3.4 Morfolojik Görüntü İşleme

Test setindeki pulmoner nodül ve nodül olmayan örüntülere morfolojik görüntü işleme uygulanarak sınıflandırma performans ölçümleri elde edilmiştir. Destek vektör makinelerinin çekirdek fonksiyonlarında doğrusal ve karesel çekirdek fonksiyonu için düzenleyici parametre $C=50$, normalleştirilmiş çekirdek fonksiyonu için düzenleyici parametre $C=25$ ve radyal tabanlı çekirdek fonksiyonu için düzenleyici parametre $C=50$ ve kernel boyutu $\gamma=0.1$ olarak alınmıştır.

En iyi 10, 9, 8, 6 ve 5 adet öznitelik sayılarına göre performans ölçüm sonuçları Tablo 4.21-25'de verilmektedir. Ayrıca öznitelik sayılarına göre AUROC değeri değişimi eğrileri Şekil 4.9'da görülmektedir.

Tablo 4.21: Morfolojik görüntü işleme ile 10 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	63	17	
Negatif (Nodül olmayan örüntü)	24	46		
Duyarlılık	78.8 %	Kappa	0.447	
Seçicilik	73.0 %	RMSE	0.523	
Doğruluk	72.7 %	AUROC	0.722	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	54	26	
Negatif (Nodül olmayan örüntü)	18	52		
Duyarlılık	67.5 %	Kappa	0.415	
Seçicilik	66.7 %	RMSE	0.542	
Doğruluk	70.7 %	AUROC	0.709	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	61	19	
Negatif (Nodül olmayan örüntü)	23	47		
Duyarlılık	76.3 %	Kappa	0.436	
Seçicilik	71.2 %	RMSE	0.529	
Doğruluk	72.0 %	AUROC	0.717	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	62	18	
Negatif (Nodül olmayan örüntü)	24	46		
Duyarlılık	77.5 %	Kappa	0.435	
Seçicilik	71.9 %	RMSE	0.529	
Doğruluk	72.0 %	AUROC	0.716	

Tablo 4.22: Morfolojik görüntü işleme ile 9 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	62	18	
	Negatif (Nodül olmayan örüntü)	24	46	
	Duyarlılık	77.5 %	Kappa 0.435	
	Seçicilik	71.9 %	RMSE 0.529	
	Doğruluk	72.0 %	AUROC 0.716	
	Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	55	25
		Negatif (Nodül olmayan örüntü)	20	50
Duyarlılık		68.8 %	Kappa 0.400	
Seçicilik		66.7 %	RMSE 0.548	
Doğruluk		70.0 %	AUROC 0.701	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu		Pozitif (Pulmoner Nodül)	61	19
		Negatif (Nodül olmayan örüntü)	23	47
	Duyarlılık	76.3 %	Kappa 0.436	
	Seçicilik	71.2 %	RMSE 0.529	
	Doğruluk	72.0 %	AUROC 0.717	
	Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	63	17
		Negatif (Nodül olmayan örüntü)	24	46
Duyarlılık		78.8 %	Kappa 0.447	
Seçicilik		73.0 %	RMSE 0.523	
Doğruluk		72.7 %	AUROC 0.722	

Tablo 4.23: Morfolojik görüntü işleme ile 8 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.


Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	64	16
	Negatif (Nodül olmayan örüntü)	24	46
	Duyarlılık	80.0 %	Kappa 0.460
	Seçicilik	74.2 %	RMSE 0.516
	Doğruluk	73.3 %	AUROC 0.729
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	51	29
	Negatif (Nodül olmayan örüntü)	18	52
	Duyarlılık	63.8 %	Kappa 0.377
	Seçicilik	64.2 %	RMSE 0.560
	Doğruluk	68.7 %	AUROC 0.690
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	63	17
	Negatif (Nodül olmayan örüntü)	27	43
	Duyarlılık	78.8 %	Kappa 0.405
	Seçicilik	71.7 %	RMSE 0.542
	Doğruluk	70.7 %	AUROC 0.701
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	62	18
	Negatif (Nodül olmayan örüntü)	24	46
	Duyarlılık	77.5 %	Kappa 0.435
	Seçicilik	71.9 %	RMSE 0.529
	Doğruluk	72.0 %	AUROC 0.716

Tablo 4.24: Morfolojik görüntü işleme ile 6 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	63	17	
	Negatif (Nodül olmayan örüntü)	22	48	
	Duyarlılık	78.8 %	Kappa 0.475	
	Seçicilik	73.8 %	RMSE 0.510	
	Doğruluk	74.0 %	AUROC 0.737	
	Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	57	23
		Negatif (Nodül olmayan örüntü)	21	49
Duyarlılık		71.3 %	Kappa 0.412	
Seçicilik		68.1 %	RMSE 0.542	
Doğruluk		70.7 %	AUROC 0.706	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu		Pozitif (Pulmoner Nodül)	62	18
		Negatif (Nodül olmayan örüntü)	30	40
	Duyarlılık	77.5 %	Kappa 0.350	
	Seçicilik	69.0 %	RMSE 0.566	
	Doğruluk	68.0 %	AUROC 0.673	
	Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	63	17
		Negatif (Nodül olmayan örüntü)	21	49
Duyarlılık		78.8 %	Kappa 0.489	
Seçicilik		74.2 %	RMSE 0.503	
Doğruluk		74.7 %	AUROC 0.744	

Tablo 4.25: Morfolojik görüntü işleme ile 5 öznitelik için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	61	19	
Negatif (Nodül olmayan örüntü)	20	50		
Duyarlılık	76.3 %	Kappa	0.477	
Seçicilik	72.5 %	RMSE	0.510	
Doğruluk	74.0 %	AUROC	0.738	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	57	23	
Negatif (Nodül olmayan örüntü)	23	47		
Duyarlılık	71.3 %	Kappa	0.384	
Seçicilik	67.1 %	RMSE	0.554	
Doğruluk	69.3 %	AUROC	0.692	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	61	19	
Negatif (Nodül olmayan örüntü)	30	40		
Duyarlılık	76.3 %	Kappa	0.337	
Seçicilik	67.8 %	RMSE	0.572	
Doğruluk	67.3 %	AUROC	0.667	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	63	17	
Negatif (Nodül olmayan örüntü)	23	47		
Duyarlılık	78.8 %	Kappa	0.461	
Seçicilik	73.4 %	RMSE	0.516	
Doğruluk	73.3 %	AUROC	0.729	



Şekil 4.9: TBA istatistiksel değerlerde tüm çekirdek fonksiyonlarının öznitelik sayısına göre AUROC değeri eğrileri.

4.3.5 Hibrid Yaklaşım Sonuçları

Çalışmada sunulan öznitelik çıkarma yöntemlerindeki en iyi özniteliklerden oluşturulan hibrid yaklaşım ile pulmoner nodül ve nodül olmayan örüntülerin sınıflandırma performans sonuçları bağımsız test verisi kullanılarak elde edilmiştir. Hibrid yaklaşım, ayrıık dalgacık dönüşümünden 20 adet, temel bileşen analizinden 10 adet, TBA istatistiksel değerlerden 4 adet ve morfolojik özelliklerden 6 adet seçilerek toplam 40 (kırk) adet öznitelik ile oluşturulmuştur (Tablo 4.26). Tartar ve ark. [116] tarafından pulmoner nodüllerin sınıflandırılması için önerilen hibrid yaklaşımda 20 adet TBA, 5 adet TBA istatistik değeri ve 5 adet morfolojik özellik olmak üzere toplam 30 (otuz) adet öznitelik kullanılmıştır. Ayrıca önerilen en iyi 30 adet öznitelik için oluşturulan hibrid yaklaşımın DVM çekirdek fonksiyonlarına ait sınıflandırma başarımları Tablo 4.27'de verilmiştir. Destek vektör makinelerinin çekirdek fonksiyonlarında doğrusal ve karesel çekirdek fonksiyonu için düzenleyici parametre $C=1$, normalleştirilmiş çekirdek fonksiyonu için düzenleyici parametre $C=60$ ve radyal tabanlı çekirdek fonksiyonu için düzenleyici parametre $C=30$ ve kernel boyutu $\gamma=0.1$ olarak alınmıştır.

Tablo 4.26: Hibrid yaklaşım (en iyi 40 adet öz nitelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	57	23	
Negatif (Nodül olmayan örüntü)	19	51		
Duyarlılık	71.3 %	Kappa	0.440	
Seçicilik	68.9 %	RMSE	0.529	
Doğruluk	72.0 %	AUROC	0.721	
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	58	22	
Negatif (Nodül olmayan örüntü)	17	53		
Duyarlılık	72.5 %	Kappa	0.480	
Seçicilik	70.7 %	RMSE	0.510	
Doğruluk	74.0 %	AUROC	0.741	
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	63	17	
Negatif (Nodül olmayan örüntü)	15	55		
Duyarlılık	78.8 %	Kappa	0.572	
Seçicilik	76.4 %	RMSE	0.462	
Doğruluk	78.7 %	AUROC	0.787	
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)	
	Pozitif (Pulmoner Nodül)	62	18	
Negatif (Nodül olmayan örüntü)	14	56		
Duyarlılık	77.5 %	Kappa	0.573	
Seçicilik	75.7 %	RMSE	0.462	
Doğruluk	78.7 %	AUROC	0.788	

Tablo 4.27: Hibrid yaklaşım (en iyi 30 adet öznelik) için DVM sınıflandırıcısı çekirdek fonksiyon tiplerine göre hata matrisi ve performans ölçüm sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Doğrusal Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	64	16
	Negatif (Nodül olmayan örüntü)	24	46
	Duyarlılık	80.0 %	Kappa 0.460
	Seçicilik	74.2 %	RMSE 0.516
	Doğruluk	73.3 %	AUROC 0.729
	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Karesel Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	58	22
	Negatif (Nodül olmayan örüntü)	25	45
	Duyarlılık	72.5 %	Kappa 0.369
	Seçicilik	67.2 %	RMSE 0.560
	Doğruluk	68.7 %	AUROC 0.684
	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	60	20
	Negatif (Nodül olmayan örüntü)	25	45
	Duyarlılık	75.0 %	Kappa 0.395
	Seçicilik	69.2 %	RMSE 0.548
	Doğruluk	70.0 %	AUROC 0.696
	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)
Radyal Tabanlı Çekirdek Fonksiyonu	Pozitif (Pulmoner Nodül)	62	18
	Negatif (Nodül olmayan örüntü)	23	47
	Duyarlılık	77.5 %	Kappa 0.448
	Seçicilik	72.3 %	RMSE 0.523
	Doğruluk	72.7 %	AUROC 0.723
	Gerçek Durum	Kestirilen Durum	
		Pozitif (Pulmoner Nodül)	Negatif (Nodül olmayan örüntü)

4.3.6 Literatürde Yapılan Çalışmalarla Performans Karşılaştırması

Tez çalışmasında pulmoner nodüllerin tespiti ve sınıflandırma yaklaşımı için önerilen BDT sisteminin performansını [116] değerlendirmek için literatürdeki sekiz farklı çalışma ile karşılaştırma yapılmıştır. Literatürdeki çalışmalarda veri sayısı, nodül çap aralığı farklılıkları gibi parametreler göz önüne alındığında hem performans karşılaştırmasının oldukça zor olduğu hem de her bir araştırmanın önemli bir başarıyı gerçekleştirdiği söylenebilir. Bu açıdan görece bir karşılaştırma yapmak oldukça önemlidir.

Tez çalışmasında pulmoner nodüllerin tespiti için önerilen BDT sistemi, Tablo 4.28’de literatür çalışmaları ile karşılaştırılmıştır.

Tablo 4.28: Literatürdeki BDT sistemlerinin performans karşılaştırması.

BDT Sistemi	Nodül Çapı (mm)	Duyarlılık (%)
Opfer ve Wiemeker [117]	≥ 4	74.0
Gori ve ark. [118]	≥ 5	74.7
Rubin ve ark. [119]	≥ 3	76.0
Hardie ve ark. [120]	-	78.1
Şahiner ve ark. [121]	3-36.4	79.0
Suarez-Cuenca ve ark. [122]	4-27	80.0
Suzuki ve ark. [123]	8-20	80.3
Messay ve ark. [124]	3-30	82.66
Tartar ve ark. [116]	2-20	89.6

Opfer and Wiemeker [117] 127 nodül içeren 2-3 mm kesit aralığına sahip 93 adet hastanın BT görüntüsü veri setinde kullanılmıştır. Gori ve ark. [118] tarafından önerilen

BDT sisteminde 19 adet BT taramasından 45 adet nodülü kullanmışlardır. Rubin ve ark. [119], 1.25 mm kesit kalınlığına ve 0.6 mm piksel aralığına sahip olan 20 adet BT taramasından toplam 195 adet nodül örüntüsü ile uygulama yapmışlardır. Hardie ve ark. [120], 167 adet radyografi görüntüsünden 181 adet nodül görüntüsünü eğitim algoritmasında; 154 adet nodül örüntüsünü (100 adet malign ve 54 adet benign) test veri setinde kullanmışlardır. Şahiner ve ark. [121] tarafından 73 adet nodül içeren 28 adet hastanın BT taramaları incelenmiştir. Suarez-Cuenca ve ark. [122] tarafından 77 adet nodül içeren 22 adet BT taramasını BDT sistemlerinde kullanmışlardır. Suzuki ve ark. [123] tarafından LIDC veri setinden 28 adet ve diğer hastane veri setinden 20 adet olmak üzere toplam 71 adet farklı hastadan çekilen 101 BT taramasından 121 adet nodülü önerilen BDT sistemlerinde kullanmışlardır. Messay ve ark. [124] tarafından 3-30 mm nodül aralığında 143 adet nodül içeren 84 adet BT görüntüsü kullanılmıştır.

Üniversite hastanemizdeki tüm BT görüntüleri, uluslararası standart görüntüleme protokollerine göre çekim yapılarak elde edilmektedir. Önerilen BDT sistemimizde [116] üniversitemiz hastanesinden aldığımız BT görüntüleri kullanılmıştır. Pulmoner nodüllerin tespit ve sınıflandırılmasında yeni bir Hibrid Yaklaşım önerilerek 95 adet pulmoner nodül ve 75 adet nodül olmayan toplam 170 adet örüntü içeren 63 adet BT taraması ile BDT sistemi gerçekleştirilmiştir. Tablo 4.28'deki sonuçlar dikkate alındığında önerilen BDT sistemi % 89.6 duyarlılık, % 90.7 doğruluk ve % 87.5 seçicilik değerleri ve 2-20 mm nodül çap aralığı açısından son derece iyi bir performans göstermektedir.

4.4. MALİGN- BENİGN SINIFLANDIRMA SONUÇLARI

Akciğer kanserinde pulmoner nodül örüntülerinin hekimler tarafından malign (*kötü huylu, kötücül*), benign (*iyi huylu, iyicil*) gibi teşhis ve tedavi sürecine katkı sağlayabilecek nitelikte teşhis edilmesi son derece önemlidir.

Çalışmada radyoloji ve patoloji raporları neticesinde hastadaki nodülün malign veya benign özellikte olduğu şeklinde değerlendirilen BT görüntüleri kullanılmıştır. İki boyutlu pulmoner nodül örüntülerinin öznitelikleri için yaş, cinsiyet, nodül lokalizasyonu, kontrast ve nodül çapı niceliklerini içine alan *Risk Faktörleri* ve Eksantriklik, Kompaktlık, Yuvarlaklık, Dairesellik ve Eliptisite gibi şekil özelliklerini tanımlayan *Morfolojik Özellikler* tanımlanmıştır.

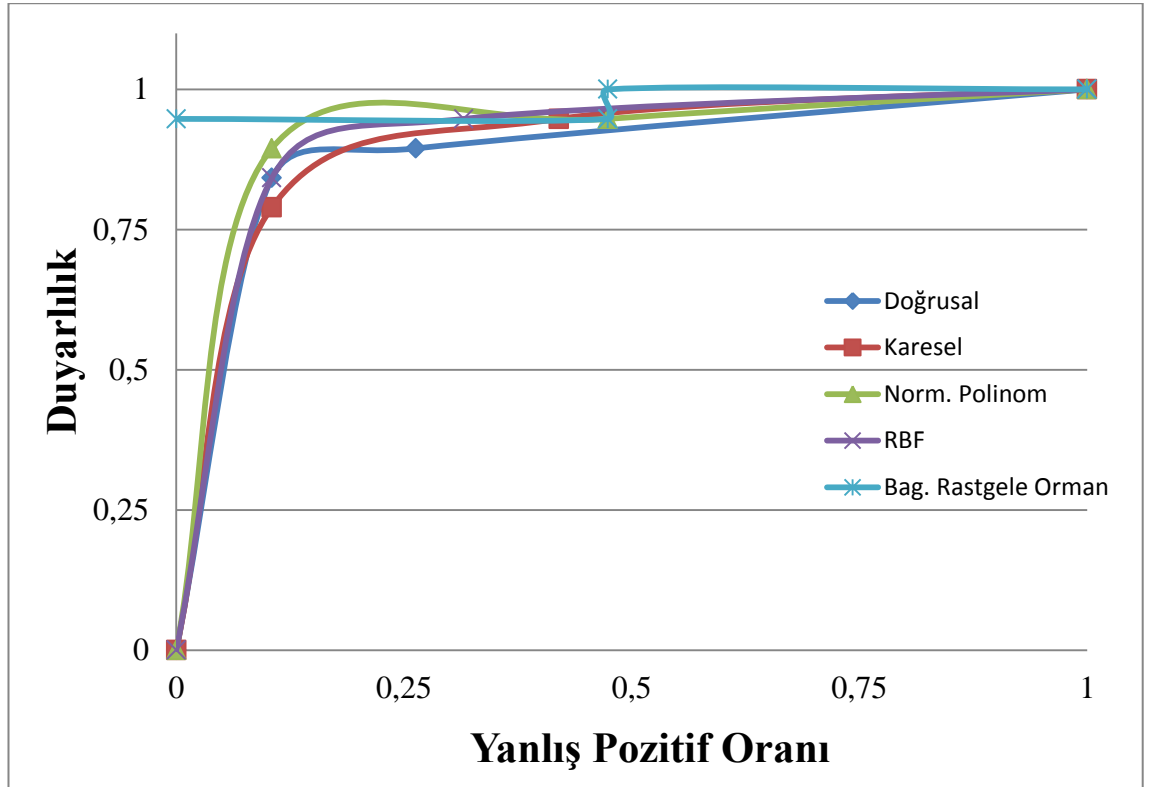
Destek vektör makinelerinin çekirdek fonksiyonlarında doğrusal ve karesel çekirdek fonksiyonu için düzenleyici parametre $C=50$, normalleştirilmiş çekirdek fonksiyonu için düzenleyici parametre $C=100$ ve radyal tabanlı çekirdek fonksiyonu için düzenleyici parametre $C=100$ ve kernel boyutu $\gamma=0.1$ olarak alınmıştır. Destek vektör makineleri çekirdek fonksiyonlarına ait sınıflandırma performans değerleri Tablo 4.29'da verilmektedir. Tartar ve ark. [116] tarafından kullanılan Bagging Rastgele Orman Topluluk Sınıflandırıcısı, malign ve benign veri setine uygulanmış ve performans sonuçları Tablo 4.30'da elde edilmiştir. Sınıflandırıcılara ait malign benign sınıflandırma başarımlarını gösteren ROC eğrileri Şekil 4.10'da verilmektedir.

Tablo 4.29: Malign Benign sınıflandırma performans sonuçları.

Doğrusal Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Benign	Malign	Belirsiz
	Benign	17	2	0
	Malign	2	5	3
	Belirsiz	0	3	6
	Duyarlılık	89.5 %	50.0 %	66.7 %
	AUROC	0.880	0.682	0.801
	Doğruluk	73.7 %		
Karesel Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Benign	Malign	Belirsiz
	Benign	15	3	1
	Malign	2	6	2
	Belirsiz	0	5	4
	Duyarlılık	78.9 %	60.0 %	44.4 %
	AUROC	0.880	0.621	0.736
	Doğruluk	65.8 %		
Normalleştirilmiş Polinom Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Benign	Malign	Belirsiz
	Benign	17	2	0
	Malign	2	5	3
	Belirsiz	0	5	4
	Duyarlılık	89.5 %	50.0 %	44.4 %
	AUROC	0.899	0.602	0.745
	Doğruluk	68.4 %		
Radyal Tabanlı Çekirdek Fonksiyonu	Gerçek Durum	Kestirilen Durum		
		Benign	Malign	Belirsiz
	Benign	16	3	0
	Malign	2	5	3
	Belirsiz	0	5	4
	Duyarlılık	84.2 %	50.0 %	44.4 %
	AUROC	0.899	0.607	0.745
	Doğruluk	65.8 %		

Tablo 4.30: Bagging Rastgele Orman Topluluk Sınıflandırıcısına ait malign benign sınıflandırma performans sonuçları.

Bagging Rastgele Orman Topluluk Sınıflandırıcısı	Gerçek Durum	Kestirilen Durum		
		Benign	Malign	Belirsiz
	Benign	18	1	0
	Malign	0	8	2
	Belirsiz	0	2	7
	Duyarlılık	94.7 %	80.0 %	77.8 %
	AUROC	0.975	0.889	0.862
	Doğruluk	86.8 %		



Şekil 4.10: Malign Benign sınıflandırmasında Sınıflandırıcılara ait ROC eğrileri.

5. TARTIŞMA VE SONUÇ

Tez çalışmasında pulmoner nodüllerin tespit ve teşhisi için iki farklı BDT sistemi önerilmiştir. Oldukça zor bir görüntü işleme problemi olan pulmoner nodüllerin sınıflandırılması ile alakalı oldukça memnun edici sonuçlar elde edilmiştir. Ayrıca çalışmada pulmoner nodüllerin malign ve benign ayrımının yapılması literatüre bir yenilik kazandırması açısından son derece önemlidir. Çalışmada malign ve benign ayrımı ile ilgili önerilen yaklaşım, pulmoner nodüllerin teşhis sisteminde bir ilki temsil etmesi açısından büyük önem arz etmektedir. Bu bölümde pulmoner nodüllerin tespit ve teşhis sisteminden elde edilen sonuçlarla ilgili önemli değerlendirmeler yapılmaktadır.

5.1 PULMONER NODÜL TESPİT SONUÇLARININ DEĞERLENDİRİLMESİ

Çalışmada, pulmoner nodül ve nodül olmayan örüntülere ait özneliklerin çıkartımı için dört farklı yöntem kullanılmıştır. Ayrıca çalışmada, her bir yöntemde örüntüleri en iyi karakterize eden özneliklerin seçildiği *Hibrid Yaklaşım* olarak adlandırılan yeni bir sınıflandırma yaklaşımı önerilmiştir. Böylece pulmoner nodüller için BDT sisteminin karar verme performansının artırılması hedeflenmiştir.

Ayrık dalgacık dönüşümünde Haar ve Daubechies (db4) dalgacık tipleri kullanılarak nodüllerin öznelikleri elde edilmiştir. Şekil 4.5'te görüldüğü gibi Haar dalgacık tipine ait 24 adet öznelik için DVM'nin radyal tabanlı çekirdek fonksiyonu sınıflandırıcısında % 73.8 duyarlılık, % 69.1 seçicilik, % 70.7 doğruluk, 0.410 Kappa, 0.542 RMSE ve 0.704 AUROC değerleri ile en iyi performans ölçümleri elde edilmiştir. Doğrusal çekirdek fonksiyonu için % 75.0 duyarlılık ve 0.646 AUROC, karesel çekirdek fonksiyonu için % 62.5 duyarlılık ve 0.655 AUROC ve normalleştirilmiş çekirdek fonksiyonu için % 73.8 duyarlılık ve 0.640 AUROC değerleri elde edilmiştir.

Daubechies (db4) dalgacık tipinde ise Şekil 4.6'da görüldüğü üzere 15 adet öznelik sayısında Doğrusal, Karesel ve Normalleştirilmiş polinom çekirdek fonksiyonları en iyi

performansı gösterirken; RBF çekirdek fonksiyonu 20 adet öznitelik sayısında daha iyi performans elde edilmektedir. Doğrusal çekirdek fonksiyonu için % 70.0 duyarlılık ve 0.579 AUROC, karesel çekirdek fonksiyonu için % 68.8 duyarlılık ve 0.701 AUROC, normalleştirilmiş polinom çekirdek fonksiyonu için % 75.0 duyarlılık ve 0.625 AUROC ve radyal tabanlı çekirdek fonksiyon için % 66.3 duyarlılık ve 0.703 AUROC sınıflandırma başarımları elde edilmiştir.

Temel bileşen analizinde Şekil 4.7'de görüldüğü gibi genel olarak öznitelik sayısının azalması ile sınıflandırma başarımının artış gösterdiği görülmektedir. Doğrusal çekirdek fonksiyonu 30 adet öznitelik sayısında, karesel ve normalleştirilmiş polinom fonksiyon 20 adet öznitelik sayısında ve radyal tabanlı çekirdek fonksiyonu 49 adet (tüm) öznitelik sayısında en iyi sınıflandırma başarımı göstermektedirler. Doğrusal çekirdek fonksiyonu için % 77.5 duyarlılık ve 0.638 AUROC, karesel çekirdek fonksiyonu için % 73.8 duyarlılık ve 0.576 AUROC, normalleştirilmiş polinom çekirdek fonksiyonu için % 65.0 duyarlılık ve 0.575 AUROC ve radyal tabanlı çekirdek fonksiyon için % 68.8 duyarlılık ve 0.594 AUROC sınıflandırma başarımları elde edilmiştir.

TBA istatistiksel değerlerinde Şekil 4.8 görüldüğü üzere öznitelik sayısının azalması ile doğrusal, normalleştirilmiş polinom ve RBF çekirdek fonksiyonlarının sınıflandırma başarımları artış göstermektedir. Karesel çekirdek fonksiyonunda 6 adet öznitelik ile en iyi sonuç elde edilirken doğrusal, normalleştirilmiş polinom ve RBF çekirdek fonksiyonlarında 4 adet öznitelik sayısında daha yüksek performans değerleri elde edilmektedir. Doğrusal çekirdek fonksiyonu için % 68.8 duyarlılık ve 0.544 AUROC, karesel çekirdek fonksiyonu için % 62.5 duyarlılık ve 0.534 AUROC, normalleştirilmiş polinom çekirdek fonksiyonu için % 47.5 duyarlılık ve 0.580 AUROC ve radyal tabanlı çekirdek fonksiyon için % 52.5 duyarlılık ve 0.555 AUROC sınıflandırma başarımları elde edilmiştir.

Morfolojik görüntü işlemede Şekil 4.9'da görüldüğü gibi öznitelik sayısının azalması ile sınıflandırma başarımı artış göstermektedir. Pulmoner nodüller üzerinde morfolojik görüntü işleme yapılarak örüntüleri oldukça iyi karakterize eden önemli öznitelikler elde edilmiştir. Doğrusal çekirdek fonksiyonu 5 adet öznitelik sayısı ile % 76.3 duyarlılık ve 0.738 AUROC, karesel çekirdek fonksiyonu 10 adet öznitelik sayısı ile % 67.5

duyarlılık ve 0.709 AUROC, normalleştirilmiş polinom çekirdek fonksiyonu 9 adet öznitelik sayısı ile % 76.3 duyarlılık ve 0.717 AUROC ve radyal tabanlı çekirdek fonksiyonu 6 adet öznitelik sayısı ile % 78.8 duyarlılık ve 0.744 AUROC değerleri olmak üzere sınıflandırma başarımları elde edilmiştir.

Hibrid yaklaşımda kullanılan yöntemlerde en iyi sınıflandırma performansına sahip olan öznitelikler bir araya getirilerek sınıflandırma başarımının artması hedeflenmiştir. Önerilen hibrid yaklaşım sonuçları diğer yöntemlere göre daha yüksek performans değerlerine sahiptir. Öncelikle 20 adet öznitelik ayrık dalgacık dönüşümünden, 10 adet öznitelik TBA'dan, 4 adet öznitelik TBA istatistik değerlerinden ve 6 adet öznitelik morfolojik özelliklerden olmak üzere toplam 40 adet öznitelik kümesi oluşturulmuştur. Buna göre doğrusal çekirdek fonksiyonu için % 71.3 duyarlılık ve 0.721 AUROC, karesel çekirdek fonksiyonu için % 72.5 duyarlılık ve 0.741 AUROC, normalleştirilmiş polinom çekirdek fonksiyonu için % 78.8 duyarlılık ve 0.787 AUROC ve radyal tabanlı çekirdek fonksiyon için % 77.5 duyarlılık ve 0.788 AUROC sınıflandırma başarımları elde edilmiştir. Benzer şekilde 20 adet öznitelik TBA'dan, 4 adet öznitelik TBA istatistik değerlerinden ve 6 adet öznitelik morfolojik özelliklerden olmak üzere toplam 30 adet öznitelik kümesine ait destek vektör makineleri sınıflandırma performans sonuçları elde edilmiştir. Buna göre doğrusal çekirdek fonksiyonu için % 80.0 duyarlılık ve 0.729 AUROC, karesel çekirdek fonksiyonu için % 72.5 duyarlılık ve 0.684 AUROC, normalleştirilmiş polinom çekirdek fonksiyonu için % 75.0 duyarlılık ve 0.696 AUROC ve radyal tabanlı çekirdek fonksiyon için % 77.5 duyarlılık ve 0.723 AUROC sınıflandırma başarımları elde edilmiştir.

Tartar ve ark. [116] tarafından 30 öznitelik kullanılarak önerilen hibrid yaklaşım, 20 adet öznitelik TBA'dan, 5 adet öznitelik TBA istatistik değerlerinden ve 5 adet öznitelik morfolojik özelliklerden olmak üzere toplam 30 adet öznitelikten oluşmaktadır. Yapay sinir ağları kullanılarak % 89.6 duyarlılık, % 90.7 duyarlılık, % 87.5 seçicilik ve 0.904 AUROC sınıflandırma performans değerleri elde edilmiştir. Çalışmada önerilen hibrid yaklaşım, pulmoner nodüllerin sınıflandırılmasında önemli katkı sağlayan etkili bir yöntem olarak kullanılabilir.

Çalışmanın diğer önemli hususlarından biri Tablo 4.28’de ve Şekil 3.6’da görüldüğü üzere kullanılan veri setinde oldukça küçük boyutlu pulmoner nodül örüntülerinin kullanılmasıdır. Çalışmada 2-20 mm boyut aralığında kullanılan 159 adet pulmoner nodül örüntüsünden 141 adedi 2-9 mm boyut aralığında yer almaktadır. BDT sisteminde küçük boyutlu örüntülerin dikkate alınması, hastalığın erken aşamada teşhisine büyük katkı sağlamaktadır.

5.2 MALİGN BENİGN AYRIM SONUÇLARININ DEĞERLENDİRİLMESİ

Malign benign ayrımı için kullanılan destek vektör makineleri çekirdek fonksiyonları kullanılarak elde edilen sınıflandırma başarımları benign sınıfı için oldukça iyi sonuçlar vermektedir. Ancak malign ve belirsiz sınıfların tespit edilmesinde aynı başarımlar görülmemektedir. Çalışmada pulmoner nodüllerin teşhis seviyesinde malign ve benign ayrımının yapılması için Bagging rasgele orman topluluk sınıflandırıcısı [116] önerilmektedir.

Doğrusal çekirdek fonksiyonunda % 73.7 sınıflandırma doğruluğu ile beraber benign sınıfta % 89.5 duyarlılık ve 0.880 AUROC, malign sınıfta % 50.0 duyarlılık ve 0.681 AUROC, takibi gereken belirsiz sınıfta % 66.7 duyarlılık ve 0.801 AUROC sınıflandırma başarımları elde edilmiştir. Karesel çekirdek fonksiyonunda % 65.8 sınıflandırma doğruluğu ile beraber benign sınıfta % 78.9 duyarlılık ve 0.880 AUROC, malign sınıfta % 60.0 duyarlılık ve 0.621 AUROC, takibi gereken belirsiz sınıfta % 44.4 duyarlılık ve 0.736 AUROC sınıflandırma başarımları elde edilmiştir. Normalleştirilmiş polinom fonksiyonunda % 68.4 sınıflandırma doğruluğu ile beraber benign sınıfta % 89.5 duyarlılık ve 0.899 AUROC, malign sınıfta % 50.0 duyarlılık ve 0.602 AUROC, takibi gereken belirsiz sınıfta % 44.4 duyarlılık ve 0.745 AUROC sınıflandırma başarımları elde edilmiştir. Radyal tabanlı çekirdek fonksiyonunda % 65.8 sınıflandırma doğruluğu ile beraber benign sınıfta % 84.2 duyarlılık ve 0.899 AUROC, malign sınıfta % 50.0 duyarlılık ve 0.607 AUROC, takibi gereken belirsiz sınıfta % 44.4 duyarlılık ve 0.745 AUROC sınıflandırma başarımları elde edilmiştir.

Önerilen Bagging rasgele orman topluluk sınıflandırıcısında malign ve benign huylu nodüllerin ayrımı için 86.8 % sınıflandırma doğruluğu ile beraber benign sınıfta % 94.7 duyarlılık ve 0.975 AUROC değeri, malign sınıfta 80.0 % duyarlılık ve 0.889 AUROC değeri ve takibi gereken belirsiz sınıfta ise 77.8 % duyarlılık ve 0.862 AUROC sınıflandırma başarımları elde edilmiştir. Önerilen yöntem, malign ve benign ayrımının yapılmasında literatüre önemli bir katkı sağlamaktadır.

KAYNAKLAR

1. CANCER FACTS AND FIGS, 2009, *The American Cancer Society*.
2. KAIZOE, T., 1995, *Figures on Cancer in Japan*, Foundation for Promotion of Cancer Research.
3. GOULD M.K., FLETCHER J., MARK D.L., LYNCH W.R., MIDTHUN D.E., NAIDICH D.P., OST D.E., 2007, Evaluation of patients with pulmonary nodules: When is it lung cancer? ACCP Evidence-Based Clinical Practice Guidelines (2nd Edition), *American College of Chest Physicians*, DOI 10.1378/chest.07-1353.
4. JOHNSEY L.L III, JEFFREY S.K., 2002, The solitary pulmonary nodule, *Radiologic Clinics of North America*, Vol. 40 (1), 123-143.
5. ÇELİK A., KARAOĞLANOĞLU N., 2010, Soliter pulmoner nodül, *Journal of Clinical and Analytical Medicine*, DOI: 10.4328/JCAM.496.
6. MARTIN D., 2007, Detection of pulmonary nodules from CT scans, Master Thesis, Czech Technical University.
7. KIM D.Y., KIM J.H., NOH S.M., PARK J.W., 2003, Pulmonary nodule detection using chest CT images, *Acta Radiologica*, 44, 252-257.
8. REN Y., PATRICK M.V., PETER L.C., 2006, Computer-aided detection in screening CT for pulmonary nodules, *American Journal of Roentgenology*, 186, 1280-1287.
9. TARTAR, A., 2007, Klinik Lineer Hızlandırıcıların Su Fantomundaki Doz Dağılımlarının Monte Carlo Yöntemi ile Elde Edilmesi, Yüksek Lisans Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü.
10. Akciğer Kanseri, <http://www.trakya.edu.tr/ckarlikaya/acca/ackanserinedir.htm> [Ziyaret Tarihi:17.05.2013].
11. AYDINER, A., CAN, G., 2010, *Akciğer Kanserinde Tedavi ve Bakım*, 1. Baskı, İpomet Matbaacılık San. ve Tic. Ltd. Şti., ISBN: 978-605-125-143-1, İstanbul.
12. HELEN T.WINER-MURAM, 2006, The solitary pulmonary nodule, *Radiology*, V.239, No.1, 1-16.
13. Akciğer Kanseri, <http://www.akcigerkanseri.com/index.php/akciger-kanseri>, [Ziyaret Tarihi:30.06.2013].
14. Risk Faktörleri, <http://thsk.gov.tr/tr/index.php/kanser-nedir/316-risk-faktorleri>, [Ziyaret Tarihi:30.06.2013].

15. PALMARINI M, FAN H., 2001, Retrovirus-induced ovine pulmonary adenocarcinoma, an animal model for lung cancer, *J Natl Cancer Inst.*, Nov 7, 93(21), 1603-14.
16. AKKOÇLU, A., *Akciğer kanserleri*, Türk Toraks Derneği.
17. GÖKSEL, T., *Akciğer kanseri*, Türk Toraks Derneği yayınları.
18. SAVAŞ İ., KAYA A., 2006, Akciğer Kanserlerinde Semptomlar ve Bulgular, *Türkiye Klinikleri J Surg Med Sci*, 2(12), 66-71.
19. Akciğer Kanseri Belirtileri, http://www.akcigerkanserilazer.com/bilgidetay/akciger-kanseri-belirtileri_482.html, [Ziyaret Tarihi:30.06.2013].
20. Akciğer Kanseri, <http://www.kansersavas.com/akciger-kanseri.html>, [Ziyaret Tarihi:30.06.2013].
21. Akciğer Kanseri, <http://www.trakya.edu.tr/ckarlikaya/acca/ackanserinedir.htm>, [Ziyaret Tarihi:15.02.2013].
22. KÖKTÜRK N, ULUKAVAK ÇİFTÇİ T, YEĞİN D, BİLGİN MULLAOĞLU S, HABEŞOĞLU MA, ÖZTÜRK C., 2004, Akciğer Kanserli Olgularımızda Semptomatolojik, Radyolojik ve Endoskopik Bulguların Histopatolojik Bulgularla Birlikte Değerlendirilmesi, *Türk toraks dergisi*, 5 (3), 143-147.
23. WYNDER EL, HOFFMAN D., 1994, Smoking and lung cancer: Scientific challenges and opportunities, *Cancer Res.*, 54, 5284-5295.
24. COLLINS LG, HAINES C, PERKEL R, ENCK RE, 2007, Lung cancer: diagnosis and management, *Am. Fam. Physician*, 75(1), 56-63.
25. AKKOÇLU, A., Akciğer kanserlerinde tanı, evreleme ve tedavi öncesi değerlendirme, *Türk Toraks Derneği*.
26. SCHILLER JH, VIDAVER RM, NOVELLO S, BRAHMER J, MONROE L, 2007, Living with a Diagnosis of Lung Cancer, Standard Treatments for Lung Cancer, *National Lung Cancer Partnership*.
27. MINNA, JD, 2004, *Harrison's Principles of Internal Medicine*. McGraw-Hill, s. 506-516. ISBN 0-07-139140-1.
28. EL-SHERIF A, GOODING WE, SANTOS R, PETTIFORD B, FERSON PF, FERNANDO HC, URDA SJ, LUKETICH JD, LANDRENEAU RJ., 2006, Outcomes of sublobar resection versus lobectomy for stage I non-small cell lung cancer: a 13-year analysis, *Ann Thorac Surg*, 82(2), 408-16.
29. YILMAZBAYHAN A, DAMADOĞLU E, AYBATLI A., 2005, Soliter pulmoner nodüle tanısal yaklaşım, *Tuberk Toraks*, 53(3), 307-18.
30. CANCER FACTS AND FIGURES, 2010, American Cancer Society, Atlanta.

31. KAIZOE, T., 1995, *Figures on Cancer in Japan*, Foundation for Promotion of Cancer Research.
32. SAĞLIK İSTATİSTİKLERİ YILLIĞI, 2009, *Türkiye Cumhuriyeti Sağlık Bakanlığı*, Ankara.
33. MICHELI, A., BAILI, P., QUINN, M., MUGNO, E., CAPOCACCIA, R., GROSCLAUDE, P., 2003, Life Expentancy and Cancer Survival in The EURO CARE-3 Cancer Registry Areas, *Ann.Oncol*, 14(5), V28-V40.
34. SINGH, G.K., MILLER, B.A., HANKEY, B.F., 2002, Changing area socioeconomic patterns in U.S. cancer mortality, 1950-1988:Part II-Lung and colorectal cancers, *J.Natl. Cancer Inst.*, 94, 916-925.
35. IHDE, D.C., MINNA, J.D., 1991, Non-small cell lung cancer, Part I-Biology, diagnosis and staging, *Curr. Probl. Cancer*, 15(2), 61-104.
36. TRAVIS WD, TRAVIS LB, DEVESA SS., 1995, Lung cancer, *Cancer*, 1 (75), 191-202.
37. AYDINER, A., CAN, G., 2010, *Akciğer Kanserinde Tedavi ve Bakım*, 1. Baskı, İpommet Matbaacılık San. ve Tic. Ltd. Şti., ISBN: 978-605-125-143-1, İstanbul.
38. JEMAL, A., SIEGEL, R., WARD, E., HAO, Y., XU, J., THUN, M.J., 2009, Cancer statistics, *CA: A cancer journal of clinicians*, 59, 225-249.
39. ADAPINAR B., 1997, *Temel Radyoloji Tekniği*, 3. Baskı, Güneş-Nobel Yayınevi, 316-324.
40. ANDREW WEBB, 2003, *Introduction to Biomedical Imaging*, John Willey & Sons, Inc.
41. TUNCEL, E., 2006, Uludağ Üniversitesi Radyoloji A.B.D, *Ders Notları*, 3-64.
42. AYER T., CHEN Q., BURNSIDE E.S., 2013, Artificial neural networks in mammography interpretation and diagnostic decision making, *Computational and Mathematical Methods in Medicine*, Volume 2013, pp.1-10, ID 832509.
43. DOI K., 2007, Computer-aided diagnosis in medical imaging: historical review, current status and future potential, *Computerized Medical Imaging and Graphics*, 31(4-5), 198-211.
44. KILIC N., GORGEL P., UCAN O.N., SERTBAS A., 2010, Mammographic mass detection using wavelets as input to neural networks, *Journal of Medical Systems*, 34, 1083-1088.
45. GIGER ML, CHAN HP, BOONE J., 2008, Anniversary paper: history and status of CAD and quantitative image analysis: the role of medical physics and AAPM, *Medical Physics*, 35, 5799-820.

46. SUMMERS RM., 2003, Road maps for advancement of radiologic computer-aided detection in the 21st century, *Radiology*, 229(1), 11–3.
47. RETICO A., DELOGU P., FANTACCI M.E., GORI I., MARTINEZ A.P., 2008, Lung Nodule detection in low dose and thin-slice computed tomography, *Computers in Biology and Medicine*, 38, 525-534.
48. KANAZAWA K., KAWATA Y., NIKI N., SATOH H., OHMATSU H., KAKINUMA R., KANEKO M., MORIYAMA N., EGUCHI K., 1998, Computer-aided diagnosis for pulmonary nodules based on helical CT images, *Computerized Medical Imaging and Graphics*, 22, 157-167.
49. MARTEN K., ENGELKE C., SEYFARTH T., GRILLHÖSL A., OBENAUER S., 2005, Computer aided detection of pulmonary nodules: Influence of nodule characteristics on detection performance, *Clinical Radiology*, 60, 196-206.
50. SUAREZ-CUENCA JJ., TAHOSES P.G., SOUTO M., LADO M.J., REMY-JARDÍN M., REMY J., VIDAL JJ., 2009, Application of the iris filter for automatic detection of pulmonary nodules on computed tomography images, *Computers in Biology and Medicine*, 39, 921-933.
51. ÖZEKES, S., 2006, Tıbbi görüntüleme sistemlerinde bilgisayar destekli tespit, Doktora Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü.
52. LEE M.C., BOROCZKY L., SUNGUR S-K., CANN A.D., BORCZUK A.C., KAWUT S.M., POWELL C.A., 2010, Computer-aided diagnosis of pulmonary nodules using a two-step approach for feature selection and classifier ensemble construction, *Artificial Intelligence in Medicine*, 50, 43-53.
53. LIN D-T., YAN C-R., CHEN W-T., 2005, Autonomous detection of pulmonary nodules on CT images with a neural network-based fuzzy system, *Computerized Medical Imaging and Graphics*, 29, 447-458.
54. MESSAY T., HARDIE R.C., ROGERS S.K., 2010, A new computationally efficient CAD system for pulmonary nodule detection in CT imagery, *Medical Image Analysis*, 14, 390-406.
55. CHOI W-J, CHOI T-S., 2012, Genetic programming-based feature transform and classification for the automatic detection of pulmonary nodules on computed tomography images, *Information Sciences*, 212, 57-78.
56. BAĞCI U., BRAY M., CABAN J., YAO J., MOLLURA D.J., 2012, Computer-assisted detection of infectious lung diseases: A review, *Computerized Medical Imaging and Graphics*, 36, 72-84.
57. SOUSA J.R.F.S., SILVA A.C., PAIVA A.C., NUNES R.A., 2010, Methodology for automatic detection of lung nodules in computerized tomography images, *Computer Methods and Programs in Biomedicine*, 98, 1-14.
58. MURPHY K., GINNEKEN B. V., SCHILHAN A.M.R., HOOP B.J., GIETEMA H.A., PROTOP M., 2009, A large-scale evaluation of automatic pulmonary

nodule detection in chest CT using local image features and k-nearest-neighbour classification, *Medical Image Analysis*, 13, 757-770.

59. IWANO S., NAKAMURA T., KAMIOKA Y., ISHIGAKI T., 2005, Computer-aided diagnosis: A shape classification of pulmonary nodules imaged by high-resolution CT, *Computerized Medical Imaging and Graphics*, 29, 565-570.
60. JOSE M.F-F., ENRIQUE J.H.-L., FRANCISCO S-L.I ANTONIO R-C., PAULA A.C-G., GISELA L-P, MARIA G. G-P., R. FEMAT, MOISES M-V., 2012, Development of an optimized multi-biomarker panel for the detection of lung cancer based on principal component analysis and artificial neural network modeling, *Expert Systems with Applications*, 39, 10851-10856.
61. KUBOTA T., JEREBKO A. K., DEWAN M., SALGANICOFF M., KRISNAN A., 2011, Segmentation of pulmonary nodules of various densities with morphological approaches and convexity models, *Medical Image Analysis*, 15, 133-154.
62. LEE S.L.A., KOUZANI A.Z., HU E.J., 2010, Random forest based lung nodule classification aided by clustering, *Computerized Medical Imaging and Graphics*, 34, 535-542.
63. LI B., CHEN K., TIAN L., YEBOAH Y., OU S., 2013, Detection of pulmonary nodules in CT images based on fuzzy integrated active contour model and hybrid parametric mixture model, *Computational and Mathematical Methods in Medicine*, Volume 2013, 1-15.
64. YUDONG G., YONG W., MINGXIN L., Computer aided detection for pulmonary nodules base on the morphological and spatial features, 978-1-4244-5316-0/10.
65. LIU Y., YANG J., ZHAO D., LIU J. 2010, A study of pulmonary nodule detection in three dimensional thoracic CT scans, *Second International Conference on Computer Modeling and Simulation*, pp 1-4.
66. WANG Q., KANG W., WU C. WANG B., 2012, Computer-aided detection of lung nodules by SVM based on 3D matrix patterns, *Clinical Imaging*, Doi:10.1016.
67. CHEN S., SUZUKI K., MACMAHON H., 2011, Development and evaluation of a computer aided diagnostic scheme for lung nodule detection in chest radiographs by means of two-stage nodule enhancement with support vector classification, *Medical Physics*, 38 (4), 1844-1858.
68. TARTAR A., KILIÇ N., OLGUN D.Ç., AKAN A., 2013, Pulmoner nodüller için yeni bir bilgisayar destekli tespit sistemi, *21. IEEE Sinyal işleme ve İletişim Uygulamaları Kurultayı*, s.1-4, Girne, KKTC.
69. TARTAR, A., KILIÇ, N., AKAN, A., 2013, Bagging support vector machine approaches for pulmonary nodule detection, *IEEE International Conference on Control, Decision and Information Technologies*, s.1-4, Tunisia.

70. TARTAR A., KILIÇ N., AKAN A., 2013, A new method for pulmonary nodule detection using decision tress, *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, s.1-5, Osaka, Japan.
71. KO J.P., NAIDICH D.P., 2003, Lung nodule detection and characterization with multislice CT, *Radiologic Clinics of North America*, 41, 575-597.
72. DANACI M., AKAN H., BELET Ü., İNCESU L., BAŞTEMİR M., SELÇUK M.B., 2000, Soliter Pulmoner nodüllerin malign-benign ayrımında dinamik kontrastlı BT incelemesi, *OMÜ Tıp Dergisi*, 17 (1), 25-32.
73. KAMIYA H., MURAYAMA S., KAKINOHANA Y., MIYARA T., 2011, Pulmonary nodules: A quantitative method of diagnosis by evaluating nodule perimeter difference to approximate oval using three-dimensional CT images, *Clinical Imaging*, 35, 123-126.
74. XU D.M., KLAVEREN R.J., BOCK G.H., LEUSVELD A., ZHAO Y., WANG Y., Vliegenthart R., KONING H.J., SCHOLTEN E.T., VERSCHAKELEN J., PROKOP M., OUDKERK M., 2009, Role of baseline nodule density and changes in density and nodule features in the discrimination between benign and malignant solid indeterminate pulmonary nodules, *European Journal of Radiology*, 70, 492-8.
75. CHEN H., ZHANG J., XU Y., CHEN B., ZHANG K., 2012, Performance comparison of artificial neural network and logistic regression model for differentiating lung nodules on CT scans, *Expert Systems with Applications*, 39, 11503-11509.
76. LEE M.C., BOROCZKY L., SUNGUR S-K., CANN A.D., BORCZUK A.C., KAWUT S.M., POWELL C.A., 2010, Computer-aided diagnosis of pulmonary nodules using a two-step approach for feature selection and classifier ensemble construction, *Artificial Intelligence in Medicine*, 50, 43-53.
77. HANAMIYA M., AOKI T., KAWANAMI S., KOROGI Y., 2010, Frequency and significance of pulmonary nodules on thin-section CT in patients with extrapulmonary malignant neoplasms, *European Journal of Radiology*, EURR-4910.
78. HARDIE R.C., ROGERS S.K., WILSON T., ROGERS A., 2008, Performance analysis of a new computer aided detection system for identifying lung nodules on chest radiographs, *Medical Image Analysis*, 12, 240-258.
79. IWANO S., NAKAMURA T., KAMIOKA Y., IKEDA M., ISHIGAKI T., 2008, Computer-aided differentiation of malignant from benign solitary pulmonary nodules imaged by high-resolution CT, *Computerized Medical Imaging and Graphics*, 32:416-422.
80. Somatom Sensation 10/16 Application Guide: Protocols, Principals, Helpful Hints, *Siemens AG Medical Solutions*.

81. GONZALES, R.C, WOODS, R.E., 2002, *Digital image processing*, Prentice Hall, New Jersey, 0-130-94650-8.
82. PAO-YEN, L., *An introduction to wavelet transform*, National Taiwan University, Taipei, Taiwan.
83. STRANG, G., NGUYEN, T., 1996, *Wavelets and Filter Banks*, Wellesley Cambridge Press, Boston.
84. UÇAN, O.N., OSMAN, O. ve ALBORA, A.M., 2006, *Görüntü işleme teknikleri ve mühendislik uygulamaları*, Nobel Yayıncılık, Ankara, 9944-77-051-5.
85. KÜÇÜK, M. ve AĞIRALIOĞLU, N., 2006, Dalgacık dönüşüm tekniği kullanılarak akım serilerinin modellenmesi, *İTÜ Dergisi Mühendislik*, 5(2), 69-80.
86. DASZYKOWSKI, M., WALCZAK, B., 2006, Use and abuse of chemometrics in chromatography, *Trends in analytical chemistry*, Vol.25, No.11.
87. DEMİR, H., 1998, Dalgacık dönüşümü ve işaret işleme uygulamaları, Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü.
88. WALKER, J.S., 1999, *A Primer on Wavelets and Their Scientific Applications*, CRC Press, Boca Raton.
89. GROSSMAN, A. and MORLET, J., 1984, Decomposition of hardy function into square integrable wavelets of constant shape, *SIAM Journal on Applied Mathematics*, 15, 723-736.
90. CASTLEMAN, K.R., 1996, *Digital Image Processing*, Prentice Hall, New Jersey, 0-13-211467-4.
91. CHUN-CIN, L., 2010, *A tutorial of the wavelet transform*.
92. DAUBECHIES, I., 1992, *Ten Lectures on Wavelets*, Society for Industrial and Applied Mathematics, Philadelphia, Pennsylvania.
93. http://en.wikipedia.org/wiki/Daubechies_wavelet, [Ziyaret Tarihi:30.06.2013].
94. TIMM, N.H., 2002, *Applied Multivariate Analysis*, Springer- Verlag, ISBN 0-387-95347-7, USA.
95. YANG, T., WANG, S, 1999, *Robust Algorithms For Principal Component Analysis*, Department of Electrical Engineering National Taiwan University. 927-933.
96. LUDWIG, J.A., REYNOLDS J.F., 1988. *Statistical Ecology*, A Wiley-Intescience Publication, ISBN 0-471-83235-9, USA.
97. CHEN, J. L., *Principal Component Analysis*, http://graphics.cs.ucdavis.edu/~jchen007/Research/CurrentPub/PCA/PCA_Chen.pdf, [Ziyaret Tarihi: 12.09.2012].

98. LINDSAY, I., SMITH, A *tutorial on Principal Components Analysis*, [http://kybele.psych.cornell.edu/~edelman/ Psych-465-Spring-2003/PCA-tutorial](http://kybele.psych.cornell.edu/~edelman/Psych-465-Spring-2003/PCA-tutorial), [Ziyaret Tarihi: 12.09.2012].
99. RENCHER, A. L., 2002, *Methods of Multivariate Analysis*, John Wiley and Sons, Inc., ISBN 0-471-41889-7, 708p. USA.
100. PIERCE, K.M., HOPE, J.L., HOGGARD, J.C., SYNOVEC, R.E., 2006. A Principal Component Analysis Based Method to Discover Chemical Differences in Comprehensive Two-Dimensional Gas Chromatography With Time-of-Flight Mass Spectrometry (GCXGC-TOFMS) Separation of Metabolites in Plant samples, *J. Talanta*, Vol:70, 797-804p.
101. GONZALES, R., WOODS, R., 2007, *Digital Image Processing*, Prentice Hall.
102. SOLOMON C., BRECKON T., 2011, *Fundamentals of Digital Image Processing: A practical approach with examples in Matlab*, Wiley-Blackwell.
103. HANCHUAN PENG, FUHUI LONG, AND CHRIS DING, 2005, Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27 (8), 1226-1238.
104. VAPNIK, V.N., 2000, *The Nature of Statistical Learning Theory*, Second Edition, Springer-Verlag, New York.
105. BURGESS, C.J.C., 1998, A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery II*, 121-167.
106. SCHÖLKOPF, B., 1998, Support vector machine, *IEEE Intelligent System*, 13(4), 18-21.
107. KILIÇ, N., 2008, Bilgisayarlı Tomografi Görüntülerinde Üç Boyutlu Şablonlar Kullanılarak Kolonik Polip Tespiti, Doktora Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü.
108. ANDREW, NG, Part V: Support Vector Machines, CS229 Lecture Notes.
109. KAVZOĞLU, T., ÇÖLKESEN, İ., 2010, Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi, *Harita Dergisi*, Sayı:144.
110. OSUNA, E.E., FREUD, R., GIROSI, F., 1997, Support Vector Machines: Training and Applications, CBCL Paper No-144, *MIT and Artificial Intelligence Laboratory*, Massachusetts.
111. HSU, C.W., CHANG, C.C., LIN, C.J., 2010, A practical guide to support vector Classification.
112. ARNULF, B.A., GRAF, S..B., 2001, Normalization in Support Vector Machines, *Lecture Notes in Computer Science*, 2191:227-282.

113. KARTALOĞLU, Z., 2008, Soliter pulmoner nodüle yaklaşım, *Turkish Journal of Thoracic and Cardiovascular Surgery*.
114. CHOI W-J, CHOI T-S., 2012, Genetic programming-based feature transform and classification for the automatic detection of pulmonary nodules on computed tomography images, *Information Sciences*, 212, 57-78.
115. FAWETT, T., 2003, ROC graphs: notes and practical considerations for data mining researches, *Technical report*, HPL-2003-4 HP Labs.
116. TARTAR A., KILIC N., AKAN A., 2013, Classification of pulmonary nodules by using hybrid features, *Computational and Mathematical Methods in Medicine*, Volume 2013, s.1-11, doi:10.1155/2013/148363.
117. OPFER, R., WIEMKER, R., 2007, Performance analysis for computer-aided lung nodule detection on LIDC data, *Proceedings of SPIE Medical Imaging*, 6515, 65151C.
118. GORI, I., FANTACCI, M., MARTINEZ, A.P., RETICO, A., 2007, An automated system for lung nodule detection in low dose computed tomography, *Proceedings of the SPIE on Medical Imaging, Computer Aided Diagnosis*, 6514, 65143R.
119. RUBIN, G., LYO, J., PAIK, D., SHERBONDY, A., CHOW, L., LEUNG, A., MINDELZUN, R., SCHRAEDLEY-DESMOND, P., ZINCK, S., NAIDICH, D., et al, 2005, Pulmonary nodules on multi-detector row CT scans: performance comparison of radiologists and computer-aided detection, *Radiology*, 234, 274.
120. HARDIE R.C., ROGERS S.K., WILSON T., ROGERS A., 2008, Performance analysis of a new computer aided detection system for identifying lung nodules on chest radiographs, *Medical Image Analysis*, 12, 240-258.
121. SAHINER, B., HADJIISKI, L., CHAN, H., SHI, J., CASCADE, P., KAZEROONI, E., ZHOU, C., WEI, J., CHUGHTAI, A., POOPAT, C., et al, 2007, Effect of CAD on radiologists' detection of lung nodules on thoracic CT scans: observer performance study, *Proceedings of SPIE Medical Imaging*, 6515, 65151D.
122. SUAREZ-CUENCA JJ., TAHOSES P.G., SOUTO M., LADO M.J., REMY-JARDIN M., REMY J., VIDAL JJ., 2009, Application of the iris filter for automatic detection of pulmonary nodules on computed tomography images, *Computers in Biology and Medicine*, 39,921-933.
123. SUZUKI, K., ARMATO III, S.A., LI, F., SONE, S., DOI, K., 2003, Massive training artificial neural network (MTANN) for reduction of false positives in computerized detection of lung nodules in low-dose computed tomography, *Medical Physics*, 30, 1602-1617.
124. MESSAY T., HARDIE R.C., ROGERS S.K., 2010, A new computationally efficient CAD system for pulmonary nodule detection in CT imagery, *Medical Image Analysis*, 14:390-406.

ÖZGEÇMİŞ

Ahmet TARTAR, 1982 yılında Rize/Ardeşen’de doğdu. İlköğrenimini Ardeşen ilçesinde, orta ve lise eğitimlerini Pazar ilçesinde Okul Birincilikleri ile tamamladı. 1999 yılında Uludağ Üniversitesi Fen-Edebiyat Fakültesi Fizik Bölümü’nde lisans eğitimine başladı. 2003 yılında bu bölümden Bölüm İkincisi olarak mezun oldu. 2004 yılında aynı bölümde Nükleer Fizik Anabilim Dalı/ Medikal Fizik alanında yüksek lisans eğitimine başlayıp, 2007 yılında yüksek lisans eğitimini tamamladı. 2009 yılında İstanbul Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı’nda doktora eğitimi almaya hak kazandı.

2005-2006 yılları arasında Bursa Ali Osman Sönmez Onkoloji Hastanesi Lineer Akseleratör ve Tedavi Planlama Ünitesi’nde radyoterapi fizikçisi olarak görev yaptı. 2006-2007 yıllarında Uludağ Üniversitesi Fen Bilimleri Enstitüsü’nde araştırma görevliliğinde bulundu. Daha sonra 2007-2008 yıllarını kapsayan altı aylık kısa dönemde askerlik vazifesini (337. Dönem) Balıkesir/Edremit’te tamamladı. 2008-2009 yılları arasında Türkiye Atom Enerjisi Kurumu (TAEK), Çekmece Nükleer Araştırma ve Eğitim Merkezi, Metroloji Birimi’nde Uzman Medikal Fizikçi olarak çalıştı. 2009-2012 yılları arasında İstanbul Üniversitesi Döner Sermaye ve İşletme Müdürlüğü Biyomedikal ve Klinik Mühendisliği Birimi’nde Radyoloji Departmanı ve Görüntüleme/Sinyal İşleme Departmanı’nda teknik şartname hazırlama bölümünde Sorumlu Mühendis olarak görev yaptı. 2012 Mart ayı itibari ile İstanbul Üniversitesi Mühendislik Fakültesi Mühendislik Bilimleri Bölümü’nde halen Araştırma Görevlisi olarak görev yapmaktadır. Çalışma konuları tıbbi görüntüleme sistemleri, medikal görüntü işleme ve yapay zeka uygulamaları, dozimetri sistemleri, medikal fizik, radyoterapi fiziği, radyoloji ve görüntüleme cihazlarıdır. Ahmet TARTAR evli ve bir çocuk babasıdır.