

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**AKCİĞER TOMOGRAFİSİ GÖRÜNTÜLERİNDE GÖRÜNTÜ
İŞLEME TEKNİKLERİ KULLANILARAK NODÜL TESPİTİ
VE YAPAY ZEKA İLE NODÜLLERİN NİTELENDİRİLMESİ**

YÜKSEK LİSANS TEZİ

Enes ÇAKAR

Enstitü Anabilim Dalı : BİYOMEDİKAL MÜHENDİSLİĞİ

Tez Danışmanı : Dr. Öğr. Üyesi Ahmet KARACA

Haziran 2018

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKCİĞER TOMOGRAFİSİ GÖRÜNTÜLERİNDE GÖRÜNTÜ
İŞLEME TEKNİKLERİ KULLANILARAK NODÜL TESPİTİ
VE YAPAY ZEKA İLE NODÜLLERİN NİTELENDİRİLMESİ

YÜKSEK LİSANS TEZİ

Enes ÇAKAR

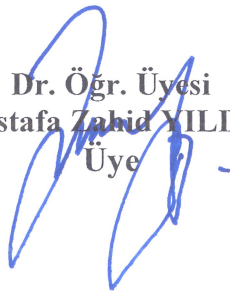
Enstitü Anabilim Dalı : BİYOMEDİKAL MÜHENDİSLİĞİ

Bu tez 04/06/2018 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

Dr. Öğr. Üyesi
Ahmet KARACA
Jüri Başkanı



Dr. Öğr. Üyesi
Mustafa Zahid YILDIZ
Üye



Dr. Öğr. Üyesi
Mehmet KOCATÜRK
Üye



BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Enes ÇAKAR

04.06.2018

TEŐEKKÜR

Yüksek lisans eğitiminin boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Dr. Öğr. Üyesi Ahmet KARACA'ya ve Biyomedikal Mühendisliği Ana Bilim Dalı koordinatörü Dr. Öğr. Üyesi Mustafa Zahid YILDIZ'a teşekkürlerimi sunarım.

Veri seti oluşturmada Sakarya Üniversitesi tıp fakültesi radyoloji bölüm başkan yardımcısı Dr. Öğr. Üyesi Huri Tilla İLÇE'ye ve Sakarya Eğitim ve Araştırma Hastanesi'nde PET-CT bölümü çalışanı Samet YILMAZ'a yardımlarından dolayı teşekkür ederim.

Ayrıca bu çalışmanın maddi ve manevi açıdan desteklerini esirgemeyen aileme, arkadaşlarıma ve bölüm öğretim görevlilerine teşekkür ederim.

İÇİNDEKİLER

BEYAN	i
TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ	ix
ÖZET.....	xi
SUMMARY	xii

BÖLÜM 1.

GİRİŞ	1
1.1. Kanser ve Akciğer Kanseri	4
1.2. Akciğer Kanseri Hastalığı İstatistikleri.....	5
1.3. Akciğerde Bulunan Nodül Tipleri.....	6
1.4. Akciğer Görüntüleme Yöntemleri ve Medikal Görüntü	7
1.5. Bilgisayarlı Tomografi(BT)	7
1.6. PET-CT	8
1.7. Veri Toplama	8
1.8. Bilgisayar Destekli Tam Sistemleri.....	10
1.9. BDT ve Akciğer Kanseri.....	11

BÖLÜM 2.

KAYNAK ARAŞTIRMASI.....	13
2.1. BT'de Akciğer Lob Segmentasyonu	13
2.2. Damar Segmentasyonu	14
2.3. Yapay Zekâ.....	14

2.4. Akciğer Nodül Algılama	15
BÖLÜM 3.	
MATERYAL VE YÖNTEM.....	17
3.1. Görüntü İşleme.....	17
3.1.1. Görüntü alma	17
3.1.2. Ön işlemler.....	18
3.1.3. İkinci dereceden medyan filtresi	19
3.1.4. Laplacian filtresi	19
3.1.5. Eşik belirleme	20
3.1.6. Lob segmentasyonu	21
3.1.7. Aday nodül belirleme	21
3.1.8. Aday nodülleri işaretleme ve numaralandırma.....	23
3.2. Öznitelik Çıkarımı.....	23
3.3. Yapay Zekâ.....	25
3.3.1. Yapay sinir ağı	25
3.3.2. İleri yönlü geri yayımlı.....	26
3.4. ROC Eğrisi.....	28
3.5. Genetik Algoritma.....	30
3.5.1. Değer kodlama.....	31
3.5.2. İlk popülasyon oluşumu	32
3.5.3. Amaç fonksiyonu.....	32
3.5.4. Doğal seçim.....	32
3.5.5. Çaprazlama	35
3.5.6. Mutasyon	37
BÖLÜM 4.	
ARAŞTIRMA BULGULARI	38
4.1. Görüntü İşleme Bulguları	38
4.1.1. Medyan filtresi.....	38
4.1.2. Laplacian filtresi.....	38
4.1.3. Eşik belirleme	39

4.1.4. Lob segmentasyonu	40
4.1.5. Aday nodül bulma	42
4.1.6. Aday nodül işaretleme ve numaralandırma	43
4.2. Özellik Çıkarımı Bulguları	45
4.3. Yapay Sinir Ağı Bulgular	46
4.4. Genetik Algoritma Bulguları.....	47
BÖLÜM 5.	
TARTIŞMA VE SONUÇ	48
KAYNAKLAR.....	56
ÖZGEÇMİŞ	61

SİMGELER VE KISALTMALAR LİSTESİ

A.E. Uzunluğu	: Ana Eksen Uzunluğu
AUC	: Area Under Curve
BDT	: Bilgisayar Destekli Tanı
BT	: Bilgisayarlı Tomografi
CAD	: Computed Aided Diagnosis
CT	: Computered Tomography
CVIP	: Computer Vision and Image Processing
DICOM	: Digital Imaging and Communications in Medicine
DNA	: Deoksiribo Nükleik Asit
FACD	: From Fully Automatic Computer Diagnosis
FN	: False Negative
FOV	: Field of View
FP	: False Positive
GA	: Genetik Algoritma
IARC	: International Agency for Research on Cancer
ICD	: Interactive Computer Diagnosis
IELCAP	: International Early Lung Cancer Action Program
kVe	: Kilovolt elektron
K.E Uzunluğu	: Kenar Eksen Uzunluğu
LICD	: Lung Image Cancer Data
MRG	: Manyetik Rezonans Görüntüleme
NEMA	: National Electrical Manufacturers Association
PET	: Pozitron Emisyon Tomografisi
PET-CT	: Pozitron Emisyon Tomografisi-Bilgisayarlı Tomografi
RGB	: Red-Green-Blue
ROC	: Receiver Operating Characteristic

ROI : Region of Interest
TN : True Negative
TP : True Positive
YSA : Yapay Sinir Ađı

ŞEKİLLER LİSTESİ

Şekil 1.1. Türkiye'de erkeklerde en sık görülen kanserler [2].....	5
Şekil 1.2. Türkiye'de kadınlarda en sık görülen kanserler [2].	6
Şekil 1.3. (a)Düz sınırlı nodül, (b)Damara yakın nodül, (c)Plevral kuyruklu nodül, (d) Plevraya yakın nodül.....	6
Şekil 1.4. BT görüntüsü üzerinde bening nodül görüntüsü.....	9
Şekil 1.5. PET-CT görüntüsü üzerinde benign nodül görüntüsü	9
Şekil 1.6. BT görüntüsü üzerinde malign nodül görüntüsü	10
Şekil 1.7. PET-CT görüntüsü üzerinde malign nodül görüntüsü	10
Şekil 3.1. Sistemin çalışma algoritması	17
Şekil 3.2. Elde edilen örnek görüntü.....	18
Şekil 3.3. Medyan filtresi çalışma prensibi.....	19
Şekil 3.4. Rastgele oluşturulan noktaların indisleri [47].....	22
Şekil 3.5. Oluşturulan noktaların çekme faktörü 1 olduğunda dışbükey olarak çizdirilmesi [47].....	22
Şekil 3.6. Çekme faktörü 0,1 olarak ayarlandığında elde edilen alan [47].	23
Şekil 3.7. Görüntü için uyum sağlama ve yönelim örneği.....	24
Şekil 3.8. Modellenmiş nöron ile biyolojik nöronun benzetimi	26
Şekil 3.9. Tanjant sigmoid fonksiyonu	27
Şekil 3.10. Oluşturulan sinir ağı modeli.....	28
Şekil 3.11. Elde edilen sınıflar	29
Şekil 3.12. Kesme değeri 0,5 iken sonuçların değerlendirilmesi	29
Şekil 3.13. Kesme değeri 0,4 iken sonuçların değerlendirilmesi.....	30
Şekil 3.14. Genetik algoritma blok diyagramı	31
Şekil 3.15. Birinci kromozom elde edilmesi	31
Şekil 3.16. İlk popülasyon.....	32
Şekil 3.17. Kromozom hata sayısı.....	33

Şekil 3.18. Kromozomların 1/ hata sayısı	33
Şekil 3.19. Kromozomların yaşama olasılığı	34
Şekil 3.20. Kromozomların yaşama olasılığı aralıkları.....	34
Şekil 3.21. Ara popülasyon	35
Şekil 3.22. Kromozomların çaprazlamada eşleştirilmesi.....	36
Şekil 3.23. Çaprazlanma oranı ve eşleşme.....	36
Şekil 3.24. Tek noktalı çaprazlamanın uygulanması	37
Şekil 4.1. Medyan filtresi uygulanmış görüntü.....	38
Şekil 4.2. Laplacian filtresi uygulanmış görüntü	39
Şekil 4.3. Laplacian filtresinin görüntüye etkisi	39
Şekil 4.4. Otsu eşik belirleme metodu uygulanmış görüntü	40
Şekil 4.5. (a) Filtrelenmiş görüntüye eşikleme işlemi (b) lob piksel değerinin altındaki piksel değerli birimlerin elenmesi (c) lobların ayırt edilmesi için görüntüyü binary olarak tersleme (d) kalan birimler taranması (e) lobların işaretlenmesi ve sınırlarının taranması	41
Şekil 4.6. Orjinal görüntüde lobların işaretlenmesi ve numaralandırılması.....	41
Şekil 4.7. Çekme faktörü uygulanmış binary görüntü	42
Şekil 4.8. Çekme faktörü ile elde edilen yeni sınırların orijinal görüntü üzerinde çizdirilmesi.....	43
Şekil 4.9. Kesilen lobların görüntü işleme uygulanmış görüntüde görünümü.....	43
Şekil 4.10. Lob içerisinde bulunan birimlerin binary görünümü	44
Şekil 4.11. Aday nodülleri ayrılmış binary görüntü.....	44
Şekil 4.12. Belirlenen aday nodüllerin orijinal görüntü üzerinde işaretlenmesi ve numaralandırılması.....	45
Şekil 4.13. Yapay sinir ağı topolojisi	46
Şekil 5.1. PET görüntüsü.....	49
Şekil 5.2. BT Görüntüsü üzerinde görüntü işleme işlemleri ile elde edilen aday nodül	49
Şekil 5.3. YSA sınıfların roc eğrileri (class 1=malign, class 2=benign, class 3=bronşlar ve damarlar, class 4=yanlışlar).....	51
Şekil 5.4. GA Sınıfların ROC eğrileri (class 1=Malign, class 2=Benign, class 3=Bronşlar ve Damarlar, class 4=Yanlışlar)	54

TABLolar LİSTESİ

Tablo 1.1. Akciğer nodül tipleri.....	6
Tablo 1.2. Oluşturulan veri setinin içeriği	10
Tablo 4.1. Ön işlemlerden geçirilmemiş görüntüden elde edilen özellik değerleri	45
Tablo 4.2. Ön işlemlerden geçirilmiş görüntüden elde edilen özellik değerleri ...	46
Tablo 4.3. Gerçek sonuçlar ile yapay zekâ sonucu karşılaştırması.....	47
Tablo 4.4. Gerçek sonuçlar ile genetik algoritma uygulanmış sonuçların karşılaştırması	47
Tablo 5.1. Malign değerler için gerçek sonuçlar ve yapay zekâ sonucu karşılaştırılması.....	50
Tablo 5.2. Benign değerler için gerçek sonuçlar ve yapay zekâ sonucu karşılaştırılması.....	50
Tablo 5.3. Bronşlar ve Damarlar için gerçek sonuçlar ve yapay zeka sonucu karşılaştırılması.....	50
Tablo 5.4. Yanlış değerler için gerçek sonuçlar ve yapay zekâ sonucu karşılaştırılması.....	51
Tablo 5.5. YSA ROC eğrisi altında kalan toplam alanlar ve seçilen optimum kesim noktaları.....	52
Tablo 5.6. Malign değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması.....	52
Tablo 5.7. Benign değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması.....	53
Tablo 5.8. Bronşlar ve damar değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması	53
Tablo 5.9. Yanlış bulunan değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması	53

Tablo 5.10. GA ROC eğrisi altında kalan toplam alanlar ve seçilen optimum kesim noktaları.....	54
--	----

ÖZET

Anahtar kelimeler: Akciğer kanseri, BDT (Bilgisayar Destekli Tespit), görüntü işleme, çekme faktörü yöntemi, yapay sinir ağı, genetik algoritmalar, akciğer aday nodül sınıflandırma

Akciğer kanseri, günümüzde gelişmiş ülkelerde en yüksek ölüm oranına sahip olan kanser türüdür. Erken tanı ve teşhisinde mortalite oranı önemli derecede azalmaktadır. Akciğer kanseri tanısındaki en büyük problem görüntülemedeki verilerin fazlalığı ve bu tür aday nodüllerin değerlendirilmesinin zorluğudur. Bilgisayar destekli tanı sistemi ise sistemi otonom hale getirerek hızlandırması ve uzman radyologlara yardımcı olması için geliştirilen uzman sistemdir.

Bu tez çalışmasında, akciğer bilgisayarlı tomografi kesit görüntüleri üzerinden akciğerde bulunan birimlere sınıflandırma işlemi gerçekleştirilmiştir. Sistem; görüntü işleme ve yapay zekâ olmak üzere iki ana başlık altında oluşturulmuştur.

Görüntü işleme bölümünde ön işlemler ve aday nodüllerin tespit edilmesi gerçekleştirilmiştir. Juxtapleural nodüller çekme faktörü kullanılarak tespit edilmiştir. Elde edilen aday nodüllerin morfolojik özellikleri çıkarılarak yapay sinir ağı eğitilmiştir. Yapay sinir ağında elde edilen katsayılar genetik algoritma ile iyileştirilerek sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma; Malign, benign, bronşlar ve damarlar, yanlıklar olarak 4 sınıfa ayrılmıştır.

Bu tez çalışmasında kullanılan veri seti, “Sakarya Eğitim ve Araştırma Hastane” ‘sinde PET-CT bölümünden temin edilmiştir. Veri setinde 36 hasta için 153 görüntüden 304 aday nodül bölgesi elde edilmiştir. Yapılan deneysel çalışma sonucunda elde edilen en iyi sınıflandırma, yapay sinir ağında %92,105 doğruluk oranı elde edilmiştir. Sınıflar için kullanılan özellikler için ve AUC (Area Under Curve) değeri 0,9847 elde edilmiştir. Genetik algoritma ile iyileştirme yapıldığında %94,407 doğruluk oranı elde edilmiştir. Sınıflar için kullanılan özellikler için AUC değeri 0,9735 değeri elde edilmiştir. Sınıfların ROC (Receiver Operating Characteristic) eğrileri kullanılarak her sınıf için optimum kesim noktaları elde edilmiştir.

Elde edilen sonuçlar akciğer nodülleri için radyografik sınıflandırma başarımına olumlu katkı sağlamıştır. Oluşturulan sistem literatürdeki yapılan çalışmalar ile karşılaştırılabilecek düzeyde başarı sağlamıştır.

NODULA DETERMINATION BY USING IMAGE PROCESSING TECHNIQUES AND CHARACTERIZATION OF NODE WITH ARTIFICIAL INTELLIGENCE IN LUNG TOMOGRAPHY IMAGES

SUMMARY

Keywords: Lung cancer, CAD (Computer Aided Diagnosis), image processing, shrink factor method, artificial neural network, genetic algorithms, lung candidate nodule classification

Today, lung cancer is the type of cancer that has the highest mortality rate in developed countries. In early diagnosis, the mortality rate decreases significantly. The biggest problem with lung cancer is the excess of imaging data and the difficulty of evaluating such candidate nodules. The computer-aided diagnosis system is an expert system developed to autonomously accelerate the system and to assist specialist radiologists.

In this thesis study, the classification of lung units was performed on lung computerized tomography cross-sectional images. The system is composed of two main topics as image processing and artificial intelligence.

In the image processing section, pre-processing and candidate nodules were detected. Juxta Pleural nodules were obtained using the shrink factor detect nodules. Obtained by subtracting the morphological characteristics of the nodule candidates are trained to artificial neural network. The coefficients obtained in the artificial neural network were classified by improving with genetic algorithm. Classification is divided into 4 classes as malign, benign, bronchi and veins, false positives.

In this thesis study data set was obtained from PET-CT department in "Sakarya Eğitim ve Araştırma Hastanesi". In the data set, 304 candidate nodule regions were obtained from 153 images for 36 patients. In the experimental study performed, the best classification was achieved with an accuracy of 92,105% in the artificial neural network. For the features used for the classes, the Area Under Curve (AUC) value of 0.9847 was obtained. Improvements by the genetic algorithm were obtained 94.407% accuracy rate. For the features used for the classes, the Area Under Curve (AUC) value of 0,9735 was obtained. Using the ROC (Receiver Operating Characteristic) curves of the classes, optimum cut points for each class were obtained.

The results obtained provided a positive contribution to the success of the radiographic classification for the lung nodules.

BÖLÜM 1. GİRİŞ

Kanser dünya genelinde gittikçe artmakta olan bir sağlık problemidir [1-3]. Toplumlarda sosyoekonomik yüklere, bireylerde ise maddi, manevi kayıplara ve zorluklara yol açmaktadır. Dünyada ölüm nedenlerinde kanser birinci sırada bulunmaktadır. Son yayımlanan global kanser istatistiklerine göre; 14,1 milyon yeni kanser vakası gelişmiş, 8,2 milyon kanserden kaynaklı ölüm olmuştur [1]. Eğer kanserdeki benzer seyir devam etmesi durumunda 2030 yılında 22 milyon yeni vaka beklenmektedir. Ülkemizde son yayımlanan resmi rakamlar değerlendirildiğinde bir yıl içerisinde 96,200 erkek ve 67,200 kadının kanser teşhisi konulduğu tahmin edilmektedir [2].

Akciğer kanseri mortalite oranı en yüksek olan kanserdir [3]. Erkek bireylerde ülkemizde ve dünyada en sık görülen türdür. Kadın bireylerde ise ülkemizde 5. Sırada dünya genelinde 4. sıradadır [1]. Tütün ile akciğer kanseri ilişkilendirildiğinde tütünün zararı halen göz ile görülür derecede yüksektir [3].

Akciğer kanseri teşhisi ve nodüllerin görüntülenmesinde yaygın olarak BT (Bilgisayarlı Tomografi), PET-CT (Pozitron Emisyon Tomografisi-Bilgisayarlı Tomografi), X ışınları ve göğüs tomografisi gibi tıbbi görüntüleme tekniklerinden faydalanılmaktadır [4,5]. Nodüllerin biçim ve boyut, konum ve doku yoğunluğunun değişiklik gösterebilmesi nodüllerin tespit edilmesi işlemini fazlasıyla zorlaştırmaktadır [6].

Bilgisayarlı tomografi görüntüleri kullanılarak nodül bilgilerinin bilgisayar destekli tespit edilmesi ve nitelendirilmesi, akciğer kanserinde tanı ve tedavi sürecini hızlandırma ve tomografi görüntülerini uzman radyologların yorumlamasına yardımcı olacaktır [7,8]. Radyologların belirli nodüllerin nitelendirilmesinde görüş

farklılıkları ve hata oranının azalmasında bilgisayar destekli tanı sistemi büyük önem taşımaktadır.

Tez kapsamında kullanılan veri seti “Sakarya Eğitim ve Araştırma Hastane” ‘si PET-CT bölümünden alınan 36 hastanın verileri kullanılarak oluşturulmuştur. Kullanılan veri seti rastgele hastalardan seçilmiştir. Ayrıca veri setinin özgün olması çalışmayı kendi alanında özgünleştirmiştir.

Tez bünyesinde oluşturulan sistemin genel amacı, görüntü işleme ve yapay zekâ yöntemleri kullanılarak bilgisayar tomografileri üzerinden akciğer nodül bölgelerini otomatik sınıflandırma işlemi yapmaktır. Oluşturulan sistem iki ana başlık altında ayrılmıştır. İlk bölüm görüntü işleme işlemlerinin bulunduğu bölümdür. Bu bölümde aday nodül bölgeleri çıkarılmaktadır. Bu işlem yapılabilmesi için ölçeklenmiş görüntülerde, ön işlemler, filtrelemeler, eşik belirleme ve lob segmentasyonu işlemleri yapılmıştır. Plevraya yakın nodül ve plevral kuyruklu nodül birimleri plevraya bağlı olduğu için çekme faktörü yöntemi kullanılarak aday nodül bölgeleri belirlenmiştir. İkinci bölümde elde edilen aday nodüllerin ayırt edici morfolojik özellikleri çıkarılmıştır. Çıkarılan özellikler yapay sinir ağı ve genetik algorithmadan oluşturulan hibrit sisteme verilerek sınıflandırma işlemi gerçekleştirilmiştir.

Tez çalışmasında literatüre yapılan katkıların ilki çekme faktörü yöntemi geliştirilerek plevraya yapışık bulunan birimler ayrılmıştır. Literatüre yapılan ikinci ve en önemli katkı ise yapay sinir ağı ve genetik algoritma kullanılarak oluşturulan hibrit yapay zekâ modeli ile sınıflandırma yapılmasıdır. Elde edilen hibrit yapay zekâ modeli ile sınıflandırma %94,407 başarı sağlayarak literatürdeki çalışmalar ile karşılaştırılacak seviyededir.

Tez metni, oluşturulan bölümler aşağıda verildiği gibi özetlenebilir;

Devam eden giriş bölümünde, kanser ve akciğer kanseri ile ilgili genel bilgiler ve istatistik verileri verilmiştir. Akciğerde bulunan nodül tipleri, tıbbi görüntüleme ve akciğer görüntüleme birimleri açıklanmakta, veri setleri ve oluşturulan veri seti

hakkında bilgiler ve bilgisayar destekli tanı sistemi ve bu sistemin akciğer kanseri ile ilişkisi açıklanmaktadır.

Tezin ikinci bölümünde, bilgisayar tomografilerinde akciğer lob segmentasyonu ile ilgili önceki çalışmalar, bulunan damarların segmentasyonu ile ilgili önceki çalışmalar, yapay zekâ literatürü ve akciğerde nodül algılama ile ilgili yapılan önceki çalışmalardan bahsedilmiştir.

Tezin üçüncü bölümünde, tez kapsamında geliştirilen sistemden bahsedilmektedir. Sistem görüntü işleme ve yapay zekâ olarak ana iki bölüme ayrılmıştır. Görüntü işleme bölümünde; görüntü alma, ön işlemler, eşik belirleme, lob segmentasyonu, aday nodül belirleme, aday nodülleri işaretleme ve numaralandırmadan oluşan alt bölüm başlıkları ile ayrıntılı olarak bahsedilmektedir. Yapay zekâ bölümünde; özellik çıkarımı ve özellikler, oluşturulan yapay sinir ağı ve oluşturulan genetik algoritmadan bahsedilmektedir.

Tezin dördüncü bölümünde, araştırma ve bulgular gösterilmektedir. Görüntü işleme ve yapay zekâ ana başlıkları altında, alt başlıklara ayrılarak bulgular sırasıyla verilmiştir. Genel elde edilen sonuç dışındaki bulgular burada analiz edilmiş ve karşılaştırmaları yapılmıştır.

Tezin beşinci bölümünde; sözlü ve görsel sonuç olarak örnek görüntü işleme sonucu gösterilmiştir. Yapay sinir ağı ve genetik algoritma sınıflandırması ve bu sınıflandırmaların duyarlılık, özgünlük, ROC eğrileri, eğri altında kalan alanlar ve eğri altında kalan genel alan ve optimum kesim noktası bulunarak en yüksek duyarlılık ve özgünlük değerleri verilmektedir. Yapay sinir ağı ve genetik algoritma sonuçlarının karşılaştırılmasından bahsedilmiştir. Ayrıca sistemin geliştirilebilirliği ve konu üzerindeki tartışmalardan bahsedilmektedir. Kaynaklar, ekler ve özgeçmiş bu bölümün devamında verilmektedir.

1.1. Kanser ve Akciğer Kanseri

Kanser, bir dokuda veya organda düzensiz bir biçimde bölünerek çoğalmasıyla kendini belli eden kötü huylu nodüllere denir. Yüzden fazla hastalık grubunu oluşturan kanser, normal olmayan hücrelerin düzensiz ve kontrol dışında çoğalması ile başlamaktadır [9].

Vücudumuzda bulunan kas ve sinir hücreleri haricindeki diğer bütün hücreler, yeterli şartları sağladığında bölünme ihtiyacı duyar ve bölünür. Vücudumuzda bölünebilen sağlıklı hücreler büyür, belirli sayıda bölünür ve ölür. Bu süreç bozulduğunda yeni hücre gereksinimi olmadan hücreler bölünmeye başlar ve kitleler oluşturur [9].

Vücudumuzda bulunan her hücre DNA'ya sahiptir. Bu DNA bozunuma uğradığında hücre ölmekte veya DNA onarılmaktadır. Eğer onarım gerçekleşmezse ve hücre ölmezse, kanser hücresi oluşur. Bu hücreler birikerek tümörü oluşturur. Bu kitleler iyi huylu veya kötü huylu olabilir. İyi huylu tümörler genellikle hayati tehlike oluşturmaz. Kötü huylu tümör kanserdir [9].

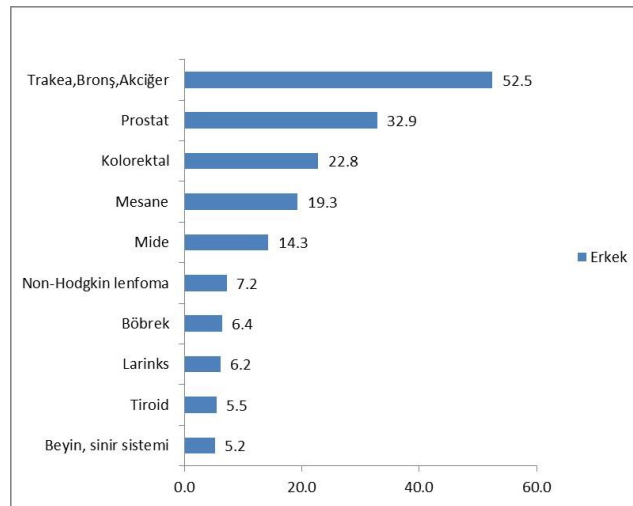
Kanserli hücreler çeşitli vasıtalar ile taşınmasına ve taşındığı yerde oluşumuna devam etmesine metastaz denir. Taşıma yolu olarak genellikle kan dolaşım sistemi ve lenf damarları kullanılmaktadır [9].

Akciğer kanseri, akciğerde bulunan hücrelerin normal olmayan hale gelmesi, kontrolsüz ve düzensiz olarak çoğalmasıyla meydana gelen bir hastalıktır. Bu hastalığın en büyük sebebi tütün ve tütün ürünlerinin kullanılmasıdır [10].

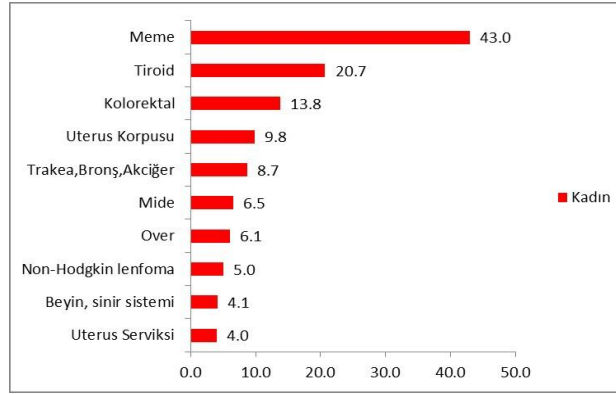
Tespit edilmek istenen kanser tipi akciğer kanseri olduğu için, akciğerin anatomik yapısını ve akciğer kanser türlerini öğrenilmesi gerekmektedir.

1.2. Akciğer Kanseri Hastalığı İstatistikleri

Kanser günümüzde, en fazla ölüm oranına sahip hastalık grubudur. Uluslararası Kanser Ajansı (IARC) tarafından yayınlanan “Globocan 2012” verilerine göre erkeklerde en sık görülen kanser akciğer kanseri, kadınlarda en sık görülen kanser meme kanseridir. Kadınlarda akciğer kanseri Türkiye’de 5. sırada, dünya genelinde ise 4. sıradadır. Ülkemizde en fazla ölüm oranı akciğer kanserinden dolayı gerçekleşmektedir. Türkiye’de Türkiye Halk Sağlığı Kurumu’nun 2017 Şubat ayında yayınladığı son verilere göre ortalama yılda 163,500 kişiye kanser teşhisi konulmaktadır. Erkeklerde %21,1, kadınlarda ise %5 akciğer kanserinin görülme oranıdır. Tütün ile ilişkilendirilen kanser teşhis sayısı erkeklerde yılda 27,700 kişidir. Tütün ile ilişkilendirilen kanserlerin Türkiye’deki etkisi çok fazla ve önemlidir. Şekil 1.1.’de Türkiye’de erkeklerde en sık görülen kanser tipleri gösterilmiştir. Akciğer kanseri birinci sıradadır. Şekil 1.2.’de ise Türkiye’de kadınlarda en sık görülen kanser tipleri bulunmaktadır. Akciğer kanseri beşinci sıradadır.



Şekil 1.1. Türkiye’de erkeklerde en sık görülen kanserler [2].




Şekil 1.2. Türkiye'de kadınlarda en sık görülen kanserler [2].

1.3. Akciğerde Bulunan Nodül Tipleri

Nodülleri doğru bir şekilde tespit edebilmek için hem nodül şekli hem de görünüm için nodül tipleri hakkında bilgi edinilmelidir. Nodül tipleri 4 ana kategoride toplanmıştır [11,12]. Dört kategoriye ayrılan nodül tiplerinin tanımları Tablo 1.1.'de yapılmıştır.

Tablo 1.1. Akciğer nodül tipleri

Nodül Tipi	Tanımı
Düz Sınırlı Nodül	Akciğerin merkezinde bulunan ve damarsal yapılarla bağlantılı olmayan nodül tipidir.
Damara Yakın Nodül	Akciğerin merkezinde bulunan ve damarsal yapılarla bağlantılı olmayan nodül tipidir.
Plevraya Yakın Nodül	Büyük bir kısmı plevra yüzeyine bağlı bulunan nodül tipidir.
Plevral Kuyruklu Nodül	Plevra yüzeyine ince bir yapı ile bağlı bulunan nodül tipidir.



Şekil 1.3. (a)Düz sınırlı nodül, (b)Damara yakın nodül, (c)Plevral kuyruklu nodül, (d) Plevraya yakın nodül

Şekil 1.3.'te gösterilen, bu sınıflandırma yöntemi, ağırlıklı olarak kanserli nodül tiplerini şekillendirir. Eğer her nodül tipinde fantomlar gelişirse, ayırma Şekil 3'te görüldüğü gibi göreceli olarak düz olacaktır. Nodülün kendisinin vasküler veya plevral duvar gibi çevreleyen anatomilerden farklı olduğu, ancak bu sınıflandırma şeması daha sonraki bölümlerde gösterildiği gibi şablon eşleştirme yaklaşımına önemli miktarda sağlamlık katar. Her nodül tipinin şekil varyasyonlarının incelenmesiyle, her bir nodül tipi için ayrı bir şekil imzası ortaya çıkabilir.

1.4. Akciğer Görüntüleme Yöntemleri ve Medikal Görüntü

Akciğer kanseri tespiti ve teşhisi için geçmişten bu yana kullanılan ya da günümüze kullanılmaya başlanılan medikal görüntüleme sistemleri bulunmaktadır. Bunların bir kısmı; X-Ray cihazı, BT (Bilgisayarlı Tomografi), MRG (Manyetik Rezonans Görüntüleme), PET (Pozitron Emisyon Tomografisi), PET-CT ve bronkoskopi'dir [13].

Medikal görüntüleme cihazları ile yapılan görüntülerin, saklanması, yeniden elde edilmesi, metinsel bilgilerin görüntü ile ilgili bilgilerin beraberinde bulundurulabilmesi ve tıbbi sistemlerin birbirlerine kolaylıkla bağlanabilip haberleşebilmesi için DICOM (Digital Imaging and Communications in Medicine) dijital görüntüleme ve iletişim formatı oluşturulmuştur. Ulusal Elektrik Üreticileri Derneği (NEMA, National Electrical Manufacturers Association) tarafından DICOM standardı desteklenmektedir [14]. DICOM dosyaları iki bölümden oluşmaktadır. İlk kısım metinsel bilgilerin kayıt edildiği bölümdür. Bu bölümde; hastanın adı, yaşı, cinsiyeti, doğum tarihi, doktorun adı, görüntüleme yöntemi gibi bilgiler bulunmaktadır. İkinci kısımda ise görüntü bulunmaktadır [15].

1.5. Bilgisayarlı Tomografi(BT)

Akciğer kanseri teşhisi için en önemli gelişmelerden biri de bilgisayarlı tomografi (BT) tarayıcısıdır. BT tarayıcıları, radyologların vücut yapıları etrafında bir X-ışını kaynağı ve detektör kullanılarak üç boyutlu olarak iç vücut yapılarını görmelerini

sağlar [16]. Radyologlar, akciğer kanserini teşhis etmek amacıyla, akciğer içindeki yapıları görmek için göğüs X-Ray veya bilgisayarlı tomografi (BT) kullanarak hastayı görüntülemektedir. İki ana çalışmada akciğer kanseri için BT taramasının etkinliğinin daha fazla olduğu gözlemlenmiştir. IELCAP (International Early Lung Cancer Action Program) tarafından desteklenen yaklaşık 53,500 katılımcı ile yapılan bir çalışmada, BT'nin akciğer grafisi ile olan etkisi X-Ray ile karşılaştırıldı. BT kullanılarak taranan katılımcılar X-Ray ile taranan katılımcılarla karşılaştırıldığında ölümlerde%20,3'lük bir azalma bulunmuştur (BT taraması için 354 ölüm, X-Ray taraması için 442 ölüm) [17].

1.6. PET-CT


Nükleer tıp görüntüleme yöntemlerinden olan PET-CT taraması nodül tespitinde kullanılan en gelişmiş yöntemdir. Radyoaktif bozunumlardan biri olan pozitron emisyonu, hücrenin çekirdeğinde bulunan proton, nötron ve pozitif yüklü elektrona (pozitron) dönüşmektedir. Çekirdek içerisinden salınan pozitron bir elektrona çarpar ve annihilasyon olayını gerçekleştirir. Annihilasyon sonucunda pozitron ve elektron kütlesi enerjiye dönüşür. Oluşan enerji 180 derece zıt yönde hareket eder ve enerjileri 511 kVe (kilovolt elektron)'dur. PET cihazındaki detektörler aracılığıyla aynı anda aynı eksende oluşmuş iki foton algılanarak bilgisayar ortamına aktarılır ve görüntü oluşturulur [18].

PET-CT cihazı bilgisayar tomografisi ve pozitron emisyon tomografisini birlikte gerçekleştirmektedir. Vücuda verilen radyoaktif madde ile kanserli bölge tespit edilmektedir. BT vücudun anatomik görüntüsünü oluştururken PET vücudun morfolojik görüntüsünü oluşturmaktadır.


1.7. Veri Toplama

Tahmin edilebileceği üzere, oluşturulacak tanı sistemleri tamamen veri edinimine bağlıdır. Bu yaklaşımla sağlam ve doğru nodül modelleri oluşturmak için “daha fazla veri, daha güçlü model” felsefesi benimsenmiştir [19]. Önerilen sistemin özgünlüğü

ve veri miktarını yüksek tutmak amaçlı olarak Sakarya Eğitim ve Araştırma Hastanesi PET-CT bölümünün yardımıyla veri seti oluşturulmuştur. Oluşturulacak veri setinde nodül şekli ve dokusu varyasyonun fazla olması sistemin güvenilirliğini ve doğruluk oranını artıracaktır. Bu alandaki önceki çalışmalar kamuya açık akciğer nodül veri tabanlarına bağımlı olmuştur. CVIP (Computer Vision and Image Processing) laboratuvarlarında toplanan en önemli veri setleri I-ELCAP (International Early Lung Cancer Action Program) ve LIDC (Lung Image Cancer Data [20])'dir. Ayrıca CVIP iş birliği ile Louisville, Kentucky (Jewish) and Mansoura veri setlerinden oluşturulmuştur [19]. Literatürde en çok rastlanılan veri seti LICD'dir. Sistemin özgünlüğü ve radyolog desteğinde kolaylık sağlanması amacıyla Sakarya Eğitim ve Araştırma Hastane 'sinden temin edilen veriler ile oluşturulan veri seti kullanılmıştır. Şekil 1.4.'te elde edilen veri setinden BT görüntüsü üzerinide kanserli olamayan örnek görüntü verilmiştir. Şekil 1.5.'te ise Şekil 1.4.'teki görüntünün PET-CT olarak gösterimi mevcuttur.




Şekil 1.4. BT görüntüsü üzerinde benign nodül görüntüsü




Şekil 1.5. PET-CT görüntüsü üzerinde benign nodül görüntüsü

Şekil 1.6.'da elde edilen veri setin kullanılarak BT görüntüsü üzerinide kanserli olan örnek görüntü verilmiştir. Şekil 1.7.'de ise Şekil 1.6.'daki görüntünün PET-CT olarak gösterimi mevcuttur. Görüldüğü gibi PET-CT verilerinde kanserli bölge ışımaktadır.



Şekil 1.6. BT görüntüsü üzerinde malign nodül görüntüsü



Şekil 1.7. PET-CT görüntüsü üzerinde malign nodül görüntüsü

Bu veri setinde bulunan verilerin türü Tablo 1.2.'de gösterilmiştir. Veri setinde kullanılan her örnek biyopsi ya da radyologlar tarafından kesin sonuçları elde edilmiştir. Ayrıca verilerin PET görüntülerinin bulunması, sistemin görüntü işleme ile elde ettiği veriler karşılaştırma imkânı sunmuştur.

Tablo 1.2. Oluşturulan veri setinin içeriği

	Malign	Benign	Toplam
Hasta Sayısı	24	12	36
Kullanılan Görüntü Sayısı	68	85	153

1.8. Bilgisayar Destekli Tanı Sistemleri

Tıbbi görüntülerin çoğu yorumu bir uzman tarafından gerçekleştirilir; bununla birlikte, insanlar tarafından yapılan görüntüsel yorumlama, insanın sistematik olmayan arama modelleri, okuyucu yorgunluğu, dikkat dağınıklığı ve arama sonuçlarının memnuniyeti nedeniyle sınırlıdır. Radyografik görüntülerin bilgisayar analizi, 1960'ların başlarında insani ilgiyi çekti ve göğüs radyografilerindeki anormalliklerin bilgisayarlı olarak saptanması 1970'lerde ortaya çıkmaya başladı.

Ancak bu çalışmalar, bilgisayarların tam tanımlar üretme yetenekleri konusunda kayda değer gelişmeler gösterdi. Bunlar “göğüs muayenesini tamamen otomatik hale getirme” yönündeki önerilerin gelişimini hızlandırdı. Halihazırda genel görüş, bilgisayar destekli bir bilginin karar vermede hekimler için faydalı olduğu bir bilgisayar sistemi hazırlanması ve bu konu üzerine yoğunlaşılması gerektiğine inanılmaktadır. Tam otomatik bilgisayar bilimi tanısı (FACD-From Fully Automatic Computer Diagnosis), interaktif bilgisayar tanısı (ICD-Interactive Computer Diagnosis), bilgisayar destekli tanı (CAD-Computer Aided Diagnosis), günümüzde sadece CAD kullanımı yaygındır [21]. Bilgisayar destekli tanı (CAD), radyoloji uzmanı tarafından, medikal görüntülerin bilgisayarlı analizinden elde edilen sonuçları, lezyonları tespit etmek ve tanı koyma kararları vermek için “ikinci görüş” olarak kullanılması şeklinde tanımlanmaktadır. BDT (Bilgisayar Destekli Tanı)’nin tıbbi görüntülemenin yorumlama performansını geliştirmesi beklenmektedir; BDT ile son tanı radyologlar tarafından yapılır [22].

1.9. BDT ve Akciğer Kanseri

Günümüzde ve önümüzdeki birkaç yıl içerisinde muayene türü olarak geleneksel göğüs taramaları, BT ve MRG cihazı taramalarıyla yer değiştirecektir. Göğüs radyografisini yorumlamak son derece zor bir işlemdir. Radyoloğun gerçekleştirmesi gereken en önemli ve zor görevlerden birisi, göğüs radyografilerinden kanserli akciğer nodüllerin saptanması ve tanılanmasıdır. Bu lezyonlar diğer anatomik yapılar tarafından kamufle edilebilmeleri nedeniyle saptanamayabilir. Ayrıca, radyologlar anormal bulgulara karar verdiklerinde, gözlemciler arasında farklılıklar ortaya çıkmaktadır. BDT sistemlerinin klinik anlamdaki önemi göğüs radyografik görüntülerini okumaya tespit ve tanıya yardımcı olmaktır.

Sayısallaştırılmış akciğer grafipleri ve BT görüntülerinde birçok nodül tespit sistemi geliştirilse de genellikle duyarlılık düşüktür ve çok fazla yanlış pozitif (FP) yapılıdır. Bu nedenle, akciğer kanserinin teşhisi için çözülmesi gereken problem, yüksek derecede gerçek-pozitif (TP) tanıyı korurken, FP'lerin sayısının azaltılması ile ilişkilidir. Kritik görev, nodüller ve nodül olmayanlar arasında ayırım yapacak

özelliklerin türünü, iyi bir özellik alanı tanımlamak ve belirtmektir. Otomatik nodül tespiti için halihazırda mevcut olan bazı değişkenler ayrı ayrı detaylı olarak tarif edilmektedir.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. BT’de Akciğer Lob Segmentasyonu

Akciğerleri analiz eden herhangi bir BDT (Bilgisayar Destekli Tanı) sistemi otomatik olarak akciğer segmentasyonuna ihtiyaç duymaktadır. Armato ve Sensakovic, akciğerin doğru segmentasyonu için bir BDT şemasında bir ön işlem adımı olduğunu belirtmişlerdir [23]. Bir akciğer nodül saptama sisteminde, test verilerindeki akciğer nodüllerinin %5 ila %17'sinin ön işleme segmentasyonu nedeniyle tespit edilemediğini gösterdi. Bu, segmentasyon algoritmasının nodül saptama prosedürüne uyum sağlayıp sağlayamadığına bağlıydı.

Akciğerin ana kısmı hava ile doluyken, BT (Bilgisayar Tomografisi)'de kontrasta bağlı olarak karanlık bir bölge olarak belirir. Akciğer ve çevre dokular arasındaki bu kontrast, segmentasyon yöntemlerinin çoğunun temelini oluşturmaktadır. Yöntemlerin çoğu, bölgeye dayalı [24-27] veya kontura dayalıdır [28,29].

Ana akciğer hacmi, bölgeye dayalı yaklaşımda iki şekilde bulunur. Birinci yol, yoğunluk değerlerini temel alan eşikleme ve ardından bağlı bileşen etiketlemesidir. Segmentasyon için bahsedilen yöntem uygulandıktan sonra, akciğerler boyut ve konumu üzerindeki kurallara dayanarak uygulanır ve tanımlanır.

İkinci yol büyüyen bölge yöntemidir. Bölge, ayrılmamış tüm komşu pikselleri bölgeye göre karşılaştırarak yinelemeli olarak büyür. Bir pikselin yoğunluk değeri ile bölgenin ortalaması arasındaki fark, benzerliğin bir ölçüsü olarak kullanılır. Bu şekilde ölçülen en küçük farkı olan piksel bölgeye ait kabul edilir. Bu yaklaşım, deliksiz pürüzsüz akciğer hacimlerini elde etmek için matematiksel morfoloji tekniğini kullanır. Zhou ve diğ., büyük akciğer lezyonları tarafından bozulmuş ve

tıkanmış akciğer bölgelerini segmentlere ayırmak için güçlü bir aktif şekil modeli önermişlerdir [29]. Bu büyük akciğer lezyonları, BT görüntülerinde kanserler ve çevredeki yapılar arasındaki yoğunluk farklılığının az olmasından dolayı segmentasyon işlemini zorlaştırmıştır. Li ve Reinhardt, tek bir akciğerin yaklaşık bir segmentasyonunu sağlayan ve eğitim verilerinin istatistiklerinde bulunmayan detayları ve şekil varyansını yakalamak için çoklu 2B düzenlemelerle birleştirilen bir 3B aktif şekil modeli önermişlerdir [28].

Diğer bir zorluk, akciğer sınırına bağlı yüksek yoğunluklu patolojilerin etkilediği akciğerlerdir. Akciğer ve çevre dokular arasında kontrast eksikliği nedeniyle, eşik alma yöntemleri, akciğerde bulunan bu patolojik bölgeleri segmente edemez. Zhou ve diğ. büyük akciğer lezyonları tarafından bozulmuş ve tıkanmış akciğer bölgelerini segmentlere ayırmak için güçlü bir aktif şekil modeli önermiştir [29].

2.2. Damar Segmentasyonu

Her bir akciğer, pulmoner arterlere ve bu damar uzantılarına sahiptir. Pulmoner arterler ve damarlar akciğerlere girdiğinde, çapı 30 mm'ye kadar çıkabilir. Bölünürken, damar çapları azalır. Damar uzantılarının segmentasyonu, BDT sistemi için yanlış pozitiflerin giderilmesinde önemlidir. Pulmoner damar segmentasyonu ile ilgili direkt çalışmaların sayısı sınırlıdır. Genel damar segmentasyonu olarak kullanılan yöntemler, pulmoner damar segmentasyonu için kullanılabilir [30]. Damar segmentasyonu yöntemi için görüntü işleme yöntemleri, model tabanlı yaklaşımlar ve sinir ağı oluşturma tabanlı yaklaşımlar gibi farklı kategorilere ayrılabilir. Genellikle hibrit sistemler tercih edilmektedir.

2.3. Yapay Zekâ

Yaygın olarak kullanılan bir sinir ağı öğrenme algoritmasına geri yayılma algoritması denir. Nöral ağlar birçok uygulamada kullanılmıştır [32-37]. Tıbbi görüntüleme, sinir ağları temel olarak sınıflandırma yöntemi olarak kullanılmaktadır. Nöral ağ sistemi bir dizi medikal görüntü ile eğitilir ve hedef görüntü eğitilmiş sistem

kullanılarak bölümlere ayrılır. Tıbbi görüntü segmentasyonunda sinir ağlarını cazip kılan avantajlardan biri de ağ eğitiminde elde edilen doğrusal olmayan sınıflandırma sınırlarını kullanma yetenekleridir.

2.4. Akciğer Nodül Algılama

Akciğer nodülü algılama sistemi, bazı yaygın adımlardan oluşur; görüntü ön işleme, nodül aday tespiti, yanlış pozitif indirgeme, nodül sınıflaması. Görüntü ön işlem adımı, arama alanını akciğer alanına sınırlamak ve damarları, hava yollarını, görüntü üzerindeki gürültüleri azaltmak için kullanılır. Nodül adayları oluşturmak için geliştirilmiş birçok yöntem vardır, ancak bu yöntemler arasında her zaman çok sayıda yanlış pozitif vardır. Sınıflandırma aşamasından sonra bile, birçok yanlış pozitif bulunmakta ve nodül tespiti üzerine yapılan güncel araştırmaların çoğu aslında tespit kısmına değil, yanlış pozitiflerin azaltılmasına odaklanılmıştır. Yanlış pozitif nesnelerin sayısının azaltılması ve her bir görüntüdeki şüpheli noktaların işaretlenmesi en kritik kısımdır. Bu nedenle, düşük sayıda yanlış pozitiflerin ve nodül adaylarının güçlü bir şekilde tanımlanması bu bölümün ana odaklanılan noktasıdır. Literatürde araştırmacılar BT görüntülerinde nodülleri tespit etmek için farklı yöntemler kullanmışlardır. El Takizawa, akciğer içindeki patolojik alanları tanımak için bir 3B Markov rastgele alan eklemiştir. Her ne kadar Takizawa, önerilen nodülü yanlış pozitif olmayan tüm nodülleri ayıklamak için önerilen yöntemi önerdiyse de önerilen yöntemi, 10 BT görüntüsünden oluşan küçük bir test veri seti üzerinde çalışılmıştır [30]. Ne yazık ki nodül tipleri ve büyüklükleri hakkında ne bilgi ne de daha büyük bir veri tabanı üzerinde performans değerlendirmesi gerçekleştirilememiştir. Antonelli ve diğ., pulmoner bölgenin anatomik bilgisine dayanan bir yöntem önermişlerdir. Temel olarak, kullanılan BDT sistemi, BT görüntülerinde hacim, X-ışını zayıflaması ve halihazırda teşhis edilen yapılara göre ve pozisyonuna göre farklı yapılar elde etme amacındadır [31]. Vücudun içindeki nesnelere tanıdıktan sonra, akciğer voksellerini 2 küme nodülü-damarı ve havayı sınıflandırmak için bir C-Means Fuzzy algoritması uygulanmıştır. Ardından nodülleri ROI (Region of Interest) havuzundan sınıflandırmak için nöral ağ sistemi kullanılmıştır. Antonelli'nin çalışması, vokselle başına 1,4 FP'lik %82'den fazla

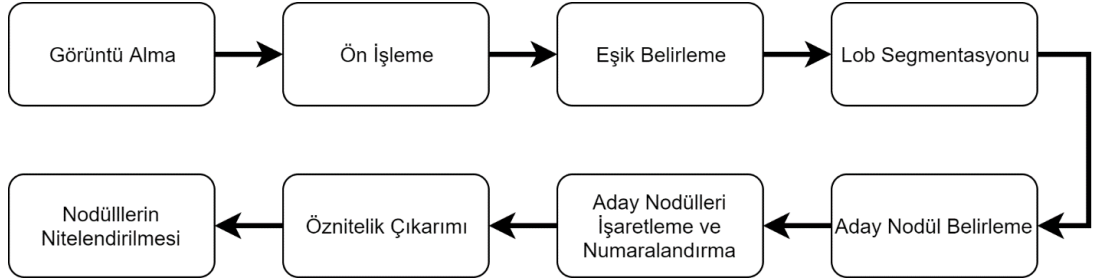
hassasiyet elde etmiştir. BT'de akciğer nodül tespitini otomatik hale getirmek için az sayıda bilgi tabanlı plan geliştirme aşamasındadır [32-37]. Bu sistemler tarafından ele alınması gereken en büyük zorluk, nodülleri normal bronkovasküler detaylardan ayırt etmektir. Bronkovasküler anatomik yapılar ve akciğer nodülleri, bireysel BT görüntülerinde benzer X-ışını zayıflaması ve görünümü vardır. Bu nedenle, bu sistemler sadece geleneksel gri düzey tabanlı görüntü işleme araçlarına dayanmamaktadır. Akciğer anatomisinin yanı sıra akciğer nodüllerin beklenen X-ışını zayıflaması, boyutu, şekli veya lokalizasyonu ile ilgili bulgular veya kurallar yoluyla anatomik ve görüntüleme bilgisini ayırt edici olarak ortaya koyarlar [38]. Nodül tespiti için özellik tabanlı bir küratifleşme yaklaşımı, ön çalışmalarda ümit verici sonuçlar vermiştir [34-37].

BÖLÜM 3. MATERYAL VE YÖNTEM

Gerçekleştirilen bilgisayar destekli tanı sistemi görüntü işleme ve yapay zekâ olarak iki ana başlık altında işlenmiştir.

3.1. Görüntü İşleme

Görüntü işleme bölümü; görüntü alma, ön işleme, lob segmentasyonu, eşik belirleme, aday nodülleri belirleme, aday nodül işaretleme ve numaralandırma alt başlıklarından oluşmaktadır. Şekil 3.1.'de bu alt başlıklardan oluşan sistemin görüntü işleme algoritma kısmı gösterilmiştir.




Şekil 3.1. Sistemin çalışma algoritması

3.1.1. Görüntü alma

Oluşturulan sistemde, PET-CT cihazından DCM(DICOM) uzantılı olarak tam kayıt verileri alınmıştır. Alınan veriler üzerinde lezyonun bulunduğu voksel değerleri ayırt edilip çıkarılmıştır. Alınan DICOM verileri MATLAB programı üzerinde DCM formatından .png formatına dönüştürülmüştür. Fakat dönüştürülen görüntüler, görüntü işleme için uygun olmayan kalitededir. Görüntülerin yüksek kalitede elde edilebilmesi için DICOM-Viewer programı kullanılarak yakın parametreler ile .png formatında kaydedilmiştir. Adaptif bir eşikleme işlemine tabii tutulacağı için

parametrelerin tamamen aynı olması gerekmemektedir. Görüntüler kaydedilirken FOV (Field of View) dikkate alınarak PET-CT cihazının görüntü üzerinde çıkan yatak kısmı ve vücut dışındaki kısımlar kesilmiştir. Şekil 3.2.'de elde edilen örnek görüntü gösterilmektedir.



Şekil 3.2. Elde edilen örnek görüntü

3.1.2. Ön işlemler

Görüntü alma işlemi ile elde edilen görüntüler üzerindeki lezyonlar morfolojik özellikler ile değerlendirileceği için bütün görüntülerin ölçeklenmesi gerekmektedir. Kesilen görüntülerde verilerin bozulmasının minimum olduğu 400x400x3 ölçeğine ölçeklenmiştir.

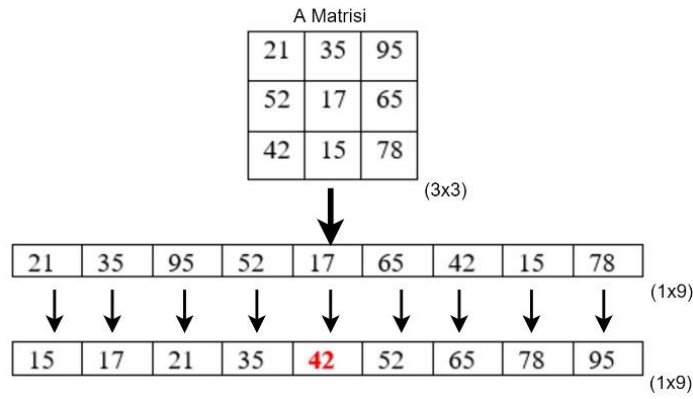
Uygunlaştırılan görüntülerde görüntü işleme işlemi gerçekleştirilmesi için görüntüler RGB (Red-Green-Blue) formatından gri düzeye dönüştürülmüştür. Renkli görüntüyü gri seviyeli görüntüye dönüştürürken, 3 bileşen için farklı katsayılar kullanılır ve bu katsayılar toplanılır [39]. Kullanılan hazır koddaki katsayılar; Kırmızı renk için 0,2989, yeşil renk için 0,5870, mavi renk için 0,1140'tır ve aşağıdaki eşitlikte (Denklem 3.1) gösterilmiştir.

$$\text{Gri Seviye} = 0,2989 * \text{Kırmızı} + 0,5870 * \text{Yeşil} + 0,1140 * \text{Mavi} \quad (3.1)$$

Gri seviyeli olarak oluşturulan görüntülerde gürültü faktörlerinin önüne geçmek için öncelikle ikinci dereceden medyan filtresi ardından laplacian filtresi uygulanmıştır.

3.1.3. İkinci dereceden medyan filtresi

İkinci dereceden medyan filtresi, oluşturulan maske içerisindeki gri seviyelerini küçükten büyüğe doğru sıralamaktadır. Sıralanan gri seviye değerlerinde tam ortada bulunan piksel değeri maske içerisinde ilgilenilen piksel için yeni değer olarak belirlenir. Bu işlem gerçekleştirildiğinde, alçak ve yüksek gri seviyelerinde pik yapan piksel değerlerini, geri ton bölgelerini ayıran gri seviye basamaklarını yassılaştırmadan yok etmektedir [40].



Şekil 3.3. Medyan filtresi çalışma prensibi

Şekil 3.3.'te 3x3'lük medyan filtre maskesi bulunmaktadır. A matrisindeki piksellerin gri seviye değerleri sıralanmıştır. Sıralanan pikseller küçükten büyüğe sıralanmış ve ortanca değer bulunmuştur. Bulunan "42" değeri, A matrisindeki 2-2'deki pikselin yeni değeridir. 2-2'deki "17" değerindeki piksel "42" ile değiştirilmiştir.

3.1.4. Laplacian filtresi

Görüntü medyan filtresinden geçirildiğinde kenar hatlarını kaybetmiştir. Lob segmentasyonu ve aday nodül tespiti için geçiş yapılan noktalar önem taşımaktadır. Bu flulaşma laplacian filtresi ile giderilmiştir.

Laplacian filtresi görüntüler üzerindeki kenarları keskinleştirmek için kullanılan bir filtre türüdür. Kullanılan filtrenin çalışma prensibi ikinci dereceden türev olarak

gerçekleştirmeye dayalıdır [41,42]. Aşağıdaki eşitliklerden yararlanılarak (Denklem 3.2-Denklem 3.3) kullanılan filtre ve çarpım katsayıları oluşturulmuştur.

$$\nabla^2 f(x, y) = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (3.2)$$

$$f(x, y) = f(x + 1, y) + f(x - 1, y) + f(x, y + 1) + f(x, y - 1) - 4f(x, y) \quad (3.3)$$

Burada ∇^2 :2. derece türev alma, $f(x, y)$: görüntü fonksiyonunu göstermektedir. Verilen laplacian maskesi ile konvolüsyon uygulandıktan sonra elde edilen laplacian görüntüsünün eşik değeri ile karşılaştırılması sonucunda keskinleştirilmiş kenar görüntüsü meydana gelir. Laplacian filtresi katasayıları ise 0, 1, 0; 1, -4, 1; 0, 1, 0 değerleridir.

3.1.5. Eşik belirleme

Eşik belirleme, belirli bir gri seviyesi değeri seçilerek bu değerden düşük seviyeli değerler için "0", seçilen değerden yüksek seviyeli değerler için "1" değeri verilerek yapılan işleme denir. Adaptif çözüm elde edebilmek için sistemde Otsu eşik belirleme metodu kullanılmıştır.

Otsu eşik belirleme metodu, gri seviyeli görüntüler üzerinde gerçekleştirilebilen eşik tespit etme yöntemidir. Görüntü üzerinde yoğunlukları farklı olan birimlerin sınıf içi varyansını en aza indirgeyerek eşik değerini belirler. Belirlenen eşik değerinde sınıf içi varyans en düşükken, sınıflar arası varyans değeri maksimum olur. Bu yöntem arka plan ve ön plan renklerinin (siyah-beyaz) en uygun şekilde ayrılmasını sağlamaktadır [43,44]. Aşağıdaki eşitliklerle (Denklem 3.4- Denklem 3.5- Denklem 3.6) otsu eşiklerinin nasıl belirlendiği gösterilmektedir.

$$\sigma_E^2 = \theta(t)\sigma_y^2 + [1 - \theta(t)]\sigma_0^2 + (\mu_y - \mu)^2\theta(t) + (\mu_0 - \mu)^2[1 - \theta(t)] \quad (3.4)$$

$$\sigma_i^2(t) = \theta(t)\sigma_y^2 + [1 - \theta(t)]\sigma_0^2 \quad (3.5)$$

$$\sigma_a^2(t) = (\mu_y - \mu)^2 \theta(t) + (\mu_0 - \mu)^2 [1 - \theta(t)] \quad (3.6)$$

3.1.6. Lob segmentasyonu

Görüntü üzerinde bulunan aday nodüle/nodüllere benzeyen birimleri yok etmek için lobların tespit edilip ayrılması gerekmektedir. Lob segmentasyonu yapıldığında sadece akciğer loblarında bulunan aday nodüller tespit edilmektedir. Bu işlem ile bilgisayar destekli tespit ve tanı sisteminin loblar dışında çalışmasını engellemektedir [45].


Lob segmentasyonu ön işlemlerden ve eşiklemeden geçirildiği takdirde yapılmaktadır. Sistemin çalışması ikilik sistemdeki görüntüye (binary görüntü, 1-0) dönüştürülmüş görüntüde belirlenen piksel boyutunun altındaki piksel boyutundaki bağlı bileşenlerin silinmesi ile gerçekleşir.

Bilgisayar tomografisi görüntüsünde önceki işlemlerden geçirilmesinin ardından, kod kullanımının kolaylaşması için görüntü binary olarak terslenmektedir, “0” değeri “1”, “1” değeri “0” yapılmaktadır. Belirlenen büyük bağlı piksel değerinin altında kalan nesnelere belirlenmektedir. Belirlenen nesnelere loblar seçilmektedir. Sadece lobların seçimi yapıldığı için diğer tüm birimler silinmiştir. Loblar elde edilmesi ile ayrı bir görüntü oluşturularak, lobların sınırları çizdirilmiştir. Sınırları çizdirilen lobların çizgi değerleri kaydedilmiştir ve işlenmiş görüntü üzerine çizilmiştir.

3.1.7. Aday nodül belirleme


Nodüller voksel görüntülerinde sadece bağımsız bir biçimde bulunmamaktadır. Nodüller iç plevraya ya da dış plevraya yapışık biçimde bulunabilmektedir. Lob segmentasyonunda elde edilen lob sınırlarında göz önünde bulundurulmamaktadır. Bu durum çekme faktörü değiştirilerek önüne geçilmiştir [46].

İki boyutta oluşturulan rastgele noktaların indisleri kullanılarak vektörler ile dışbükey bir gövde elde edilememektedir. Dışbükeyde daha kompakt bir alan elde etmek için çekme faktörü kullanılmaktadır [47]. Belirlenen noktaların çekme faktörü “1” olarak birleştirildiğinde, tam kompakt bir yapı oluşturulamamaktadır. Çekme faktörü “1” değerinden düşürülerek daha kompakt alanlar elde edilebilmektedir.




Şekil 3.4. Rastgele oluşturulan noktaların indisleri [47].

Şekil 3.4.'te rasgele oluşturulan noktalar 2 boyutlu düzlem üzerinde gösterilmiştir.



Şekil 3.5. Oluşturulan noktaların çekme faktörü 1 olduğunda dışbükey olarak çizdirilmesi [47].

Şekil 3.5.'te oluşturulan noktalar dışbükey olarak birleştirilmiştir. Kompakt yapı elde edilememiştir. Görüntüdeki çekme faktörü 1'dir. Kompakt bir yapı elde etmek için çekme faktörü düşürülmesi gerekmektedir.



Şekil 3.6. Çekme faktörü 0,1 olarak ayarlandığında elde edilen alan [47].

Şekil 3.6.'da çekme faktörü 1 değerinin altına düşürülerek daha kompakt bir alan elde edilmiştir. Bu sistemin geliştirilme sebebi akciğer loblarında bulunan olası aday nodüllerin tespitini sağlamaktır.

3.1.8. Aday nodülleri işaretleme ve numaralandırma

Aday nodül bulma işleminin sonucunda bulunan aday nodüllerin çevre çizilmiştir. Bu çizgiler kaydedilerek ana görüntü ile karşılaştırılmıştır. Çakıştırılan aday nodüller piksel numaralarının büyüklüğüne göre sayma sayıları ile numaralandırılmıştır.

3.2. Öznitelik Çıkarımı

Bu çalışmada oluşturulan veri setinde her bir veriyi sınıflandırabilmek için veriler arasındaki ayırt edici farklara bakılması gerekmektedir. Bu farkları elde etmek için morfolojik veya istatistiksel özelliklerin kullanılması gerekmektedir. Çalışma kapsamında morfolojik özellikler kullanılmaktadır. Toplamda 9 farklı morfolojik özellik kullanılmıştır. Kullanılan özellikler; alan, ana eksen uzunluğu, küçük eksek uzunluğu, dış merkezlilik, uyum sağlama, eş çap, katılık, genişlik ve çevre uzunluğu kullanılmıştır.

Alan: Bölgedeki gerçek piksel sayısıdır [48]. Özelliğin adaptif bir çözüm olabilmesi için bütün görüntüler uygunlaştırılmıştır.

Ana Eksen Uzunluğu: Bölgede aynı anda bulunan elipsin ana eksen uzunluğu (piksel değeri olarak). Bu özellik sadece 2 boyutlu üzerinde çalışılan sistemler için geçerlidir [49].

Küçük Eksen Uzunluğu: Bölgede aynı anda bulunan elipsin küçük eksen uzunluğu (piksel değeri olarak). Bu özellik sadece 2 boyutlu üzerinde çalışılan sistemler için geçerlidir [49].

Dış Merkezlik: Eksantriklik elips odakları ve ana eksen uzunluğu arasındaki mesafenin oranıdır. Değer 0 ile 1 arasındadır (eksantrikliği 0 olan bir elips aslında bir çember iken, eksantrikliği 1 olan bir elips bir çizgi segmentidir). Bu özellik 2 boyutlu sistemler için desteklenmektedir [49].

Uyum Sağlama: X-ekseni ile elipsin ana eksen arasındaki açı (derece cinsinden) uyum sağlama oranını ve yönelimi vermektedir. Bu özellik sadece 2 boyutlu giriş etiket matrisleri için desteklenmektedir. Şekil 3.7.'de sol taraf bir görüntü bölgesi ve karşılık gelen elips gösterir. Sağ taraf, grafiksel olarak aynı elips gösterilmektedir; düz mavi çizgiler eksenlerdir, kırmızı noktalar odaklardır ve yönelim yatay noktalı çizgi ile ana eksen arasındaki açıdır [49].



Şekil 3.7. Görüntü için uyum sağlama ve yönelim örneği

Eş Çap: Bölge ile aynı alana ait bir dairenin çapıdır. Aşağıdaki eşitlikte (Denklem 3.7) dairenin çap formülü gösterilmektedir [49].

$$\text{Çap} = \sqrt{\frac{4 \times \text{Alan}}{\pi}} \quad (3.7)$$

Katılık: Alanın dış bükey gövdedeki piksel oranıdır. Bu özellik 2 boyutlu sistemler için geçerlidir.


Genişlik: Bölgede bulunan sınırlayıcı piksellerin oranıdır [49].

Çevre Uzunluğu: Bölgenin sınırındaki pikselleri göz önünde bulundurarak çevre hesabı yapılmaktadır [49].

3.3. Yapay Zekâ

3.3.1. Yapay sinir ağı


Yapay sinir ağı (YSA), insan beyninden esinlenen yapı ve fonksiyona sahip matematiksel bir modeldir. Yapı, “nöronlar” adı verilen düğümler ve “ağırlıklar” denilen nöronlar arasındaki bağlantılardan oluşur. Nöronlar biyolojik sinir ağlarından esinlenerek katmanlar halinde ayarlanır. Şekil 3.8.’de bir uyarıcı yanıtı göndermeden önce birden fazla uyarıcı alan ve işleyen yapay bir nöron ve biyolojik bir nöron arasındaki bir karşılaştırmayı göstermektedir. Girişlerde sunulan bilgilerin işlenmesi, gizli ve çıktı katmanlarında gerçekleşir. YSA genel olarak, girdilerin ve çıktılarının verildiği örnek tabanlı eğitimler kullanılarak geliştirilmiştir. Ağ ağırlıkları, eğitim tamamlanana kadar çeşitli eğitim algoritmaları kullanılarak kademeli olarak ayarlanır. YSA tarafından elde edilen “bilgi”, iş ağırlıklarında saklanır. Bu öğrenme süreci, insan beyni gibi biyolojik sistemlere benzemektedir. YSA tıbbi karar almada ve BDT’de yararlıdır çünkü bir ağdaki bireysel nöronlar ve ağırlıklar herhangi bir zekaya sahip olmasa bile, birbirlerine bağlandıklarında, insan karar verme sürecinin bazı yönlerini çoğaltma gibi bir potansiyele sahiptir.



Şekil 3.8. Modellenmiş nöron ile biyolojik nöronun benzetimi

3.3.2. İleri yönlü geri yayımlı

Son nöral ağ topolojileri ve eğitim teknikleri, McCulloch ve Pitts tarafından yapay nöron kavramının tanıtılmasından son 45 yılda geliştirilmiştir. Bu projede oluşturulan YSA modeli çok katmanlı ileri besleme ağıdır. Çok katmanlı ileri beslemeli yapay sinir ağları, tipik olarak birbiriyle tamamen bağlantılı birkaç nöron katmanından oluşur. Çok katmanlı bir ağdaki her bir nöron, girdiyi aldığı önceki katmandan oluşur. Çok katmanlı bir ağdaki her bir nöron, girdiyi aldığı önceki katmandan oluşur. Çok katmanlı bir ağdaki her bir nöron, girdiyi aldığı önceki katmandan oluşur. Çok katmanlı bir ağdaki her bir nöron, girdiyi aldığı önceki katmandan oluşur. Geri yayılım çok katmanlı ileri beslemeli YSA'larda kullanılan tipik nöron, tanjant sigmoid fonksiyonu gibi doğrusal olmayan bir transfer fonksiyonuna sahip basit bir toplam nöronudur. Şekil 3.9.'da tanjant sigmoid fonksiyonu grafik olarak gösterilmiştir.



Şekil 3.9. Tanjant sigmoid fonksiyonu

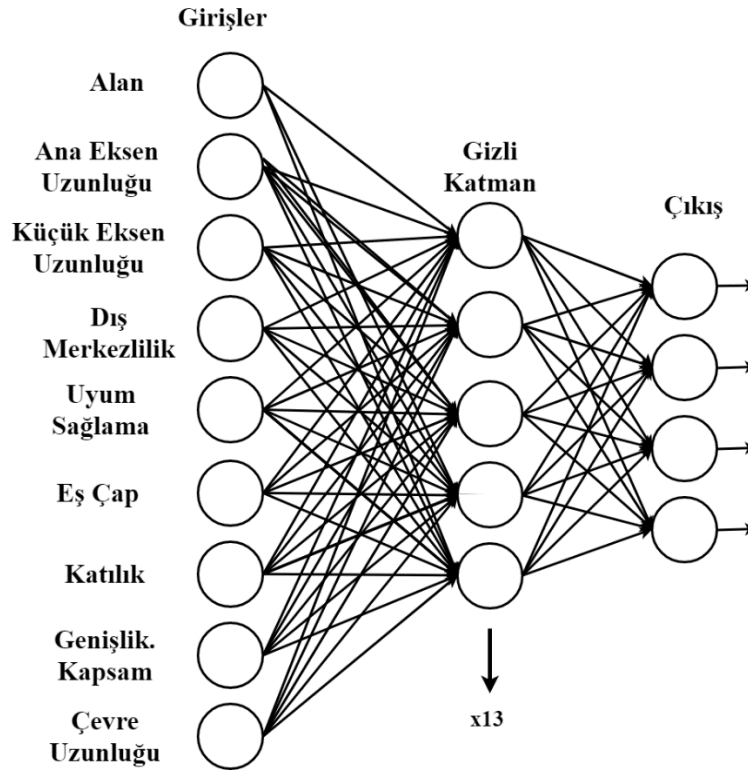
Tipik bir üç katmanlı ileri besleme şebekesinde, girişler, katmanlardaki verileri gizli katmandaki nöronlara verilmektedir. Bu dönüştürülmüş girdiler daha sonra toplanır ve bir transfer fonksiyonu ile bir değerler aralığına eşlenir. Tan-sigmoid transfer fonksiyonu için, dönüştürülmüş girişler -1 ile 1 arasında bir aralıkta normalleştirilir. Tanjant sigmoid fonksiyonunun matematiksel eşdeğeri aşağıdaki eşitlikte (Denklem 3.8) olduğu gibidir.

$$a = \tan \text{sig}(n)$$

$$a = \frac{2}{(1 + e^{-2n})} - 1 \quad (3.8)$$

Normalleştirilmiş çıktı daha sonra çıkış katmanındaki nöronlara aktarılır. Bu tür nöronlar ve mimarilerle sinir ağlarını eğitmek için birçok algoritma vardır. Ancak, yaygın olarak geri yayılma eğitim algoritması kullanılmaktadır.

Yapay sinir ağı modeli Şekil 3.10.'da görüldüğü gibi 9:13:4 olarak belirlenmiştir. Giriş katmanında morfolojik özellik çıkarımında elde edilen katsayılar kullanılmıştır. Gizli katmanın sayısı için kullanılan matematiksel formülasyon bulunmadığı için ara katman sayısı olarak 13 nöron kullanımı tercih edilmiştir. Çıkış katmanı 0 ile 1 arasında skala edilmiştir. Maling 1 değeri için, being 0, bronkovasküler yapılar ve bronşlar 0, yanlış pozitifler için 0 etiketi almıştır. Ele alınan örnek hangisi ise o sınıf için 1 etiketi diğer sınıflar için 0 etiketi atanmıştır. Girdi olarak kullanılan özellikler ve etiket değerleri yapay sinir ağına verilerek giriş-çıkış arasındaki ilişki yapay zekaya öğretilmiştir.



Şekil 3.10. Oluşturulan sinir ağı modeli

3.4. ROC Eğrisi

Bir yapay sinir ağı eğitildikten sonra, test örneklerinin hedef sınıfını tahmin etmek ya da tespit etmek için kullanılmaktadır. Fakat, test örneklerinin sınıflandırılmasından önce, bir sınıfın kalitesi, eğitim aşamasında değerlendirilir. Bir sınıfın kalitesi, doğruluk (Accuracy), duyarlılık (sensitivity) ve özgünlük (specificity) gibi ölçümler kullanılarak belirlenir. Tıbbi sistemlerde duyarlılık, özgünlük belirlemek standart bir ölçüm sistemidir. ROC eğrisinde, x eksenini özgünlük (Yanlış Pozitif Oran) temsil ederken, y ekseninde duyarlılık (Doğru Pozitif Oran) bulunmaktadır. Yapay zekanın tahminleri ise alınan sonuçların tümü ele alınarak elde edilebilmektedir;


Doğru Pozitif (True Positive-TP): Doğru etiketi doğru tahmin etme.

Doğru Negatif (True Negative-TN): Yanlış etiketi yanlış tahmin etme.

Yanlış Pozitif (False Positive-FP): Yanlış etiketi doğru tahmin etme.


Yanlış Negatif (False Negative-FN): Doğru etiketi yanlış tahmin etme.

Eđitilen yapay sinir ađında elde edilen sonuđlar 2 sınıftan fazla olduđu iin direkt olarak duyarlılık, zgnlk ve ROC eđrisi elde edilemez. Deđerleri elde edebilmek iin sınıflar ayrı olarak deđerlendirilmelidir. Oluřturulan sistemde 4 farklı sınıf elde edilmektedir. Őekil 3.11.'de elde edilen sınıflara yapılan ayırım gsterilmektedir. Dođru Pozitif (True Positive-TP), Dođru Negatif (True Negative-TN), Yanlıř Pozitif (False Positive-FP), Yanlıř Negatif (False Negative-FN), duyarlılık, zgnlk ve ROC eđrileri izdirilir. Genel sonu elde edilmek istendiđinde ise elde edilen ROC eđrilerinin altında kalan alanlar toplanır ve sınıf sayısına blnr.




Őekil 3.11. Elde edilen sınıflar

ROC eđrilerinde en iyi sonucu elde etmek iin optimum kesim noktasının elde edilmesi gerekmektedir. rneđin optimum kesim noktası 0-1 aralıđında olmak zorundadır. '0,5' deđerleri optimum kesim noktası olduđu kabul edilsin. Őekil 3.12.'de grldđ gibi kesme deđerleri '0,5' alındıđında en yksek dođruluđa ait sonu elde edilir. Eđer Őekil 3.13.'teki gibi kesme deđerleri '0,4' seilseydi dođru negatif olarak bulunan sonularda yanlıř pozitif olarak deđerlendirilecekti. Bu sebeple optimum kesim deđerleri seilmelidir.



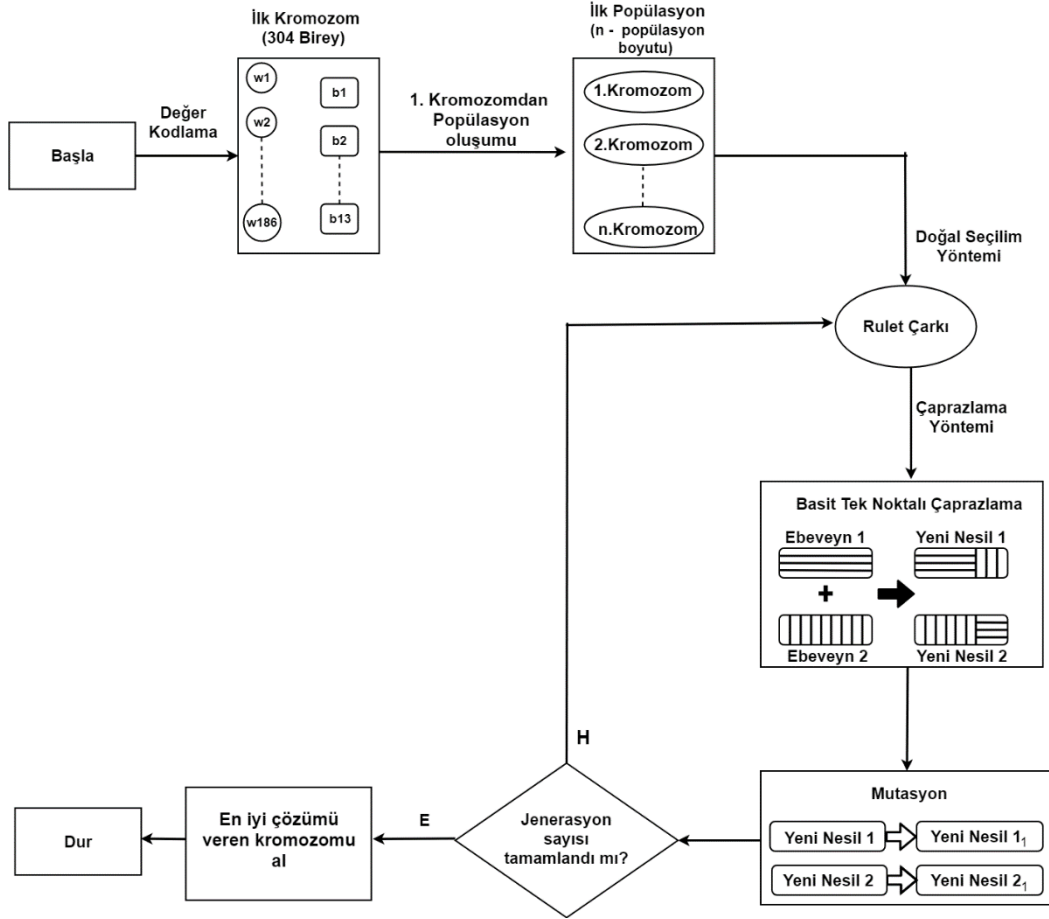
Őekil 3.12. Kesme deđerleri 0,5 iken sonuların deđerlendirilmesi



Şekil 3.13. Kesme değeri 0,4 iken sonuçların değerlendirilmesi

3.5. Genetik Algoritma


Genetik algoritma bir optimizasyon yöntemidir. Şekil 3.14.'te ki blok diyagramı kendi problemimize uyguladığımız kodlama, seçim, çaprazlama ve mutasyon yöntemlerinin gösterimidir. İlk olarak yapay sinir ağlarından elde edilen ağırlıkların değer kodlama yöntemi ile ilk kromozomu oluşturulur. Bu kromozomdaki bireylerden belli sayılar arasında rasgele sayı eklenerek veya çıkarılarak diğer kromozomlar üretilmiş olur ve ilk popülasyon oluşturulur. Doğal seçim yöntemi olarak rulet çarkı tercih edilerek sonrasında birinci ara popülasyon elde edilir. Çaprazlama yöntemi olarak ise basit tek noktalı çaprazlama yöntemi uygulanarak birinci ara popülasyondan, ikinci ara popülasyonu oluşturulur. İkinci ara popülasyondaki bireyler mutasyona uğrayarak yeni popülasyonu meydana getirir. Seçim işleminden, mutasyon sonrası yeni popülasyon oluşana kadar ki süreç bir jenerasyon olarak adlandırılır. Bu işlemler belirlenen bir jenerasyon sayısı kadar devam eder. Jenerasyon sayısı, belirlenen iterasyon sayısına eriştiği zaman algoritma durur ve en sondaki popülasyonun en iyi sonuç veren kromozomu probleme adapte edilir.



Şekil 3.14. Genetik algoritma blok diyagramı

3.5.1. Değer kodlama

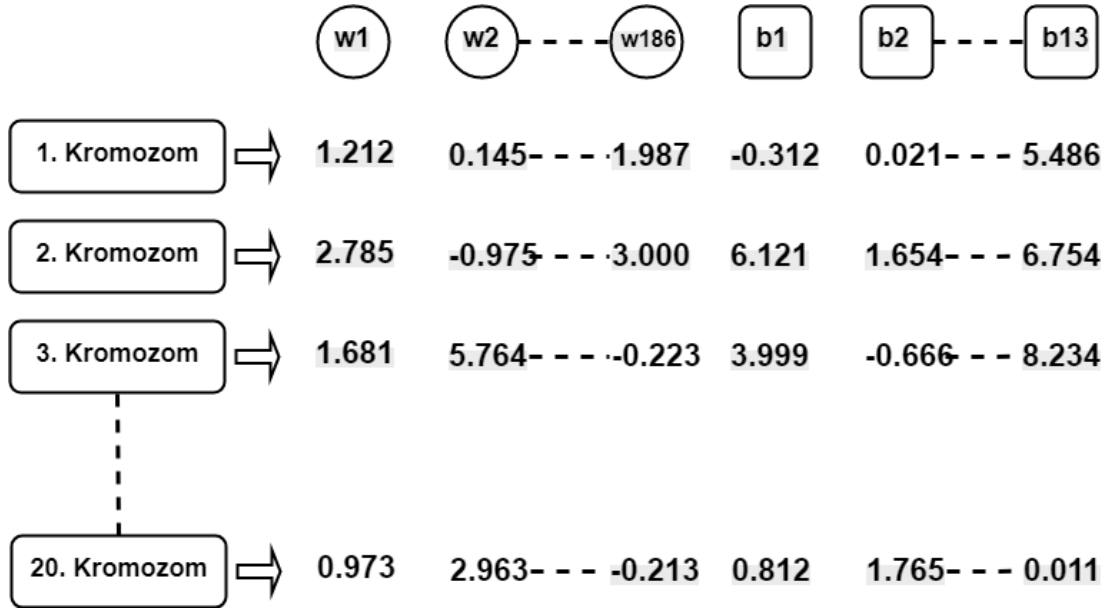
Yapay sinir ağlarından elde edilen ağırlıklar ilk kromozom olarak kullanılacağı için bir kromozom 186 bireyden meydana gelir ve değer kodlama yöntemi yapılması tercih edilmiştir. Bu çalışmada kullanılan değer kodlama yöntemi Şekil 3.15.'te ki gibidir.



Şekil 3.15. Birinci kromozom elde edilmesi

3.5.2. İlk popülasyon oluşumu

Birinci kromozom oluşturulduktan sonra diğer kromozomlar birinci kromozomdan üretilir. İlk kromozomda bulunan 186 bireye, belli sayılar arasında rastgele sayı eklenerek veya çıkartılarak diğer kromozomlardaki bireyler elde edilir. Popülasyon boyutu seçiminde herhangi bir kural yoktur. Bu çalışmada Şekil 3.16.'da görüldüğü gibi popülasyon boyutu 20 olarak tercih edilmiştir.



Şekil 3.16. İlk popülasyon

3.5.3. Amaç fonksiyonu

Popülasyonda yer alan bütün kromozomlardaki ağırlıklar, eğitilen yapay sinir ağında bulunan ağırlıklar yerine konularak bulunan sonuçlar, gerçek sonuçlar ile karşılaştırılır. Karşılaştırılmadan elde edilen fark sayısı hata olarak belirlenir. Bu çalışmanın amacı hatayı minimize ederek en optimum ağırlıkların bulunmasıdır.

3.5.4. Doğal seçim

Doğal seçim yöntemi olarak rulet çarkı kullanıldı. Bu yöntemde amaç fonksiyonunda en az hatayı veren kromozomların birinci ara popülasyonda yer alma olasılıkları

yüksektir. Öncelikle amaç fonksiyonunda bulunan hatalar belirlenir. Şekil 3.17.'de 304 veri seti içerisinde 20 kromozomun hata sayıları gösterilmektedir.

	Hata Sayısı
1. Kromozom	17
2. Kromozom	24
3. Kromozom	45
4. Kromozom	60
⋮	⋮
19. Kromozom	31
20. Kromozom	18

Şekil 3.17. Kromozom hata sayısı

Hata sayı az olan kromozomun 1. ara popülasyonda yer alma olasılığı fazla olması için $1/\text{hata sayısı}$ olacak şekilde işlem yapılır. Şekil 3.18.'de yapılan işlem görülmektedir.

	Hata Sayısı	$1/\text{Hata Sayısı}$
1. Kromozom	17	0.0588
2. Kromozom	24	0.0416
3. Kromozom	45	0.0222
4. Kromozom	60	0.0166
⋮	⋮	⋮
19. Kromozom	31	0.0322
20. Kromozom	18	0.0555

Şekil 3.18. Kromozomların $1/\text{hata sayısı}$

0 ile 1 arasında olasılık hesabı yapabilmemiz için her kromozomun 1/hata değeri, toplam 1/hata değerine bölünür. Şekil 3.19.'da görüldüğü üzere en az hata sayısı olan kromozom yaşama olasılığı yani 1. ara popülasyonda yer alma olasılığı en fazla olarak hesaplanmıştır.

	Hata Sayısı	1/Hata Sayısı	Yaşama Olasılığı
1. Kromozom	17	0.0588	0.2591
2. Kromozom	24	0.0416	0.1833
3. Kromozom	45	0.0222	0.0978
4. Kromozom	60	0.0166	0.0731
⋮	⋮	⋮	⋮
19. Kromozom	31	0.0322	0.1419
20. Kromozom	18	+ 0.0555	+ 0.2446
		<u>0.2269</u>	<u>1</u>

Şekil 3.19. Kromozomların yaşama olasılığı

Her kromozomun yaşama olasılığının farklı aralıklara ölçeklemek için yaşama olasılığı kümülatif olarak toplanır. Şekil 3.20.'de görüldüğü üzere yaşama olasılığı aralıkları hesaplanmıştır.

	Hata Sayısı	1/Hata Sayısı	Yaşama Olasılığı	Yaşama Olasılığı Aralıkları
1. Kromozom	17	0.0588	0.2591	0.2591
2. Kromozom	24	0.0416	0.1833	0.4424
3. Kromozom	45	0.0222	0.0978	0.5402
4. Kromozom	60	0.0166	0.0731	0.6133
⋮	⋮	⋮	⋮	⋮
19. Kromozom	31	0.0322	0.1419	0.7554
20. Kromozom	18	+ 0.0555	+ 0.2446	1
		<u>0.2269</u>	<u>1</u>	

Şekil 3.20. Kromozomların yaşama olasılığı aralıkları

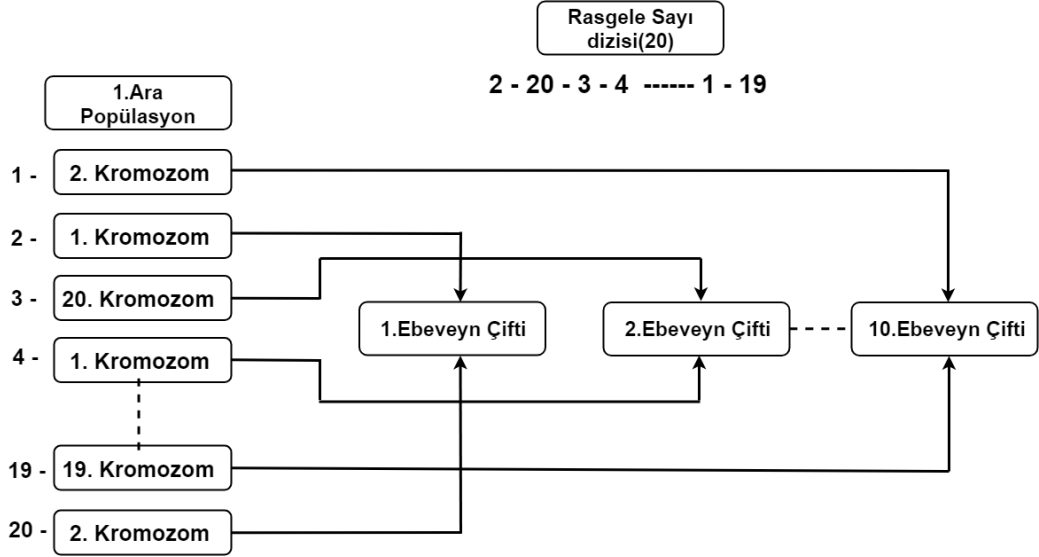
Bu işlem sonrasında 0 ile 1 arasında bir rastgele sayı üreterek hangi kromozomun 1. ara popülasyonda yer alacağına ya da diğer bir deyişle yaşayacağına karar verilir. Örneğin; üretilen rastgele sayı 0,3 olsun. 0,3, 1. kromozomla 2. kromozomun yaşama olasılığı aralığı arasında yer alacağı için 2. kromozom hayatta kalır. Popülasyon boyutu 20 olduğu için 20 adet rastgele sayı üretilir ve 1.ara popülasyonda yer alacak 20 kromozom belirlenir. Şekil 3.21.'de görüldüğü üzere hata sayısı fazla olan 3 ve 4. kromozomlar 1. ara popülasyonunda yer almazlar. Hata sayısı en az olan 1. kromozom ise 1. ara popülasyonun 2. kromozomunda yer almıştır.

	Yaşama Olasılığı Aralıkları	Üretilen Rastgele Sayılar	1.Ara Popilasyon
1. Kromozom	0.2591	0.3	2. Kromozom
2. Kromozom	0.4424	0.2	1. Kromozom
3. Kromozom	0.5402	0.8	20. Kromozom
4. Kromozom	0.6133	0.1	1. Kromozom
...
19. Kromozom	0.7554	0.7	19. Kromozom
20. Kromozom	1	0.4	2. Kromozom

Şekil 3.21. Ara popülasyon


3.5.5. Çaprazlama

Birinci ara popülasyon elde edildikten sonra çaprazlama aşamasında basit tek noktali çaprazlama yöntemi kullanılmıştır. Bu yöntemde kromozomlar birbirleriyle eşleştirilir ve ebeveynler oluşturulur. Şekil 3.22.'de gösterildiği üzere 1'den popülasyon boyutu sayısına kadar yani 1'den 20'ye kadar rastgele bir dizilim yapılır. Örneğin rastgele sayı dizi 2- 20- 3- 4-...-1- 19 olsun, bu sayı dizisine göre 1. ebeveyn çifti 1. ara popülasyonunda bulunan 1. ve 2. kromozomlarından, 2. ebeveyn çifti 20. ve 2. kromozomlarından, 10. ebeveyn çifti ise 2. ve 19. kromozomlardan oluşmaktadır.



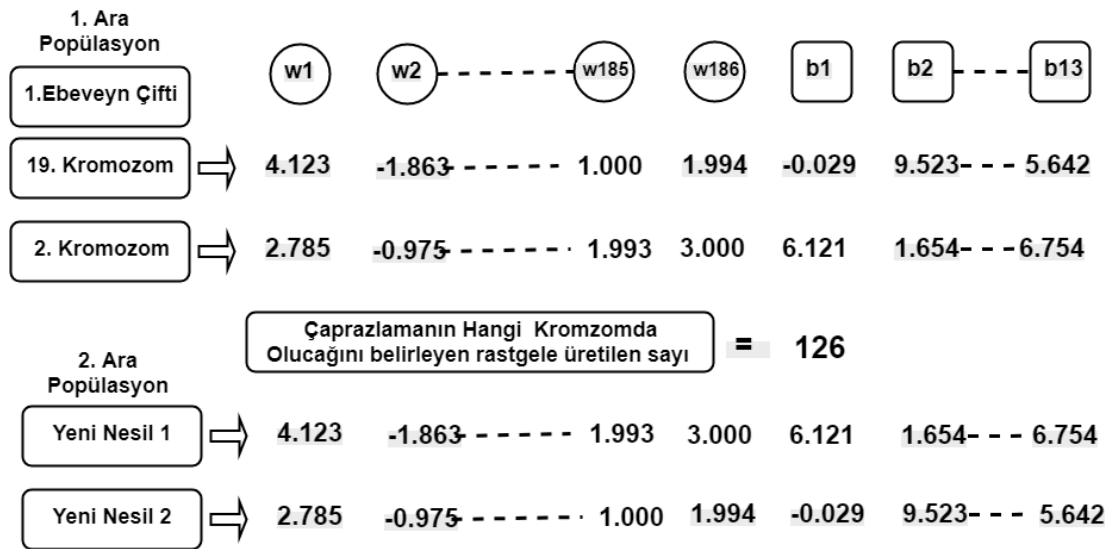
Şekil 3.22. Kromozomların çaprazlamada eşleştirilmesi

Ebeveyn çiftleri oluşturulduktan sonra çiftlerin çaprazlamaya girip girmeyeceği belirlenir. 10 ebeveyn çifti olduğu için 10 adet 0 ile 1 arasında rastgele sayı oluşturulur ve çaprazlama oranına göre karşılaştırılır. Eğer 1. ebeveyn çifti için oluşturulan rastgele sayı belirlenen çaprazlama oranından küçükse ebeveynler basit tek noktalı çaprazlama yöntemi ile çaprazlanır. Eğer rastgele sayı, çaprazlama oranından büyük ise o çift için bir değişim olmadan 2. ara popülasyonuna aktarılır. Şekil 3.22.'de olduğu üzere 1. ebeveyn çifti için üretilen rastgele sayı çaprazlanma oranından büyük olduğu için çaprazlanma işlemine tabi tutulur. 2. ebeveyn çifti için de üretilen rastgele sayı çaprazlanma oranından büyük olduğu için çaprazlanma işlemine girer. Fakat 10. ebeveyn çifti için üretilen rastgele sayı çaprazlanma oranından büyük olduğu için hiçbir işleme tabi tutulmadan 2. ara popülasyonuna aktarılır.



Şekil 3.23. Çaprazlanma oranı ve eşleşme

Çaprazlama yapılacak çiftler belirlendikten sonra hangi bireyden sonra çaprazlama yapılacağını seçmek için 1 ile bir kromozomdaki toplam birey sayısı olan 186 sayıları arasında rastgele sayı üretilir. Şekil 3.24.'te görüldüğü gibi, üretilen sayı 12 olduğu için 1. ebeveyn çiftinde bulunan 2. kromozom ile 19. kromozom arasında 126'dan 186'ye kadar olan bireyler yer değiştirilir ve 2. ara popülasyonunda yeni nesilleriyle yer alırlar.



Şekil 3.24. Tek noktalı çaprazlamanın uygulanması

3.5.6. Mutasyon


Elde edilen ikinci ara popülasyondaki birey sayısı kadar 0 ile 1 arasında rastgele sayı üretilir. Üretilen rastgele sayılar belirlenen mutasyon oranı ile karşılaştırılır. Üretilen rastgele sayı mutasyon oranından büyük ise bireyde bir değişiklik olmaz. Eğer küçük ise birey 1 ile -1 arasında üretilen rastgele sayı ile toplanarak birey mutasyona uğramış olur. Bu çalışmada mutasyon oranı 0,05 olarak belirlenmiştir.

BÖLÜM 4. ARAŞTIRMA BULGULARI

4.1. Görüntü İşleme Bulguları

4.1.1. Medyan filtresi


Görüntüye ikinci dereceden medyan filtre uygulandığında, görüntüdeki gürültüler yok olmuştur. Fakat görüntüdeki kenar hatlarındaki geçişlerde yumuşama oluşmuştur. Şekil 4.1.'de elde edilen görüntüye medyan filtresi uygulandığındaki görünümü verilmiştir. Gürültüler ve küçük vasküler yapıların kaybolduğu görülmektedir.



Şekil 4.1. Medyan filtresi uygulanmış görüntü

4.1.2. Laplacian filtresi

Gürültülerin engellendiği ikinci dereceden medyan filtreden elde edilen görüntüde sınırlardaki bozulmalar önlemek için laplacian filtresi uygulanmıştır. Şekil 4.2.'te laplacian filtresi uygulanmış görüntü görülmektedir. Görüntü kenarları keskinleştirilmiştir.



Şekil 4.2. Laplacian filtresi uygulanmış görüntü


Şekil 4.3.'teki görüntüde laplacian filtresi ile keskinleştirilen noktalar gösterilmektedir.



Şekil 4.3. Laplacian filtresinin görüntüye etkisi

4.1.3. Eşik belirleme

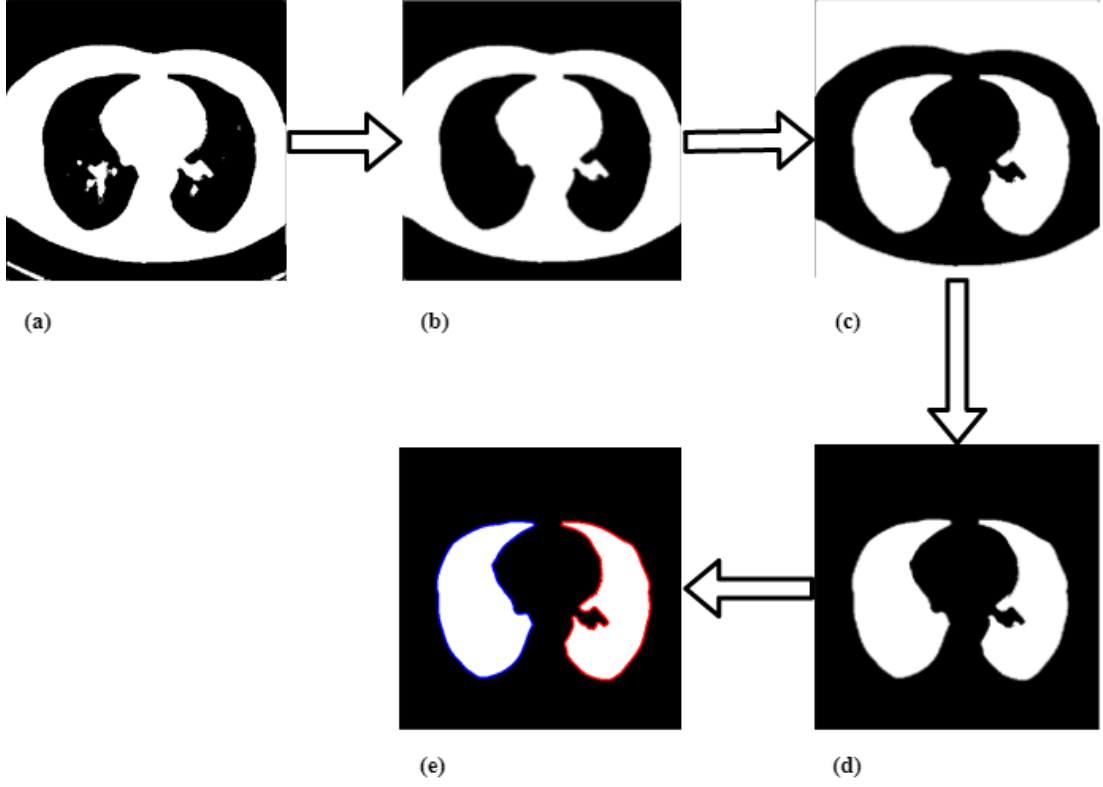
Ön işlemlerden geçirilen görüntülerde dokuların belirleme işleminin yapılması için binary görüntü elde edilmelidir. Bunun için eşik belirleme yöntemi ile piksel değerlerine göre belirlenen eşik değere göre binary görüntüye dönüştürülür. Eşik belirlemek için Otsu eşik belirleme metodu kullanılmıştır. Şekil 4.4.'te Otsu eşik belirleme metodu uygulanmış görüntü görülmektedir.



Şekil 4.4. Otsu eşik belirleme metodu uygulanmış görüntü


4.1.4. Lob segmentasyonu

Lob segmentasyonunda ilgilenilen kısımlar dışındaki birimlerden etkilenmemek için ROI (Region of Interest) çıkarılmalıdır. Şekil 4.5. (a), filtrelerden geçirilmiş ve eşik belirleme metodu uygulanmış görüntüdür. Şekil 4.5. (b), lobları ayırt edebilmek için vücut birimi dışındaki yatak, nodül, bronkovasküler yapılar gibi vücuda birleşik olmayan diğer birimler elenmiştir. Bu işlem vücut biriminin piksel değerlerinden küçük olan birimleri silerek gerçekleştirilir. Şekil 4.5. (c)'de binary tersleme işlemi yapılarak lobların tespiti kolaylaştırılır. Şekil 4.5. (d)'de lob harici kalan bölümler taranır, tarama işlemi gerçekleştiğinde loblar elde edilmektedir. Şekil 4.5. (e)'de kenarları belirlenerek matrislere atanır ve çizdirilir.



Şekil 4.5. (a) Filtrenmiş görüntüye eşikleme işlemi (b) lob piksel değerinin altındaki piksel değerli birimlerin elenmesi (c) lobların ayırt edilmesi için görüntüyü binary olarak tersleme (d) kalan birimler taranması (e) lobların işaretlenmesi ve sınırlarının taranması


Şekil 4.6.'de aday nodül belirleme işlemi için matrislere atanan değerler orijinal görüntü üzerinde çizdirilerek loblar işaretlenir.



Şekil 4.6. Orijinal görüntüde lobların işaretlenmesi ve numaralandırılması


4.1.5. Aday nodül bulma

Aday nodülleri plevraya yapışık olarak bulunan görüntüler bu işleme tabii tutulmuştur. Her görüntüde aday nodülün büyüklüğüne göre çekme faktörü değiştirilmiştir. Şekil 4.6.'de lob segmentasyonunda elde edilen görüntüde plevraya yapışık aday nodül bulunduğundan dolayı yetersiz kalmaktadır. Şekil 4.7.'de çekme faktörü uygulanmış görüntü görülmektedir. Çekme faktörü uygulandıktan sonra elde edilen binary görüntü plevraya yapışık aday nodülleri göstermektedir. Fakat bu işlem uygulandığında sadece plevraya yapışık aday nodüllerin dışında, aday nodül olamayan birimlerde elde edilmektedir. Elde edilen bu birimlere yanlış doğrular olarak isimlendirilmektedir. Bulunan yanlış doğrular yapay zekâ ile elenecektir.



Şekil 4.7. Çekme faktörü uygulanmış binary görüntü

Şekil 4.8.'de çekme faktörü uygulaması sonucuyla yeni sınırların orijinal görüntü üzerinde çizdirilmesiyle elde edilen görüntü verilmektedir.




Şekil 4.8. Çekme faktörü ile elde edilen yeni sınırların orijinal görüntü üzerinde çizdirilmesi

Çekme faktörü uygulandıktan sonra yeni oluşan sınırlar kullanılarak işlenmiş görüntü üzerinden kesilmektedir. Kesilen görüntü üzerinde 2000 piksel ile 100 piksel değerleri arasında bulunan alanlar çizilmektedir. Görüntüdeki alternatif durumlarda (aday nodülün çok büyük olması veya çok küçük olması) belirlenen piksel aralıkları değiştirilerek birbirine bağlı veya bağımsız bileşenler ayrıştırılır. Bu ayrıştırma ile bronşlar, küçük bronkovasküler yapılar ve nodül olmayan kesitler silinmektedir.

4.1.6. Aday nodül işaretleme ve numaralandırma

Çekme faktörü uygulandıktan sonra loblar kesilmiş, ana görüntü ile eşleştirilmiştir ve Şekil 4.9.'da gösterilmiştir.




Şekil 4.9. Kesilen lobların görüntü işleme uygulanmış görüntüde görünümü

Kalan birimler (loblar) otsu işleme tabii tutulur ve kalan birimler ortaya çıkarılır. Otsu işlemi ile elde edilen görüntü Şekil 4.10.'daki gibidir.




Şekil 4.10. Lob içerisinde bulunan birimlerin binary görünümü

Aday nodülleri belirlemek için eliminasyon yapılır ve belirli piksel değer aralığındaki birimler bırakılır ve Şekil 4.11.'deki görüntü elde edilir.



Şekil 4.11. Aday nodülleri ayrılmış binary görüntü

Belirlenen aday nodüllerin işaretlenir ve numaralandırılır. Şekil 4.12.'de işaretlenmiş ve numaralandırılmış görüntü görülmektedir.



Şekil 4.12. Belirlenen aday nodüllerin orijinal görüntü üzerinde işaretlenmesi ve numaralandırılması

4.2. Özellik Çıkarımı Bulguları

Ön işlemlerden ve segmentasyon işleminden geçirilen görüntülerde özellik çıkarımı yapılmıştır. Tablo 4.1. ve Tablo 4.2.'de elde edilen aday nodüllerin özellik değerleri verilmektedir. Kullanılan özellikler 2 boyutlu sistemler için özelleştirildiğinden dolayı ön işlemlerin farkı burada gözlemlenebilmektedir.

Tablo 4.1. Ön işlemlerden geçirilmemiş görüntüden elde edilen özellik değerleri

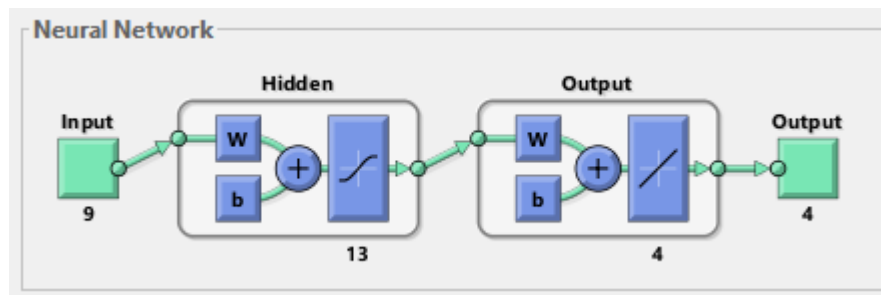
Özellikler	Aday Nodül 1	Aday Nodül 2	Aday Nodül 3
Alan	955	908	826
A.E. Uzunluğu	51,19977706	63,68082736	46,20496099
K.E. Uzunluğu	36,8520752	20,48718811	25,40325361
Dış Merkezlilik	0,05511426	0,946835962	0,835299663
Uyum Sağlama	74,2138669	79,40032345	-12,50319416
Eş Çap	34,7038522	34,00149271	32,42986068
Katılık	0,40770102	0,937048504	0,788167939
Genişlik	0,359698682	0,48042328	0,52245143
Çevre Uzunluğu	281,858	158,854	153,522

Tablo 4.2. Ön işlemlerden geçirilmiş görüntüden elde edilen özellik değerleri

Özellikler	Aday Nodül 1	Aday Nodül 2	Aday Nodül 3
Alan	949	893	836
A.E. Uzunluğu	60,4108743	64,48288807	47,85522055
K.E. Uzunluğu	33,6930562	19,35533588	27,35519796
Dış Merkezlilik	0,830021333	0,953888126	0,820515615
Uyum Sağlama	85,53852591	80,48591898	-14,02290959
Eş Çap	34,76067214	33,7194738	32,62557677
Katılık	0,541357673	0,947983015	0,696086595
Genişlik	0,367260062	0,531547619	0,423076923
Çevre Uzunluğu	254,507	150,294	181,797

4.3. Yapay Sinir Ağı Bulgular

Gerçekleştirilen yapay sinir ağında Sakarya Eğitim ve Araştırma Hastanesi'nden elde edilen veriler kullanılarak oluşturulmuştur. Kullanılan yapay sinir ağının topolojisi 9 giriş, 13 gizli nöron ve 4 çıkıştan oluşmaktadır. Şekil 4.13.'te oluşturulan ağ topolojisi gösterilmektedir.



Şekil 4.13. Yapay sinir ağı topolojisi

Oluşturulan ağ topolojisine kullanılan 304 nodül için çıkarılan özellikler ağa verilir. Yapay sinir ağı kendi içerisinde yaptığı işlemlerden dolayı her seferinde farklı sonuç elde etmektedir. Tablo 4.3.'te 1801 iterasyon ile öğretilen yapay zekâ sonucu verilmiştir. Verilen sonuçlar eğitim sonuçları ile yapay zekanın elde ettiği sonuçları göstermektedir. Etiket kısmı gerçek sonuçlar, skor ise elde edilen genetik algoritma sonuçlarıdır.

Tablo 4.3. Gerçek sonuçlar ile yapay zekâ sonucu karşılaştırması

		SKOR				Total
		Malign	Benign	Bronşlar ve Damarlar	Yanlışlar	
ETİKET	Malign	67	1	3	2	73
	Benign	9	82	5	1	97
	Bronşlar ve Damarlar	0	2	88	1	91
	Yanlışlar	0	1	5	37	43
Total		76	86	101	41	304

Ayrıca bu bölümde kullanılan çekme faktörü yöntemi ile juxtaopleural nodüllerdeki yanlış pozitiflerin eliminasyonu gerçekleştirilmektedir. Bu işlem bize gerçek doğruluk oranını ve duyarlılığı daha yüksek seviyelere çıkarmamızı sağlamıştır.

4.4. Genetik Algoritma Bulguları

Daha önceden oluşturulan yapay sinir ağında elde edilen 186 katsayı genetik algoritma uygulanarak yeni 186 katsayı elde edilmiştir. Bu katsayılar sahip olunan 304 veriye uygulandığında daha az hata oranına sahip yeni bulgular elde edilmiştir. Bulgular Tablo 4.4.'te verilmiştir. Etiket kısmı gerçek sonuçlar, skor ise elde edilen genetik algoritma sonuçlarıdır.

Tablo 4.4. Gerçek sonuçlar ile genetik algoritma uygulanmış sonuçların karşılaştırması

		SKOR				Total
		Malign	Benign	Bronşlar ve Damarlar	Yanlışlar	
ETİKET	Malign	66	3	4	0	73
	Benign	4	92	5	0	97
	Bronşlar ve Damarlar	0	2	89	0	91
	Yanlışlar	1	1	4	40	43
Total		71	98	95	40	304

BÖLÜM 5. TARTIŞMA VE SONUÇ

Bilgisayar destekli tanı ve tespit sistemi görüntü işleme ve yapay zekâ sistemlerinin birleştirilmesi ile elde edilmiştir. Yapay zekâ olarak yapay sinir ağları ve genetik algoritmadan oluşan hibrit bir sistem oluşturulmuştur.

Veri set “Sakarya Eğitim ve Araştırma Hastane” ’sinden temin edilmiştir. Temin edilen veri setten 36 hastadan toplamda 153 görüntü kullanılmıştır. 153 görüntüden toplamda 304 aday nodül elde edilmiştir. Nodüllerin dağılımı ise malign %24,01, benign %31,90, bronşlar ve damarlar %29,93, yanlış bulgular %14,14’tür.


Sistemin görüntü işleme bölümünde her görüntü için adaptif çözümler elde edilmeye çalışılmıştır. Fakat lob segmentasyonu gibi işlemlerde otonom sistem sağlanamamış her görüntü için lob seçme işlemi gerçekleştirilmiştir.

Yanlış pozitif olarak bulunan yanlış değerler, verii setteki kullanılan verilerde bulunan büyük kısmının juxtapleural nodül olmasından kaynaklıdır. Yanlış pozitiflerin azaltılması için voksel değerlerinde bulunan nodülleri karşılaştırmak ya da 3-B kontur yöntemlerinin kullanılması gerekmektedir.


Özellik çıkarımı yapılırken 2-B için ayırt edici morfolojik özellikler seçilmiştir. Özellik çıkarımı için hem morfolojik hem de istatistiksel özellikler bir arada kullanılabilir. Fakat sistem yeterliliği açısından morfolojik özellikler yeterlidir.

Sistemin gerçek sonuçları elde edilirken radyoloji biriminden faydalanılmıştır. Ayrıca gerçek verilerde hata yapmamak için görüntü işleme ile tespit edilen bölgeler PET görüntüsü ile karşılaştırılmıştır. Şekil 5.1.’de alınan malign veerilerinin birinin PET-

CT görüntüsü verilmektedir. Şekil 5.1.'de görülen parlak bölümler habis bölgeleri göstermektedir. Tez çalışması akciğer lobları içerisindeki kanserleri teşhis etmeye yöneliktir. Plevra dışında bulunan birincil ya da metastatik malign bölge çalışmaya dahil edilmemiştir. Şekil 5.2.'de ise BT görüntüsü üzerinde görüntü işleme yöntemleri ile elde edilen aday nodül bölgesi gösterilmiştir.



Şekil 5.1. PET görüntüsü



Şekil 5.2. BT Görüntüsü üzerinde görüntü işleme işlemleri ile elde edilen aday nodül

Yapay sinir ağlarına oluşturulan özellik çıkarımı ve gerçek sonuçlar verilmiştir. Yapay sinir ağı, 1801 iterasyon ile öğretildiğinde elde edilen katsayılar giriş birimine uygulanmıştır. Sonuç olarak %92,105 doğruluk elde edilmiştir. Yapay sinir ağı bir sınıflandırma yaptığı için elde edilen sınıfların ayrı ayrı olarak özgünlük ve duyarlılık değerleri hesaplanmıştır. Yapay zekadan elde edilen sonuçlar tam değerler (0-1 arasında) olmadığı için uygunlaştırma işlemi yapılmıştır. Özgünlük ve duyarlılık değerleri uygunlaştırmaya göre hesaplanmıştır.

Yapay sinir ağında çıkış olarak 4 sınıf elde edilmiştir. Bu sınıflar sırasıyla; malign, benign, bronşlar ve damarlar ve yanlışlardır. Tablo 5.1.'de malign değerler için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.1. Malign değerler için gerçek sonuçlar ve yapay zekâ sonucu karşılaştırılması

		YSA SONUÇ		
		Malign Olmayan	Malign	Total
ETİKET	Malign Olmayan	222	9	231
	Malign	8	65	73
Total		230	74	304

Malign için duyarlılık: 0,87837 özgünlük: 0,96521 olarak bulunmuştur. Tablo 5.2.'de benign değerler için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.2. Benign değerler için gerçek sonuçlar ve yapay zekâ sonucu karşılaştırılması

		YSA SONUÇ		
		Benign Olmayan	Benign	Total
ETİKET	Benign Olmayan	203	4	207
	Benign	11	86	97
Total		214	90	304

Benign için duyarlılık: 0,95555 özgünlük: 0,94859 olarak bulunmuştur. Tablo 5.3.'te bronşlar ve damarlar için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.3. Bronşlar ve Damarlar için gerçek sonuçlar ve yapay zeka sonucu karşılaştırılması


		YSA SONUÇ		
		BvD. Olmayan	Bronşlar ve Damarlar	Total
ETİKET	BvD. Olmayan	205	8	213
	Bronşlar ve Damarlar	3	88	91
Total		208	96	304

Bronşlar ve damarlar için duyarlılık: 0,91666 özgünlük: 0,98557 olarak bulunmuştur. Tablo 5.4.'te yanlış değerler için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.4. Yanlış değerler için gerçek sonuçlar ve yapay zekâ sonucu karşılaştırılması

		YSA SONUÇ		
		Yanlış Olmayan	Yanlış	Total
ETİKET	Yanlış Olmayan	258	3	261
	Yanlış	2	41	43
Total		260	44	304

Yanlış değerler için duyarlılık: 0,93181 özgünlük: 0,99230 olarak bulunmuştur. 4 sınıf içinde elde edilen özgünlük ve duyarlılık değerleri tam doğruluk göstermemektedir. Bu değerler bulunurken yapay sinir ağı sonuçları uygunlaştırılmıştır. Bu yüzden ROC eğrisinden alacağımız optimum kesim noktası cevabı “0,5” olacaktır ve elde edilen ROC eğrisi yanlış olacaktır. Bu sebeple yapay sinir ağının çıktılarını değerleri uygunlaştırılmadan ROC eğrisi çizdirilmiş ve optimum kesim noktası seçilmiştir.



Şekil 5.3. YSA sınıfların roc eğrileri (class 1=malign, class 2=benign, class 3=bronşlar ve damarlar, class 4=yanlışlar)

Genel ROC eğrisi altında kalan (AUC) alanı bulmak için elde edilen bütün ROC eğrilerinin alanları toplanır ve sınıf sayısına bölünür. Şekil 5.3.’te sınıflar için bulunan ROC eğrileri gösterilmektedir. Tablo 5.5.’te eğrilerin altında kalan alan, eğrilerin altında kalan genel alan ve optimum kesim noktaları belirlenmiştir.

Optimum kesim noktaları ile sınıflara ait optimum duyarlılık ve 1-özgünlük değerleri elde edilmiştir.

Tablo 5.5. YSA ROC eğrisi altında kalan toplam alanlar ve seçilen optimum kesim noktaları

	Eğri Altındaki Alan (AUC)	Duyarlılık	1-Özgünlük	Optimum Kesim Noktası
Malign	0,981	0,959	0,087	0,27466
Benign	0,970	0,928	0,024	0,43614
Bronşlar ve Damarlar	0,992	0,978	0,042	0,38902
Yanlışlar	0,996	0,953	0,011	0,45613
Genel Alan	0,9847			

Yapay sinir ağında elde edilen sonuçların doğruluğunu arttırmak için genetik algoritma uygulanır. Yapay sinir ağında toplamda 186 katsayı elde edilmiştir. Bu katsayılar genetik algoritma ile iyileştirilerek %92,105'ten %94,407 doğruluk oranına yükseltilmiştir. Sonuç olarak elde edilen değerler tam yapay zekada olduğu gibi tam değerler (0-1) olmadığı için uygunlaştırma işlemi burada tekrar edilmiştir. Özgünlük ve duyarlılık değerleri uygunlaştırılmış değerlere göre hesaplanmıştır.

Yapay sinir ağı katsayıları genetik algoritma ile iyileştirilerek yeni sonuçlar elde edilmiştir. Elde edilen yeni sonuçların tablolar ile gösterilmiştir. Tablo 5.6.'da malign değerler için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.6. Malign değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması

		GA SONUÇ		
		Malign Olmayan	Malign	Total
ETİKET	Malign Olmayan	226	5	231
	Malign	7	66	73
Total		233	71	304

Malign için duyarlılık: 0,92957 özgünlük: 0,96995 değerleri bulunmuştur. Tablo 5.7.'de benign değerler için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.7. Benign değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması

		GA SONUÇ		
		Benign Olmayan	Benign	Total
ETİKET	Benign Olmayan	201	6	207
	Benign	5	92	97
Total		206	98	304

Benign için duyarlılık: 0,96877 özgünlük: 0,97572 değerleri bulunmuştur. Tablo 5.8.'de bronşlar ve damarlar için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.8. Bronşlar ve damar değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması

		GA SONUÇ		
		BvD. Olmayan	Bronşlar ve Damarlar	Total
ETİKET	BvD. Olmayan	207	6	213
	Bronşlar ve Damarlar	2	89	91
Total		209	95	304


Bronşlar ve damarlar için duyarlılık: 0,93684 özgünlük: 0,99043 değerleri bulunmuştur. Tablo 5.9.'da malign değerler için; TP, TN, FP ve FN değerleri gösterilmiştir.

Tablo 5.9. Yanlış bulunan değerler için gerçek sonuçlar ve genetik algoritma uygulanmış sonucu karşılaştırılması

		GA SONUÇ		
		Yanlış Olmayan	Yanlış	Total
ETİKET	Yanlış Olmayan	261	0	261
	Yanlış	3	40	43
Total		264	40	304

Yanlış değerler için duyarlılık: 1 özgünlük: 0,98863 değerleri bulunmuştur. 4 sınıf içinde elde edilen özgünlük ve duyarlılık değerleri yapay sinir ağında olduğu gibi tam doğruluk göstermemektedir. Bu değerler bulunurken genetik algoritma sonuçları uygunlaştırılmıştır. Bu yüzden ROC eğrisinden alacağımız optimum kesim noktası cevabı "0,5" olacaktır ve elde edilen ROC eğrisi yanlış olacaktır. Bu sebeple genetik

algoritma çıktıları değerleri uygunlaştırılmadan ROC eğrisi çizdirilmiş ve optimum kesim noktası seçilmiştir.



Şekil 5.4. GA Sınıfların ROC eğrileri (class 1=Malign, class 2=Benign, class 3=Bronşlar ve Damarlar, class 4=Yanlışlar)

Genel ROC eğrisi altında kalan (AUC) alanı bulmak için elde edilen bütün ROC eğrilerinin alanları toplanır ve sınıf sayısına bölünür. Şekil 5.4.'te sınıflar için bulunan ROC eğrileri gösterilmektedir. Tablo 5.10.'da eğrilerin altında kalan alan, eğrilerin altında kalan genel alan ve optimum kesim noktaları belirlenmiştir. Optimum kesim noktaları ile sınıflara ait optimum duyarlılık ve 1-özgünlük değerleri elde edilmiştir.

Tablo 5.10. GA ROC eğrisi altında kalan toplam alanlar ve seçilen optimum kesim noktaları

	Eğri Altındaki Alan (AUC)	Duyarlılık	1-Özgünlük	En İyi Kesim Noktası
Malign	0,985	0,973	0,065	0,37850
Benign	0,972	0,959	0,087	0,35777
Bronşlar ve Damarlar	0,988	0,956	0,023	0,60277
Yanlışlar	0,949	0,884	0,111	0,34968
Genel Alan	0,9735			

Tablo 5.10.'da elde edilen deęerler ve genetik algoritmanın doęruluk sonucu oluşturulan bilgisayar destekli tanı ve tespit sisteminin genel sonuçlarıdır. Genetik algoritmadan alınan sonuç %94,407'dir.

KAYNAKLAR

- [1] Ferlay, J., Soerjomataram, I., Ervik, M., Dikshit, R., Eser, S., Mathers, C., Rebelo, M., Parkin, D.M., Forman, D., Bray, F., GLOBOCAN 2012 v1.0, Cancer Incidence and Mortality Worldwide: IARC CancerBase No.11-Lyon, France: International Agency for Research on Cancer; 2013.
- [2] Türk Halk Sağlık Kurumu, 2014, TÜRKİYE KANSER İSTATİSTİKLERİ, Erişim Adresi: <http://kanser.gov.tr/index.php/daire-faaliyetleri/kanser-istatistikleri/2106-2014-yılı-türkiye-kanser-istatistikleri>, Erişim Tarihi: 26.04.2018.
- [3] Celal, K., Funda, Ö., Zeynep, A., Metin, Ö. ve Osman, Ö., Tütün Kontrolü, Toraks Dergisi, 7(1): 51-64, 2006.
- [4] Yi, C.A., Shin, K.M., Lee, K.S., Kim, B.T., Kwon, O.J., Choi, J.Y. ve Chung, M.J., Non-small cell lung cancer staging: Efficacy comparison of integrated PET/CT versus 3.0-T whole-body MR imaging, Radiology 248(2), 632–642, 2008.
- [5] Sharma, R., Tripathi, M., D’Souza, M., diğ., The importance of 18F-FDG PET/CT, CT and X-rays in detecting primary stage III A lung cancer and the incidence of extra thoracic metastases. Hell J Nucl Med., 22–25, 2009.
- [6] Gomathi, M. ve Thangaraj, P., Computer aided diagnosis system for detection of lung cancer nodules using extreme learning machine. Intl. J. Engg. Sci. & Technol. 2(10), 5770-5779, 2010.
- [7] Way, T.W., Computer Aided Diagnosis of Pulmonary Nodules in Thoracic Computed Tomography, 2008.
- [8] Doi, K., Computer-aided diagnosis in medical imaging: historical review, current status and future potential., Comput. Med. Imaging Graph., vol. 31, no. 4–5, 198–211, 2008.
- [9] Türk Halk Sağlık Kurumu Kanser Nedir, Erişim Adresi: <http://www.kanser.saglik.gov.tr>, Erişim Tarihi: 26.04.2018.
- [10] American Cancer Society, 2018, Lung Cancer (Non-Small Cell), Erişim Adresi: <https://www.cancer.org/cancer/non-small-cell-lung-cancer.html>, Erişim Tarihi: 26.04.2018.

- [11] Kostis, W.J., diğ., Small pulmonary nodules: reproducibility of three-dimensional volumetric measurement and estimation of time to follow-up, *Radiology*, Vol. 231, 446-52, 2004.
- [12] Reeves, A., Chan, A., Yankelevitz, D., Henschke, C., Kressler, B., ve Kostis, W., On measuring the change in size of pulmonary nodules, *IEEE Transactions on Medical Imaging*, vol. 25, 435–450, Nisan 2006.
- [13] Ünal, D., *Tıpta Kullanılan Görüntüleme Teknikleri*, Gazi Üniversitesi Eğitim Fakültesi, Lisans Tezi, 2008.
- [14] Ulaş, M. ve Boyacı, A., DICOM Görüntü Standardı, *Akademik Bilişim'07-IX. Akademik Bilişim Konferansı Bildirileri*, 2: 69-74, 2007.
- [15] DICOM, 2018, DICOM Overview, Erişim Adresi: <https://www.dicomstandard.org>, Erişim Tarihi: 26.04.2018.
- [16] Buzug, T.M., *Computed Tomography: From Photon Statistics to Modern ConeBeam CT*, ch. 3. Berlin: Springer, 2008.
- [17] N.C. Institute, Lung cancer trial results show mortality benefit with lowdose CT., Press release, Kasım 2010.
- [18] Uğur, Ö., *Pozitron Emisyon Tomografisi*, XIII. TPOG Ulusal Pediatrik Kanser Kongresi, s.4, 2004.
- [19] Cambron, N.C., *CAD SYSTEM FOR LUNG NODULE ANALYSIS*, B.S., University of Louisville, Yüksek Lisans Tezi, 2011.
- [20] Armato, G., McLennan, McNitt-Gray, G., Meyer, C.R., Yankelevitz, D., Aberle, D.R., Henschke, C.I., Hoffman, E.A., Kazerooni, E.A., MacMahon, H., Reeves, A.P., Croft, B.Y., ve Clarke, L.P., Lung image database consortium: developing a resource for the medical imaging research community, *Radiology*, vol. 232, no. 3, 739–748, 2004.
- [21] Ginneken, B.V., Romeny, B.M., ve Viergever, M.A., Computer-aided diagnosis in chest radiography: a survey, *IEEE Transactions on Medical Imaging* 20, 1228-1240, Aralık 2001.
- [22] Zhang, X., *COMPUTER AIDED DETECTION OF PULMONARY NODULES IN HELICAL CT IMAGES*, Iowa Üniveresitesi, Doktora Tezi 3-5, Aralık 2005.
- [23] Armato, S., Sensakovic, W., Automated lung segmentation for thoracic ct. *Academic Radiology* 11, 1011–1021, 2004.

- [24] Brown, M., McNitt-Gray, M., Mankovich, N., Goldin, J., Hiller, J., Wilson, L., Aberle, D., Method for segmenting chest ct image data using an anatomical model: Preliminary results. *IEEE Transactions on Medical Imaging* 16, 828–839, 1997.
- [25] Hu, S., Hoffman, E., Reinhardt, J., Automatic lung segmentation for accurate quantitation of volumetric x-ray ct images. *IEEE Transactions on Medical Imaging* 20, 490–498, 2001.
- [26] Leader, J., Zheng, B., Rogers, R., Scieurba, F., Perez, A., Chapman, B., Patel, S., Fuhrman, C., Gur, D., Automatic lung segmentation for accurate quantitation of volumetric x-ray ct images. *Academic Radiology* 10, 1224–1236, 2003.
- [27] Silva, A., Silva, J., Santos, B., Ferreira, C., Fast pulmonary contour extraction in x-ray ct images: A methodology and quality assessment. In: *SPIE*. Volume 4321, 216–224, 2001.
- [28] Li, B., Reinhardt, J., Automatic generation of 3-d shape models and their application to tomographic image segmentation. In: *SPIE*. Volume 4322 of *Medical Imaging*, 311–322, 2001.
- [29] Zhou, J., Chang, S., Metaxas, D., Zhao, B., Ginsberg, M., Schwartz, L., Automatic detection and segmentation of large lung cancers from chest ct images. *Workshop of 11th International conference on Medical Image Computing and Computer Assisted Intervention*, 2008.
- [30] Kirbas, C., Quek, F., A review of vessel extraction techniques and algorithms. *ACM Comput. Surv.* 36(2), 81–121, 2004.
- [31] Antonelli, M., Frosini, G., Lazzerini, B., ve Marcelloni, F., A CAD system for Lung nodule detection based on an anatomical model and a fuzzy neural network, in *Annual meeting of Fuzzy Information Processing Society*, 448-453, 2006.
- [32] Croisille, C., Souto, M., Cova, M., Wood, S., Afework, Y., Kuhlman, J.E. ve Zerhouni, E.A., Pulmonary nodules: Improved detection with vascular segmentation and extraction with spiral CT, *Radiology*, vol. 197, 397-401, 1995.
- [33] Tozaki, T., Kawata, Y., Niki, N., Ohmatsu, H., Eguchi, K., ve Moriyama, N., Three-dimensional analysis of lung area using thin slice CT images, in *Proceedings SPIE Medical Imaging*, vol. 2709, 2-11, 1996.
- [34] Giger, M.L., Bae, K.T. ve MacMahon, H., Computerized detection of pulmonary nodules in computed tomography images, *Investig. Radiology*, vol. 29, 459-465, 1994.

- [35] Armato, S.G., Giger, M.L., Moran, C.J., Blackburn, J.T., Doi, K. ve MacMahon, H., Computerized detection of pulmonary nodules on CT scans, *Radiographics*, vol. 19, 1303-1311, 1999.
- [36] Kanazawa, K., Kawata, Y., Niki, N., Satoh, H., Ohmatsu, H., Kakinuma, R., Kaneko, M., Moriyama, N., ve Eguchi, K., Computer-aided diagnostic system for pulmonary nodules based on helical CT images, *Computer-Aided Diagnosis Medical Imaging*, Eds. Amsterdam, The Netherlands: Elsevier, 131-136, 1999.
- [37] Fiebach, M., Wietholt, C., Renger, B.C., Armato, S.G., Hoffman, K.R., Wormanns, D. ve Diederich, S., Automatic detection of pulmonary nodules in low-dose screening thoracic CT examinations, in *Proceedings Medical Imaging, SPIE*, vol. 3661, 1434-1439, 1999.
- [38] Brown, M.S., McNitt-Gray, M.F., Goldin, J.G., Suh, R.D., Sayre, J.W., ve Aberle, D.R., Patient-specific models for lung nodule detection and surveillance in CT images, *IEEE Transactions on Medical Imaging*, vol. 20, 1242-1250, 2001.
- [39] MATLAB, Convert RGB Image to Grayscale Image, Erişim Adresi: <https://in.mathworks.com/help/matlab/ref/rgb2gray.html>, Erişim Tarihi: 26.04.2018.
- [40] Chen T., Kai-Kuang M. ve Li-Hui C., Tri-state median filter for image denoising. *IEEE Transactions on Image Processing*, 8(12), 1834-1838.
- [41] Polesel A., Ramponi G., ve John V., Image Enhancement via Adaptive Unsharp Masking, *IEEE TRANSACTIONS ON IMAGE PROCESSING*, VOL. 9, NO. 3, 505-510. Mart 2000.
- [42] Shrivakshan, G.T., Chandrasekar, C., A Comparison of various Edge Detection Techniques used in Image Processing, *IJCSI International Journal of Computer Science Issues*, Vol. 9, Issue 5, No1, 269-275, Ekim 2012.
- [43] Otsu, N., A Threshold Selection Method from GrayLevel Histograms, *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 9, No. 1. 62-66, 1979.
- [44] Miss Hetal J.V., Prof. Astha B., A Review on Otsu Image Segmentation Algorithm, *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)* 2- 2, ISSN: 2278 – 1323, Şubat 2013.
- [45] Ross, J.C., Estépar, R.S., Diaz A., Westin, C.F., Kikinis, R., Silverman, E.K. ve Washko, G.R., Lung extraction, lobe segmentation and hierarchical region assessment for quantitative analysis on high resolution computed tomography images, in *Proceedings of the International Conference on Medical Imaging Computing and Computer-Assisted Intervention (MICCAI'09)*, 5762: 690–698, 2009.

- [46] Gerard, J., Kleywegt, T., Alwyn J., Detection, Delineation, Measurement and Display of Cavities in Macromolecular Structures, *Acta Cryst. DS0*, 178-185, 1994.
- [47] MATLAB, 2018, Boundary of set points, Erişim Adresi: <https://in.mathworks.com/help/matlab/ref/boundary.html>, Erişim Tarihi: 26.04.2018.
- [48] Sensakovic, W.F., Starkey, A. ve Armato, S.G., A general method for the identification and repair of concavities in segmented medical images, *IEEE Nuclear Science Symposium Konferans kayıt tarihi*, 53205326, 2008
- [49] Math Works Inc., Matlab R2017b documentation, Erişim Adresi: <http://in.mathworks.com/help/index.html>, Erişim Tarihi: 26.04.2018.

ÖZGEÇMİŞ

Enes ÇAKAR, 27.08.1994'te Eskişehir'de doğdu. İlkokul eğitimini Eskişehir'de, orta ve lise eğitimini Bursa'da tamamladı. 2012 yılında Nilüfer Anadolu Lisesi'nden mezun oldu. 2012 yılında başladığı Sakarya Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü'nü 2016 yılında bitirdi. 2016 yılında Sakarya Üniversitesi Biyomedikal Mühendisliği Bölümü'nde yüksek lisans eğitimine başladı. 2018 yılında Sakarya Üniversitesi'nde yüksek lisans eğitimine Sakarya Üniversitesi Biyomedikal Mühendisliği Bölümü'nde devam etmektedir.