



**TİMPANİK MEMBRAN GÖRÜNTÜ ANALİZİ VE
YAPAY ZEKA KULLANILARAK SANAL OTİTİS
MEdİA TANI SİSTEMİNİN GELİŞTİRİLMESİ**

Erdal BAŞARAN

**2020
DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Yüksel ÇELİK**

**TİMPANİK MEMBRAN GÖRÜNTÜ ANALİZİ VE YAPAY ZEKA
KULLANILARAK SANAL OTİTİS MEDIA TANI SİSTEMİNİN
GELİŞTİRİLMESİ**

Erdal BAŞARAN

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Doktora Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Yüksel ÇELİK**

**KARABÜK
Haziran 2020**

Erdal BAŞARAN tarafından hazırlanan “TİMPANİK MEMBRAN GÖRÜNTÜ ANALİZİ VE YAPAY ZEKA KULLANILARAK SANAL OTİTİS MEDİA TANI SİSTEMİNİN GELİŞTİRİLMESİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Yüksel ÇELİK

Tez Danışmanı, Bilgisayar Mühendisliği

Dr. Öğr. Üyesi Zafer CÖMERT

İkinci Danışmanı, Samsun Üniversitesi Yazılım Mühendisliği

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 30/06/2020

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. Mehmet HACİBEYOĞLU (NEÜ)

Üye : Dr. Öğr. Üyesi Yüksel ÇELİK (KBÜ)

Üye : Prof. Dr. Oğuz FINDIK (KBÜ)

Üye : Dr. Öğr. Üyesi Muhammed Kamil TURAN (KBÜ)

Üye : Dr. Öğr. Üyesi Zafer ALBAYRAK (KBÜ)

Üye : Dr. Öğr. Üyesi Abdulkadir KARACI (KÜ)

Üye : Dr. Öğr. Üyesi Zafer CÖMERT (SAMU)

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Erdal BAŞARAN

ÖZET

Doktora Tezi

TİMPANİK MEMBRAN GÖRÜNTÜ ANALİZİ VE YAPAY ZEKA KULLANILARAK SANAL OTİTİS MEDIA TANI SİSTEMİNİN GELİŞTİRİLMESİ

Erdal BAŞARAN

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Yüksel ÇELİK

İkinci Tez Danışmanı:

Dr. Öğr. Üyesi Zafer CÖMERT

Haziran 2020, 125 sayfa

Otitis media, orta kulakta bulunan kulak zarı arkasında sıvı birikmesi sonucu oluşan iltihaplanma olarak tanımlanmaktadır. Her yıl dünya genelinde yaklaşık 740 milyon insan bu rahatsızlığı geçirmektedir. Otitis media aynı zamanda klinik olarak, hastalara en fazla antibiyotik tedavisi reçete edilen hastalıklardan biridir. Bu hastalık erken teşhisi yapılmadığı ve tedavi edilmediği takdirde hayat kalitesinde düşüslere, bilişsel rahatsızlıklara hatta işitme duyusunun bile yitirilmesine sebep olabilmektedir. Otitis media hastalığının teşhis edilebilmesi için uzman tarafından otoskop cihazı ile kulak zarının detaylı bir şekilde analiz edilmesi gerekmektedir. Hastaların her zaman deneyimli bir kulak burun boğaz uzmanına ulaşamaması ya da hatalı muayenelerden

dolayı hatalı sonuçlar ya da yanlış yorumlamalar ortaya çıkabilmektedir. Bu çalışmada yapay zeka metodları kullanılarak orta kulak görüntülerinde zar bölgesinin tespit edilmesi ve otitis media hastalığının teşhis edilebilmesine çalışılmıştır. Yapılan çalışmada ilk olarak özgün bir veri seti oluşturulup, görüntülere ait öznelikler gri seviyeli eş oluşum matrisi, yerel ikili örüntü, yönlü gradyanların histogramı ve renk kanallarının ortalaması elde edildikten sonra yapay sinir ağları, destek vektör makineleri, kNN gibi klasik makine öğrenme yöntemleri ile sınıflandırma yapılmıştır. Daha sonra zar bölgesinin tespit edilmesi için derin öğrenme tabanlı Faster R-CNN ve YOLO yöntemleri kullanılmıştır. Sonuç olarak; zar bölgesi %93 doğruluk oranı ile tespit edilmiştir. Özgün bir model önerisi literatüre kazandırılarak orta kulak görüntülerinde zar bölgesini otomatik tespit eden ve zar bölgesi parçaları ile beslenen derin öğrenme temelli transfer öğrenme modelleri ile görüntüler % 90 doğruluk oranı ile sınıflandırılmıştır.

Anahtar Sözcükler : Otitis media, kulak zarı, biyomedikal işaret işleme, özellik çıkarma, bölge tespiti, yapay öğrenme, makine öğrenmesi, derin öğrenme, karar destek sistemleri

Bilim Kodu : 92432

ABSTRACT

Ph. D. Thesis

DEVELOPING OF VIRTUAL OTITIS MEDIA DIAGNOSTIC SYSTEM USING TYMPANIC MEMBRANE IMAGE ANALYSIS AND ARTIFICIAL INTELLIGENCE

Erdal BAŞARAN

Karabük University

Institute of Graduate Programs

Department of Computer Engineering

Thesis Advisor:

Assist. Prof. Dr. Yüksel ÇELİK

Co-Advisor:

Assist. Prof. Dr. Zafer CÖMERT

June 2020, 125 pages

Otitis media is the general name for inflammation caused by the accumulation of fluid behind the eardrum in the middle ear. Every year, 740 million people worldwide suffer from this ailment. Otitis media is also one of the most commonly prescribed antibiotic treatments in patients coming in clinically. This disease can cause loss of hearing even if it is not diagnosed and treated early. In order to diagnose otitis media disease, it is necessary to analyze the eardrum in detail with an otoscope device. Inaccurate results or misinterpretations may occur due to patients not always reaching an experienced otolaryngologist or due to incorrect examinations. In this study, it was tried to detect the membrane region of the middle ear images and to diagnose otitis media disease by

using artificial intelligence methods. In this study, firstly, a unique data set was created, and after the attributes of the images were obtained with gray level co-matrix, local binary pattern, histogram of directional gradients and average of color channels, classification was done with classical machine learning methods such as artificial neural networks, support vector machines, kNN. Then, deep learning based Faster R-CNN and YOLO methods were used to cross the membrane region. As a result; The membrane region was determined with 93% accuracy rate. By introducing an original model proposal to the literature, images are classified with 90% accuracy rate with deep learning based transfer learning models that automatically detect the membrane region in the middle ear images and feed on the membrane region parts.

Key Word : Otitis media, eardrum, biomedical signal processing, feature extraction, region detection, artificial learning, machine learning, deep learning, decision support systems.

Science Code :92432

TEŞEKKÜR

Bu tez konusunun belirlenmesinde, çalışmanın planlanmasında, araştırma sürecinde, yürütülmesinde ve tamamlanmasında desteğini ve ilgisini esirgemeyen, derin bilgi ve birikimlerinden faydalandığım, yönlendirmeleri ve katkılarıyla tezimi bilimsel temeller üzerinde şekillendiren, akademik olarak çok şey öğrenerek mesleki gelişimime önemli katkılar sağlayan çok değerli sayın danışman hocalarım Dr. Öğr. Üyesi Yüksel ÇELİK ve Dr. Öğr. Üyesi Zafer CÖMERT' e sonsuz şükranlarımı sunarım.

Tez çalışmam süresince kıymetli değerlendirme ve önerileriyle desteklerini sunan sayın hocalarım Doç. Dr. Oğuz FINDIK ve Dr. Öğr. Üyesi Muhammed Kamil TURAN' a teşekkürlerimi sunarım.

Doktora eğitimi süresinde değerli katkılarından dolayı Karabük Üniversitesi Bilgisayar Mühendisliği Bölümü tüm öğretim elemanlarına teşekkürlerimi sunarım. Doktora süresince bu tez kapsamında görüşlerinden faydalandığım Fırat Üniversitesi Teknoloji Fakültesi öğretim üyesi Prof. Dr. Abdülkadir ŞENGÜR ve Bitlis Eren Üniversitesi Elektrik Elektronik Mühendisliği öğretim üyesi Dr. Öğr. Üyesi Ümit BUDAK' a teşekkür ederim.

Verilerin toplanmasında emeği geçen Özel Van Akdamar Hospital çalışanlarına teşekkür ederim.

Yaşamım boyunca sevgi ve saygılarını esirgemeyen değerli aileme ve eşime teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ	xvi
SİMGELER VE KISALTMALAR DİZİNİ	xix
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	4
LİTERATÜR ARAŞTIRMASI	4
BÖLÜM 3	11
KULAK YAPISI VE OTİTİS MEDIA.....	11
3.1. KULAK.....	11
3.2. DIŞ KULAK	12
3.2.1 Kulak Kepçesi (Aurikula, pinna)	12
3.2.2 Dış Kulak Yolu (Acusticus Externus)	12
3.2.3 Otit Externa (Dış Kulak Yolu İltihabı)	12
3.3. ORTA KULAK (AURIS MEDIA)	13
3.3.1. Kulak Zarı (Tympanic Membrane).....	13

	<u>Sayfa</u>
3.3.2. Orta Kulak Boşluğu (Cavum Timpani)	15
3.3.3. Kemikçikler (Ossicles)	15
3.3.4. Östaki Borusu	16
3.4. OTİTİS MEDIA	16
3.4.1. Akut Otitis Media (AOM)	17
3.4.2. Efüzyonlu Otitis Media (EOM)	19
3.4.3. Kronik Otitis Media (KOM)	20
3.4.3.1. Kronik Basit Otitis Media	21
3.4.3.2. Kronik Mukozal Otitis Media	22
3.4.3.3. Kronik Kolestomatolu Otitis Media	22
3.4.3.4. Adeziv Otit ve Retraksiyon Poşları	22
3.4.4. Timpanozkleros	22
BÖLÜM 4	23
MATERYAL VE METOD	23
4.1. KULLANILAN VERİSETİ	23
4.2. VERİ ARTTIRMA	25
4.3. GÖRÜNTÜ İŞLEME TEKNİKLERİ	27
4.3.1. RGB Renk Kanalı	27
4.3.2. Uyarlanabilir Histogram Eşikleme	27
4.3.3. Gauss ve Tuz-Biber Gürültüsü	28
4.4. GÖRÜNTÜ ÖZNETELİKLERİNİN ELDE EDİLMESİ	28
4.4.1. Gri Seviyeli Eş-Oluşum Matrisi	29
4.4.2. Yerel İkili Örüntü	30
4.4.3. Yönlü Gradyan Histogramı	32
4.5. YAPAY SİNİR AĞLARI	32
4.6. K-EN YAKIN KOMŞU	33
4.7. DESTEK VEKTÖR MAKİNELERİ	34
4.8. ZAR BÖLGESİNİN TESPİTİ	36
4.8.1. Faster R-CNN	36
4.8.2. YOLO	38
4.9. EVRİŞİMSEL SİNİR AĞLARI	39
4.9.1. Giriş Katmanı	40

	<u>Sayfa</u>
4.9.2. Evrişim Katmanı (Convolution)	41
4.9.3. Havuzlama Katmanı (Pooling)	42
4.9.4. Tam Bağlı Katmanı (Fully Connected Layer)	43
4.10. ESA'NIN EĞİTİLMESİ.....	43
4.10.1. Aktivasyon Fonksiyonu	43
4.10.1.1. Sigmoid	44
4.10.1.2. Hiperbolik Tanjant	44
4.10.1.3. Relu (Rectified Linear Unit)	45
4.10.1.4. Softmax	46
4.10.2. Seyreltme katmanı (Dropout)	46
4.10.3. Mini-Batch Değeri	47
4.10.4. Epoch	48
4.10.5. Öğrenme Oranı	48
4.10.6. Optimizasyon Algoritmaları	48
4.10.6.1. Gradyan azalma (Gradient Descent)	49
4.10.6.2. Adagrad (Adaptive Gradient)	50
4.10.6.3. Adadelta	51
4.10.6.4. Karekök Ortalama Yayılımı (RMSProp)	51
4.10.6.5. Uyarlanabilir Moment Tahmini (ADAM)	52
4.11. TRANSFER ÖĞRENME	52
4.11.1. AlexNet.....	53
4.11.2. VGGNet.....	54
4.11.3. GoogLeNet.....	54
4.11.4. ResNet.....	55
4.12. PERFORMANS ÖLÇÜTLERİ	56
4.12.1. Karmaşıklık Matrisi	56
4.12.2. Alıcı İşlem Karakteristiği (AİK).....	58
4.12.3. K-Katlı Çapraz Doğrulama.....	59
 BÖLÜM 5	 60
BULGULAR ve TARTIŞMA.....	60
5.1. ÖZNİTELİK ÇIKARILARAK SINIFLANDIRMA.....	61
5.1.1. YSA ile Normal TM ve AOM TM Görüntülerini sınıflandırma	61

	<u>Sayfa</u>
5.1.2. Yönlü Gradyanların Histogramı ve RKO ile Normal TM ve Anormal TM Sınıflandırılması	65
5.1.3. Yerel İkili Örüntü ve RKO Değeri ile Normal TM ve Anormal TM sınıflandırılması	69
5.1.4. GSEM ve RKO Öznitelikleri ile Normal TM ve Anormal TM İmgelerinin Sınıflandırılması.....	72
5.2. ZAR BÖLGESİNİN TESPİT EDİLMESİ VE DERİN ÖĞRENME İLE TM GÖRÜNTÜLERİNİN SINIFLANDIRILMASI.....	75
5.2.1. YOLO Yöntemi ile Zar Bölgesinin Tespiti	75
5.2.2. Derin ESA yöntemiyle COM ve Normal TM Görüntülerinin Sınıflandırılması	79
5.2.3. Faster-R CNN Yöntemi ile Zar Bölgesinin Tespiti ve Derin ESA TM Görüntülerinin Sınıflandırılması.....	83
BÖLÜM 6	96
SONUÇ VE ÖNERİLER	96
KAYNAKLAR	99
EK AÇIKLAMALAR A. Etik kurulu kararı.....	121
EK AÇIKLAMALAR B. Veri setinin paylaşımı.....	123
ÖZGEÇMİŞ	125

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3. 1. Kulak yapısı	11
Şekil 3. 2. Dış Kulak yolunda otit externa ve buşon (kulak kiri).....	13
Şekil 3. 3. Kulak zarının bölümlere ayrılışı	13
Şekil 3. 4. Kulak zarı.....	14
Şekil 3. 5. TM bölümleri.....	15
Şekil 3. 6. Orta Kulaktaki kemikçikler.....	16
Şekil 3. 7. AOM TM görüntüleri	18
Şekil 3. 8. EOM TM görüntüleri.....	19
Şekil 3. 9. KOM TM görüntüleri	21
Şekil 4. 1. Normal ve anormal TM görüntüleri.....	24
Şekil 4. 2. Arttırılmış TM görüntüleri.....	26
Şekil 4. 3. Normal TM ve ortalama RGB değeri alınmış görüntü	27
Şekil 4. 4. Gri renkli ve UHE uygulanmış hali	28
Şekil 4. 5. Normal ve gauss, tuz-biber gürültülü TM	28
Şekil 4. 6. GSEM örneği	29
Şekil 4. 7. YİÖ Hesaplanması	31
Şekil 4. 8. a) $P=8, r=1$ b) $P=18, r=2$ c) $P=24, r=3$	31
Şekil 4. 9. Hücre ve histogram yönlendirme gradyanı.....	32
Şekil 4. 10. YSA nöron modeli	33
Şekil 4. 11. DVM' de en büyük aralıklı sınıflandırma	35
Şekil 4. 12. Faster R-CNN diagramı	37
Şekil 4. 13. BÖK blok diagramı.....	38
Şekil 4. 14. TM'nin YOLO ile tespit edilmesi	39
Şekil 4. 15. Evrişim işlemi	41
Şekil 4. 16. Havuzlama örneği (adım sayısı ve boyutu:2)	42
Şekil 4. 17. Sigmoid aktivasyon fonksiyonu	44
Şekil 4. 18. Tanjant hiperbolik aktivasyon fonksiyonu	45
Şekil 4. 19. Relu aktivasyon fonksiyonu.....	46
Şekil 4. 20. Standart sinir ağı	47

Şekil 4. 21. Seyreltme işleminden sonra.....	47
Şekil 4. 22. Momentum kullanılarak SGD.....	50
Şekil 4. 23. Momentum kullanılmadan SGD.....	50
Şekil 4. 24. AlexNet Mimarisi	53
Şekil 4. 25. VGG16 mimarisi.....	54
Şekil 4. 26. GoogLeNet'te kullanılan inception mimarisi	55
Şekil 4. 27. Kalıntı bloğu	56
Şekil 4. 28. Karmaşıklık Matrisi	57
Şekil 4. 29. AİK eğrisi	58
Şekil 4. 30. k-katlı çapraz doğrulama.....	59
Şekil 5. 1. Normal ve AOM örneğin görüntü işlemeden önceki ve sonraki hali	61
Şekil 5. 2. Önerilen modelin blok diagramı	62
Şekil 5. 3. Gizli katmandaki nöronların başarı sonuçları	64
Şekil 5. 4. Önerilen modelin AİK eğrisi	65
Şekil 5. 5. Veri setinde yer alan görüntülerin R,G,B kanallarına ait ortalama değerleri	66
Şekil 5. 6. YGH özellikleri ile AİK eğrisi (5-katlı çapraz doğrulama).....	68
Şekil 5. 7. YİÖ + RKO özellikleri ile DVM yöntemiyle sınıflandırma modeline ait AİK eğrisi.....	71
Şekil 5. 8. GSEM ve RKO özellikleri ile Anormal ve Normal TM görüntülerinin ayrılması modeline ait AİK eğrisi	74
Şekil 5. 9. YOLO yöntemi ile zar bölgesinin tespit edilmesi.....	75
Şekil 5. 10. Kesinlik-Hassasiyet Eğrileri (%50)	76
Şekil 5. 11. Kesinlik-hassasiyet eğrileri (%70 - %30)	77
Şekil 5. 12. YOLO yöntemi ile zar bölgesi tespit edilen TM görüntüleri.....	78
Şekil 5. 13. Transfer öğrenme modellerinin eğitimi tamamlama süreleri.....	80
Şekil 5. 14. Transfer öğrenme modellerine ait AİK eğrileri	81
Şekil 5. 15. Transfer öğrenme modellerine ait karmaşıklık matrisi	82
Şekil 5. 16. Önerilen modelin akış diyagramı.....	83
Şekil 5. 17. Faster-R CNN ile zar bölgesi bulunan orta kulak imgeleri.....	86
Şekil 5. 18. a) Orijinal veri kümesi, b) artırılmış veri kümesi, c) gauss gürültüsü ile artırılmış veri kümesi ve d) tuz ve biber gürültüsü ile artırılmış veri kümesi için maksimum dönem sayısını göz önünde bulunduran hassasiyet ve geri çağırma eğrileri.	87

- Şekil 5.19. Orijinal veri seti ile eğitim ve test örneklerinin doğruluk ve maliyet grafikleri. a) eğitim doğruluğu b) eğitim maliyeti c) test doğruluğu d) test maliyeti..... 88
- Şekil 5.20. Transfer öğrenme ile eğitilmiş arttırılmış imgeler ile edilen karmaşıklık matrisi a) Doğru pozitif b) Yanlış pozitif c) Yanlış negatif d) Doğru negatif 89
- Şekil 5.21. Zar bölgesi bulunan TM parçaları ile transfer öğrenme girişine verilen modellerinin eğitimi a) Eğitim doğruluğu b) Eğitim maliyeti c) Test doğruluğu d) Test maliyeti 90
- Şekil 5.22. Zar bölgesi tespit edilen TM parçaları ile transfer öğrenme girişine verilen modellere ait karmaşıklık matrisi a) Doğru pozitif b) Yanlış pozitif c) Yanlış negatif d) Doğru negatif..... 91
- Şekil 5.23. Modellerin AİK eğrileri. (a) Arttırılmış numunelerle beslenen modeller. (b) Modeller otomatik olarak algılanan TM parçaları ile beslenir. 92

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Normal TM ve AOM TM otoskop görüntü özellikleri.....	19
Çizelge 3.2. Normal, AOM ve EOM TM özellikleri	20
Çizelge 3.3. Normal, AOM, EOM KOM TM özellikleri.....	21
Çizelge 4.1. Hastalara ait demografik bilgiler	24
Çizelge 4.2. Veri setindeki görüntülere ait sayısal bilgiler (10/18-01/20).....	25
Çizelge 4.3. Veri setindeki toplam görüntü sayısı (10/18-06/20)	25
Çizelge 4.4. Kullanılan veri çoğaltma yöntemleri	26
Çizelge 4.5. Veri artırma sonrası görüntü sayıları	26
Çizelge 5.1. GSEM ve RKO özelliklerin birleşmesiyle sınıflandırma sonuçları.....	62
Çizelge 5.2. GSEM ve RKO özelliklerin birleşmesiyle sınıflandırma sonuçları.....	63
Çizelge 5.3. GSEM ve RKO özelliklerin birleşmesiyle sınıflandırma sonuçları.....	64
Çizelge 5.4. YGH öznitelikleri ile sınıflandırma sonuçları (%70-%30).....	65
Çizelge 5.5. YGH öznitelikleri ile sınıflandırma sonuçları (5-katlı çapraz doğrulama)	66
Çizelge 5.6. YGH + RKO öznitelikleri ile sınıflandırma sonuçları (%70 - %30)	67
Çizelge 5.7. YGH + RKO öznitelikleri ile sınıflandırma sonuçları (5-katlı çapraz doğrulama).....	67
Çizelge 5.8. YİÖ özellik vektörü Anormal TM ve Normal TM sınıflandırma sonuçları (%70 - %30)	69
Çizelge 5.9. YİÖ özellik vektörü ile Anormal TM ve Normal TM sınıflandırma sonuçları (5-katlı çapraz doğrulama).....	69
Çizelge 5.10. YİÖ ve RKO Özellikleri ile Normal TM ve Anormal TM görüntülerin sınıflandırılması (%70 - %30)	70
Çizelge 5.11. YİÖ ve RKO özellikleri ile Normal TM ve Anormal TM görüntülerin sınıflandırılması (5-katlı çapraz doğrulama)	70
Çizelge 5.12. GSEM özellikleri Normal TM ve Anormal TM görüntülerinin sınıflandırılması (%70 - %30)	72
Çizelge 5.13. GSEM özellikleri Normal TM ve Anormal TM görüntülerinin sınıflandırılması (5-katlı çapraz doğrulama)	72

Sayfa

Çizelge 5.14. GSEM ve RKO özellikleri kullanılarak Normal TM ve Anormal TM görüntülerinin sınıflandırılması (%70 - %30).....	73
Çizelge 5.15. GSEM ve RKO özellikleri ile Normal TM ve Anormal TM görüntülerinin sınıflandırılması (5-katlı çapraz doğrulama)	73
Çizelge 5.16. Transfer öğrenme modellerine ait özellik çıkarma katmanlarının doğruluk oranları	78
Çizelge 5.17. Transfer öğrenme modellerinin doğruluk oranları.....	82
Çizelge 5.18. Eğitim ve test olarak ayrılan veri sayısı.....	84
Çizelge 5.19. Faster-R CNN modeli ile zar bölgesinin tespiti.....	84
Çizelge 5.20. Arttırılmış imgeler transfer öğrenme performans sonuçları	89
Çizelge 5.21. Zar bölgesi tespit edilen TM parçaları ile transfer öğrenme girişine verilen modellere ait karmaşıklık matrisinden elde edilen performans metrikleri	91
Çizelge 5.22. Arttırılmış imgelerin sınıflandırma sonuçları	92
Çizelge 5.23. Tespit edilen TM parçaları ile beslenmiş sınıflandırma sonuçları.....	93
Çizelge 5.24. OM teşhis edilmesine yönelik yapılan diğer çalışmalar	93

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

g_c	: örnekleme noktası
g_p	: örnekleme noktası
g_{t-1}	: gradyanının kare ortalama karekökünün hatasıdır
$1/ w $: marj aralığı
3D	: 3 boyutlu
∞	: sonsuz
c	: ceza parametresi
cc	: kübik santimetre
dk	: dakika
F-Skor	: özgünlük ve hassasiyet değerlerinin harmonik ortalaması
G_n	: boyut
$G_{t,ii}$: maliyet fonksiyonunun kısmi türevi
G_x	: yatay gradyan
G_y	: dikey gradyan
h	: kernel
k	: uzaklık mesafesi
mg	: miligram
mm	: milimetre
mm^2	: milimetre kare
n	: veri setindeki veri sayısı
nm	: nanometre
p:	: dolgu boyutu
Pr	: nesnenin tahmin değeri
px	: piksel
r	: yarıçap
S	: ızgara sayısı

s:	: adım kaydırma
t	: RMSProp iterasyon sayısı
tanh	: tanjant hiperbolik
yy	: yüzyıl
β	: ADAM hiper parametreleri
γ	: RMSProp momentum faktörü
δ	: uzaklık
ΔL	: maliyet fonksiyonun gradyan eğimi
ϵ	: eleman
θ	: açı
ζ_i	: marj alanı optimizasyon değeri
Bh	: koordinatlardan emin olma düzeyi
Bw	: nesnenin genişliği
Bx	: nesnenin orta noktasının apsisi
By	: nesnenin orta noktasının ordinatı
IoU	: tahmin kutusunun doğruluk değeri
f	: dvm ayırıcı fonksiyon, giriş görüntüsü
$f(net)$: toplam fonksiyonu
η	: gradyanda aşağı doğru atılan büyüklüğü
σ	: aktivasyon fonksiyonu

KISALTMALAR

ADAGRAD	: Adaptive Gradient (Uyarlanabilir Gradyan)
ADAM	: Adaptive Moment (Uyarlanabilir Moment)
AI	: Anteroinferior
AİK	: Alıcı İşlem Karakteristiği
AOM	: Akut Otitis Media (Akut Orta Kulak İltihabı)
AS	: Anterosuperior
AUC	: Area Under Curve (Alıcı İşlem Karakteristiği)
BÖA	: Bölge Öneri Ağı
CGP	: Polak-Ribiére Güncellemesi ile Conjugate Gradyan
CNN	: Convolution Neural Network (Evrışimsel Sinir Ağları)
CSOM	: Chronic Supuratif Otitis Media (Kronik Akıntılı Orta Kulak İltihabı)
DN	: Doğru Negatif
DP	: Doğru Pozitif
DVM	: Destek Vektör Makinaları
EOM	: Efüzyonlu Otitis Media (Seröz Orta Kulak İltihabı)
ESA	: Evrışimsel Sinir Ağları
FTP	: Dosya Transfer Protokolü
GCM	: Grid Color Moment (Izgara Renk Momemnti)
GD	: Gradient Descent (Gradyan Azalma)
GDA	: Gradient Descent Algorithm (Gradyan Azalma Algoritması)
GLCM	: Gray Level Co-Occurance Matrix (Gri Seviyeli Eş-Oluşum Matrisi)
GSEM	: Gri Seviyeli Eş-Oluşum Matrisi
HOG	: Histogram of Oriented Gradient (Yönlü Histogram Gradyanları)
KBB	: Kulak Burun Boğaz
kNN	: K Nearest Neighbor (k En Yakın Komşuluk)
KOM	: Kronik Otitis Media (Kronik Orta Kulak İltihabı)
LBP	: Local Binary Pattern (Yerel İkili Örüntü)
LDA	: Linear Discriminant Analysis (Doğrusal Ayırma Analizi)

LM	: Levenberg-Marquardt
MAX	: Maksimum (En Yüksek)
MIN	: Minimum (En Düşük)
OM	: Otitis Media (Orta Kulak İltihabı)
PI	: Posteroinferior
PS	: Posterosuperior
RELU	: Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
RKO	: Renk Kanallarının Ortalaması
RMSProp	: Root Mean Square Propagation (Ortalama Hata Kare Kökü)
ROC	: Receiver Operating Characteristic Curve (Alıcı İşlem Karakteristiği)
ROI	: Region of Interest (İlgi Alanı Bölgesi)
RP	: Resilient Backpropagation (Esnek Geriyayılım)
SGD	: Stokastik Gradient Descent (Stokastik Eğim İniş)
TM	: Tympanic Membrane (Kulak Zarı)
UHE	: Uyarlanabilir Histogram Eşikleme
USYE	: Üst Solunum Yolu Enfeksiyonu
VD	: ve diğerleri
YGH	: Yönlü Gradyan Histogramı
YİÖ	: Yerel İkili Örüntü
YN	: Yanlış Negatif
YOLO	: You Only Look Once (Sadece Birkez Bak)
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

BÖLÜM 1

GİRİŞ

İşitme duyusunun en önemli hastalıklarından biri olan otitis media, bireyde çeşitli bilişsel ve duyuşsal problemlerin ortaya çıkmasına sebep olabilmektedir. Orta kulakta sıvı birikmesi sonucu meydana gelen, kulakta hissedilen şiddetli ağrı, kan veya pürülan akıntı gibi çeşitli semptomlarla kendini gösteren otitis medianın birden fazla çeşidi bulunmaktadır. Bu semptomlarla kliniğe başvuran bireye doğru tanı konabilmesi için deneyimli bir uzman tarafından ucunda led ışığı bulunan ve kulak yolu boyunca ilerleyen otoskop cihazı ile kulak zarının monitörize edilerek detaylı bir şekilde incelenmesi gerekmektedir. Kliniğe başvuran hastaya doğru tanının konması ve uygun tedavinin planlanması bireyin sağlığı açısından hayati önem taşımaktadır. Literatür incelendiğinde; çocukların yaklaşık %90'ının iki yaşına kadar en az bir kez AOM geçirdikleri, bunların sadece %60'ına doğru tanı konduğu ve uygun şekilde tedavi edilmemesi sonucu çok daha kötü tabloların görüldüğü bildirilmektedir [1-2]. Benzer şekilde EOM'un çocuklarda çok sık rastlandığı ve en çok karşılaşılan işitme kaybının nedeni olduğu belirtilmektedir [3].

Günümüzde otitis medianın uzmanlar tarafından klinikte tıbbi olarak tanılanmasına ilaveten tıbbi tanılama becerilerinin geliştirilmesine yönelik teletıp, simülasyon, web tabanlı gibi tıbbi eğitim yöntemleri de büyük önem taşımaktadır. Bu tıbbi eğitim yöntemlerinin dışında bilgisayar temelli karar destek sistemleri ile otitis medianın tanısının konmasında uzmanların karar verme süreçlerine destek olma yönünde bilim dünyasında önemli çalışmalar yapılmaktadır. Bu amaç doğrultusunda; hem uzmanlara düşen iş yükü azaltılmakta, hem de doğru tanının erken zamanda konulması kolaylaştırılmaktadır. Yapılan çalışmalar incelendiğinde; teletıp yöntemi kullanılarak 9 aylık ve 16 yaş aralığındaki 66 çocukla yapılan bir çalışmada çocuklara ait kaydedilen orta kulak görüntülerinin farklı lokasyonlardaki uzmanlar tarafından değerlendirilerek teşhis edilmesi ve uzman önerilerinin bir araya

getirilmesi sağlanmıştır [4]. Tıp alanında tanısal becerilerin geliştirilmesine yönelik olarak simülasyonlara yönelik olarak akıllı telefona takılan CellScope Oto ile geleneksel otoskopun tanılamadaki doğruluğunun değerlendirildiği bir çalışmada CellScope Oto'nun geleneksel otoskoptan daha doğru tanı koyduğu belirlenmiştir [5]. Benzer bir çalışmada; otoskopi simülasyonu, web-tabanlı eğitim ve klasik eğitimle tıp öğrencilerinin hastaları değerlendirmeleri sonucunda en iyi tanılamamanın otoskopi simülasyonu ile elde edildiği belirlenmiştir [6]. Literatürde ayrıca farklı OM görüntülerine ait veri setleri kullanılarak yapılan sınıflandırma yöntemlerinin doğruluk oranının yüksek olduğu ve kullanılabilirliği ifade edilmektedir [7-9].

Bu tezin amacı; otoskop cihazı ile elde edilen orta kulak görüntülerinde hayati önem taşıyan kulak zarı bölgesini otomatik olarak tespit ederek, normal ve anormal kulak zarı görüntülerini yapay zekâ yöntemleri ile sınıflandırmaktır. Bu amaç doğrultusunda; öncelikle kulak zarı bölgesinin tespit edilmesine yönelik nesne algılamada biyomedikal görüntülerde başarılı sonuçlara ulaşılan derin öğrenme temelli nesne algılama algoritmaları kullanılarak kulak zarı bölgesi en yüksek doğruluk oranı ile tespit edilmeye çalışılmıştır. Bununla beraber normal ve anormal kulak zarı görüntülerini makine öğrenme yöntemleri ile sınıflandırmak için dokusal özellik çıkarma algoritmaları ve görüntü özellikleri ile özellik vektörü elde edilerek makine öğrenme yöntemleri ile sınıflandırılmıştır. Diğer yandan özelliklerin otomatik olarak elde edildiği ve biyomedikal görüntülerde başarı oranının oldukça yüksek olduğu derin öğrenme temelli transfer öğrenme modelleri ile görüntülerin sınıflandırılması çalışmaları yapılmıştır. Buna ilaveten; tez çalışmamızda kulak zarı bölgesinin otomatik olarak tespit edilerek görüntülerin sınıflandırılmasına yönelik özgün bir model önerisi geliştirilmiştir. Ayrıca deneysel çalışmalarımızda özgün bir veri seti elde edilerek araştırmacılara açık erişimli olarak sunulmuştur.

Bu kapsamda yürütülen ve altı bölümden oluşan bu tez çalışmasının düzeni şu şekilde sıralanmıştır: Birinci bölümde, teze genel bir bakış açısı kazandırmaya yönelik olarak bilgiler verilmiştir.

İkinci bölümde, otitis medianın tanılama becerilerini geliştirilmesine yönelik ve bilgisayar temelli yapılan çalışmalara yönelik detaylı literatür taramasının sonuçları verilmiştir.

Üçüncü bölümde, kulak yapısı, otitis medianın tanımı ve türleri hakkında bilgiler sunulmuştur.

Dördüncü bölümde, deneysel çalışmalarımızda kullanılan veri setinin tanımlanması, kullanılan görüntü işleme teknikleri, kulak zarı bölgesinin tespitinde ve normal ve anormal görüntülerin sınıflandırılmasında kullanılan yöntem ve teknikler hakkında bilgiler verilmiştir.

Beşinci bölümde; deneysel çalışmaların sonucunda elde edilen bulgular, tablolar ve şekiller aracılığıyla sunulmuştur. Ayrıca çalışmalarımızda elde edilen sonuçlar literatürdeki diğer çalışma sonuçları ile tartışılarak detaylandırılmıştır.

Altıncı bölümde-sonuç ve önerilerde; bu çalışma süresince elde edilen kazanımlar verilmiş ve öneriler sunulmuştur. Yapılan çalışmanın literatüre katkılarına değinilmiş ve gelecekte yapılabilecek çalışmalar hakkında önerilerde bulunulmuştur. Kaynaklar dizini, deneysel çalışmamız sonucunda elde edilen ve araştırmacılara açık hale getirilen özgün veri setinin erişim adresi bu bölümü takip etmektedir.

BÖLÜM 2

LİTERATÜR ARAŞTIRMASI

OM tanı ve teşhisinin kolaylaştırılmasına yönelik yapılan bilgisayar destekli çalışmalar incelendiği zaman; istatistiksel, sınıflandırma, teletıp, simülasyon, web-tabanlı gibi çalışmaların yapıldığı belirlenmiştir.

Teletıp yöntemi, biyomedikal cihazlar ile elde edilen görüntülerin ve klinik raporların uzmanlar arasında değerlendirilmesidir [10]. Teletıp yöntemi ile yapılan bir çalışmada; 9 aylık ve 16 yaş aralığındaki 66 çocuğa ait kaydedilen orta kulak görüntülerinin farklı lokasyonlardaki uzmanlar tarafından değerlendirilerek teşhis edilmesi ve uzman önerilerinin bir araya getirilmesi sağlanmıştır [4]. OM tanısı alacak becerilerinin geliştirilmesine yönelik olarak çocuklardan elde edilen video-otoskop kayıtlarının tekrarlı değerlendirildiği bir çalışmada vakaların %87'sinde iyi kayıtlar elde edilip tanı konulmuşken, %18'inde ise görüntülere herhangi bir tanı konulamamıştır. Sonuç olarak; video-otoskop kayıtlarına bağlı olarak elde edilen tanımlar ile yerinde otomikroskopiden elde edilen tanımlar arasında önemli bir uyumluluk olduğu belirlenmiştir [11].

Simülasyon, gerçek dünyanın var olan yönlerini çağrıştırarak ya da yineleyerek yaratılan bir doğallık içinde tamamen katılımcı bir tarzda, gerçek deneyimleri rehberli deneyimlerle değiştiren ya da geliştiren teknik olarak tanımlanmaktadır [12]. Tıp alanında, tanısal becerilerin geliştirilmesine yönelik olarak yaygın bir şekilde simülasyonlar kullanılmaktadır. Akıllı telefona takılan CellScope Oto ile geleneksel otoskopun çocuklarda AOM tanısındaki doğruluğunun değerlendirildiği bir çalışmada CellScope Oto'nun geleneksel otoskoptan daha işlevsel olduğu belirlenmiştir [5]. Kbb alanında bir çok farklı simülasyon cihazı kullanılmaktadır. Bu kapsamda Japonya'da Ear Examination Model II, Kanada'da OtoSim Simulator ve University of Western Ontario, ABD'de Virginia Üniversitesi'nde Nasco ticari cihaz simülatörü ve Ohio Üniversitesi'nde OSU, University of Stanfor Simulator, Hamburg-Eppendorf

Üniversitesi'nde VOXEL-MAN Tempo 3D gibi cihazları OM'nin tanınmasında ciddi katkılar sağlamaktadır [13].

Prospektif bir kohort çalışmasında; web tabanlı eğitim, simülasyon cihazları ve sınıf ortamında yapılan sunumların tanısal becerilere olan katkı düzeyleri karşılaştırılmıştır. Bu doğrultuda tıp fakültesi öğrencileri rastgele olarak; otoskopi simülasyonu, web-tabanlı eğitim ve klasik sınıfta eğitim olmak üzere üç gruba ayrılmıştır. Ardından öğrenciler 5 gönüllü hasta üzerinde (10 kulak) tanısal doğruluk ve otoskopi becerileri açısından değerlendirmiş ve müdahaleler yapmışlardır. Öğrencilerin yaptıkları müdahalelerden hemen sonra hastalar tekrar değerlendirilmiştir. Her üç eğitim yönteminde, müdahaleden hemen sonra teşhis doğruluğunda bir iyileşme gösterdiği, en iyi tanısal teşhis gelişmesinin otoskopi simülasyonu ile elde edildiği belirlenmiştir [6]. Benzer olarak tıp fakültesi öğrencileri ile yapılan farklı bir çalışmada; öğrencilerin tanısal otoskopi becerilerini arttırmak amacıyla web-tabanlı platformun etkililiği değerlendirilmiştir. Öğrenciler rastgele olarak simülatör (21 kişi) ve kontrol grubu (20 kişi) olarak ikiye ayrılmıştır. Öğrenciler ön teste tabi tutulduktan sonra Kbb derslerine katılmaları sağlanmış ve bir hafta boyunca öğrencilerin simülatörlere sınırsız erişimlerine izin verilmiştir. Daha sonra farklı bir otoskopi videosu ile test tamamlanarak derecelendirilmiştir. Ön testte gruplar arasında herhangi bir anlamlı fark bulunmazken; son testte kontrol grubunda derslerden sonra %31 iyileşme sağlanırken simülasyon grubunda %71 iyileşme sağlandığı gözlemlenmiştir [14]. Tıp fakültesi öğrencileri ile yapılan randomize kontrollü bir çalışmada; tanısal becerilerin etkililiğine yönelik otoskop simülasyonu, web tabanlı öğrenme ve sınıfta öğrenme yöntemlerinin öğrenme becerisine etki düzeyleri karşılaştırılmıştır. Öğrenciler rastgele gruplara ayrıldıktan sonra, tüm gruplarda tanısal doğruluk ve otoskopi becerileri temel test ile belirlenmiştir. Her müdahalenin hemen ardından ve 3 ay sonra test tekrarlanmıştır. Müdahaleden hemen sonra ve üç aylık takiplerde, tüm gruplarda başlangıç durumlarına göre tanısal doğruluk düzeyinde iyileşme olduğu gözlenmiştir. En büyük artışın ise otoskop simülasyonu ve web-tabanlı gruplarda olduğu belirlenmiştir [15]. Birinci basamakta ve Kulak Burun Boğaz Baş Boyun Cerrahisi lisansüstü kursiyerleri ile yapılan çalışmada algılanan kulak burun boğaz eğitimi ve otoskop tanı becerileri ihtiyacının değerlendirilmesi ve karşılaştırılması amaçlanmıştır. Katılımcılar otoskopi becerileri OtoSim simülatörü kullanılarak

değerlendirilmiştir. Aile ve toplum hekimi, pediatri hekimlerinden oluşan 57 kişilik 3 gruba ayrı olarak otoskopi eğitimi verilmiştir. OtoSim simülatörü ile verilen eğitimden önce ön test ve son test yapılarak 3 ay sonraki test sonuçları ile karşılaştırılmıştır. Eğitim sonunda hekimlerin otoskopik teşhis becerilerinde önemli oranda iyi gelişme sağlandığı gözlemlenmiştir [16].

İstatistiksel yöntemler ve ortalama renk değerleri kullanılarak 100 TM görüntüsü ile imgelerde renge dayalı otit sezme performansı değerlendirilmiştir. Bu deneysel çalışmada; normal ve otitli TM olmak üzere görüntüler 2 sınıfa ayrılmış, bayes decision, gauss karışımı olarak renk dağılım yöntemleri kullanılmıştır. Sonuç olarak; ortalama renk değerlerinde sadece kulak zarı değil aynı zamanda kulak yolu da dikkate alındığı takdirde daha yüksek doğruluk oranı elde edilmiştir [17].

Otoskop cihazı ile video kaydından elde edilen resimlerin görsel olarak daha iyi analiz edilebilmesi için yapılan çalışmada ilk olarak ön işleme adımında linear unsharp algoritması uygulanmıştır. Ön işlemeden geçirilen görüntü sinyal işleme yöntemlerinden biri olan alçak geçiren filtreleme yöntemi ile görüntünün morfolojik özelliklerinin daha net görülmesi sağlanmıştır. Laplacian çekirdek filtresi görüntüye uygulanarak orijinal görüntünün üzerine eklenmiştir. Görüntü iyileştirme teknikleri uygulandıktan sonra timpanik membran, çekiç ve damarlanmanın daha iyi bir şekilde gözlemlendiği sonucuna varılmıştır [18].

TM görüntülerinin sınıflandırılması için otoskop cihazı ile elde edilen çeşitli otitis media görüntüleri kullanılmaktadır. AOM, EOM ve efüzyonlu olmayan OM olmak üzere 3 sınıfa ait toplamda 135 adet otit görüntü kullanılarak, zar bölgesinin segmentasyonu için active contour algoritması kullanılmıştır. Görüntülerde bulunan gri renk yoğunluğuna sahip yarı saydam bölge içinde Kmeans kümeleme ile bölge elde edilmiştir. Görüntüde yer alan kabarcık varlığının tespit edilmesi için ise ortalama renk değeri ve canny kenar tespit algoritması kullanılmıştır. Son olarak görüntülerin sınıflandırılması için hiyerarşik ağaç şeması yöntemi kullanılmıştır. Sınıflandırma sonucunda %84 doğruluk oranı elde edilmiştir [19]. TM görüntülerinin sınıflandırılması için yapılan bir diğer çalışmada; AOM, EOM ve normal TM'den oluşan 3 sınıfa sahip veri seti ile görüntüler telefonla uyumlu otoskop ile çekildikten sonra uzaktaki bir cihaza FTP protokolü ile gönderilmiştir. Burada görüntü üzerinde

zar bölgesini almak için görüntü işleme teknikleri ile ön işlemden geçirildikten sonra active contour segmentation ve kenar çıkarma teknikleri uygulanarak zar bölgesi ayrılarak bu dokuya ait öznitelik vektörü elde edilmiştir. Ardından deep first search algoritması ile %70 başarı oranı ile sınıflandırma işlemi gerçekleştirildiği belirlenmiştir [20]. Yine benzer başka bir çalışmada; 865 adet TM görüntüsünün yer aldığı normal, AOM, EOM ve COM olmak üzere 4 sınıfa ait veri setinde sınıflandırma işlemi gerçekleştirilmiştir. İlk olarak Active contour segmentation ile zar kısmı alındıktan sonra özellik vektörlerini elde edilmesi için grid color moment (GCM) ile renk özellikleri, dokusal özellik çıkarma algoritmalarından yönlü histogram gradyanları ve yerel ikili örüntü algoritması kullanılmıştır. Aynı zamanda bu vektöre her görüntüye ait gabor özelliği de eklendikten sonra Adabost yöntemi ile %88.06 başarı oranı ile sınıflandırılma yapılmıştır [21]. TM'nin görsel özellikleri kullanılarak yapılan sınıflandırma çalışmasında; veri setinde bulunan görüntülerde kulakta yabancı madde-wax, normal, AOM, EOM, COM olmak üzere 5 sınıfa sahip bir veri seti üzerinde deneysel işlem yapılmıştır. Veri setinde yer alan 562 adet görüntüden 489 görüntü ele alınmıştır. Görüntü işleme teknikleri kullanılarak resimdeki perforasyon, malleus bone, TM şekil renk ve perforasyon, wax, orta kulakta sıvı ve ışık yansımaları gibi özellikler elde edildikten sonra karar ağacı yöntemi ile sınıflandırılarak %81.58 doğruluk oranı elde edilmiştir [7]. Yine aynı araştırmacı tarafından yapılan farklı bir çalışmada; veri setinde yer alan ve çok net olmayan 100 adet görüntü elimine edilerek 389 adet görüntü ile deneysel çalışma yapılmıştır. Görüntülerin arka planında yer alan siyah bölge kesilmiş ve görüntü üzerinde bulanık bölge sezimi yapılmıştır. Laplacian filtresi ile görüntülerde keskinleştirme işlemi gerçekleştirilmiştir. Görüntüler üzerinde kenar tespit etmek için canny kenar çıkarma yöntemi kullanılmış ve görüntülere ait özellik vektörüne bu sefer görüntülerin renk ortalamaları da eklenerek özellik vektörü oluşturulmuştur. Modeli test etmek için veri setinin %80'ini eğitim %20'sini ise test olarak ayırıldıktan sonra yapay sinir ağına giriş olarak verilmiştir. Sınıflandırma sonucunda %86.84 başarı oranı elde edilmiştir [22]. TM görüntülerinin yanı sıra hastalara ait demografik özellikleri ve klinik bulguları ile geliştirilen bir modelde; 150 adet hastanın yaş, cinsiyet, preoperatif odyometrik sonuçları, kulak patolojileri ve cerrahi işlemin detayı giriş verisi olarak kullanılarak, KOM hastalığına sahip bireylerin orta kulak ameliyatı geçirdikten sonra yorumlayıcı bir yapay sinir ağı ve k-NN modeli geliştirmişlerdir. Ameliyat sonrası işitme eşiği öngörülen çıkış olarak kabul edilmiştir.

Önerilen model ile % 84 ve k-NN ile % 75.8 oranında başarı elde edilmiştir [9]. Kulak zarlarında şişliğin tespit edilmesine yönelik olarak AOM, EOM ve efüzyonlu olmayan OM tanılarının konulduğu 367 adet çocuğa ait TM görüntüsü kullanılmıştır. Bu veri setindeki 68 AOM TM görüntüsünde şişkinlik var iken, 308 TM görüntüsünde ise şişkinlik olmadığı belirlenmiştir. Şişkinliğin tespit edilmesi için kıvrımlı üçgen algoritması kullanılarak doğrudan 3D mesh diagramı ile görüntülenmiştir. Isocontour algoritması ile özellik çıkartılarak destek vektör makinaları ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonucunda %91 doğruluk oranı ile şişkin olan TM görüntüleri ayrılmıştır [23]. Biyomedikal uygulamalarda renkli görüntüler ile farklı renk kanalları ve renk uzayları kullanılarak; 111 normal TM ve 75 adet renkli otit TM görüntüsü olmak üzere toplamda 186 görüntü ile HSV renk uzayı ve HSV Color Coherence teknikleri ile imgelerin özellikleri temsil edilmiştir. Daha sonra makine öğrenme algoritmaları kullanılarak performans karşılaştırılması yapılmıştır. k-NN, karar ağaçları, Linear Discriminant Analysis (LDA), Naive Bayes, Çok katmanlı yapay sinir ağı ve destek vektör makineleri ile yapılan sınıflandırma sonucunda yapay sinir ağları ile %73.11 ve destek vektör makineleri ile %72.4 oranında başarıya ulaşılmıştır [24]. EOM otitis media tedavisinde kullanılan timpanoplastinin ekli olduğu kulak zarı görüntülerinde timpanoplastinin tespit edilmesine yönelik olarak; klinikten elde edilen 235 TM görüntüsü ve internetten elde edilen 40 TM olmak üzere toplamda 275 adet otoskopik TM görüntüsünde timpanoplasti tüpünün varlığının tespit edilmesi amaçlanmıştır. Timpanoplasti tüpünün varlığının tespit edilmesi için renk bazlı özellikler, kenar çıkarma özellikleri ve bir dizi gelişmiş özellik çıkarma algoritmaları olan HOG, SIFT, LBP, GLCM, wavelet kullanılmıştır. Ayrıca görüntünün merkezinin tespiti edilmesi için k-means algoritması kullanılmıştır. 22 özelliğe sahip vektör elde edildikten sonra SVM ile sınıflandırma işlemi gerçekleştirilmiştir. Önerilen bu model yüksek kaliteli ve düşük kaliteli görüntüler üzerinde denenmiştir. Deneysel çalışmalar sonucunda timpanostomi tüpünün tespitinde %90 doğruluk oranı elde edilmiştir [25].

TM görüntülerini monitörize etmek için, otoskop cihazının başında bulunan beyaz ışık yerine alternatif olarak farklı otoskop cihazı tasarımlarının geliştirildiği gözlenmiştir. Bu doğrultuda ışığın farklı dalga boylarından faydalanılarak modifiye bir otoskop cihazı ile normal TM, AOM ve kolesteatom görüntüleri elde edilmiştir. Dört ayrı dalga

boyu (mavi: 455nm, green:253 nm, kırmızı:625 nm) ve beyaz ışık birleştirilmiştir. Matlab ortamında tüm resim yerine küçük veri bölgesi üzerine kontrast sınırlı adaptive histogram eşikleme uygulanmıştır. Ayrıca resmi küçük dilimlere segmente ederek her bir dilimin max ve min yoğunluk değerlerinin toplamına farkının oranı hesaplanarak görüntüler elde etmişlerdir. Görüntüler bu şekilde monitörize edildiğinde; TM üzerindeki farklı doku bölgelerinin farklı renkler ile temsil edildiği belirlenmiştir [26]. Otoskop cihazının tasarımına yönelik olarak, dağınık yansıtma spectreskopisi ve emilim spektroskopisinin özelliklerinin birleştirilmesi ile adına GASMAS denilen yeni bir cihaz tasarlanmıştır. GASMAS tekniği sinus boşluklarının incelenmesinde kullanılmıştır. Otoskop kulağa girdiğinde otoskopun ışığı fiber ile spektroskopiye yansır ve GASMAS bu sayede ışığın dalgasını, sıcaklığını ölçer. Bu şekilde iltihaplı TM'den dönen ışığın dalga boyunun ölçülmesi ile iltihaplı TM'nin normal TM'den farkı anlaşılabilirliği sonucu elde edilmiştir [27]. Literatür incelendiğinde; EOM'da orta kulakta biriken sıvının kurutulması amacıyla ventilasyon tüpünün kullanıldığı ve bu işlemi gerçekleştiren çeşitli cihazların da geliştirildiğini gösteren çalışmaların da bulunduğu belirlenmiştir [28-30].

TM görüntülerinin sınıflandırılması için yapılan çalışmalara bakıldığı zaman genellikle TM görüntü özelliklerinin çıkarılarak sınıflandırma işleminin yapıldığı gözlenmiştir. Görsel özelliklerin yanı sıra, görüntüye ait özelliklerin derin öğrenme ile çıkarıldığı çalışmada; toplamda 1338 görüntü kullanılmıştır. Bunların 714 (sağ:347, sol:367) normal TM ve 624 (305 sağ, 319 u sol) ise perforasyon olmuş TM görüntülerinden oluşmuştur. Kullanılan evrişimli sinir ağları modelinde 224x224 giriş görüntü evrişim için filtre boyutu 3x3 ve 32 adet maske kullanılmıştır. Havuzlama katmanı için filtre boyutu 2x2 ve tam bağlı katmanda 128 adet bağlantıya sahiptir. Ağı optimize etmek için hiper parametreleri ise mini topluluk boyutu (mini-batch size) 32, epochs sayısı 400 ve optimizasyon olarak SGD kullanılmıştır. Öğrenme oranı 0.0001, momentum 0,9 Nesterov momentum olarak belirlenmiştir. Bu sinir ağı modelinde 2 evrişim 2 havuzlama ve 2 tam bağlı katmandan oluşmaktadır. Ağın eğitimi 2 aşamada gerçekleştirilmiştir. İlk olarak lezyon varlığı ayırt edilmeksizin TM'da sağ ve veya sol kulak olduğunu bulmak, ikinci olarak TM'da perforasyon varlığı tespit edilmeye çalışılmıştır. Test aşamasında özellik çıkarmayı değerlendirmek için aktivasyon haritası uygulanmıştır. Bu işlem aracılığıyla normal yapılar ve lezyonlar gözlenmiştir.


Aktivasyon haritası ile görüntüler 8 parçaya bölünmüştür (external auditory canal, TM, TM annulus, malleolar short process, malleolar handle, umbo, cone of light, perforation margin, ve middle ear). Ağı test etmek için %60 eğitim, %20 doğrulama ve %20 test olarak rastgele kullanılmıştır. Deneysel çalışmalar sonucunda sağ ve sol tarafı bulmada % 97.9, perforasyon varlığını bulma da % 91.0 oranında başarı elde edildiği belirlenmiştir [31].

BÖLÜM 3

KULAK YAPISI VE OTİTİS MEDIA

3.1. KULAK

Başın iki yanında bulunan kulak (auris), beş duyu organlarımızdan biridir. İnsanda işitme ve denge fonksiyonlarını yerine getirmekte rol oynar. Günlük hayatımızda insanlar arasında iletişimin sağlanması için sağlıklı bir şekilde işitmenin hayati önemi vardır. Kulak, dıştan içe doğru sırasıyla dış kulak (auris externa), orta kulak (auris media) ve iç kulak (auris interna) olmak üzere üç kısımdan oluşmaktadır. Kulağın yapısına ait görüntü Şekil 3.1’de verilmiştir.



Şekil 3. 1. Kulak yapısı [29].

3.2. DIŐ KULAK

Kulak kepçesi (Aurikula) ve dıŐ kulak yolu (acusticus externus) olmak üzere iki kısımdan meydana gelir.

3.2.1. Kulak Kepçesi (Aurikula, pinna)


BaŐın iki tarafında çene eklemiyle mastoid çıkıntı arasında yer alan ve ses dalgalarının dıŐ kulak yolu boyunca ilerlemesini saėlayan yapraėa benzeyen ve dıŐ etkenlerden en fazla etkilenen bölümdür. İskeleti dıŐ kulaėın kıkırdaėıyla meydana gelmiŐtir, ince yaėsız deri ile çevrelenmiŐtir. Kompleks bir yapıya sahip olan kulak kepçesi konkav yüz olan lateral ve konveks yüz olan medial olmak üzere iki yüzden oluşmakta [32]. Baė dokusu, yaė ve kıkırdaktan meydana gelmektedir. Kıkırdak kısmı tek bir parçadan meydana gelmiŐ. Kulak kepçesi başa deri, dıŐ kulak yolu kıkırdaėı, kas ve baėlarla baėlıdır [33].

3.2.2. DıŐ Kulak Yolu (Acusticus Externus)

EriŐkin insanlarda arka üst duvarı 25 mm iken ön alt duvar uzunluėu da 31 mm ve Őekil olarak S harfine benzeyen bir kanaldır. DıŐ kulak yolunun kıkırdak kısmını örten deride yaė, ter ve serümen (kulak kiri) bezleri bulunur, kemik kısmında ise sadece ince deri bulunur [34]. DıŐ kulak yolunun 1/3 lateral kısmını kıkırdak, 2/3 medial kısmını kemik yapısından oluşmaktadır [35]. Endoskopi ile kulak zarına bakmak istenildiėinde dıŐ kulak yolunda buŐon (kulak kiri), yabancı maddeler ve otit externa hastalıėı görülebilmektedir.

3.2.3. Otit Externa (DıŐ Kulak Yolu İltihabı)

DıŐ kulak yolunda enfeksiyondan ya da birbaŐka sebepten ötürü meydana gelen iltihaplanmaya otit externa denilmektedir [36]. Sıcak olan bölgelerde ve tropikal ölkelerde daha sık meydana gelmektedir. İklimin sıcak olması ve suda yüzölmesi dıŐ kulak hastalıklarının artmasına sebep olmaktadır [37]. 8 günlük tedavi edilmesine raėmen otit externa iyileŐmediėi takdirde malign otit externaya dönüşebilmektedir [38]. Őekil 3.2.'de dıŐ kulak yolu iltihaplanmış ve kirli kulaėa ait görüntü verilmiŐtir.




Şekil 3. 2. Dış Kulak yolunda otit externa ve buşon (kulak kiri).

3.3. ORTA KULAK (AURIS MEDIA)

Timpanik membranla iç kulak arasında yer alır. Mukoz membranla döşeli içi havayla dolu olan bir boşluktur [39]. Orta kulak boşluğu yaklaşık 2 cc'dir [32]. Dış kulak yolundan gelen ses dalgalarının iç kulağa iletilmesinde rol alır. Orta kulak; kulak zarı, orta kulak boşluğu, kemikçikler, östaki borusundan oluşur.

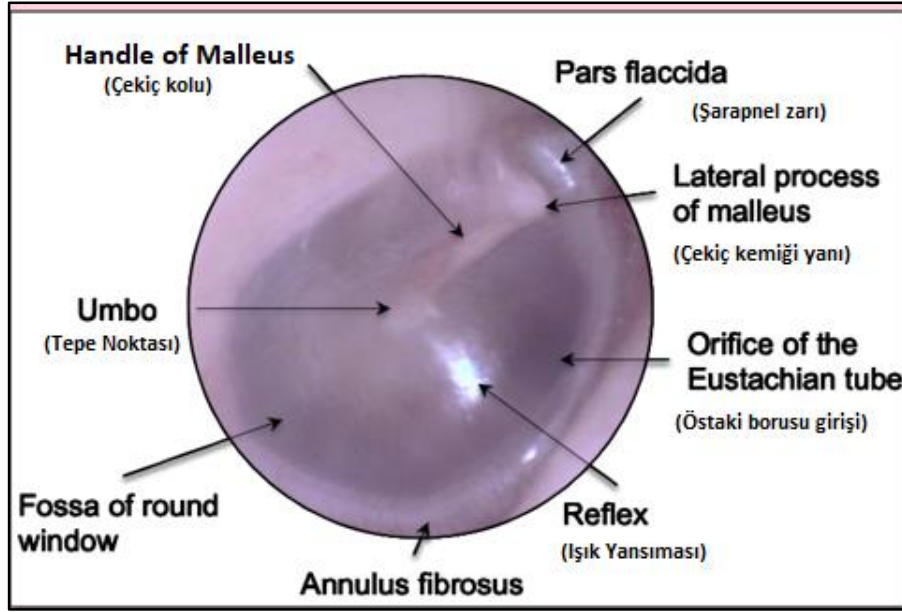
3.3.1. Kulak Zarı (Tympanic Membrane)

Kulak zarı yani timpanik membran(TM) literatürde tympanic membrane ve eardrum olarak da geçmektedir. TM dört farklı bölüme ayrılır, bu bölümler TM'nin farklı patolojik özelliklerini açıklamada kolaylaştırır. Şekil 3.3.'te bir sağ kulağın bölümlere ayrılışı gösterilmiştir. Şekil 3.4.'te kulak zarının farklı bölümleri üzerinde görülen bölgelerin isimleri yer almaktadır.



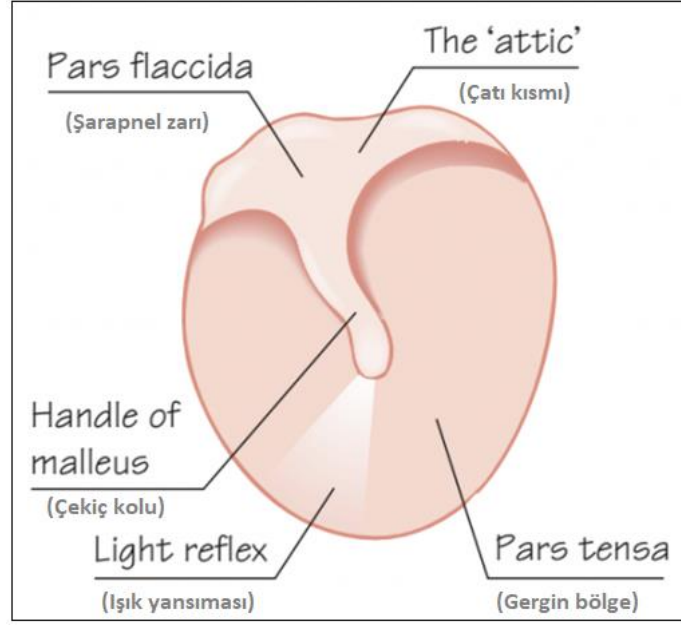
Şekil 3. 3. Kulak zarının bölümlere ayrılışı [38].

Şekil 3.3'e bakıldığında kulak zarının bölümleri olan AS, anterosuperior, AI, anteroinferior; PS, posterosuperior; PI, posteroinferior görülmektedir. Orta kulak boşluğuyla dış kulak yolunu birbirinden ayıran TM; genişliği 8-10 mm ve uzunluğu 9-10 mm olan, 0.1 mm kalınlığında, yaklaşık olarak 85 mm² alana sahip, kavisli koni bir şekle benzeyen, yarı opak, gri renkli bir yapıdadır [34,40].



Şekil 3. 4. Kulak zarı [40].

Timpanic membrane orta kulak lateral duvarın önemli bir kısmını oluşturur, dıştan içe doğru epitel, fibros, ve mukozal olmak üzere üç tabakadan oluşmaktadır [41]. Timpanik membrane, fiziksel yapısı itibari ile oval pencere üzerindeki basıncı artırır [42]. Dış kulak yolu ile 140°'lik bir açıya sahiptir [43]. Ses dalgaları TM'dan iç kulağa orta kulakta bulunan üç adet kemikçik olan çekiç (malleus), örz (incus), üzengi (stapes) ile iç kulağa iletir ve eğer yüksek bir sese maruz kalırsa timpanik kaslarını kasarak akustik bir refleks ile iç kulağı koruma görevi de üstlenir [44,45]. Koni şeklinde olan TM'nin en tepe kısmına umbo denilmektedir. Umbo, malleusun en küçük sapıyla haberleşir. Umbo'dan başlayıp öne ve aşağıya doğru TM'nin kenarına kadar uzanan üçgen şeklindeki aydınlık alana politzer üçgeni (ışık üçgeni) adı verilir [34]. TM'nin timpanik kemik içerisindeki gergin ve asıl titreten kısmına pars tensa adı verilir. Rivinus çentiğini dolduran gevşek kısmına ise pars flaccida (shrapnell zarı) adı verilir. Bu bölümler Şekil 3.4 ve Şekil 3.5.'te görülmektedir.



Şekil 3. 5. TM bölümleri [43].

Eğimli bir yapıda olan TM pars tensanın (zar üzerindeki doku) arka kısmı dış tarafa daha yakın, ön kenarı ise daha uzaktadır. TM'deki pars tensada ortadan yukarıya doğru uzanan malleusun eardrum içerisindeki kısmı olan manibrium mallei bulunur [46]. Kulak kanalına annulus fibrosus ile bağlanmıştır [43].

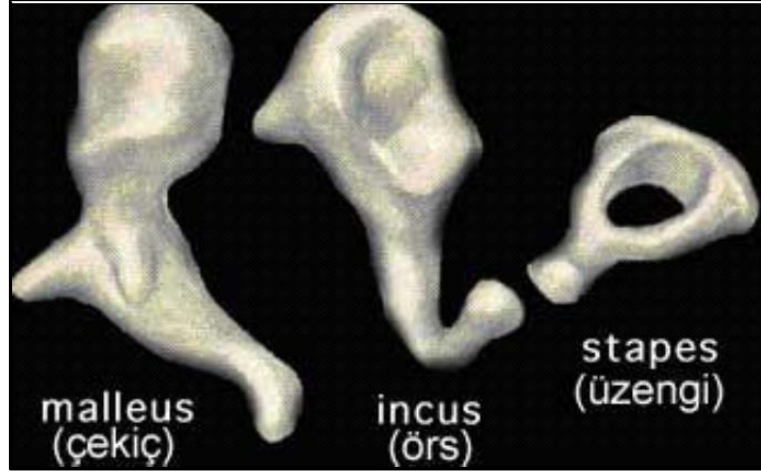
3.3.2. Orta Kulak Boşluğu (Cavum Timpani)

Ses iletimi işlevinin tam olarak tamamlanması için sağlıklı bir mukozaya ve iyi ventilasyon olan bir orta kulak boşluğu gereklidir. Bu ventilasyonda östaki borusundan gelen hava aracılığıyla gerçekleşir [47]. Orta kulak boşluğu, yapısal olarak TM' a göre mezotimpanium, epitympanium ve hipotimpanium olmak üzere üç kısma ayrılmaktadır. Mezotimpanium; kulak zarı seviyesine erişen, epitympanium; kulak zarı seviyesini geçen ve hipotimpanium ise kulak zarı seviyesinin altında kalan boşluğun adıdır [34]. Orta kulak boşluğu 6 adet duvardan oluşmaktadır.

3.3.3. Kemikçikler (Ossicles)

Orta kulak boşluğunda TM ve iç kulak arasında içten dışa doğru sırasıyla malleus, incus ve stapes kemikçikleri bulunmaktadır. İncus malleus ve stapes arasında eklem yapar [48]. Malleus kemikçiklerin en büyük olanıdır. İncus kısa gövdeli ve iki adet koldan oluşmakta kollardan biri uzunken diğeri kısadır. İncusun uzun kolu yaklaşık 7

mm'dir stapes ise 3.5 mm uzunluğunda ve 2.5 mg ağırlığındadır [47]. Dışardan gelen ses dalgaları dış kulaktan sonra kulak yoluna doğru ilerler ve TM titreşmeye başlar. TM'nın malleus ile bağlantılı olduğundan TM titreşmesinden sonra malleusda titreşmeye başlar ve bununla birlikte incus ve stapes de titreşerek ses dalgalarını iç kulağa doğru iletirler [49]. Şekil 3.6.'da orta kulakta bulunan kemikçiklerin yapısı verilmiştir.



Şekil 3. 6. Orta Kulaktaki kemikçikler [19].

3.3.4. Östaki Borusu

İlk olarak anatomist olan İtalyan Bartolomeus Eustachius tarafından 16. yy' da incelenmiştir [50]. Orta kulak boşluğunu genize bağlayan yaklaşık olarak 31-38 mm arasında uzunluğa sahip bir boru şeklindedir [51]. Östaki borusunun temel fonksiyonu orta kulaktaki ventilasyonu (hava akımını) sağlamaktır. Östaki borusu orta kulaktaki basıncı atmosferik basınca dengeleyerek düzenler [52]. Östaki borusunun orta kulakta sağlamış olduğu basınçla buradaki kemikçiklerin gerilimini etkiler ve sesin iletiminin işlevselliğini de dolaylı olarak etkiler [53].

3.4. OTITIS MEDIA

Otitis media(OM), kulak zarının arka tarafında meydana gelen iltihaplanma için kullanılan genel bir tıbbi terimdir. OM, orta kulak bölgesinin iltihaplanması, orta kulakta sıvı varlığı olarak bilinir [54,55]. Çocuklarda üst solunum yolu enfeksiyonundan sonra en sık rastlanılan hastalıktır [56-58].

OM, dünya genelinde 5 yaşın altındaki çocuklarda en fazla görülen solunum yollarındaki rahatsızlıklardan biridir [59]. Dünya genelinde her yıl yaklaşık olarak 740 milyon insan OM'den etkilenmektedir, bunların %90'ı 10 yaşına kadar olan çocuklardır [60]. OM aynı zamanda klinik olarak gelen hastalarda en fazla antibiyotik tedavisi reçete edilen hastalıklardan biridir [61]. Duyma kaybının en önemli sebeplerinden biri olan OM, bireyde yaşam kalitesinin azalmasına ve aynı zamanda ülke ekonomisinin de ciddi oranda etkilenmesine sebep olmaktadır [59, 62-64]. OM çoğu zaman konuşma, dil ve zihinsel gelişimi de etkilemektedir [57]. OM; çevresel faktörler, soğuk algınlığı, genetik faktörler, bağışıklık sistemi, östaki borusu, bakteriler, yarı damak, astım, alerji gibi çeşitli faktörlerden kaynaklanmaktadır [65, 66].

Farklı tipleri olan OM' yi teşhis etmek için otoskopi, oto-mikroskop, el otoskopu (auriscope), alın aynası ya da video-endoskopi kayıtları ile elde edilen TM görüntüsünün değerlendirilmesi gerekir [34,67]. Orta kulak endoskopisi ilk olarak 1967 yılında Mer ve arkadaşları tarafından TM'nin görüntüsünün alınması ve teşhis amaçlı olarak kullanılmıştır [68]. Video-otoskopi hem hekim hem de hasta tarafından TM görüntüsünün bir monitöre yansıtılarak görüntülenmesini sağlayan bir endoskopik teknolojidir [69]. Otoskopi sadece kulak burun boğaz uzmanları için değil aynı zamanda pratisyen hekimler ve pretisyen hekimler için de rutin bir tetkik etme yöntemidir [70]. Otoskopik muayene ile TM'nin durumu ve dış kulak yolundaki normal ve anormal durumların tanımlanabilmesi için kullanılmaktadır [34]. OM TM'deki perforasyonun varlığı ve orta kulaktaki irinin varlığının incelenmesiyle teşhis edilmektedir [71].Pediatriker ve KBB uzmanları otoskop cihazı ile yaklaşık olarak %50-%70 arasında doğru teşhis koyabilmektedir [72]. OM farklı kaynaklarda farklı sınıflandırma altında kategorize edilen birçok hastalığı barındırmaktadır, birbiriyle yakından ilişkili olan ancak her birinin farklı bir şekilde incelenmesi gereken Akut OM, Efüzyonlu OM ve Kronik OM olmak üzere üç ana gruptan oluşmaktadır [73].

3.4.1. Akut Otitis Media (AOM)

Akut orta kulak iltihabı (Akut otitis media) hemen her yaşta görülmesine rağmen özellikle çocuklarda üst solunum yolu enfeksiyonundan sonra en çok hekime görünme nedenidir. Dünya genelinde en yaygın çocukluk çağındaki kulak rahatsızlığıdır

[74,75]. Çocukların % 90'ı iki yaşına kadar minimum bir kere akut otit geçirmekte ve bunların yaklaşık yarısı tekrarlayan (iki veya üç defa) bir şekilde geçirmektedirler [1]. Çocukların % 80'i 3 yaşa kadar en az bir kere otit atağı geçirmektedirler [76]. Çocuklarda antibiyotik kullanımının, acil servis ziyaretlerinin ve çocukluk cerrahilerinin en yaygın sebeplerindendir [77].

AOM teşhisi zordur çünkü TM'nin otoskopik incelenmesi ve pnömatik otoskop ile hareketinin değerlendirilmesi eğitim ve uzmanlık gerektiren yöntemlerdendir bu yüzden çocuklardaki AOM şüphelisi hastaların sadece %60'ı doğru bir şekilde teşhis edilmektedir [2]. AOM TM ait görüntüler Şekil 3.7'de verilmiştir.



Şekil 3. 7. AOM TM görüntüleri.

AOM' nin teşhisinin altın standardı TM görüntüsüne tam olarak bakmaktır [78]. Pediatrik AOM' nin şikâyetleri arasında ateş, otoloji (kulak ağrısı), kusma, ishal, halsizlik, kulak iltihabı, kulak akıntısı (otore), üst solunum yolu enfeksiyonu (USYE) esnasında geçici işitme kaybı AOM'nin semptomları arasındadır [58,79]. AOM genellikle USYE ve östaki borusunun tıkanması sonucunda akışkan olan orta kulaktaki sıvının birikmesiyle bakteri enfekte olur, en yaygın görülen bakteriler Streptococcus pneumoniae, non-typeable Haemophilus influenza and Moraxella catarrhalis [41,77]. AOM bakterilerin neden olduğu bir patojen olarak bilinmesine rağmen AOM'lu rahatsızlıkların % 70'i patojen bakteriyal kaynaklıdır [80].

AOM hastalığına sahip bir hastanın kulağında yapılan otoskopik muayenede timpanik zarında bombeleşme inflamasyonun en özgül belirtisidir, TM'de hava kabarcıkları, bül (içi sıvı dolu kabarcıklar), hiperemi (normalden fazla kanlanma) olması koyu pembe veya kızarıklıkta görülmesine neden olur, sıvı birikmesi gibi görünüşler AOM'ye

işaret etmektedir [58,81]. Çizelge 3.1.' de normal bir TM ve AOM hastalığına sahip bir TM'nin otoskopik muayenede görüntülerinin özellikleri bulunmaktadır.

Çizelge 3. 1. Normal TM ve AOM TM otoskop görüntü özellikleri.

Normal TM	AOM TM
Yarı opak, gri renkli, konik bir yapıda, ışık yansımaları	Bulging, kızarıklık-pembemsi, sıvı varlığı, kabarcık, hava kabarcığı

3.4.2. Efüzyonlu Otitis Media (EOM)

AOM semptom ve belirtileri olmaksızın orta kulaktaki sıvının varlığı olarak tanımlanmaktadır [82-84]. Östaki borusunun disfonksiyonu, kitle, adenoid (geniz eti) vejetasyon (geniz eti büyümesi) gibi efüzyon olarak adlandırılan sıvının TM arkasında birikmesi sonucu meydana gelmektedir [85].

EOM; kataral otitis media, nonsüpüratif otitis media, serotimpanum, mukotimpanum, zamklı kulak (glue ear) gibi ifadeler kullanılsa da yaygın olarak EOM ve sekretuar otitis media kullanılmaktadır [86]. EOM karşımızda yaygın bir şekilde çocukluk döneminde çıkmaktadır, çocukluk dönemindeki işitme kaybının en çok karşılaşılan nedenidir [3]. Şekil 3.8.'de EOM TM'ye ait görüntüler yer almaktadır.



Şekil 3. 8. EOM TM görüntüleri.

EOM tedavi edilmezse TM'de çeşitli değişimlere neden olur, buda kronik otitis mediaya sebep olabileceği gibi bireyin eğitsel ve psikolojik gelişimi de kapsayan ciddi sorunlara sebep olabilir [87]. EOM soğuk algınlığı, grip, alerjik rinit (burun mukozasının iltihabı), sinüzit, bademcik iltihaplanması gibi hastalıkların geçirilmesi ile östaki borusunun işlevinde aksaklıklar oluşmakta ve zamanla orta kulak

boşluğunda sıvı birikmesine sebep olmaktadır [88]. EOM tanısı konabilmesi için otoskop ile muayene de TM sarı, mat ve vaskülarize (damarlarda belirginleşme), bazen hava kabarcıkları ve sıvı görülmektedir. AOM'de zarda bombeleşme görülürken EOM'de ilk aşamada nötral iken ileriki aşamalarda retraksiyon (büzüşme) ve adhezyonlar (yapışkanlık) görülmektedir [89]. Çizelge 3.2.'de Normal, AOM ve EOM TM görüntülerinin özellikleri vermiştir.

Çizelge 3. 2. Normal, AOM ve EOM TM özellikleri.

Normal TM	AOM TM	EOM TM
Yarı opak, gri renkli, konik bir yapıda, ışık yansımaları	Bulging, kızarıklık-pembemsi, sıvı varlığı, kabarcık, kabarcığı	Matlaşma, koyu sarı, retraksiyon yapıda, adhezyonlar, hava kabarcığı

3.4.3. Kronik Otitis Media (KOM)

Kronik otitis media (KOM); kulak zarında meydana gelen perforasyon, dış kulak yolundan bazen gelen süpüratif yapıdaki akıntı, genellikle iletim şeklinde bir işitme kaybı ve üç aydan uzun süreli tıbbi tedaviye cevap vermeyen OM türü olarak tanımlanabilir [90,91]. KOM'de hastalığın aktif olarak geçirildiği dönem kronik süpüratif otitis media ve inaktif olarak geçirdiği dönem ise KOM olarak adlandırılmaktadır [89]. KOM'da TM perforatedir. Perforasyon çok küçükten tüm perforasyona kadar değişebilmektedir. Perforasyonun yeri oldukça önem arz etmektedir, santral ya da marjinal olabilir. Perforasyon eğer anulusa kadar uzanıyorsa marjinaldir, uzanmıyorsa santral perforasyon olarak isimlendirilir. Pars flaksida perforasyonları da marjinaldir [89].

KOM'ye bağlı komplikasyonların birçoğunda kolesteatom (kulak zarı arkasında anormal kansersiz büyüyen dokudur) mevcuttur [92]. Genel olarak KOM ve rekürren otitis risk faktörleri; erkeklerde, beyaz ırk insanlarda, küçük yaşta çocuklar, ilk otitis atağının doğumdan sonraki altı ayda geçirilmesi, sigara içilen ortam faktörü, ailede orta kulak hastalığının geçirilmesi ile ailesel veya kişisel olarak alerji hikayesi, biberonla beslenme, bilateral OM, geçirilmiş OM hikayesi ve burun tıkanıklığı gibi KOM'de bünye ile ilgili, genetik ve çevresel faktörler sayılabilir [93]. Şekil 3.9.'da KOM TM'ye ait görüntüler bulunmaktadır.



Şekil 3. 9. KOM TM görüntüleri.

KOM'de tanısı için otoskopik muayene yapılır. Video otoskopi ile yapılan incelemede kulak zarında delinme, marjinal ve santral perforasyon görülebilir, perforasyonun bölgesi, orta kulak mukozasının durumu, akıntının kanlı olması ve rengi, polip varlığı, kolesteatom gibi gözlemler KOM türünün belirlenmesinde önemli işaretlerdir [93-96]. KOM kliniksel olarak farklı özellikler göstermelerinden dolayı otoskopi ile değerlendirmeye göre tubotimpanik veya attikoantral özellikler gösterebilirler. Tubopimpanik ve attikoantral özelliklerine göre KOM beş farklı türden oluşmaktadır [93, 95-97]. Tubotimpanik hastalıkta; İltihaplanma orta kulağın mukozası ile sınırlıdır, kemiğin defektesi beklenmemektedir, TM'deki perforasyon pars tensa'dadır, kolesteatom bulunmamakta ve fibroz anulus sağlamdır [95,96]. Attikoantral de ise; iltihaplanma attik alanda, pars flaksiyada perforasyon, pars tensa bölgesinde kolesteatom veya granülasyon bulunmakta, kemik erimeside gözlenmektedir [63,64]. Normal TM ve Otitis Media TM görüntülerinin görsel özellikleri Çizelge 3.3. 'te verilmiştir.

Çizelge 3. 3. Normal, AOM, EOM KOM TM özellikleri.

Normal TM	Akut TM	Efüzyonlu TM	Kronik TM
Yarı opak, gri renkli, konik bir yapıda, ışık yansımaları	Bulging, kızarıklık, pembemsi, sıvı varlığı, kabarcık, kabarcığı	Matlaşma, koyu sarı, retraksiyon yapıda, edhezyonlar, kabarcığı	Delik, perforasyon, kemikler ermiş, polip, orta kulak mukozası delikten görülür.

3.4.3.1. Kronik Basit Otitis Media

Tübopimpanik karaktere sahip, TM'de pars tensa da çeşitli büyüklüklerde perforasyon görülmektedir. Genellikle süpüratif ya da non süpüratiftir, orta kulak mukozası sağlıklı, doğal ve pembe renkli ve bir görünüme sahiptir, akıntılı zamanlarda kırmızı

renge sahip bir mukozası vardır, işitmenin derecesi perforasyonun büyüklüğüne göre değişmektedir [96, 98].

3.4.3.2. Kronik Mukozal Otitis Media

Orta kulağı ve mukozayı kaplayan bir iltihaplanmadır, polip ve granülasyon görülebilir, kemikçikleri çevreleyen mukoza görülmekte, akıntı uzun dönemli olup kokusuzdur, işitme kaybı ise ileri boyutlu değildir [98-99].

3.4.3.3. Kronik Kolesteatomlu Otitis Media

Attikoantral karaktere sahiptir. Kolesteatom çok tabakalı yassı epitelin orta kulak ve temporal kemiğin hava kısımlarında bulunmasıdır [96,100]. Orta kulak boşluğunda gelişen deriye kolesteatom denilmektedir. Kemik erimesine yol açmaktadır, diğer KOM tiplerinde de görülebilmekSte fakat kolestatom varlığı durumunda çok daha fazla geniş ve en az iki katı kadar olabilmektedir [101]. Kolesteatom kitlesi orta kulak ve mastoid boşluğunu doldurarak TM’da bir perforasyona neden olabilir ve bunun sonucu olarak otore görülebilir [102].

3.4.3.4. Adeziv Otit ve Retraksiyon Poşları

TM’nin, negatif basınçtan kaynaklı orta kulak yönüne çekilmesi “atelektazi” denilmekte, Adeziv otit söz konusu olduğunda TM’de daha ileri bir düzeyde çekilme ve orta kulak yapılarına yapışma olur. Retreaksiyon poşları ise TM’nin daha lokal bir bölgesinde meydana gelen çekilmedir [93].

3.4.4. Timpanozkleroz

Timpanozkleroz genellikle KOM’nin iyileşme süreci sonunda meydana gelen, TM ve orta kulakta submukozal fibröz ve elastik tabakanın hyalen dejenerasyona uğramasıdır. Bazen ossifikasyon (kemik dokusunun meydana gelmesidir) veya kalsifikasyon (kireçlenme) da bu inaktif otit sekeline eklenir [93,103].

BÖLÜM 4

MATERYAL VE METOD

4.1. KULLANILAN VERİSETİ

OM tanısının konması ve zar bölgesinin tespiti için uzmanlar tarafından orta kulak bölgesinin oldukça dikkatli bir şekilde incelemesi ve değerlendirilmesi gerekmektedir. OM tanısının konması için yapılan çalışmalara bakıldığında zaman araştırmacılara sunulan bir veri setine rastlanılmamıştır. Bu tez kapsamında etik kurulu izni (Ek 1 Etik kurulu izni) alındıktan sonra “Özel Van Akdamar Hospital” hastanesi KBB servisine gelen gönüllü hastalardan otoskop cihazı görüntüleri toplanmıştır. Ekim 2018 ve Ocak 2019 tarihleri arasında 282 adet, Ocak 2019 – Haziran 2019 tarihleri arasında ise 674 adet elden görüntü toplanarak toplamda 956 adet elde edilen orta kulak resimleri USB bağlantısı ile bilgisayarda kayıt altına alınmıştır.

Orta kulak imgelerinin toplanması için kişisel bilgisayarda OM türlerini içeren klasör adları oluşturulduktan sonra görüntüleri uzman tarafından kayıt edilmeye başlandı. Matlab 2018b Image Labeler uygulaması kullanılarak zar bölgesi seçilerek yer bilgisi (ground-truth) elde edilmiştir. Bu işlemin ardından sınıflandırmanın doğrulanması için ayrıca 2 adet uzman tarafından da görüntülerin sınıflandırılması ve zar bölgesi doğrulanmıştır.


Sınıflandırma ve zar bölgesinin tespit edilmesi için yüksek çözünürlüğe sahip resimler seçilmeye özen gösterilmiştir. Bu kapsamda elde edilen 950 TM görüntüsünden otoskopun ışık yansıması, el titremesinden kaynaklı bulanık resimler ve zar bölgesi net bir şekilde belli olmayan TM görüntüleri elenerek sonuç itibari ile 282 adet orta kulak görüntüsü ile çalışmalar yapılmıştır.

Veri setinde yer alan 282 adet TM görüntüsü 178 bay ve 104 adedi ise bayan hastalara ait görüntülerdir. Hastalara ait demografik bilgiler Çizelge 4.1.'de yer almaktadır.

Çizelge 4. 1. Hastalara ait demografik bilgiler.

Hasta	Sayı
Yaş Aralığı	2-71
Yaş Ortalaması	8
Medya	5
Bay	178
Bayan	104
Toplam Görüntü	282

Veri setimizde yer alan görüntülerden ilk aşamada Normal sınıfa ait 154 adet görüntü yer alırken, anormal sınıfa ait görüntü sayısı ise 128 adettir. Anormal görüntüler içerisinde AOM, CSOM, earwax, miringoskleroz, tympanostomy tüplü, otit externa gibi hastalıklara ait normal olmayan görüntüler yer almaktadır. Bu sınıflara ait görüntü Şekil 4.1'de, veri setimizde yer alan görüntülere ait sayısal bilgiler de Çizelge 4.2.'de verilmiştir.



Şekil 4. 1. Normal ve anormal TM görüntüleri.

Çizelge 4. 2. Veri setindeki görüntülere ait sayısal bilgiler (10/18-01/20).

Sınıf	Görüntü Sayısı
Normal	154
Anormal	128
AOM	69
CSOM	14
Earwax	21
Miringoskleroz	4
Tympanostomy Tüplü	2
Otit Externa	18

Veri setimizi ilk olarak 282 adet görüntü elde ettikten sonra çalışmalarımızı bu görüntüler ve imge arttırım yöntemlerinden yararlanarak yaptıktan sonra Haziran 2019'dan sonra 956 adet görüntü ile gerçekleştirilmiştir. Veri setimizde yer alan görüntü sayıları Çizelge 4.3.'te verilmiştir.

Çizelge 4. 3. Veri setindeki toplam görüntü sayısı (10/18-06/20).

Sınıf	Görüntü Sayısı
Normal	535
Anormal	421
AOM	119
CSOM	63
Earwax	140
Otit Externa	41
Diğer	58

4.2. VERİ ARTTIRMA

Derin öğrenme uygulamalarında sınıflandırma işlemlerini gerçekleştirmek için veri seti yetersiz olduğu durumlarda veri seti hacminin artırılmasının çeşitli yöntemleri bulunmaktadır. Literatürde yapılan çalışmalar göz önünde bulundurulduğunda; veri arttırma yöntemlerinden olan imgenin parlaklığı ile oynama, döndürme, ölçekleme, yatay ve dikey aynalama, gürültü ekleme, görüntü parçalama, ilgi alanı bölgelerini bölütleme, görüntünün kontrast ve yoğunluğunu değiştirme gibi veri çoğaltma tekniklerinden yararlandıkları belirlenmiştir [104-108]. İncelenen çalışmalar Çizelge 4.4.'te kullanılan veri arttırma yöntemleri ile detaylı bir şekilde verilmiştir.

Çizelge 4. 4. Kullanılan veri çoğaltma yöntemleri.

	Parlaklık	Döndürme	Ölçekleme	Aynalama	Gürültü	Parçalama(Bölme)
Anabel gomez-Rios[104]	✓	✓	✓	✓	x	x
Zaifeng Shi [105]	x	✓	X	x	✓	x
Ariel Waisman [106]	✓	x	✓	x	x	x
Maayan Frid-Adar [107]	x	✓	✓	x	x	✓
Nicholas j Tustison [108]	x	✓	X	✓	x	x
Bu Tez Çalışmasında	x	✓	X	✓	✓	x

Bu tez çalışması kapsamında otoskop cihazından alınan TM imgeleri yatay ve dikey olarak döndürülmesi ve aynı zamanda 90^0 , 180^0 , 270^0 döndürülerek bir imgeden 5 adet çoğaltılarak imge arttırımına gidilmiştir (Şekil 4.2.).



Şekil 4. 2. Arttırılmış TM görüntüleri.

Veri setimizdeki imge arttırımından sonra görüntü sayısı 282'den 1692'ye yükselmiştir. Veri setimizdeki normal ve anormal imgelere ait bilgiler Çizelge 4.5.'te verilmiştir.

Çizelge 4. 5. Veri arttırma sonrası görüntü sayıları.


Sınıf	Görüntü Sayısı	Arttırılmış Görüntü
Normal	154	924
Anormal	128	768
AOM	69	414
CSOM	14	84
Earwax	21	126
Miringoskleroz	4	24
Tympanostomy Tüplü	2	12
Otit Externa	18	108

4.3. GÖRÜNTÜ İŞLEME TEKNİKLERİ

Dijital görüntü işleme; dijital görüntüleri bilgisayar aracılığıyla işlemek için kullanılan yöntem ve algoritmalarla ilgili sürekli gelişen bir alandır [109]. Görüntü, en küçük birimi olan piksel matrisinden oluşmaktadır [110]. Makine ve bilgisayar için iki boyutlu olan görüntü, bilgisayarlar tarafından işlenebilmesi, örneklenebilmesi ve nicellenebilmesi için iki boyutlu bir fonksiyon olarak anlaşılması gerekmektedir [111].

4.3.1. RGB Renk Kanalı


RGB (red green blue), renk modeli en çok kullanılan renk kanalı sistemlerinden biridir. Herhangi bir renk üretmek için isminin İngilizce karşılığı olan kırmızı, yeşil ve mavi renkleri karıştırır [112]. RGB, CMYK ve HSV gibi renk kanalları bulunmaktadır [113]. Bu tez kapsamında RGB renk kanalı görüntüler kullanılmıştır. RGB renk kanalındaki bir resmi gri renkli bir resme dönüştürmek R, G ve B değerlerini sırasıyla 0.299, 0.587 ve 0.144 değerleri ile çarpılır [114]. RGB renk kanallarının ortalama değerleri alınan görüntü Şekil 4.3'te görülmektedir.



Şekil 4. 3. Normal TM ve ortalama RGB değeri alınmış görüntü.

4.3.2. Uyarlanabilir Histogram Eşikleme


Histogram eşitleme, görüntüyü temsil eden piksellerin görüntünün toplam yoğunluk seviyesi sayısını değiştirmeden eşit olarak dağıtıldığı bir kontrast geliştirme yöntemidir [115]. Uyarlanabilir histogram eşikleme (UHE) yöntemi ise bir görüntünün kontrastını arttırmaya yarayan histogram eşikleme yöntemlerinden biridir. Şekil 4.4.'te gri renkli bir orta kulak imgesi ve UHE tekniğinden sonraki görünümü görülmektedir.



Şekil 4. 4. Gri renkli ve UHE uygulanmış hali.

4.3.3. Gauss ve Tuz-Biber Gürültüsü

Tuz-biber gürültüsü, görüntünün elde edilmesi aşamasında iletim ve hafıza hatalarından dolayı bulunur. Gri resimlerde de pikselin değerini pozitif ve negatif yapmaktadır [116]. Bir diğer gürültü çeşidi olan gauss ise beyaz gürültü olarak da adlandırılır. Gauss gürültüsünde şiddet frekansa göre değişkenlik göstermemektedir [117]. Normal TM görüntüsüne gauss ve tuz-biber gürültü eklendikten sonraki TM görüntüsü Şekil 4.5.'te görülmektedir.



Şekil 4. 5. Normal ve gauss, tuz-biber gürültülü TM.


4.4. GÖRÜNTÜ ÖZNETELİKLERİNİN ELDE EDİLMESİ

Özellik, her biri bir nesnenin ölçülebilir bir özelliğini temsil eden ve nesnenin bir takım önemli sayılabilecek özelliğini ölçecek şekilde hesaplanan bir veya daha fazla ölçümün işlevi olarak tanımlanır [118]. Özellik çıkarmanın amacı orijinal bir veriyi düşük boyutlu bir veri ile temsil etmektir [119].

Doku analizi; bilgisayar görü, sınıflandırma ve örüntü tanıma gibi alanlarda sık kullanılan yöntemlerden biridir [120]. Bu tez kapsamında dokusal özellik çıkarma algoritmalarından olan gri seviyeli eş-oluşum matrisi (GSEM), yerel ikili örüntü (YİÖ), yönlü gradyan histogramı (YGH) gibi algoritmaların yanı sıra öznitelik olarak bir görüntünün ortalama renk değeri de kullanılmıştır.

4.4.1. Gri Seviyeli Eş-Oluşum Matrisi

İki piksel arasındaki gri seviyenin geçişine ilişkin dokusal bilgilerin çıkarılmasına yönelik bir yaklaşım olan GSEM, bir ortak oluşum matrisi kullanır [121]. Doku, istatistiksel olarak bir özellik kümesi olan piksel yoğunluğudur [122]. GSEM, bir görüntüdeki komşu piksellerin gri seviye çiftlerini verir. Şekil 4.6.'da görüntüdeki piksel çiftlerinin eş oluşum matrisinde gösterilmektedir.



Şekil 4. 6. GSEM örneği.

GSEM, gri renkli görüntülerde pikseller arasındaki açı (θ) ve uzaklığa (δ) göre GSEM Denklem 3.1'deki gibi hesaplanmaktadır.

$$M_{\delta, \theta} = 0(p, q) \sum_{n=1}^N \sum_{m=1}^K \begin{cases} 1 & I(n, m) = p \\ 0 & I(n, m + \delta) = q \end{cases} \quad (4.1)$$

Denklem 4.1'de p ve q değerleri görüntüdeki gri rengin yoğunluğunu; N, K ise görüntünün boyutunu ifade etmektedir. Eşitlikte belirttiği üzere belirlenen bir θ açı yönünde ve δ uzaklık değerlerine bağlı olarak değişmektedir. Burada θ açısı genellikle 0° , 45° , 90° ve 135° olarak alınmaktadır.

GSEM'ye dayanılarak istatistiksel olarak birçok özellik hesaplanabilir. Bu tez çalışması kapsamında bir GSEM'de, bitişik pikseller arasındaki gri düzeydeki benzerliği temsil eden köşegene yakın öğelerin varlığına duyarlılığı olan homojenlik, görüntüdeki doğrusal olarak bağımlılığın ölçütü olan korelasyon, zıtlığın ölçütü yani pikseller arasındaki büyük renk değişimi olan kontrast ve dokulardaki piksel çift tekrarları olan tekdüzeliğin ölçütü olan enerji metrikleri hesaplanarak özneteliğe eklenmiştir [123]. Bu metrikler matematiksel olarak (Denklem 4.2 - 4.5) verilmiştir.

$$\text{Homojenlik} = \sum_{i,j} \left(\frac{P(i,j)}{1+|i-j|} \right) \quad (4.2)$$

$$\text{Korelasyon} = \sum_{i,j} \left(\frac{(i-\mu_x)(j-\mu_y)P(i,j)}{\sigma_x\sigma_y} \right) \quad (4.3)$$

$$\text{Kontrast} = \sum_{i,j} |i - j|^2 P(i, j) \quad (4.4)$$

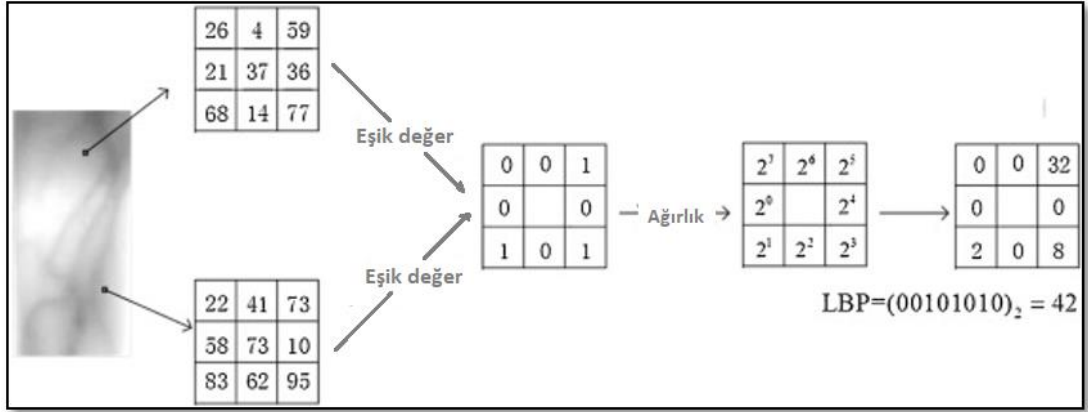
$$\text{Enerji} = \sum_{i,j} P(i, j)^2 \quad (4.5)$$

Eşitliklerde i ve j parametreleri satır ve sütunların indislerini, μ ortalamayı, P indisleri ifade ederken σ ise standart sapmayı gösterir.

4.4.2. Yerel İkili Örüntü

Yerel ikili örüntü (YİÖ), ilk olarak bir görüntünün histogramlarını hesaplayarak, doku sınıflandırması gerçekleştirilmiştir [124]. Görüntü işleme uygulamaları için etkili ve verimli bir yöntem olan YİÖ kullanılarak, yerel olarak yinelenen örüntüler ortaya çıkar.

YİÖ genellikle 3x3 piksel görüntülere uygulanır. Buradaki piksel görüntülerin merkezdeki değeri, komşu sekiz piksele göre hesaplanmaktadır [125]. Eğer piksel değeri eşik değerden büyükse, değer 1 olarak alınır. Değilse değer 0 olur. 3x3 piksel görüntüdeki tüm değerler için bu uygulanır ve ikili tabana karşılık gelen on tabanlı sayı, yerel komşunun YİÖ değeri olarak alınır [126]. YİÖ hesaplanmasının örneği Şekil 4.7.'de verilmiştir.




Şekil 4. 7. YİÖ Hesaplanması [125].

Yerel bir dairesel bölgedeki merkezi bir piksel c ve p komşu pikselleri verildiğinde, YİÖ, gri tonlama farklarının bir ikili formata dönüştürülmesiyle hesaplanır. Denklem 4.6'de YİÖ hesaplanması matematiksel olarak ifade edilmiştir.

$$YİÖ_{p,r} = \sum_{p=0}^{p-1} s(g_p - g_c) 2^p, \quad s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (4.6)$$

Denklemden ifade edilen merkezi örnekleme noktasının g_p ve g_c 'nin p 'nci komşusunun gri değerleri olan r , yerel dairesel bölgenin örnekleme yarıçapıdır.



Şekil 4. 8. a) P=8, r=1 b) P=18, r=2 c) P=24, r=3.

Ojala ve arkadaşları (2002) YİÖ geliştirmek için farklı üç dairesel komşuluk değeri ile hesaplamışlardır [127]. Şekil 4.8.'de P komşuluk ve r yarıçapı olacak şekilde 3 farklı şekilde ilişki görülmektedir.

4.4.3. Yönlü Gradyan Histogramı


YGH, ilk olarak Dalal ve Tigris tarafından görüntülerde yer alan insan tespiti için geliştirilmiştir [128]. Bu algoritmanın amacı, görüntü bloğunda var olan görüntü piksellerinin yönlendirilmiş gradyanlarının istatistiklerini elde ederek bir görüntüyü tanımlamaktır. Görüntüdeki ışık değişikliklerine karşı sağlamlığı ve yerel geometrik dönüşümlere karşı değişmezliği nedeniyle YGH, insan tespiti, karakter tanıma ve yüz tanımada başarıyla kullanılmıştır [129].

YGH, görüntüyü hücrelere bölerek bu hücrelerdeki histogram gradyan hesaplaması yapılır. Bir görüntünün YGH'yi çıkarmak için ilk olarak görüntünün yatay G_x ve dikeydeki G_y gradyan hesaplaması için sobel filtresi (yatay $[-1 \ 0 \ 1]$ ve dikey $[-1 \ 0 \ 1]^T$ olarak) kullanılır. Ardından her bir gradyanın açısı (θ) ve boyutu (G) Denklem 4.6 – 4.7'ye göre hesaplanır.

$$|G(x, y)| = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (4.6.)$$

$$\theta_{x,y} = \arctan\left(\frac{\sin \theta}{\cos \theta}\right) \quad (4.7.)$$

Her hücredeki gradyan histogramı hesaplaması yapıldıktan sonra, bu histogram hücre merkezi pikseline tahsis edilir (Şekil 4.9.). Bu nedenle, her piksel için çevresindeki gradyan histogramını temsil eden n boyutlu bir vektör hesaplanır [130].



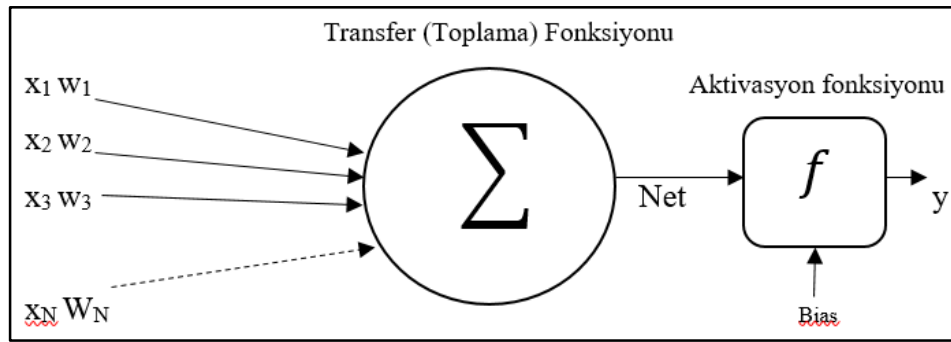
Şekil 4. 9. Hücre ve histogram yönlendirme gradyanı [129].

4.5. YAPAY SİNİR AĞLARI

Yapay sinir ağı (YSA), öğrenme süreci deneyimden kaynaklanan biyolojik nöronların basitleştirilmiş matematiksel modellerine dayanan bir bilgi işleme sistemidir [131]. Bir

YSA'ya giriş olarak verilen örnekler ile öğrenen ağ, elde ettiği bağlantı ağırlık bilgilerini kullanarak yeni örnekler için doğru bir karar vermeye çalışır. Doğrusal olmayan problemlerde ve genelleştirme kapasitesi oldukça yüksek olan YSA; matematik, mühendislik, ekonomi gibi diğer birçok alanda da başarılı sonuçlar elde etmektedir [132].

Katmanlı bir yapıdan oluşan YSA giriş, ara (gizli) katman/katmanlar ve çıkış katmanından oluşmaktadır. Örnek bir YSA ağının yapısı Şekil 4.10'da görülmektedir.



Şekil 4. 10. YSA nöron modeli.

Şekil 4.10'da verildiği gibi bir YSA nöronunda girdiler ($x_1, x_2, x_3, \dots, x_N$), ağın öğrenmesi için verilen örneklerdir. Bu girdilere karşılık ağırlık değerleri ($w_1, w_2, w_3, \dots, w_N$) ağ üzerindeki etki değerleridir. Tüm girdiler ağırlık değerleri ile çarpılarak transfer fonksiyonunda birleşip bias değeri de (b) eklendikten sonra aktivasyon fonksiyonundan (σ) geçirilmektedir. Matematiksel olarak Denklem 4.8'deki gibi modellenir.

$$f(net) = \sigma(\sum_{i=1}^N x_i w_i + b) \quad (4.8)$$

YSA ağı kurulduktan sonra ağın optimizasyonu için bazı parametreler ayarlanması gerekir. Ağ kurulduktan sonra kullanılan aktivasyon fonksiyonu, modelin yapısı, kullanılan katman sayısı bias değeri gibi ayarlanabilen parametrelerin gözden geçirilmeleri yararlı olur.

4.6. K-EN YAKIN KOMŞU

k-en yakın komşu algoritması (kNN) algoritması veri seti üzerindeki k adet komşu sayısına en yakın komşulara göre arama yapar [133]. Makine öğrenme algoritmaları

içerisinde bilinen en kolay algoritmalarındandır. Uygulanması ve yüksek doğruluk sonuçları elde edilmesiyle yaygın bir şekilde kullanılmaktadır [134].


kNN sınıflandırıcısı kullanmanın iki büyük dezavantajı vardır. Bunlardan biri büyük veri seti için kullanıldığı zaman oldukça yavaş çalışmasıdır, çünkü yeni bir örneği veri setinde bulunan tüm veriler ile karşılaştırır. Diğer dezavantajı ise ilgisiz olan örnekler yanılığa kapılabilmesidir [135].

Bu yöntemin başarısı seçilen k uzaklık mesafesidir. En iyi başarı sonuçlarını elde etmek için farklı k komşuluk oranları denenip sonuçlarına bakılmalıdır. Verileri arasındaki uzaklık Öklid, Manhattan, Minkowski ölçütleri ile hesaplanmaktadır. Bu tez çalışması kapsamında Öklit bağlantısından yararlanılmıştır. Öklid uzaklığın hesaplanması Denklem 4.9'da matematiksel olarak verilmiştir.

$$d(x, y) = |x - y| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.9)$$

4.7. DESTEK VEKTÖR MAKİNELERİ

DVM, diğer makine öğrenme algoritmalarından farklı olarak eğitim hatalarını en aza indirmeye yerine hiper düzlem ile eğitim verileri arasındaki sınır ayrımını en üst düzeye çıkararak hatanın üst sınırını minimize etmeye çalışır [136]. Güçlü öğrenme ve genelleştirme yeteneği olan SVM, diğer geleneksel makine öğrenme yöntemleri ile karşılaştırıldığında çok sayıda uygulamadan performansının daha yüksek olduğu görülebilir [137].



Şekil 4. 11. DVM' de en büyük aralıklı sınıflandırma [138].

DVM, bir hiper düzlemde veri setini ayırmak için maksimum aralığı en üst düzeye çıkarmayı hedefler. Şekil 4.11'de DVM ile en yüksek aralıkla ayırma gösterilmiştir. DVM burada sınıflar arasındaki en uygun ayırcıyı bulmaya çalışır. $\{ (x_i, y_i) \}_{i=1}^n$, $y_i \in \{-1, 1\}$, n ifadesi veri setindeki verilerin sayısını, ifade eder. En uygun ayırcıyı bulmak için $f(x) = w^T x + b = 0$ uygulanır. Burada marj aralığının (p) -1 ve $+1$ değer aralığında tanımlanır. SVM iki veri sınıfı arasındaki marj aralığını $(1 / \|w\|)$ maksimum tutarak verilerin bu çizgilerin üzerinde veya dışında tutmayı amaçlar [138].

SVM modelleri ayırırken tüm veriler her zaman marj bölgesinin dışında olmayabilir bu arada da olabildiği gibi, bir sınıfın içinde diğer sınıfta verileri olabilir. Bu durumda marj alanı optimizasyonu için ξ_i değişkeni eklenerek problem Denklem 4.10-4.11'deki gibi tanımlanabilir [139].

$$\text{Min } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (4.10)$$

$$\text{Burada } y_i (w^T x_i + b) \geq 1 - \xi_i, i=1, \dots, n, \quad \xi_i \geq 0 \quad (4.11)$$

Eşitlikte c , hatayı düzelten bir ceza parametresidir. Lagrange çarpanları kullanılarak aşağıdaki gibi ifade edilebilir.

$$\text{Max } \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j x_i^T x_j \quad (4.12)$$

$$\text{Burada } 0 \leq a_i \leq C, \quad i=1 \dots n \quad (4.13)$$

$$\sum_{i=1}^n a_i y_i = 0 \quad (4.14)$$

DVM, veri setini doğrusal olarak ayıramadığı takdirde verileri ayırabilmesi için iki boyutlu düzlemden daha yüksek boyutlu bir düzlem uzayına giderek ayırabilir. Daha yüksek düzlem uzayına geçmek için çekirdek fonksiyonu kullanmak gerekir. En çok kullanılan kernel fonksiyonları; polinom kernel, doğrusal kernel, sigmoid kernel, radyal temelli ve gauss kernel fonksiyonlarıdır.

4.8. ZAR BÖLGESİNİN TESPİTİ

Nesne algılama için literatürde kullanılan yöntemlere bakıldığında; Geleneksel yöntemler olarak; renk özellikleri, SIFT, LBP, HOG, histogram temelli kMeans, derin öğrenme temelli olarak SSD, R-CNN, Fast R-CNN, Faster R-CNN, YOLO gibi yöntemler kullanılmıştır.

Object detection; biyomedikal görüntü işleme, yüz tanıma, yaya tespiti, araç tespiti, meyve tespiti, İHA görüntülerinde nesne tespiti gibi birçok alanda kullanılmıştır [140-144].

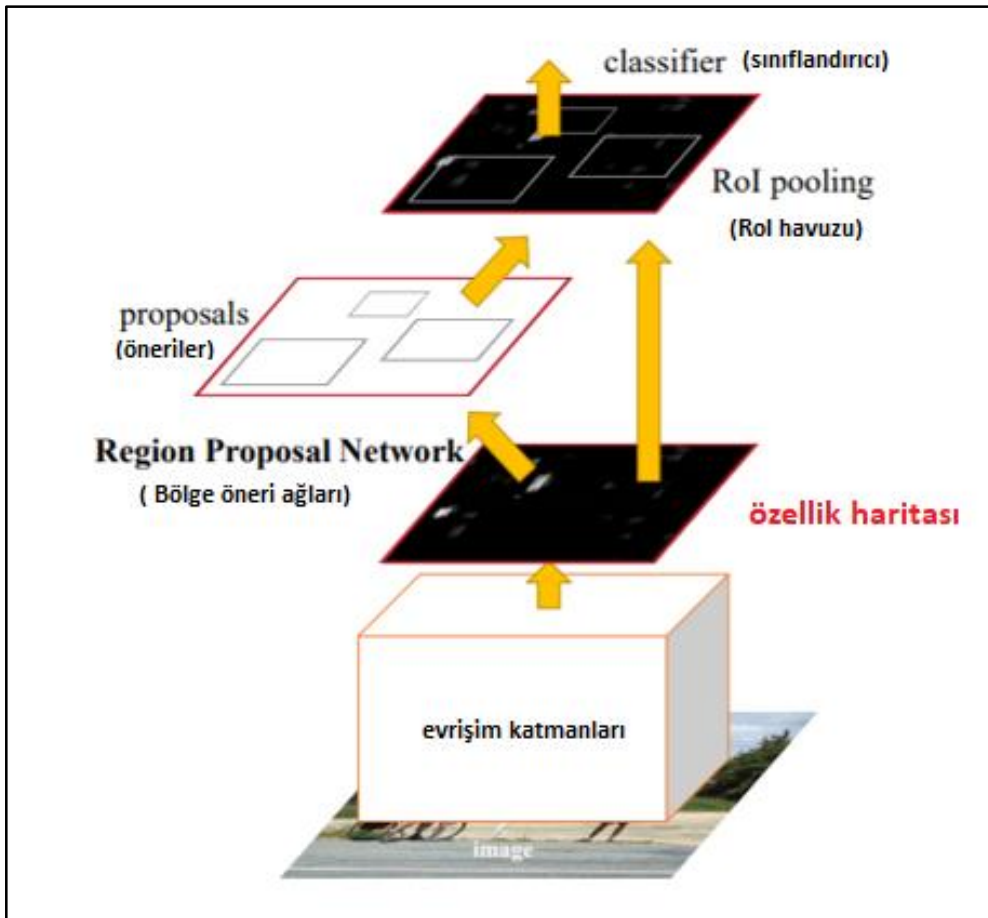
Bu tez çalışmasında orta kulak imgelerinde zar bölgesinin tespiti için derin öğrenme temelli yöntemlerden olan Faster R-CNN ve YOLO kullanılmıştır.

4.8.1. Faster R-CNN


Faster R-CNN, bir görüntünün derin özelliklerini çıkarabilen gerçek zamanlı, çok sınıflı bir nesne algılamada kullanılan ve gerçek zamanlı bir tanıma sistemidir [145]. Nesne algılama sadece bir nesnenin kategorisini tanımakla kalmaz bunun yanında nesneyi bir sınırlandırıcı kutu içerisinde barındırır [146]. Bölge önerilerine dayanan nesne algılama yöntemlerinden özellikle R-CNN serileri ile oldukça iyi algılama hassasiyetleri elde edilmiştir. R CNN yöntemi seçici arama algoritması ile giriş görüntüsünü tarar ve 2000 adet bölge önerisi üretir ve bu üretilen her bir bölge üzerinde ESA çalışır. Her bir CNN'nin çıktısını alınarak, bölgeyi sınıflandırmak için destek vektör makinası girişine verilir ve eğer bir nesne var ise nesnenin sınırlayıcı kutusunu doğrusal regresyon kullanılır [147].

R-CNN yönteminde 2000 defa ESA çalıştığından dolayı ciddi bir zaman hesaplama gücü gerektiriyordu. Bu problemin önüne geçilmesi için Fast R-CNN yöntemi ile R-CNN yönteminde bölge önerisi için 2000 sefer ESA çalıştırmak yerine sadece bir sefer ESA çalıştırılarak ciddi bir zaman tasarrufu elde edildi. Evrişim katmanında özellik haritasından, önerilen bölgeleri tespit eder ve bir ROI havuzlama katmanı oluşturup bunları tam bağlı bir katmana tüm özellikler yerine bu havuzlama katmanı ile bağlanır. Sınıflandırma katmanında ise SVM yerine softmax fonksiyonu kullanıldı [148].

Faster R-CNN yönteminin ana hedefi yavaş olan seçici arama algoritmasını hızlı bir sinir ağı ile yer değiştirmektir. Özellikle bölge öneri ağı (Region Proposal Network - BÖA) ile kendini tanıttı. BÖA tam olarak evrişimsel bir sinir ağıdır [149]. Girdisi bir görüntü olan, önerilen bölgeleri çıkartmak için kullanılır ve önerilen bölgelere aynı zamanda skorlar (tahmin etme doğruluğu) verilir [150]. Faster R-CNN diagramı Şekil 4.12'de verilmiştir.



Şekil 4. 12. Faster R-CNN diyagramı [151].



Şekil 4. 13. BÖK blok diyagramı [150].

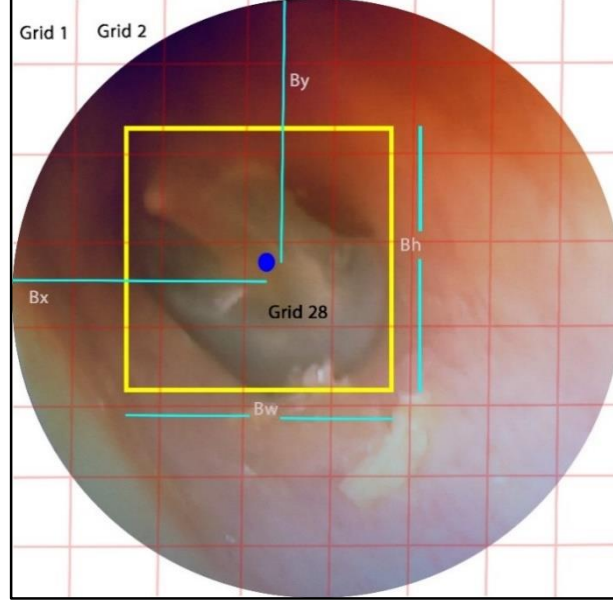
Şekil 4.13'te belirtildiği gibi BÖA, ESA'daki özellik haritasını alarak her bir konum için k tahmini alır, her bir lokasyon için $4k$ koordinat ve $2k$ sınıf üretir. Önerilen bölgelerin sınıflama katmanı ve skor değerlerini, tahmin katmanı aşamasında Fast R-CNN ağında birleştirilir [151]. Fast R-CNN ağının da iki çıkış katmanı bulunmaktadır. Bunlardan ilki Softmax sınıflayıcı katmanı diğeri ise tespit edilen bölgenin tespit edilme doğruluğunu veren regresyon katmanıdır [152].

4.8.2. YOLO

Gerçek zamanlı ve derin öğrenmeye dayalı bir nesne algılama algoritması olan YOLO (You only look once) Joseph Redmon ve arkadaşları tarafından geliştirilmiştir. YOLO sınırlayıcı kutuları ve sınıf olasılıklarını tahmin etmek için tek bir sinir ağı kullanır ve tek bir regresyon problemi olarak nesne tespitini yeniden çerçeveler [153]. YOLO mimarisi, 27 katmandan oluşmaktadır. Bunların 24'ü evrişim katmanı, iki tam bağlı katman ve son olarak bir algılama katmanından oluşmaktadır [154].

Tek bir evrişimsel ağ kullanarak aynı anda birden fazla sınırlama kutusunu ve bu kutular için sınıf olasılıklarını öngörür. YOLO giriş görüntüsünü $S \times S$ ızgara ile hücrelere böler ve x, y eksenleriyle resim eşit bir şekilde ızgaraya bölünür, bir nesnenin merkezi bir hücreye düşerse bu hücre nesneyi tespit etmekle sorumludur (Şekil 4.14).

Her bir ızgara hücresi nesnelerin varlığının güvenini tahmin eder. Güven (*Conf*) matematiksel olarak Denklem 4.15’de gösterilmiştir.



Şekil 4. 14. TM'nin YOLO ile tespit edilmesi.

$$\text{Conf}(\text{Object}) = \text{Pr}(\text{Object}) \times \text{IoU} \quad (4.15)$$

$\text{Pr}(\text{Object})$ nesnenin tahmin değeridir ve $\text{Pr} \in \{0,1\}$ ve IoU burada tahmin kutusunun doğruluk değeridir ve Denklem 4.16’de matematiksel modeli verilmiştir [155].

$$\text{IoU} = \frac{\text{area}(\text{box}(\text{Truth}) \cap \text{box}(\text{Pred}))}{\text{area}(\text{box}(\text{Truth}) \cup \text{box}(\text{Pred}))} \quad (4.16)$$

Güven; nesnenin varlığının olup olmadığını ya da nesnenin konumunun orta noktasının x (Bx) ve y (By) koordinatı, nesnenin genişliği (Bw) ve yüksekliğinin (Bh) koordinatlarından ne kadar emin olduğudur [156,157].

4.9. EVRİŞİMSEL SİNİR AĞLARI

Evrışimsel sinir ağları (ESA) çok katmanlı bir algılayıcı türü olan ileri beslemeli bir yapay sinir ağıdır. Yapay sinir ağları ilk olarak 1943 yılında Warren McCulloch ve arkadaşları tarafından ortaya çıkarılmıştır [158]. Ardından Pitts ve arkadaşları pörseptron mimarisini sunmuşlardır. David Hubel arkadaşları ise kedi görme sistemi üzerinden gerçekleştirmiş oldukları deneysel çalışmada görme

işlevinin basit yapılarla başladığını ve bilginin beyin nesnelere tanıma sürecinin karmaşık bir şekilde olduğu sonucuna varmışlardır [159]. Pörseptron mimarisindeki sorunların çok katmanlı pörseptron ile giderilmesiyle tekrar popülerliğini sağlayan sinir ağları 1980 yılında da Fukushma ilk derin öğrenme mimarisini olan 'neocognitron'ı sunmuştur [160]. Bu yapı ESA'ya benzeyen ilk katmanlı hiyerarşik yapıdır. 1998 yılında Lecun ve ekibi tarafından posta numaraları, banka çeklerinin üzerindeki sayıları okunması LeNet 5 ağını geliştirmiştir bu model ilk başarılı ESA modelidir [161]. Modelin dünya çapında ön plana çıkması 2012 yılında yapılan ImageNet yarışmasında Alex Krizhevsky tarafından önerilen AlexNet ESA modeli ile oldu [162].

ESA mimarisinde her biri farklı görevleri olan birkaç katmandan oluşmaktadır. ESA'da katmanlar genişlik, yükseklik ve derinlik olmak üzere üç boyutta düzenlenmektedir. ESA, biyomedikal imgelelerde hastalığın teşhisi, sınıflandırma, nesne tanımlama, ses sinyalleri işleme, video ve metin işleme, imge bölütleme gibi pek çok bilgisayarlı görme çalışmalarında üstün performansından dolayı oldukça fazla kullanılmaktadır.

Yapay zekâ kapsamında değerlendirilen makine öğrenme algoritmaları ile birçok problem çözüme kavuşabilmektedir. Makine öğrenme algoritmaları bir problemi temsil eden özellikler çıkarılarak sınıflandırma, kümeleme, regresyon problemleri gibi birçok problemi çözer. Algoritmanın problemi çözmeye başarısı örneklemin öznelik denilen özelliklerinin temsili ile yapılmaktadır. ESA ise algoritma girişine ham veriyi alır ve bünyesinde bulunan katmanlar ile özellik haritasını elde eder ve sınıflandırma işlemini gerçekleştirir. Bir ESA'da giriş katmanı, evrişim katmanı (convolution), ortaklama (pooling), tam bağlı katman, çıkış katmanı bulunmaktadır. Bu katmanlara sırasıyla aşağıda değinilmiştir.

4.9.1. Giriş Katmanı


Bu katman ESA'ya ham olarak verilen giriş görüntüsüdür. Bu katmandaki görüntünün boyutunun artması hesaplama maliyetinin neden olurken görüntüyle ilgili ayrıntı bilgisi elde edilmesini de sağlar. Giriş boyutunun küçük olması da hesaplama maliyetini azaltmaktadır.

4.9.2. Evrişim Katmanı (Convolution)

ESA mimarisinde çekirdek (kernel) katmanı olarak da bilinir. Bu katmanda filtreler ile görüntü matrisi üzerinde soldan sağa ve yukardan aşağıya doğru filtre ile gezdirilmesiyle oluşur. Kaydırma işlemi esnasında filtre ile aynı boyutta görüntü matrisi ile çarpma işlemi sağ alt köşeye kadar gerçekleştirilir. Bu katmanın ana amacı giriş görüntüsünden özellik çıkarmadır. Burada uygulanan filtrenin sayısı imgenin derinliği kadardır. İlk evrişim katmanı kenar bilgileri gibi basit özellikleri çıkarmaktadır. Bunu izleyen diğer evrişim katmanlarında ise üst düzey özellikler tespit edilir [163]. Evrişim işleminin matematiksel ifadesi Denklem 4.17’de gösterilmiştir.

$$(f * h)[m, n] = \sum_j \sum_k h[j, k], f(m - j, n - k) \quad (4.17)$$

Burada f giriş görüntüsü ve h kernel olmak üzere, çıkış matrisinin satır ve sütun indisleri sırasıyla m ve n ’dir. j ve k ise yeni evrişim işleminden sonra yeni oluşacak matrisin satır ve sütunu ifade eder. Evrişim katmanında filtreler ile özellik çıkarma işlemi Şekil 4.15.’de gösterilmiştir.



Şekil 4. 15. Evrişim işlemi.

$$(f * h)(1,1) = (1 * 1) + (1 * 1) + (1 * 1) + (1 * 0) + (0 * 0) + (1 * 0) + (0 * 1) + (0 * 1) + (1 * 1) = 4$$

Evrişim işlemi sonunda bir aktivasyon haritası oluşur. Oluşan aktivasyon haritası giriş görüntüsünün boyutu, kernel boyutu, adım büyüklüğü ve dolguya bağlı olarak değişir. Filtrenin giriş görüntü üzerinde ilerleme boyutu adım sayısı (stride) olarak adlandırılmaktadır. Adım sayısı değeri arttıkça çıkış matrisi daha da küçülmektedir. Çıkış boyutundaki küçülmenin önüne geçmek için görüntü üzerinde dolgu (padding)

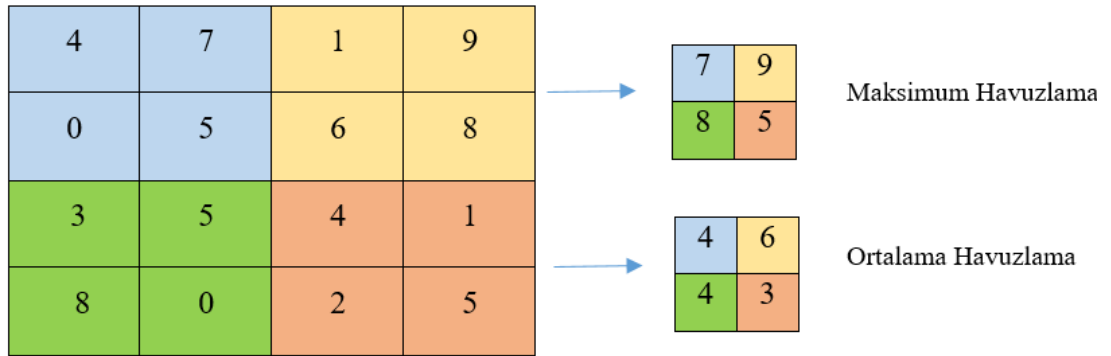
yöntemi kullanılmaktadır. Dolgu yönteminde görüntü genellikle 0 değerleri ile tamamlanır. Bir evrişim işleminde axa boyutlu bir girişi görüntüsünün b*b filtre boyutu, s adım kaydırma ve p dolgu boyutu olmak üzere çıkış boyutunun büyüklüğü (O), Denklem 4.18’de formülize edilmiştir.

$$O = \frac{a-b+2p}{2s} + 1 \quad (4.18)$$

4.9.3. Havuzlama Katmanı (Pooling)

Evrişim işlemi sonunda ortaya çok fazla sayıda parametre çıkar. Bu parametrelerin fazlalığı hesaplama maliyetini arttırdığı gibi ağın ezberlemesine de sebep olabilmektedir. Bu katmanda komşu piksellerin değerini tek bir değer ile temsil edilir. Kare matrisinde komşu piksellerin genelde ya ortalama ya da maksimum değeri alınarak havuzlama katmanı oluşturulmaktadır [164].

Havuzlama katmanı aynı zamanda ortaklama katmanı ve alt-örnekleme olarak da bilinmektedir. Bu katman sayesinde evrişim katmanı sonucu oluşan fazla sayıda parametre özetlenmiş olur. Havuzlama katmanında evrişim katmanında olduğu gibi çeşitli boyutlarda filtreler ve bu filtreler uygulanırken adım sayısı da kullanılmaktadır. Bu filtrelerin komşuluk indislerinin ortalama ya da maksimum gibi istatistiksel değeri hesaplanmaktadır. Havuzlama katmanının çalışma prensibi Şekil 4.16’daki örnekte özetlenmiştir.



Şekil 4. 16. Havuzlama örneği (adım sayısı ve boyutu:2).

4.9.4. Tam Bağlı Katmanı (Fully Connected Layer)

Bu katmanda önceki evrişim ve havuzlama katmanında elde edilen özellikler vektöre dönüştürülür. Tipik bir yapay sinir ağı modeli olan bu katman genellikle havuzlama katmanı ve çıkış katmanı arasına bulunur. Önceki katmanda yer alan nöronların tamamı mevcut katmandaki nöronlara bağlıdır [165]. Bu katmanın amacı girdi görüntülerini eğitim verisine dayanılarak çeşitli özelliklerini kullanıp sınıflandırma işlemini gerçekleştirmektir [166].

4.10. ESA’NIN EĞİTİLMESİ

Evrişimsel sinir ağları ile sınıflandırma işlemini gerçekleştirmek için ağın optimize edilmesi gereken ve kullanıcının karar vermesi için birçok parametre bulunmaktadır. Modelin ve ağı iyileştirilmesine yönelik yapılan iyileştirmelere hiper parametre denilmektedir. Hiper parametreler genel olarak ağın yapısına ve iyileştirilmesine yönelik yapılan karar verilen iyileştirmelerdir. Ağın iyileştirilmesi için giriş resminin boyutu, katman sayısı, filtre sayısı ve boyutu, aktivasyon fonksiyonu, adım boyutu, dolgulama işlemi, kullanılan tam bağlı katman sayısı, seyreltme katmanı gibi parametrelerdir. Ağı iyileştirmeye yönelik de iterasyon sayısı, eğitim verisinin paket boyutu, öğrenme oranı, regülarizasyon, momentum gibi parametreler sayılabilir [167-169].

4.10.1. Aktivasyon Fonksiyonu


Sinir ağlarında giriş değerleri ağırlık değerleri ile çarpıldıktan sonra bias değeri eklenir ve ardından bir aktivasyon fonksiyonundan geçirilerek bir çıktı üretilir. Elde edilen çıktı bir başka nörona ait giriş olabileceği gibi nihai çıkış da olabilir. Aktivasyon fonksiyonları sinir ağlarında doğrusal olan ifadeleri doğrusal olmayan ifadelere dönüştürür. Tüm sinir ağlarında, bir nöronun aktif olup olmayacağını belirlemek için aktivasyon fonksiyonları kullanılır ayrıca aktivasyon fonksiyonları ağın öğrenmesini ve optimizasyon sürecini de etkilerler [169]. Sinir ağlarında yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid, tanjant hiperbolik, ReLu, Softmax’dır.

4.10.1.1. Sigmoid

Bu aktivasyon fonksiyonu türevi alınabilir bir fonksiyondur ve sık bir şekilde kullanılmaktadır[170]. Giriş değeri olarak $-\infty$ ile $+\infty$ arasında değer alır. Sigmoid aktivasyon fonksiyonu 0 ile 1 bir arasında bir değer üretir [171]. Bu aktivasyon fonksiyona ait matematiksel Denklem 3.19'da ve grafik ise Şekil 4.17'de verilmiştir.

$$\sigma = \frac{1}{1+e^{-x}} \quad (4.19)$$

Denklem 4.19'daki x üstel değeri çok küçük ya da çok büyük olduğu zaman türev değeri 0'a yakınsar. Sigmoid aktivasyon fonksiyonun grafiği Şekil 4.17'de verilmiştir.




Şekil 4. 17. Sigmoid aktivasyon fonksiyonu [165].

4.10.1.2. Hiperbolik Tanjant

Bir diğer popüler olan aktivasyon fonksiyonu hiperbolik tanjant (tanh), -1 ile 1 arasında değer üretmektedir. Grafikselsel olarak Şekil 3.18.'de verilmiştir. Sigmoid ve tanh aktivasyon fonksiyonlarının ortak özelliği gradyan yokolması (vanishing gradient) probleminin olmasıdır [172]. Bu fonksiyon sinir ağlarının gizli katmanlarında önemli rol oynamaktadır [173]. Tanh aktivasyon fonksiyonu Şekil 4.18.'de grafiği gösterilmekte olup, aynı zamanda Denklem 4.20'de matematiksel olarak ifade edilmiştir.

$$\sigma = \frac{1-e^{-2x}}{1+e^{-2x}} \quad (4.20)$$



Şekil 4. 18. Tanjant hiperbolik aktivasyon fonksiyonu.


4.10.1.3. Relu (Rectified Lineer Unit)

Bu aktivasyon fonksiyonu ilk olarak kısıtlı Boltzman Makinalarında kullanıldı [174]. Bu fonksiyonda alınan değer sıfırın altında ise çıkış olarak 0 döndürür eğer 0'dan büyük ise çıkış değeri olarak giriş değerini olduğu gibi verir, Denklem 4.21'de matematiksel olarak ifade edilmiştir.

Sigmoid ve hiperbolik tanjant aktivasyon fonksiyonu yapay sinir ağlarında sık bir şekilde kullanılırken Relu aktivasyon fonksiyonu hesaplama yükü daha az ve gradyan yok olma probleminin üstesinden gelmek için sık bir şekilde derin sinir ağlarında kullanılmaktadır [175,176]. Relu aktivasyon fonksiyonuna ait grafik aşağıda görülmektedir.

$$f(x)=\begin{cases} x \leq 0 & x = 0 \\ x > 0 & x = x \end{cases} \quad (4.21)$$

Bu aktivasyon fonksiyonunda negatif olan değerler elenmektedir.



Şekil 4. 19. Relu aktivasyon fonksiyonu.


4.10.1.4. Softmax

Olasılıksal temelli ve sınıflandırma problemlerinde kullanılan, lojistik regresyonun genişletilmiş şekli olan, iki veya daha fazla sınıfa sahip sınıflandırıcıdır [177]. Softmax aktivasyon fonksiyonu kategorik bir dağılımı temsil etmek için kullanılmaktadır. Sınıfsal olasılıkları üretirken $[0,1]$ arasında değer döndürür. K farklı olası duruma göre olasılık dağılımı Denklem 4.22'deki gibi hesaplanmaktadır.


$$\sigma = \frac{e_j^z}{\sum_{k=1}^K e_k^z} \quad \text{for } j=1 \dots K \quad (4.22)$$

4.10.2. Seyreltme katmanı (Dropout)

Eğitim esnasında bazı nöronların belirli bir oranda devre dışı bırakılması işlemi seyreltme olarak bilinmektedir [178]. Bazı nöronlar devre dışı bırakılmasıyla ağın ezberlemesinin önüne geçilebilmektedir [179]. Bu yöntemle nöronlar arasındaki etkileşim azaltılıp tutarlı öğrenme gerçekleşmesi sağlanmaktadır [180]. Seyreltme işlemi uygulanmış bir ağ uygulanmamış aynı ağa göre eğitimin gerçekleşmesi çok daha kısa sürmektedir. Bu bakımdan seyreltme yapılmış bir ağ zaman bakımından oldukça daha maliyetlidir [181]. Seyreltme oranı genelde 0.1 ile 0.3 arasında [182] değişmektedir, bazı çalışmalarda 0.5-0.8 oranında da [178,183] kullanılmıştır. Şekil 4.20' de seyreltme işlenmemiş bir standart nöronun yapısı görülürken Şekil 4.21'de seyreltme işlemi sonrası ağın yapısı görülmektedir.



Şekil 4. 20. Standart sinir ağı [142].



Şekil 4. 21. Seyreltme işleminden sonra.

4.10.3. Mini-Batch Değeri

Verisetinin eğitimi esnasında geri yayılım yapılarak ağırlık güncellemesi yapılmaktadır. Sinir ağlarında modeli eğitirken verisetinin tamamının aynı anda eğitilmesi makinanın hafızası ve eğitim süresi açısından oldukça maliyetli olur. Bu

problemin önüne geçilmesi için verisetinin parçalar halinde bölünerek eğitilmesi işlemine mini-batch denilmektedir. Verisetinin mini-batch değeri belirlenirken hafızaya sığması için 2^n katı olacak bir değer seçilir. Belirlenen mini-batch değeri ile aynı anda kaç adet veriyi eğiteceği belirlenir.

4.10.4. Epoch

Sinir ağının eğitilmesi için veri seti mini-batch değeri belirlenerek küçük parçalara bölünüp eğitim işlemi gerçekleştirilir. Tüm bu parçaların bir sefer eğitilmesi işlemine epoch denilmektedir. Mini-batch değeri ile aynı anda eğitilecek verinin bir sefer eğitilmesi yani ileri ve geri yönlü besleme sonucu da bir iterasyon olarak adlandırılmaktadır. Sinir ağının eğitimi için epoch sayısı arttırıldığı zaman hata miktarı başta azalırken bir noktadan sonra çok fazla değişmediği görülür [184]. Bu noktadan itibaren eğitimi sonlandırmadığında zaman kaybına sebep olmaktadır.

4.10.5. Öğrenme Oranı

Sinir ağlarının ağırlık güncellemeleri geri yayılım ile yapılırken geriye doğru türevi alınarak fark bulunur ve bu fark öğrenme oranı ile çarpılmaktadır. Öğrenme oranı seçilirken ağıın eğitimi ve genelleştirmesi üzerine büyük bir etkisi bulunmaktadır. Eğer öğrenme oranı çok büyük seçilirse genel minimuma yakınsama sorunu ortaya çıkabilir. Eğer öğrenme oranı çok küçük seçilirse buda eğitimin çok fazla zaman almasına ve yerel minimuma takılmasına sebep olabilir [185,186].

4.10.6. Optimizasyon Algoritmaları

Optimizasyon, belli şartlar altında en iyi durumu elde etme yöntemidir [187]. Evrimsel sinir ağlarında da temelde en iyi sonuca ulaşılmaya çalışılır dolayısıyla bu da bir optimizasyon problemidir. Doğrusal olmayan problemde optimum değer bulunur.

Derin öğrenme uygulamaları büyük veri kullanıldığından dolayı çok fazla zaman tüketir. Eğitim süresini ve ağıın öğrenmesini geliştirmek için optimizasyon algoritmaları kullanılır. Derin öğrenmede en sık kullanılan optimizasyon algoritmaları Gradyan azalma (Gradient Descent), ADAM, Adagrad, Adadelat ve RMSprop optimizasyon algoritmalarıdır [188].

4.10.6.1. Gradyan azalma (Gradient Descent)

Sinir ağlarını optimize etmek için en sık kullanılan optimizasyon algoritmasıdır [189]. ESA'da geriyayılım işleminde maliyeti minimuma indirmek için ağırlık güncellemesi birinci dereceden türevi alınarak yapılır [190]. Burada ağırlık üretmiş olduğu değer ile çıkış değeri arasındaki farkın minimum olması beklenir.

Gradyan azalmada her bir örnek ileri yayılıma verilir ve geri yayılımda ağırlık güncellemesi olursa bu olasılıksal eğim azalmasıdır (Stochastic Gradient Descent (SGD)). Eğer veriler bütün olarak eğitim yapılırsa bu da toplu eğim azalma (batch gradient descent) olarak bilinir. Mini batch gradient descent ise iki yöntemin de avantajları kullanılarak geliştirilmiştir. Bu yöntemlerde kullanılan gradyan hesaplamaları veri miktarına bağlı olarak değişmektedir [191]. Tüm veri ile eğitim gerçekleştirildiği zaman her bir iterasyonun tamamlanma süresi uzun zaman alır ve yerel minimuma takılma riski ortaya çıkabilir. Bu problemin önüne geçmek için verileri parçalara ayırılarak mini-batch eğim azalma (mini-batch gradient descent) olarak eğitim gerçekleştirilebilir [167,192].

Maliyet fonksiyonu eğrisinde δ_w ve δ_b , w ve b parametrelerinin yönlerinde meydana gelen değişim olmak üzere bu maliyet fonksiyonunun gradyan eğimi ΔL , Denklem 4.23'deki gibi hesaplanmaktadır.

$$\Delta L = \left(\frac{\partial L}{\partial w}, \frac{\partial L}{\partial b} \right) \quad (4.23)$$

Burada her yenilemede gradyan hesaplaması tekrardan yapılır ve aşağı doğru adım atılarak minimum bulunmaya çalışılır.

$$\eta * \frac{\partial L}{\partial w} \quad (4.24)$$

$$\eta * \frac{\partial L}{\partial b}$$

Burada η aşağı doğru atılan adım büyüklüğü olan öğrenme oranını ifade etmektedir.

Momentum Katsayısı

SGD eğitimde global minimuma ulaşmak için çok fazla salınım gerçekleştirildiği zaman bu gürültünün normalize edilmesi için kullanılan yöntemlerden biri de momentum katsayısının kullanılmasıdır.

Geri yayılım işlemi esnasında her adımda türev alınarak maliyet hesaplaması gerçekleştirilir ve parametreler güncellenir. Momentum normalizasyon yöntemi ile üstel olarak azalan, önceden belirlenen sayıda hesaplanmış gradyanların ortalaması alınır ve bu ortalamalarla katsayı hesaplanarak o yönde bir ilerleme sağlanır [167]. Momentum katsayısı genelde 0.9 vb gibi bir değer kullanılmaktadır [189]. Momentum kat sayısının kullanılıp kullanılmadığı durumda salınımda meydana gelen değişim Şekil 4.22 - 4.23'te [189] görülmektedir.



Şekil 4. 22. Momentum kullanılarak SGD.



Şekil 4. 23. Momentum kullanılmadan SGD.

4.10.6.2. Adagrad (Adaptive Gradient)

Bu algoritma gradient descent tabanlı olup öğrenme oranını parametrelere göre güncellemektedir [193]. Öğrenme hızının seyrek verilerde uyarlanabilir olmasını

sağlamak için Adagrad algoritması geliştirilmiştir[194]. Adagrad algoritması, bu amaca ulaşmak için öğrenme hızını gradyanla ilgili bir miktara böler. Her bir adımda parametreler için farklı bir öğrenme oranı kullanır [195]. Parametrelerin güncellenmesi Denklem 4.25’de gösterilmiştir.

$$\theta_{t+1, i} = \theta_{t, i} - \left(\frac{\eta}{\sqrt{G_{t, ii} + \epsilon}} \right) g_{t, i} \quad (4.25)$$

Burada η öğrenme oranını, $G_{t, ii}$ maliyet fonksiyonunun kısmi türevi, ϵ sifıra bölünmeyi önleyen terimdir.

4.10.6.3. Adadelta

Bu optimizasyon algoritması, Adagrad optimizasyonun öğrenme oranının zamanla sifıra azalarak yaklaşmasından ve manuel olarak seçilen küresel öğrenme oranını ortadan kaldırılmasından ilham alınarak geliştirilmiştir [196,197]. Adadelta algoritması parametreleri önceki kare ortalamalarının kareköküne (root mean square (RMS)) göre güncelleyen ve bu güncellemeleri önceki güncellemenin RMS' sine göre düzeltir [198].

$$\theta_t = \theta_{t-1} - \frac{RMS[\Delta\theta]}{RMS[g]_{t-1}} g_{t-1} \quad (4.26)$$

Burada $RMS[g]_{t-1}$, g_{t-1} ’in gradyanının kare ortalama karekökünün hatasıdır.

4.10.6.4. Karekök Ortalama Yayılımı (RMSProp)

RMSProp (Root mean square propagation), Tieleman ve Hinton [199] tarafından ortaya çıkarılan bu algoritma uyarlanabilir öğrenme oranını sunmaktadır. Büyük gradyanlarda parametre öğrenme oranlarını etkin bir şekilde azaltır ve küçük gradyanlarda parametre öğrenme oranlarını artırır [200].

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1-\gamma)g_t^2 \quad (4.27)$$

$$\theta_t = \theta_{t-1} - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t \quad (4.28)$$

Burada γ momentum faktörünü, $E[g^2]_t$ ise t iterasyonda g^2 'nin ortalamasını belirler [201]. Rmsprop, Adagrad algoritmasındaki öğrenme oranının aşırı küçültme problemine karşı bir çözüm olarak geliştirilmiştir [202].

4.10.6.5. Uyarlanabilir Moment Tahmini (ADAM)

ADAM (Adaptive moment), az bellek gereksinimi olan sadece 1. Dereceden eğim gerektiren verimli optimizasyon algoritmalarından biridir. Bu optimizasyon algoritması seyrek eğimlerde iyi çalışan Adagrad algoritması ile sabit öğrenme oranı olmayan RMSProp algoritmalarının avantajlarını birleştirmiştir [203].

ADAM, momentumunu üstel ağırlıkların gradyanı olarak hesaplar. Yöntem, gradyanların birinci ve ikinci momentlerinin tahminlerinden farklı parametreler için bireysel uyarlanabilir öğrenme oranlarını hesaplar; Adam ismi uyarlanabilir moment tahmininden türetilmiştir [204].

$$V_t = \beta_1 * V_{t-1} - (1 - \beta_1) * g_t \quad (4.29)$$

$$S_t = \beta_2 * S_{t-1} - (1 - \beta_2) * g_t^2$$

$$\Delta_{wt} = -\eta \frac{V_t}{\sqrt{S_t + \epsilon}} * g_t$$

$$W_{t+1} = W_t + \Delta_{wt}$$

Denklem 4.29'da β_1 ve β_2 hiper parametreler, V_t w_j gradientlerin üssel ortalaması, S_t gradyanların karesel üssel ortalamalarını ifade eder.

4.11. TRANSFER ÖĞRENME

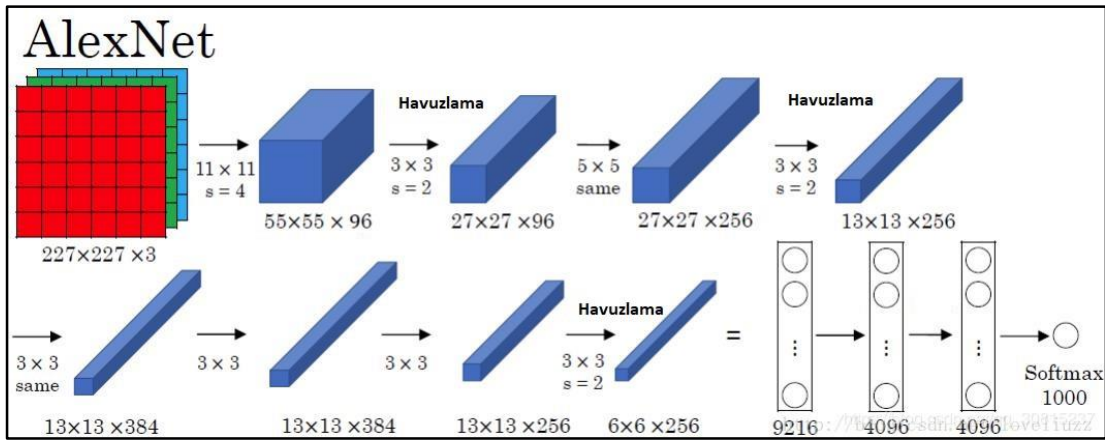
ESA ile problemi eğitilirken en büyük zorluklardan biri veri setinin yetersiz olmasıdır. Imagenet yarışmasında büyük ölçekli ve çok sayıda sınıfa sahip olan veriler ile ESA yöntemi kullanılarak oldukça başarılı sınıflandırma işlemi gerçekleştirilmiştir [205]. Veri setinin az olduğu durumlarda önceden eğitilmiş bir CNN modelinin sınıflarını probleme göre değiştirerek hedef veri kümesi üzerinde ince ayar (fine-tuning) yapan parametrelerin aktarımının öğrenilmesinin sağlanması transfer öğrenme olarak

bilinmektedir [206]. Transfer öğrenme farklı olasılık dağılımlarını izleyerek farklı alanlarda genelleme yapan öğrenme makinaları oluşturmayı amaçlamaktadır [207].

Transfer öğrenme bir problemin çözümünde geliştirilen bir ESA modelinden elde edilen bilgileri kullanarak bir başka problemi çözmek için kullanılan bir makine öğrenim yöntemidir. Bu ESA modelleri önceden eğitilmiş ve rastgele olarak başlatılmış ağırlık değerlerinden daha kolay olduğundan dolayı kullanılır [208]. Bu tez çalışması kapsamında AlexNet, VGG16, VGG19, GoogLeNet, ResNet-50, ResNet-101 modelleri kullanılarak eğitim işlemi gerçekleştirilmiştir.

4.11.1. AlexNet

Bu model 2012 yılında büyük ölçekli veri seti ILSVRC-2010 yarışması için ImageNet veri tabanının eğitimini ve sınıflandırmasını gerçekleştirmek üzere Krizhevsky ve arkadaşları tarafından geliştirmiştir [162]. Bu yarışmada AlexNet 2 grafik işlemci üzerinde çalıştırılmış, hata oranını %15.3'e düşürerek büyük bir başarı göstermiştir.




Şekil 4. 24. AlexNet mimarisi.

ESA'nın dünya çapında ünlenmesini sağlayan AlexNet toplamda 25 adet katmandan oluşmakta [209]. Şekil 4.24.'te AlexNet mimarisinde verildiği gibi sekiz öğrenilebilir katmandan oluşan AlexNet, 5 evrişim, 3 tam bağlı katmanı, 11x11, 5x5, 3x3 boyutlarında filtrelere sahiptir [210,211]. Bu model her bir görüntü için çıktı katmanından önceki gizli katman aktivasyonlarını içeren 4096 boyutunda özellik vektörü oluşturmaktadır [212]. AlexNet yaklaşık olarak 60 milyon parametre ve

650.000 adet nöron dan oluşan çok büyük bir ağıdır [213]. Bu model giriş katmanındaki görüntü boyutu olarak 227x227 px boyutunda almaktadır [214].

4.11.2. VGGNet

Oxford Üniversitesi tarafından önerilen özel bir ESA türüdür. ImageNet veri kümesinde %92.7 ile ilk beş sınıflandırma testi doğruluğu elde ediyor [215]. VGGNet modelleri AlexNet mimarisinden daha derin bir mimariye sahiptir. VGG16 modelinde 13 adet evrişim katmanı ve 3 adet tam bağlı katmanı bulunmaktadır. VGGNet mimarileri daha derin olan modellerin daha iyi bir ağ olduğu fikrine dayanılarak tasarlanmıştır [216]. Simonyan ve Zisserman tarafından geliştirilen VGG16 modeli, 3x3 boyutunda filtrelerle sahiptir ve adım boyutu (stride) olarak 1 kullanır [217]. Toplamda 41 adet katmandan oluşmaktadır. VGG16 mimarisi Şekil 4.25’ de görülmektedir.



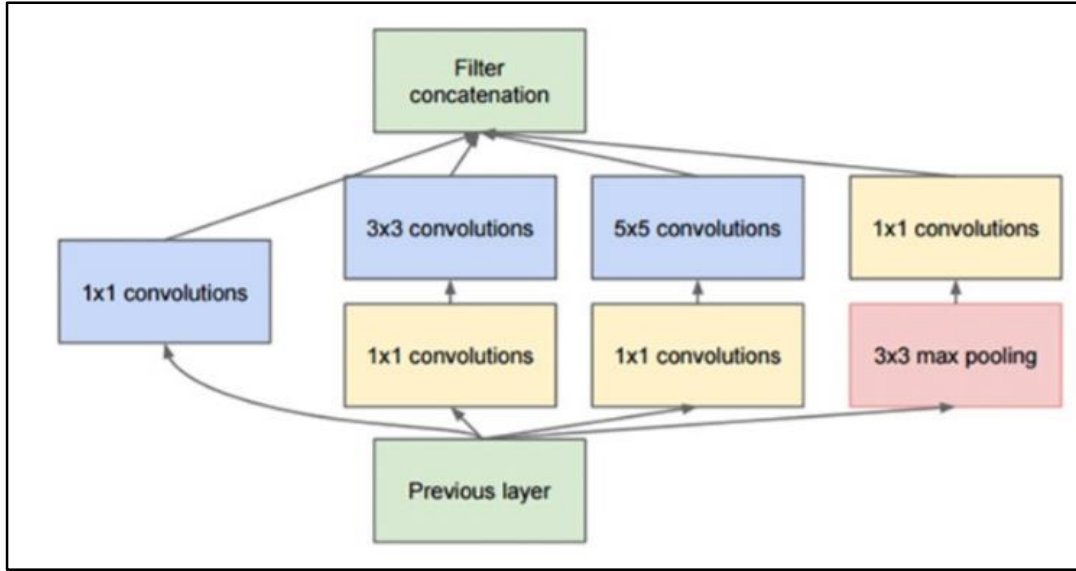
Şekil 4. 25. VGG16 mimarisi.

VGGNet’in bir diğer modeli olan VGG19 modelinde VGG16’sya göre 3 adet fazladan evrişim katmanı bulunmaktadır ve 144 milyon parametreye sahiptir [218,219]. VGGNet mimarileri giriş katmanında görüntü boyutu olarak 224x224 px olarak alır [220].

4.11.3. GoogLeNet

GoogLeNet mimarisi, iç ağındaki Inception olarak adlandırılan bağlantılar yaparak hesaplama maliyetini düşürmesi ile ön plana çıkmaktadır. 144 katmandan oluşan GoogLeNet mimarisi giriş görüntüsü olarak 224x224 px boyutunda resim alır [221]. 21 evrişim ve 1 adet tam bağlantı katmanından oluşan GoogLeNet %5,7 hata 2014 ImageNet yarışmasını kazanmıştır.


Bu model AlexNet modeline göre çok az sayıda parametreye sahiptir. Alexnet modelinde yaklaşık 60 milyon parametre varken bu model de parametre sayısını 5 milyona indirmiştir. GoogLeNet mimarisinde ağın çıktıları önceki ağa giriş olarak verilmesi ile ağ içinde ağ yapısı oluşur. Bundan dolayı karmaşık bir yapıya sahiptir [222]. Özellik haritasını elde etmek için Inception mimarisinde 1x1, 3x3 ve 5x5 boyutlarında filtreler kullanılır. Bu filtreler kullanıldıktan sonra diğer katmanda filtreler birleştirilir. 1x1 boyutundaki filtreler 3x3 ve 5x5 boyutundaki filtrelerden önce kullanılarak özellik haritası azaltılır [223]. Inception mimarisi Şekil 4.26'da görülmektedir.



Şekil 4. 26. GoogLeNet'te kullanılan inception mimarisi.

4.11.4. ResNet

2015 yılında Microsoft tarafından geliştirilen ResNet, ağların eğitiminin kolaylaştırılması için kalıcı bir öğrenme çerçevesine odaklanmıştır [224]. Bu mimaride kalıntı blokları ve ağın derinliği dikkat çekmektedir. ResNet modelleri ara katmanları birbirine bağlayan bağlantıları ilave etmiştir. Bu eklenen bağlantılar sayesinde modeli eğitirken doğabilecek bilgi kaybı önlenerek daha derin bir ağın inşasına olanak sağlanmıştır [179]. Kalıntı blokları (residual block) ile ağ optimize edilerek daha önceki modellerden daha yüksek doğruluk oranına erişildi [225]. Residual bağlantısı Şekil 4.27'de görülmektedir.



Şekil 4. 27. Kalıntı bloğu.

Bu tez kapsamında farklı mimarileri olan ResNet'in, ResNet18, ResNet50 ve ResNet101 modelleri kullanılmıştır. Bu modeller sırasıyla 72, 177 ve 347 katmandan oluşmaktadır.

4.12. PERFORMANS ÖLÇÜTLERİ

Sınıflandırma problemlerinde yaygın bir şekilde kullanılan karmaşıklık matrisi, karmaşıklık matrisinden elde edilen doğruluk, duyarlılık, özgüllük, hassasiyet gibi değerlerin yanı sıra; alıcı işlem karakteristik (AİK) eğrisi, k-katlı çapraz doğrulama bu bölümde anlatılacaktır.

4.12.1. Karmaşıklık Matrisi

İki veya daha fazla sınıfa sahip sınıflandırma problemlerinde elde edilen sonuçların irdelenmesi için karmaşıklık matrisinin kullanılması model başarısını yorumlamada oldukça yardımcı olmaktadır. Karmaşıklık matrisinde modelin performansını değerlendirmek için hedef niteliğe ait yapılan tahminlerin ve gerçek değerlerin karşılaştırıldığı değerler bulunmaktadır [226]. Bu matrise sınıflandırma problemine ilişkin olarak yapılan tahminlerin özeti olduğu söylenebilir. Şekil 4.28' de görülen ikili bir sınıflandırma için karmaşıklık matrisi görülmektedir. Bu Şekilde 4 adet değer bulunmaktadır [224]. Tabloda bulunan doğru pozitif (DP); doğru olarak tahmin edilen ve aslında doğru olan değeri, doğru negatif (DN) ise yanlış olanı doğru tahmin etmektir. DP ve DN, OM problemi için hastalıklı veya hastalıklı olmayan TM görüntüsünün doğru bir şekilde tahmin ettiği değerler olduğunu söyleyebiliriz. Yanlış pozitif (YP) ve yanlış negatif (YN) değerleri ise sırasıyla yanlış tahmin edilen TM görüntülerinin sayısını ifade etmektedir.

	GERÇEK	
TAHMİN	DP	YP
	YN	DN

Şekil 4. 28. Karmaşıklık Matrisi [229].

Karmaşıklık matrisi ile birçok performans metrikleri elde edilebilir [227]. Bu tez kapsamında karmaşıklık matrisi ile doğruluk (accuracy), duyarlılık-hassasiyet (sensitivity-recall), özgünlük (specificity), kesinlik (precision), f-skor (f-score), ortalama doğruluk (average-precision) gibi başarımlar ölçütleri kullanılmıştır. Denklem [4.30–4.35] 'de verilmiştir.

Doğruluk, modelin tüm örnekler üzerindeki başarımlarını ifade eder. Modelin test sonucunda normal TM ve anormal TM görüntülerinden doğru olarak ayırt edebildiği tanı sayısının oranıdır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+YN+DN} \quad (4.30)$$

Duyarlılık, tüm anormal TM görüntülerinde doğru olarak anormal tespit edilen anormal imgelerin oranıdır. Modelin hasta olanları belirlemede ne kadar duyarlı olduğunu gösterir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4.31)$$

Özgünlük, modelin negatif durumları ayırt etmesidir. Hasta olmayan Normal TM görüntülerini ayırt edebilme yeteneğini göstermektedir.

$$\text{Özgünlük} = \frac{DN}{DN+YP} \quad (4.32)$$

Kesinlik, Tüm doğru sınıflar içerisinde DP tahmin edilenlerin sayısıdır. Test sonucunda DP etkenleri belirleme oranıdır.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4.33)$$

F-Skor, özgünlük ve hassasiyet değerlerinin harmonik ortalaması olarak ifade edilmiştir.

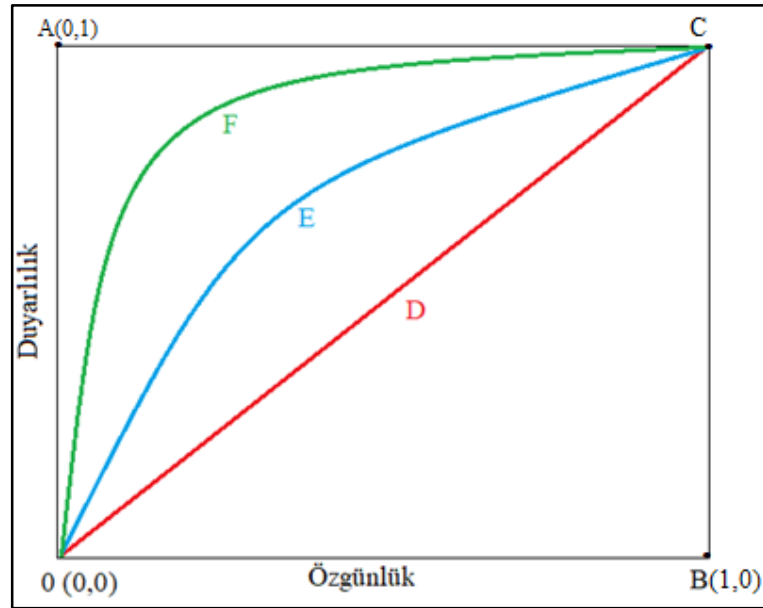
$$F - Skor = 2 \frac{Kesinlik \times Hassasiyet}{Kesinlik + Hassasiyet} \quad (4.34)$$

Ortalama-doğruluk, doğru pozitiflerin tüm doğru pozitif ve doğru negatif sınıftakilere oranıdır.

$$Ortalama - Doğruluk = \frac{DP}{DP+DN} \quad (4.35)$$

4.12.2. Alıcı İşlem Karakteristiği (AİK)

Alıcı işlem karakteristiği (Receiver Operating Characteristic Curve-ROC), tanısal doğruluğu değerlendirmek için kullanılan grafiksel yöntemlerden biridir [228]. AİK grafiğinin y ekseninde duyarlılık x ekseninde ise özgünlük oranları bulunmaktadır. AİK eğrinin altında kalan alanın mümkün olduğu kadar bire yakın bir değer olması beklenir. Hassasiyeti olası tüm değerler için bir özgüllük fonksiyonu olarak çizen AİK eğrileri, bir sınıflandırıcının gerçek pozitifler ve yanlış negatifler arasındaki ödünleşmeyi gösterir [229]. AİK eğrisine ait grafik Şekil 4.29'da verilmiştir.



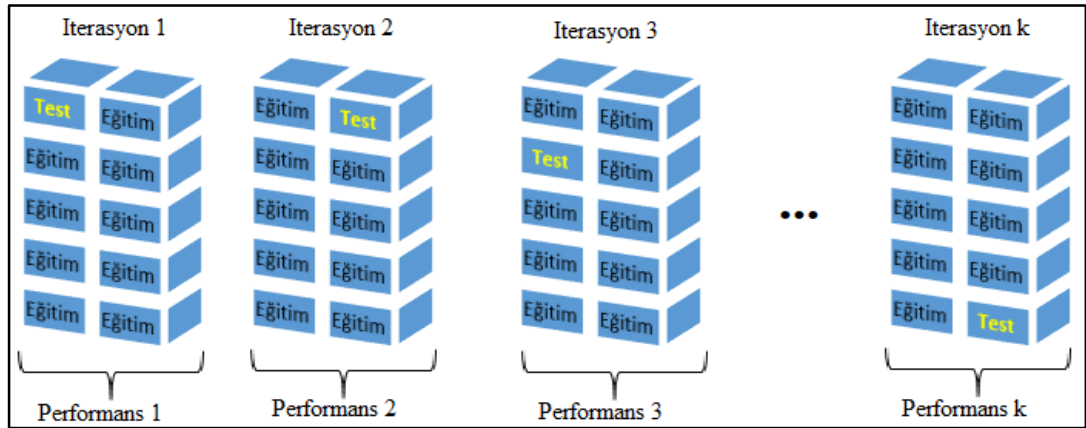
Şekil 4. 29. AİK eğrisi.

Şekil 4.29 da verilen gafiği yorumlamak üzere $O(0,0)$, A, B, C noktaları ve D, E, F eğrileri verilmiştir. A(0,1) noktası çok iyi bir sınıflandırma noktasıdır. F ve E eğrilerine baktığımızda F eğrisinin altında kalan alan E noktasına göre daha çok olduğundan dolayı genelleştirme performansının daha iyi olduğu söylenebilir.

$O(0,0)$ noktası ile C noktası boyunca uzanan D eğrisi ise 0.5 ayırt edicilik değerine sahiptir. Bu doğru boyunca rastgele bir tahmini sağlayacak bir sınıflayıcıyı temsil etmektedir [230]. Bu doğrunun altındaki değerler ise kabul edilebilir bir oranı temsil etmezken üstündekiler ise kabul edilebilir bir oranı temsil eder.

4.12.3. K-Katlı Çapraz Doğrulama

Bu yöntem model performansı üzerine istatistiksel analiz yaparak veri seti üzerinde genelle yapar [231]. k-çapraz doğrulama tekniği veri setini rastgele k adet kümeye böler. Ardından k-1 adet veri kümesi modeli eğitmek için kullanılırken bir kümede modelin doğrulama verisi olur. Bu işlem veri setindeki k adet küme sayısınca tekrarlanır ve her defasında kümelerden biri doğrulama verisi olacak şekilde k adedince tekrarlanır [232]. Son olarak bu k adet veri işlemin performans sonuçlarının aritmetik ortalaması alınır [233]. k-katlı çapraz doğrulama tekniği Şekil 4.30'da görülmektedir.



Şekil 4. 30. k-katlı çapraz doğrulama.

BÖLÜM 5

BULGULAR ve TARTIŞMA

Bu tez çalışması kapsamında otoskop cihazı ile elde edilen orta kulak görüntülerinde OM tanısının konması için hayati önem taşıyan zar bölgesinin tespiti ve normal ve anormal TM görüntüleri sınıflandırılmıştır. Sınıflandırma işlemi ve zar tespitini en başarılı şekilde gerçekleştirmek için üzerinde durulan ve araştırılan soru maddeleri şunlardır:


- Makine öğrenme yöntemleri ile sınıflandırma işlemi gerçekleştirmek için hangi öznelik elde etme algoritmaları kullanılmalıdır?
- Kullanılan öznelik elde etme algoritmalarından en başarılı sonuçlar hangisi ile elde edilir?
- Makine öğrenme algoritmalarında en doğru sonuca ulaşmak için hangi model önerisi kullanılmalıdır?
- En başarılı sınıflandırma sonucu elde edilen makine öğrenme algoritması hangisidir?
- Zar bölgesinin tespit edilmesi için hangi algoritma kullanılmalıdır?
- Hangi model ile zar bölgesi en kısa sürede tespit edilebilir?
- Özneliklerin otomatik olarak çıkarıldığı derin öğrenme ile modellerinin performans karşılaştırılması?
- En iyi öğrenme oranı kaçınıcı epochta elde edilir?
- Zar bölgesinin tespiti ve sınıflandırma işlemi gerçekleştirmek özgün bir model önerisi nasıl olabilir?

5.1. ÖZİNİTELİK ÇIKARILARAK SINIFLANDIRMA

OM teşhis edilebilmesi için bu bölümde TM görüntülerinden geleneksel özellik çıkartılarak makine öğrenme yöntemleri ile görüntüler sınıflandırılmıştır. Bu amaca yönelik TM görüntülerinden geleneksel özellik çıkarma algoritmalarından olan GSEM, YGH, YİÖ ve renk kanallarının ortalama değeri çıkartılarak her görüntüye ait özellik vektörleri elde edilerek sınıflandırma performanslarına bakılmıştır.

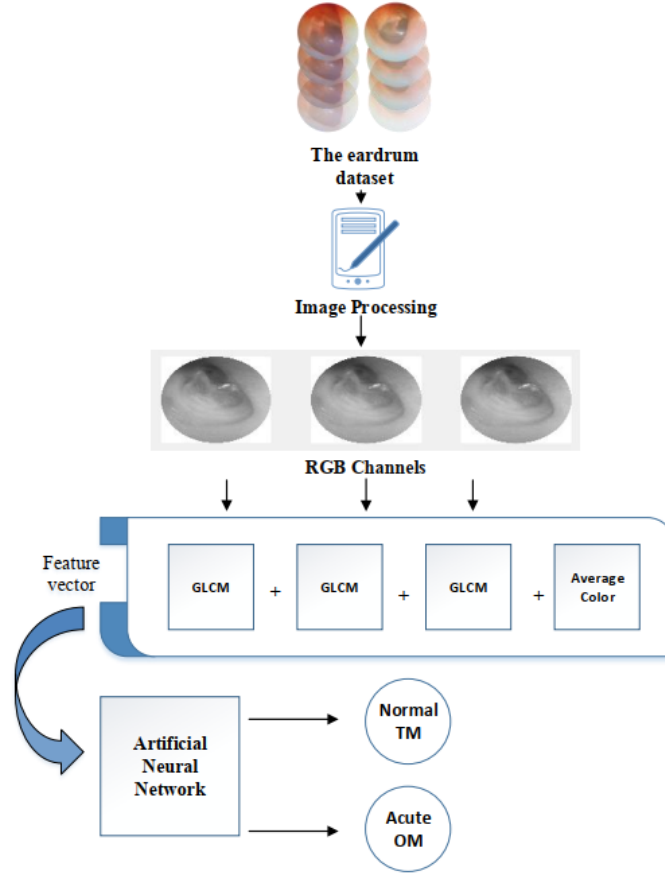
5.1.1. YSA ile Normal TM ve AOM TM Görüntülerini sınıflandırma

İlk deneysel çalışma olarak, Otoskop görüntüleri bir dizi özellik çıkarma işleminden önce ön işleme prosedürleri uygulanmıştır. İlk olarak, yüksek çözünürlüklü görüntüler 500x500 piksel olarak yeniden boyutlandırılmıştır. Ardından gri sevideki resimlere GSEM uygulandığından dolayı görüntüler 8 bitlik gri renge dönüştürülmüştür. Ön işlemenin son adımında, gri renkli görüntülere uyarlanabilir histogram eşitleme (UHE) uygulanmıştır. Bu görüntü yapısının ayrıntılarını ve görüntülerdeki kontrastı artırır (Şekil 5.1.).



Şekil 5. 1. Normal ve AOM örneğinin görüntü işlemeden önceki ve sonraki hali.

Görüntü işleme aşaması tamamlandıktan sonra sınıflandırmak için YSA ile çeşitli konfigürasyon ve özellik setleri uygulanmıştır. Önerilen modelin blok diyagramı Şekil 5.2.'de görülmektedir.



Şekil 5. 2. Önerilen modelin blok diagramı.

İlk olarak GSEM özellik çıkarma algoritması R, G, B renk kanallarına ayrı ayrı uygulanmıştır. Ağın eğitilmesi için geri yayılım algoritması olarak Levenberg-Marquardt ve 16 nörondan oluşan bir gizli katmanlı ağ kurulmuştur. Elde edilen sonuçların genelleştirilmesi için eğitim ve test aşamasında 10-katlı çapraz doğrulama yöntemi kullanılmıştır. Bu parametrelerle varılan sonuçlar Çizelge 5.1.'de verilmiştir.

Çizelge 5. 1. GSEM ve RKO özelliklerin birleşmesiyle sınıflandırma sonuçları.

Renk Kanalı	Özellik sayısı	Doğruluk (%)	Hassaslık (%)	Özgüllük (%)
R	16	61.40	39.95	69.76
G	16	63.65	44.83	73.04
B	16	59.66	36.49	69.10

Çizelge 5.1’de görüldüğü gibi Normal TM görüntüleri AOM örnekleri ile karşılaştırıldığında Normal TM imgelerini daha iyi tanıdığı görülmektedir. Bu durumun temel sebebi veri setindeki sınıfların örnek sayısının eşit olmamasıdır. Normal TM sınıfına ait 154 örnek varken AOM sınıfında ise 69 adet görüntü vardır. YSA baskın örnek sayısına sahip olan sınıfı daha iyi ayırt etmiştir. En iyi doğruluk oranı G kanalında % 63.65 başarısına oranına sahiptir. Daha iyi sonuçlar elde edilmesi için modelin geliştirilmeye ihtiyacı vardır.


Bir sonraki aşamada aynı hiper parametreleri kullanarak görüntülerin renk kanallarının ortalaması (RKO) da alınıp GSEM özellikleri ile birleştirilerek sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi sonucunda elde edilen sonuçlar Çizelge 5.2.’da görülmektedir.

Çizelge 5. 2. GSEM ve RKO özelliklerin birleşmesiyle sınıflandırma sonuçları.

Renk Kanalı	Özellik sayısı	Doğruluk (%)	Hassaslık (%)	Özgüllük (%)
R + RKO	19	71.26	57.10	77.07
G + RKO	19	76.20	64.69	81.09
B + RKO	19	77.15	57.29	85.47

RKO’ nun GSEM ile birleşmesi sonucu ortalama doğruluk değerleri artmıştır. Çizelge 5.2.’de görüldüğü gibi en iyi doğruluk sonucu yine G kanalında elde edilmiştir. Bu çalışmadaki en önemli performans metriği hassaslık ölçütüdür. Bu metrik modelin AOM örneklerini ayırt etmesini temsil etmektedir. Hassasiyet ölçütü renk kanallarının ortalaması eklendikten sonra doğruluk değeri % 44.83’ten % 64.69’a yükselmiştir.

Üçüncü deneysel çalışmada her bir kanalın ortalama değerini ve GSEM özelliklerini birleştirilerek 51 adet özellikten oluşan vektör yapılmıştır. 3 adet özellik R, G, B renk kanalının ortalamasından gelirken 48 adet özellik de GSEM’den oluşturulmuştur. GSEM’de uzaklık değeri olarak 1 ve açı olarak 0^0 , 45^0 , 90^0 ve 135^0 olarak bakılmıştır. Bu deneysel çalışmada ağ üzerindeki farklı parametrelerin model başarısı üzerindeki etkileri incelenmiştir.



Şekil 5. 3. Gizli katmandaki nöronların başarı sonuçları.

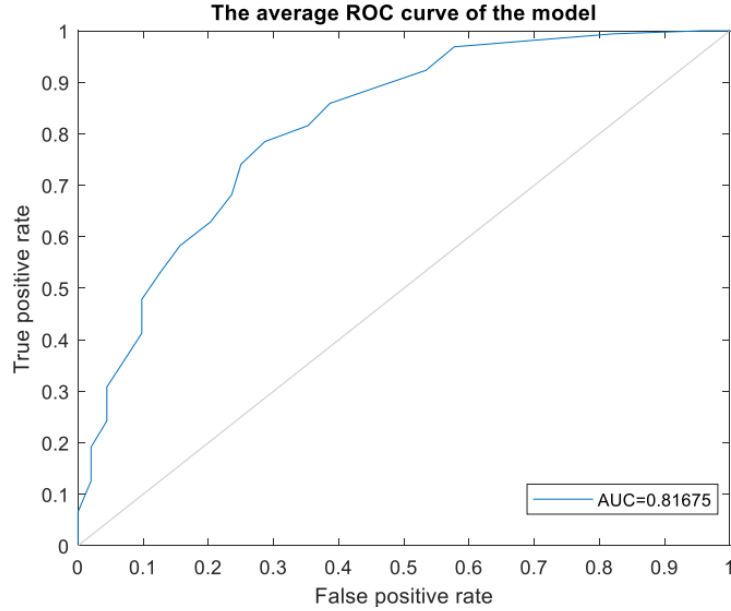
İlk olarak Şekil 5.3'te verildiği gibi ağ üzerinde gizli katmandaki 15 ile 100. nöron arasındaki düğümlerin etkileri incelenmiştir. Her seferinde nöron sayısı bir arttırılmış ve 10-katlı çapraz doğrulama sonuçlarına bakılmıştır. En etkili sonuç nöron sayısı 19 olduğunda elde edilmiştir. 19. Nöronda doğruluk hassasiyet ve özgünlük değerleri sırasıyla % 79.76, % 70.59 ve % 84.93 elde edilmiştir.

Çizelge 5. 3. GSEM ve RKO özelliklerin birleşmesiyle sınıflandırma sonuçları.

Renk Kanalı	Doğruluk (%)	Hassaslık (%)	Özgüllük (%)
GD	79.78±7.25	68.72±23.06	85.09±9.65
GDA	76.14±7.65	70.75±20.43	80.07±6.00
CGP	77.13±11.22	65.41±21.73	84.06±13.4
RP	73.02±6.22	60.92±14.63	78.36±8.83
LM	75.25±9.52	67.17±23.68	80.14±9.49

Bir sonraki aşamada YSA' daki Gradyan azalması (GD), adaptif öğrenmeli gradyan azalması (GDA), Polak-Ribiére güncellemesi ile Conjugate gradyan (CGP), Resilient backpropagation (RP) ve Levenberg-Marquardt backpropagation (LM) gibi eğitim algoritmaları kullanılarak ağ konfigüre edildikten sonra başarı oranlarına bakılmıştır. Elde edilen sonuçlar Çizelge 5.3.'te verilmiştir. Ayrıca önerilen modelin AİK eğrisi de

elde edilmiştir. Veri sayısının dengesiz dağıldığı durumlarda bu metrik önemlidir (Şekil 5.4). AİK eğrisi ile model için en iyi eşik değeri belirlenebilmektedir.



Şekil 5. 4. Önerilen modelin AİK eğrisi.

5.1.2. Yönlü Gradyanların Histogramı ve RKO ile Normal TM ve Anormal TM Sınıflandırılması

Bu deneysel çalışmada 421 adet anormal TM görüntü ve 534 adet Normal TM görüntüsü sınıflandırılmıştır. YGH öznitelikleri ve görüntülerin ortalama renk değerleri alınarak elde edilen özellik vektörü ile kNN ve DVM yöntemleri ile farklı parametrelerin deneysel sonuçları incelenmiştir. Veri seti %70 eğitim %30 test olacak şekilde iki parçaya bölünmüştür. Aynı zaman 5-katlı çapraz doğrulama ile de sonuçlarına bakılmıştır. İlk olarak TM görüntüleri 227 x 227 piksel olarak yeniden boyutlandırma işlemi gerçekleştirilmiştir. Ardından her bir görüntünün YGH öznitelikleri elde edilerek kNN yöntemi ile $k=\{1, 2, 5, 10\}$ kümesi öklid uzaklığına göre komşuluk değerlerinin sonuçlarına bakılmıştır. Ardından aynı özellik seti ile DVM yöntemi ile sınıflandırma işlemi gerçekleştirilmiştir.

Çizelge 5. 4. YGH öznitelikleri ile sınıflandırma sonuçları (%70-%30).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YGH	67.13	67.03	63.11

Çizelge 5.4. (devam ediyor).


kNN (k=2)	YGH	59.79	62.91	60.83
kNN (k=5)	YGH	67.48	69.66	70.87
kNN (k=10)	YGH	63.63	63.63	62.59
DVM	YGH	67.13	66.89	66.39

YGH öznitelikleri ile sınıflandırmak için Çizelge 5.4 'te verilen deneysel sonuçlar incelendiğinde %70 eğitim ve %30 test olarak ayrıldığında en iyi doğruluk sonucu kNN yöntemi ile 5 komşuluğa göre Öklid uzaklığı ile elde edilmiştir. Çizelge 5.4.'te görüldüğü gibi Bu modelin özgüllük değerinin hassasiyet değerine göre daha üstün olduğu görülmektedir. Normal TM sınıfına ait örnek sayısı daha çok olduğundan dolayı sınıflandırma başarısına etki etmiştir.

Çizelge 5. 5. YGH öznitelikleri ile sınıflandırma sonuçları (5-katlı çapraz doğrulama).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YGH	64.60	64.44	64.28
kNN (k=2)	YGH	63.56	63.25	62.95
kNN (k=5)	YGH	62.30	63.35	63.86
kNN (k=10)	YGH	63.76	67.11	68.54
DVM	YGH	68.48	68.33	68.10

5-katlı çapraz doğrulama yönteminde en yüksek doğruluk değeri % 68.48 ile DVM yöntemi ile elde edilmiştir. Çizelge 5.5'teki sonuçlar incelendiğinde YGH öznitelikleri ile Normal ve Anormal TM ile sınıflandırma işlemi yapıldığında ayrıca başka özelliklerden de yararlanılabilir.



Şekil 5. 5. Veri setinde yer alan görüntülerin R,G,B kanallarına ait ortalama değerleri.

İkinci deneysel çalışmada aynı yöntem ve parametreler ile özneliğe her bir görüntünün ortalama renk değeri de eklenerek sınıflandırma sonuçlarına bakılarak YGH ile bir görüntüden 26244 adet özellik elde edilmiştir. Her görüntünün RKO değeri de eklenerek 26247 özellik vektörü oluşturulmuştur. Veri setinin %70 eğitim ve % 30 test olacak şekilde ayrıldığı zaman elde edilen sınıflandırma sonuçları Çizelge 5.6’da verilirken, 5-katlı çapraz doğrulama yöntemi ile elde edilen sonuçlar Çizelge 5.7’de verilmiştir.

Çizelge 5. 6. YGH + RKO öznelikleri ile sınıflandırma sonuçları (%70 - %30).


Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YGH + RKO	66.78	66.62	66.41
kNN (k=2)	YGH + RKO	65.03	66.29	64.64
kNN (k=5)	YGH + RKO	63.28	64.61	65.29
kNN (k=10)	YGH + RKO	60.83	61.34	61.59
DVM	YGH + RKO	67.48	67.25	66.74

Çizelge 5. 7. YGH + RKO öznelikleri ile sınıflandırma sonuçları (5-katlı çapraz doğrulama).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YGH + RKO	63.66	63.36	63.06
kNN (k=2)	YGH + RKO	60.52	60.94	59.64
kNN (k=5)	YGH + RKO	60.52	61.00	61.23
kNN (k=10)	YGH + RKO	62.51	63.96	64.65
DVM	YGH + RKO	68.27	68.07	67.69

Çizelge 5.6.’da verildiği gibi RKO’ da özellik vektörlerine eklendiğinde %70 eğitim ve %30 test olacak şekilde ayrıldığı zaman en yüksek doğruluk sonucu % 67.48 ile DVM ile elde edilmiştir. Aynı doğruluk değeri RKO değeri eklenmediği zaman sadece YGH özellikleri ile kNN yöntemi ile elde edilmiştir. RKO değeri eklendikten sonra k=1, 5, 10 komşulukları için doğruluk oranı azalırken k=2 değeri için ortalama doğruluk değeri artmıştır. 5-katlı çapraz doğrulama ile performans sonuçlarına bakıldığı zaman ortalama renk değeri eklendiği zaman tüm performans metriklerinde düşüş göstermektedir. YSA yöntemi ile Normal TM ve AOM TM görüntülerinin sınıflandırıldığı deneysel çalışmaya bakıldığı zaman Normal ve AOM sınıfı ile yapılan sınıflandırmada ortalama renk değeri özelliğinin eklenmesi ile doğruluk değerinin artmasının AOM TM hastalığında fizyolojik olarak zarın kızarmasından kaynaklandığından ve Normal TM görüntüsünün ise grimsi olduğundan dolayı bu

özelliğın ayırıcılık özelliğine önemli derecede etki etmektedir. Bu deneysel çalışmada kullanılan anormal sınıfa sahip veriler içerisinde AOM TM görüntüler dışında diğer Anormal TM görüntüleri de olduğundan dolayı veri seti oldukça heterojen bir dağılım yapısına sahiptir. Normal TM ve AOM TM'ye göre YGH ve ortalama renk değeri ile Anormal ve Normal TM görüntülerinin sınıflandırılmasında sadece YGH özelliğinin kullanılmasıyla en yüksek doğruluk sonucuna erişilmiştir. Şekil 5.5'te Anormal TM görüntülerinin RKO değerlerine bakıldığında dalgalanmanın 421. Görüntüden sonraki normal sınıfa ait görüntülere göre çok daha fazla olduğu görülmektedir. Veri setindeki verilerin dengesiz olarak dağılımını sınıflandırma başarısını etkilemiştir. Literatürdeki [234-236] çalışmaları desteklediği görülmektedir. Sadece YGH ile 5-katlı çapraz doğrulama sonucu elde edilen AİK eğrisi ve altında kalan alan (AUC) Şekil 5.6'da verilmiştir.



Şekil 5. 6. YGH özellikleri ile AİK eğrisi (5-katlı çapraz doğrulama).

5.1.3. Yerel İkili Örüntü ve RKO Değeri ile Normal TM ve Anormal TM sınıflandırılması

Anormal TM ve Normal TM görüntüleri sınıflandırmak için bu deneysel çalışmada gri renkli görüntüler ile YİÖ özelliği ve bu özellik vektörüne RKO özelliği de eklenerek ayrı ayrı kNN ve SVM makine öğrenme yöntemleri ile sınıflandırılmıştır. 421 adet Anormal TM ve 534 adet Normal TM ile ikili sınıflandırmak için YGH ve RKO özellikleri kullanılarak yapılan sınıflandırma için kullanılan kNN ve SVM parametreleri kullanılarak YİÖ özelliğinin sınıfları ayırmadaki etkisi incelenmiştir. YİÖ özellik vektörü 3x3'lük matrisler ve yarıçapı bir olan olan 8 komşuluk değerine bakılmıştır. İlk olarak veri seti 227 x 227 piksel olarak ayrıldıktan sonra renkli görüntüler 8 bitlik gri renklere dönüştürülmüş ve ardından YİÖ algoritması ile özellik vektörü elde edilmiştir. Ardından veri seti % 70 eğitim ve % 30 test verisi olarak ayrıldığında elde edilen bulgular Çizelge 5. 8. 'de verilirken 5-katlı çapraz doğrulama yöntemi ile elde edilen bulgular Çizelge 5. 9'da verilmiştir.

Çizelge 5. 8. YİÖ özellik vektörü Anormal TM ve Normal TM sınıflandırma sonuçları (%70 - %30).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YİÖ	70.27	71.21	71.95
kNN (k=2)	YİÖ	70.62	70.68	69.77
kNN (k=5)	YİÖ	70.62	73.35	74.95
kNN (k=10)	YİÖ	68.18	70.59	71.93
DVM	YİÖ	73.07	73.51	74.00

Çizelge 5. 9. YİÖ özellik vektörü ile Anormal TM ve Normal TM sınıflandırma sonuçları (5-katlı çapraz doğrulama).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YİÖ	70.99	71.09	71.21
kNN (k=2)	YİÖ	70.99	71.09	71.21
kNN (k=5)	YİÖ	71.83	73.54	74.74
kNN (k=10)	YİÖ	68.90	70.94	72.16
DVM	YİÖ	76.33	76.54	76.87

YİÖ özellikleri ile veri seti %70 eğitim ve %30 test olarak bölündüğünde en yüksek doğruluk oranı Çizelge 5.8'de verildiği gibi % 73.07 ile DVM ile elde edilmiştir. Bu deneysel çalışmada hassaslık ölçütü Anormal TM sınıfları ayırt etme ölçütüdür. Hassasiyet değeri % 73.51 ile iyi oran da sınıflandırma gerçekleşmiştir. Özgüllük oranı

ise Normal TM'leri ayırt etme ölçütüdür. Veri setindeki Normal örnek sayısı daha çok olduğundan dolayı bu sınıfta daha yüksek bir doğruluk oranı elde edilmiştir. 5-katlı çapraz doğrulamada DVM yöntemi ile % 76.33 değeri sadece YİÖ ile elde edilen en iyi doğruluk sonucudur. Yine hassasiyet ve özgüllük değerleri de sırasıyla % 76.54 ve %76.87 ile iyi bir oranda sınıflandırma başarısı elde edilmiştir.

Bu deneysel çalışmanın 2. Aşamasında YİÖ özellik vektörüne her bir görüntünün RKO değerleri eklenerek DVM ve kNN de aynı parametreler ile sınıflandırma işlemi gerçekleştirilmiştir. Modelin doğruluk testleri içinde %70 eğitim %30 test ve 5-katlı çapraz doğrulama yöntemleri kullanılmıştır.

Çizelge 5. 10. YİÖ ve RKO Özellikleri ile Normal TM ve Anormal TM görüntülerin sınıflandırılması (%70 - %30).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YİÖ + RKO	71.67	72.65	73.46
kNN (k=2)	YİÖ + RKO	69.93	69.98	69.05
kNN (k=5)	YİÖ + RKO	68.53	70.39	71.52
kNN (k=10)	YİÖ + RKO	68.53	70.39	71.52
DVM	YİÖ + RKO	78.67	78.85	79.17

RKO değerlerinin de özellik vektörüne eklenmesi ile %70 eğitim %30 test olacak şekilde veri seti ayrıldığında Çizelge 5.10'da görüldüğü gibi k=1, k=10 komşuluk değeri ve DVM yöntemi ile doğruluk oranı artarken k'nın 2 ve 5 komşuluk oranlarında doğruluk oranı azalmıştır. En iyi sınıflandırma sonucu DVM ile % 78.67 ile bu model iyi oranda sınıflandırma işlemi gerçekleştirilmiştir. Bu sınıflandırma sonucu Anormal TM imgeleri ve Normal TM imgelerini ayırt etme başarısı olan Hassasiyet ve Özgüllük değerleri de sırasıyla % 78.85 ve % 79.17'dir. Burada en yüksek değer Normal TM sınıf ayırıcı metriği olan Özgüllük değeridir. Dengesiz veri kümesinde, sınıflandırıcı taraflı olduğu için değerlendirme sonucunun doğruluğu azaltılabilir ve daha fazla görüntüye sahip bir sınıfa öncelik verdiği literatürü doğrular niteliktedir [236].


Çizelge 5. 11. YİÖ ve RKO özellikleri ile Normal TM ve Anormal TM görüntülerin sınıflandırılması (5-katlı çapraz doğrulama).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	YİÖ + RKO	70.99	70.94	70.86
kNN (k=2)	YİÖ + RKO	67.43	68.39	66.86

Çizelge 5.11. (Devam ediyor).

kNN (k=5)	YİÖ + RKO	67.64	68.85	69.94
kNN (k=10)	YİÖ + RKO	67.01	67.98	68.62
DVM	YİÖ + RKO	73.71	73.75	73.80

Çizelge 5.11’de verilen 5-katlı çapraz doğrulama yöntemi ile modelin performans metrikleri incelendiğinde k=1 komşuluk değeri ile aynı doğruluk oranı elde edilirken diğer performans metriklerinde ise sadece YİÖ ile elde edilen performans metrikleri daha iyi sonuçlar elde edilmiştir. YİÖ ve RKO özelliklerin bir arada kullanılarak ve % 70 eğitim % 30 test olarak ayrıldığında en iyi performans metrikleri elde edilmiştir.



Şekil 5. 7. YİÖ + RKO özellikleri ile DVM yöntemiyle sınıflandırma modeline ait AİK eğrisi.

Veri setinin homojen olarak dağılmadığı ve sınıflandırma başarısını yorumlamada yol gösterici olan AİK eğrisi ve altında kalan Şekil 5.7’de verilmiştir. AİK değerinin altında kalan burada 0.85 olarak elde edilmiştir.

5.1.4. GSEM ve RKO Öznitelikleri ile Normal TM ve Anormal TM İmgelerinin Sınıflandırılması

Veri setimizde bulunan Anormal ve Normal TM imgelerini sınıflandırmak için bu çalışmada dokusal özellik çıkarma algoritmalarından GSEM ve görüntülere ait RKO öznitelikleri ile makine öğrenme algoritmalarından DVM ve kNN sınıflandırma algoritmaları kullanılmıştır. Bu çalışma ile GSEM matrisi ve RKO özelliklerinin orta kulak imgelerini tanımlama üzerindeki etkisi incelenmiştir. İlk olarak veri setimizdeki görüntüler 227 x 227 px olarak ayarlandıktan sonra görüntüler 8 bitlik gri renge dönüştürülmüştür. Ardından GSEM algoritması ile her bir görüntünün kontrast, entorpi, enerji ve homojenlik özellikleri çıkarılmıştır. Uzaklık değeri olarak 1 ve açılmal olarak 0^0 , 45^0 , 90^0 ve 135^0 derece olarak bakılmıştır. Elde edilen özellik vektörü sınıflandırıcı girişlerine verilerek % 70 eğitim ve %30 test olacak şekilde veri seti bölünmüştür. Model doğruluğunu test etmek için aynı zamanda 5-katlı çapraz doğrulama yöntemi de kullanılmıştır. Deneysel çalışma sonucunda elde edilen bulgular Çizelge 5.12. ve Çizelge 5.13'te verilmiştir.

Çizelge 5. 12. GSEM özellikleri Normal TM ve Anormal TM görüntülerinin sınıflandırılması (%70 - %30).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	GSEM	67.13	67.03	66.20
kNN (k=2)	GSEM	59.79	62.91	60.83
kNN (k=5)	GSEM	65.38	65.10	64.48
kNN (k=10)	GSEM	63.63	63.63	62.59
DVM	GSEM	66.78	66.70	66.62

Çizelge 5. 13. GSEM özellikleri Normal TM ve Anormal TM görüntülerinin sınıflandırılması (5-katlı çapraz doğrulama).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	GSEM	71.20	71.22	71.24
kNN (k=2)	GSEM	65.23	68.20	65.99
kNN (k=5)	GSEM	70.05	69.99	69.90
kNN (k=10)	GSEM	69.10	68.93	68.39
DVM	GSEM	70.47	70.35	69.71

GSEM ile elde edilen bulgulara bakıldığında %70 eğitim ve %30 test olarak veri seti ayrıldığında en yüksek doğruluk oranı Çizelge 5.12'de görüldüğü gibi kNN

yöntemi ile k=1 komşuluk değeri % 67.13 doğruluk değeri elde edilmiştir. 5-katlı çapraz doğrulama yöntemi ile en yüksek doğruluk değeri yine Çizelge 5.13'te görüldüğü gibi kNN yöntemi ve k=1 komşuluk değeri ile % 71.20 doğruluk değeri elde edilmiştir. Anormal ve TM ve Normal TM görüntülerini ayırt etme başarıları olan hassasiyet ve özgüllük değerleri ise sırasıyla % 71.22 ve % 71.24 gibi iyi bir sonuç elde edilmiştir.

Çalışmanın diğer aşamasında GSEM ile elde edilen 16 vektör uzunluğundaki özellik matrisine RKO değerleri olan 3 adet yeni özellik daha eklenerek aynı parametreler ve doğrulama metrikleri sınıflandırma sonuçlarına bakılmıştır.

Çizelge 5. 14. GSEM ve RKO özellikleri kullanılarak Normal TM ve Anormal TM görüntülerinin sınıflandırılması (%70 - %30).


Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	GSEM + RKO	71.32	71.44	70.48
kNN (k=2)	GSEM + RKO	66.43	70.28	67.76
kNN (k=5)	GSEM + RKO	69.58	69.42	68.83
kNN (k=10)	GSEM + RKO	68.53	68.65	67.63
DVM	GSEM + RKO	72.73	72.62	72.36

Çizelge 5. 15. GSEM ve RKO özellikleri ile Normal TM ve Anormal TM görüntülerinin sınıflandırılması (5-katlı çapraz doğrulama).

Yöntem	Özellik	Doğruluk oranı (%)	Hassaslık (%)	Özgüllük (%)
kNN (k=1)	GSEM + RKO	70.88	70.88	69.80
kNN (k=2)	GSEM + RKO	65.23	67.77	65.69
kNN (k=5)	GSEM + RKO	69.73	69.61	69.41
kNN (k=10)	GSEM + RKO	69.00	68.85	68.21
DVM	GSEM + RKO	74.13	74.03	73.77

RKO özellikleri GSEM özellik vektörüne eklenmesi ile elde edilen bulgulara bakıldığı zaman veri setini %70 eğitim %30 test olarak ayrıldığı zaman Çizelge 5.12 ve Çizelge 5.14 te görüldüğü üzere doğruluk oranı % 67.13'ten % 72.73 oranına önemli derecede arttırdığı belirlenmiştir. En yüksek doğruluk oranı ise DVM yöntemi ile yapılan sınıflandırma sonuçları ile elde edilmiştir. Çizelge 5.15'teki 5-katlı çapraz doğrulama ile sonuçlara bakıldığı zaman tüm deneysel çalışmalardaki en yüksek doğruluk sonucuna erişilmiştir. RKO özellikleri eklendikten sonra sınıflandırma sonuçları % 2,93 oranında iyileşme sağladığı görülmüştür. Anormal TM görüntüleri ayırmada %

3,68 Normal TM görüntüleri ayırmada ise % 2,53 iyileşme sağladığı görülmüştür. Normal TM görüntüleri daha fazla olmasına karşın Anormal TM görüntüleri ayırmada daha başarılı olması sınıf içerisinde örneklerin dengesiz dağılmasından kaynaklanmaktadır. YSA yöntemi ile Normal TM ve Anormal TM görüntülerinin sınıflandırıldığı çalışmada sadece AOM TM ve Normal TM görüntüleri ilse sınıflandırılma yapıldığında RKO özelliği sınıflandırma başarısını oldukça iyi etkilemiştir. AOM sınıfına ait görüntülerde genel itibari ile kızarıklık bulunmakta, Normal görüntüler ise genel itibari ile grimsi bir renk yapısına sahiptir. Bu çalışmada Anormal TM sınıfında COM, earwax, tüplü gibi birçok farklı anormal sınıfa ait TM görüntüleri yer almaktadır. Earwax sınıfına sahip görüntülerde siyah renk ağırlıklı olurken COM sınıflarında kızarıklık bulunabilmektedir. Bu durumda Anormal TM verileri kendi içerisinde oldukça heterojen bir dağılım göstermektedir. Veri seti dengesiz dağıldığı durumlarda sınıflandırma başarısını etkilemektedir [234,235].




Şekil 5. 8. GSEM ve RKO özellikleri ile Anormal ve Normal TM görüntülerinin ayrılması modeline ait AİK eğrisi.

Model başarısını gösteren AİK eğrisi ve AUC değeri Şekil 5.8.'de verilmiştir. Y ekseninde DP oranı ve x ekseninde YP oranı değerlerinin olduğu AİK grafiğinde eğrinin altında kalan alan 0.77 olarak belirlenmiştir.

5.2. ZAR BÖLGESİNİN TESPİT EDİLMESİ VE DERİN ÖĞRENME İLE TM GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

5.2.1. YOLO Yöntemi ile Zar Bölgesinin Tespiti


Orta kulak görüntülerinde zar bölgesinin tespit edilmesi için bu deneysel çalışmada elde edilen 282 adet TM görüntülerinde COM ve earwax (kirli orta kulak) sınıflarına ait görüntüler zar bölgesi deforme olduğundan ve net bir şekilde belli olmadığından dolayı bu çalışmaya dâhil edilmemiştir. Deneysel çalışmalar 155 adet Normal TM sınıfına ait ve 59 adedi AOM TM sınıfına ait olmak üzere toplamda 224 adet TM görüntüsü üzerinde zar bölgesinin tespit edilmesi çalışması yapılmıştır. Veri setini elde edildikten sonra ilk olarak Matlab Image Viewer uygulaması ile zar bölgesi uzman tarafından işaretlenmiştir. Model eğitimi için derin öğrenme temelli transfer öğrenme stratejisinden yararlanılarak AlexNet, VGGNet-16, VGGNet-19, GoogLeNet ve ResNet-50 modelleri kullanılmıştır. Görüntüleri modellere giriş olarak vermeden önce AlexNet için 227x227 px diğer modeller için giriş görüntü boyutu 224x224 px olarak kabul edildiğinden dolayı yeniden boyutlandırılmıştır. Önerilen modele ait akış şeması Şekil 5.9.'da verilmiştir.



Şekil 5. 9. YOLO yöntemi ile zar bölgesinin tespit edilmesi.


Transfer öğrenme modelleri ile ağırmızı eğitim parametreleri için öğrenme oranı 1×10^{-3} , optimizasyon olarak skotastik gradyan azalma algoritması kullanılmıştır. Model

doğruluğunu test etmek için ilk olarak verisetini % 50 eğitim ve % 50 test olacak şekilde rastgele 2'ye ayrılmıştır. Ardından aynı model parametreleri kullanılarak % 70 eğitim ve % 30 test olacak şekilde ikiye ayrılmıştır. Veri seti % 50 eğitim ve test olarak ayrıldığında, Şekil 5.10'da verilen kesinlik-hassasiyet eğrilerinde görüldüğü gibi en yüksek doğruluk oranı VGG-16 modeli ile elde edilmiştir, oysa AlexNet, VGG19, GoogLeNet ve ResNet50 modelleri sırasıyla % 29, % 53, % 70 ve % 92 doğruluk oranlarına sahiptir. YOLO yöntemi ile membran bölgesinin belirlenmesinde en düşük sonuçlar AlexNet modeli ile elde edilmiştir.



Şekil 5. 10. Kesinlik-Hassasiyet Eğrileri (%50).


Şekil 5.10 da verilen modelin hassasiyet-kesinlik eğrilerine bakıldığında mümkün olduğunca hassasiyet ekseninde 1'e yakın olması beklenir. Burada en yüksek doğruluk oranı % 93 ile VGG-16 modeline aitken en düşük değer ise % 29 ile AlexNet modeline aittir.



Şekil 5. 11. Kesinlik-hassasiyet eğrileri (%70 - %30).

Aynı hiper parametreler ile veri seti % 70 eğitim % 30 test olarak ayrıldığında ise En yüksek doğruluk değeri Şekil 5.11’de görüldüğü üzere % 93 ile ResNet-50 modeli ile elde edilirken AlexNet, VGG16, VGG19 ve GoogLeNet modelleri ile sırasıyla % 44, % 82, % 87 ve % 90 doğruluk oranlarına sahiptir. YOLO yöntemi ile membran bölgesinin belirlenmesinde en düşük sonuçlar yine AlexNet modeli ile elde edilmiştir.

Veri seti eğitim ve test olarak bölündüğünde VGG-16 ve ResNet-50 modelleri zar bölgesini tespit etmede üstün olduğu belirlenmiştir. Veri seti %50 eğitim ve test olarak bölündüğünde VGG-16 modeli ile %93 oranında doğruluk değeri elde edilirken % 70 eğitim ve %30 test olacak şekilde bölündüğünde ise aynı modelin doğruluk oranı % 82 olarak ölçülmüştür. Model doğruluğunu test etmek için ilk deneysel testte ResNet-50 modeli ile %92 doğruluk değerine erişirken ikinci testte ise aynı model ile %93 doğruluk değerine erişilmiştir. Eğitimde kullanılan veri sayısı arttırıldığında, AlexNet, GoogLeNet, VGG19 ve ResNet modellerindeki doğruluk oranı artarken sadece VGG 16 modelinde azalmıştır. Şekil 5.12’de YOLO yöntemi ile zar bölgesi tespit edilen TM görüntüleri verilmiştir.



Şekil 5. 12. YOLO yöntemi ile zar bölgesi tespit edilen TM görüntüleri.

YOLO yöntemi ile zar bölgesi tespit etmek için aynı zamanda transfer öğrenme modellerinde özellik çıkarma katmanları ile modellerin katmanlar bazında zar bölgesi tespit etme başarı oranları da incelenmiştir. Eğitimde kullanılan veri sayısı artırıldığında, VGG16 modelinde başarı oranı azalırken diğer modellerin başarı oranı genellikle artmıştır. En yüksek sonuçlar, VGG16 modelinde conv5_3 katmanında elde edilirken, ResNet50 modelinde de activation_49 katmanında elde edilmiştir. Katmanlara ait deneysel sonuçlar Çizelge 5.16'da verilmiştir.

Çizelge 5. 16. Transfer öğrenme modellerine ait özellik çıkarma katmanlarının doğruluk oranları.

Transfer öğrenme modeli	Katmanlar	Doğruluk oranı (%)	
		%50 eğitim %50 test	%70 eğitim %30 test
AlexNet	conv3	21	44
	conv4	20	39
	conv5	32	37

Çizelge 5.16. (Devam ediyor).


VGG-16	conv5_3	93	82
	conv5_1	90	81
	conv4_2	56	34
VGG-19	conv5_4	49	87
	conv5_1	53	86
	conv4_1	52	44
GoogLeNet	inception_5a-output	70	90
	inception_4e-output	57	82
	inception_4d-output	64	89
ResNet-50	activation_49_relu	91	93
	activation_31_relu	92	91
	activation_13_relu	63	62

Transfer öğrenme modellerinde farklı katmanlar ile yapılan eğitim sonucunda farklı doğruluk sonuçlarının elde edildiği Çizelge 5.16’da görülmektedir. Literatür incelendiğinde; ESA ağlarında her bir evrişim katmanında görüntüler ile ilgili farklı özelliklerin öğrenildiği, bu deneysel çalışmada da gözlenmiştir [163]. Yapılan çalışma literatür ile paralellik göstermektedir. İkinci deneysel çalışmada, eğitimde kullanılan veri sayısı arttırıldığında, başarı oranlarının genel olarak arttığı, ancak VGG16 modelinde ve ResNet50 modellerinin bazı katmanlarında azaldığı görülmüştür. CNN ağlarının öğrenme yeteneği, veri sayısındaki artışa paraleldir. Bu durum literatür çalışmalarını desteklemektedir [237]. Deneysel çalışmada kullanılan veri setine bakıldığında 155 normal TM ve 69 anormal TM kullanılmıştır. Bu sınıflardaki görüntüler, farklı renklere, parlaklığa ve karanlık olmasına göre farklı görsel özelliklere sahiptir. Önerilen modelin doğruluğunu test ederken, veri kümesindeki veriler rastgele seçilir. Veri kümesi eşit olmayan bir şekilde dağıtıldığında model başarısını etkiler [238].

5.2.2. Derin ESA yöntemiyle COM ve Normal TM Görüntülerinin Sınıflandırılması


Bu deneysel çalışmada Normal TM sınıfa ait 535 görüntü ve 63 adet COM sınıfına ait görüntü kullanılmıştır. Deneysel çalışmaları gerçekleştirmek için NVIDIA Quadro P6000 GPU donanımına sahip grafik ekran kartı ve işlemci olarak Intel(R) Xeon (R) Gold 6132 @2.6 GHz ile donatılmış bir makinada gerçekleştirildi. Derin ESA temelli önceden eğitilmiş transfer öğrenme modellerine TM görüntüleri girdi olarak verilmiştir. Veri setimizi %70 eğitim ve %30 test olarak rastgele olacak şekilde ayarlanmıştır. Modelimizi eğitmek için mini-batch değeri 32 olarak ayarlandığından

dolayı her döngüde 18 adet görüntü kullanılmıştır ve max-epoch'da 64 olarak ayarlandığından dolayı modelin eğitimi 1152 döngüde tamamlanmıştır. Transfer öğrenme modellerinde eğitim oranı değeri 1×10^{-4} olarak ayarlanmıştır, optimizasyon olarak ise skotastik gradyan iniş algoritması kullanılmıştır.



Şekil 5. 13. Transfer öğrenme modellerinin eğitimi tamamlama süreleri.


Derin ESA ile parametre sayısının artması beraberinde hesaplama yükünde artmasına sebep olmaktadır [164]. Şekil 5.13'te ağıın eğitimi için harcanan süreler bakıldığında en erken AlexNet modeli ile eğitim 59 dk' da tamamlanmıştır. En geç eğitimi tamamlayan model ise ResNet101 ile 69 dk sürmüştür. AlexNet modelinde yaklaşık 60 milyon parametre bulunmaktadır. ResNet-101 modelinde ise 44.6 milyon parametre bulunmaktadır. ResNet-101 modelinde daha az parametre bulunmasına rağmen AlexNet modeli eğitimi daha kısa zamanda tamamlamıştır. AlexNet mimarisi 41 katmandan oluşurken ResNet-101 mimarisi AlexNet mimarisine göre çok derin bir katmanlı yapıya sahiptir. ResNet-101 mimarisinde 347 katman bulunmaktadır. Bu modelin eğitim süresinin AlexNet mimarisinde göre daha fazla sürmesi derin bir yapıya sahip olmasından kaynaklanmaktadır.



Şekil 5. 14. Transfer öğrenme modellerine ait AİK eğrileri.

Model eğitimleri tamamlandıktan sonra ikili sınıflandırma sistemlerinde sık kullanılan duyarlılık değerinin özgüllük değerine oranı olarak ifade edilen AİK eğrileri çıkarılmıştır. Şekil 5.14'te görüldüğü gibi gözlenen en yüksek oran 0.9872 ile VGG16 modeline ait iken gözlenen en düşük oran ise ResNet50 mimarisiyle 0.9151 oranında değerler elde edilmiştir.

Toplamda 598 TM görüntüsü ile literatürde yaygın olarak kullanılan 7 farklı transfer öğrenme modeli ile sınıflandırma işlemi yapılmıştır. En yüksek başarı oranı VGG-19 modeli ile % 97.2067 değerine erişilmiştir, en düşük başarı oranı da ResNet-50 ve ResNet-101 modelleriyle %92.1788 sonucu elde edilmiştir. Derin ESA temelli transfer öğrenme modelleri Normal TM ve COM TM görüntülerini ayırmak için oldukça elverişlidir. Modeller ait karmaşıklık matrisleri Şekil 5.15'te ve karmaşıklık matrisinden elde edilen doğruluk oranları Çizelge 5.18'de verilmiştir.



Şekil 5. 15. Transfer öğrenme modellerine ait karmaşıklık matrisi.

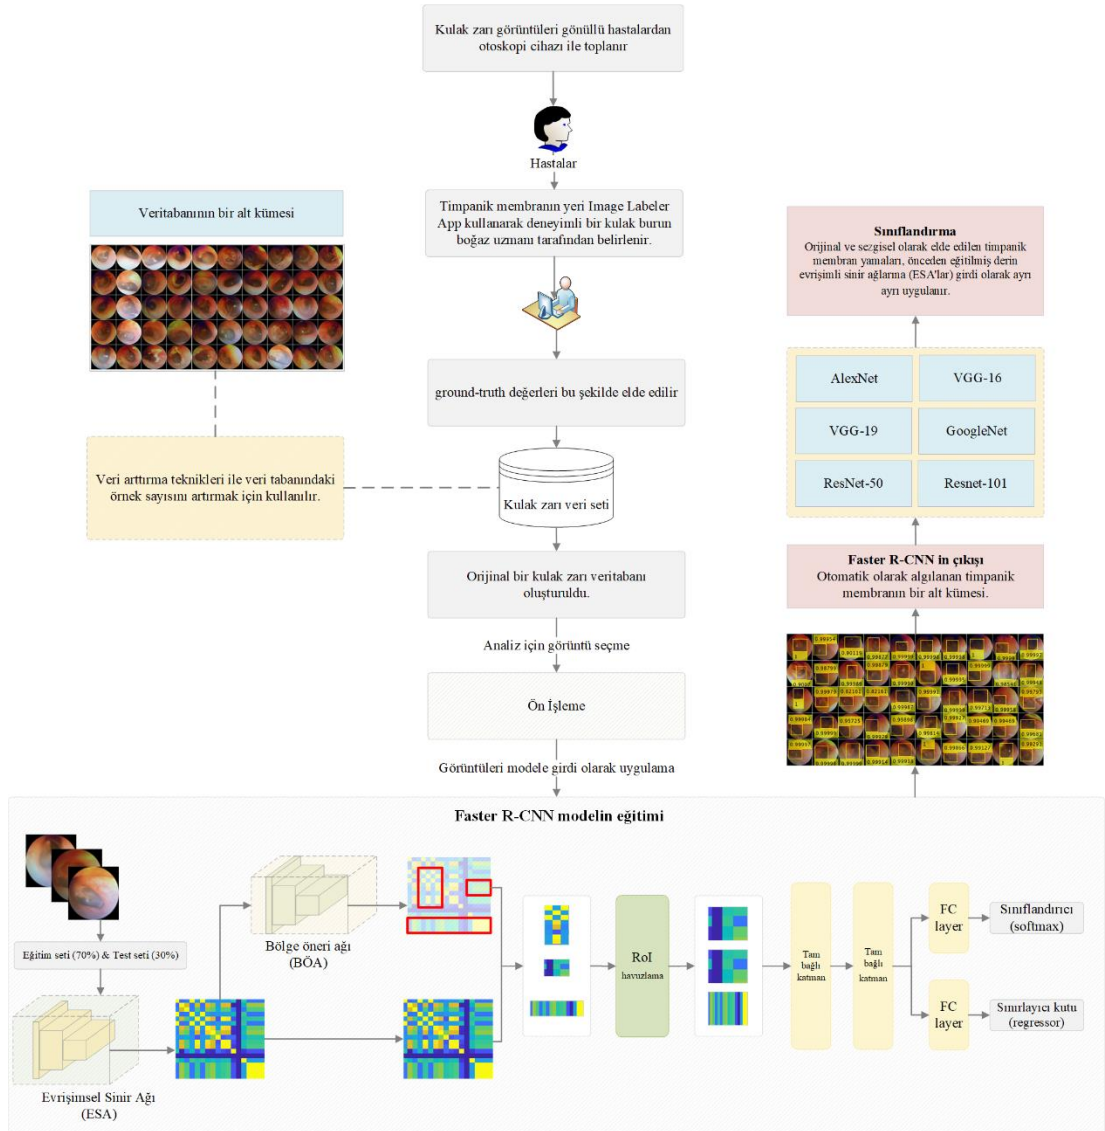
Çizelge 5. 17. Transfer öğrenme modellerinin doğruluk oranları.

ESA Mimarileri	Doğruluk Oranı(%)
AlexNet	96.6480
VGG16	94.9721
VGG19	97.2067
GoogLeNet	94.9721
ResNet18	93.8547
ResNet50	92.1788
ResNet101	92.1788

Şekil 5.15. 'te bulunan karmaşıklık matrisleri incelendiğinde Normal TM imgeleri ResNet-18 ve GoogLeNet modellerinde sadece 1 adet görüntünün tespit edilemediği diğer tüm modellerde ise tamamının doğru bir şekilde sınıflandırıldığı görülmektedir. COM sınıfına ait görüntülerde ise Normal TM görüntüleri olarak algılanan örneklerin oranında fazlalık görülmektedir. Bu durum veri setinde verilerin dengesiz bir şekilde dağılmasından kaynaklanmaktadır. 534 adet Normal TM görüntü varken COM TM görüntülerinden ise sadece 63 adet görüntü vardır. Veri setinin dengesiz olduğu durumlarda diğer sınıftaki görüntülerin sayıca çok olan sınıf gibi algılandığı literatürleri ile paralellik göstermektedir [236,239].

5.2.3. Faster-R CNN Yöntemi ile Zar Bölgesinin Tespiti ve Derin ESA TM Görüntülerinin Sınıflandırılması

Zar bölgesinin tespit edilmesi ve derin öğrenme ile TM imgelerinin sınıflandırılması için ilk olarak orijinal ve arttırılmış imgeleri ESA temelli transfer öğrenme yaklaşımı olan AlexNet, VGGNet, GoogLeNet, ResNet modellerinin girişine vererek sınıflandırma işlemi gerçekleştirilmiştir. Ardından Faster-R CNN yaklaşımı ile zar bölgesi sezilen TM parçalarını da transfer öğrenme modellerinin girişine verilerek özgün bir modelle zar bölgesinin tespiti ve sınıflandırma işlemi gerçekleştirilmiştir. Önerilen modelin akış diyagramı Şekil 5.16’da verilmiştir.



Şekil 5. 16. Önerilen modelin akış diyagramı.

Faster-R CNN yöntemi ile zar bölgesinin tespit edilmesi için orijinal veri seti ve arttırılmış veri seti %70 eğitim ve %30 test olacak şekilde rastgele ayrılmıştır. Orijinal veri seti üzerinde 196 adet görüntü eğitim ve 86 adet görüntü de test olacak şekilde ayrılmıştır. Arttırılmış görüntülerde ise 1185 adet görüntü eğitim ve 507 adet TM görüntüsü ise test olarak ayrılmıştır. Deneysel çalışmaları gerçekleştirmek için NVIDIA Quadro P6000 GPU grafik ekran kartı, Intel(R) Xeon(R) Gold 6132 CPU @2.60 GHz işlemci donanım özelliklerine sahip makine makinada deneysel çalışmalar gerçekleştirilmiştir. Eğitim ve test olarak kullanılan veri seti Çizelge 5.18’de tanımlanmıştır.

Çizelge 5. 18. Eğitim ve test olarak ayrılan veri sayısı.

Orijinal veri seti		Arttırılmış veri seti	
Eğitim	Test	Eğitim	Test
196	86	1185	507

Zar bölgesinin Faster-R CNN yöntem ile tespit etmek için dört farklı deney gerçekleştirilmiştir. İlk olarak bu model 282 adet TM görüntüsüne sahip orijinal veri setine uygulanmıştır. Faster-R CNN ağ mimarisindeki en iyi öğrenme oranını belirlemek için 1×10^{-3} , 1×10^{-4} , 1×10^{-5} ve 1×10^{-6} olarak belirlenmiştir. Bu öğrenme oranları ideal bir yakınsama değeri elde etmek için çok büyük veya çok küçük değildir. Epoch değeri minimum olarak 10, maksimum olarak 100 belirlenmiştir. En iyi doğruluk değeri 25 epoch olarak ayarlandığında 0.6772 doğruluk oranı elde edilmiştir. Test setindeki 86 adet görüntüden sadece 8 adedinde zar bölgesi tespit edilememiştir. Veri setini eğitmek ve test etmek için sırasıyla 19.37 dk ve 0.073 dk olarak tamamlanmıştır. Çizelge 5. 19’de TM tespit edilme sonuçları verilmiştir.


Çizelge 5. 19. Faster-R CNN modeli ile zar bölgesinin tespiti.

Veri seti	Epoch	Doğruluk oranı	Zar bölgesi tespit		
			edilemeyen örnek sayısı	Eğitim süresi (dk)	Test Süresi (dk)
Orijinal veri seti	10	0.4015	31	7.793	0.667
	15	0.5007	25	11.380	0.0701
	20	0.6079	17	14.533	0.0668
	25	0.6772	8	19.370	0.0753
	50	0.6026	16	36.173	0.0646
	100	0.6325	9	70.142	0.0815
	10	0.5827	98	60.412	0.4657
	15	0.6330	72	84.078	0.5243

Çizelge 5.19. (Devam ediyor).

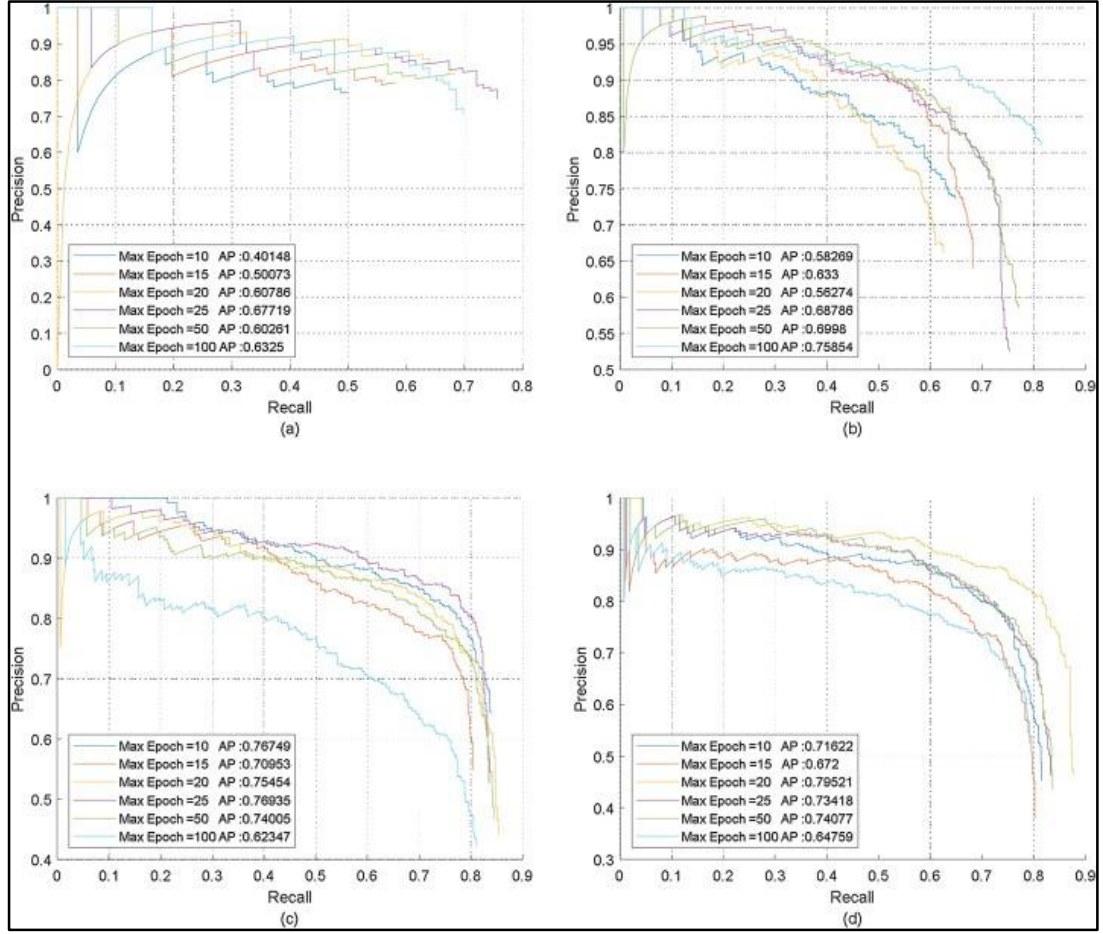
Orijinal	20	0.5627	83	113.986	0.4478
Veri seti	25	0.6879	30	137.284	0.4484
	50	0.6998	30	272.18	0.4552
	100	0.7585	34	529.56	0.5220
	10	0.7675	8	87.101	0.4519
Gauss	15	0.7095	12	85.651	0.4324
gürültülü	20	0.7545	1	110.171	0.4439
arttırılmış	25	0.7694	4	135.089	0.4346
veri seti	50	0.7400	0	268.187	0.4394
	100	0.6235	2	555.808	0.5141
	10	0.7162	0	52.4371	0.4461
Tuz-biber	15	0.6720	1	75.2132	0.4767
gürültülü	20	0.7952	1	111.467	0.4215
arttırılmış	25	0.7342	1	142.931	0.4264
veri seti	50	0.7408	0	266.220	0.4198
	100	0.6476	6	552.200	0.4772

İkinci deneysel çalışmada da veri arttırma tekniklerinden yararlanılarak 282 adet imgeden 1692 imge elde ederek gerçekleştirilmiştir. Arttırılmış imgelerde eğitim işlemini gerçekleştirmek için orijinal veri seti ile aynı hiper parametreler kullanılmıştır. En iyi doğruluk değer max epoch değeri olarak belirlendiği zaman 0.7585 olarak elde edilmiştir. 509 adet test veri setinde sadece 34 adet görüntüde zar bölgesi tespit edilememiştir. Eğitim için 529.56 dk gerekirken test etmek için ise 0.5220 dakikalık zaman belirlenmiştir. Bu deneysel çalışma sonucunda veri arttırma tekniği ile Faster-R CNN yöntemiyle zar bölgesinin tespitini olumlu yönde etkilediği, max epoch sayısının artması da model performansını arttırdığı gözlemlenmiştir. Faster-R CNN yaklaşımı ile zar bölgesi bulunan imgelerin temsili resimleri Şekil 5.17’de görülmektedir.



Şekil 5. 17. Faster-R CNN ile zar bölgesi bulunan orta kulak imgeleri.

Üçüncü ve dördüncü deneysel çalışmaları gerçekleştirmek için imgelere gürültü eklenerek arttırılmış veri seti üzerinde zar bölgesi tespit edilmeye çalışılmıştır. Bunun için sırasıyla Gaussian ve tuz-biber gürültü ekleme teknikleri kullanılmıştır. Gaussian gürültü ekleme ile en iyi sonuç epoch 25 olarak ayarlandığında 0.7694 doğruluk oranı ile elde edilmiştir. Modeli eğitmek için 135.089 dk gerekirken test etmek için ise 0.4346 dk geçmiştir. 509 adet TM görüntüsünden sadece 4 adet görüntüde TM tespit edilememiştir. Arttırılmış veri setine tuz-biber gürültüsü eklendiğinde en iyi doğruluk değeri 0.7952 ile epoch 20 olarak ayarlandığında elde edilmiştir. Test veri setinde zar bölgesi tespit edilemeyen sadece bir örnektir. Modeli eğitmek için eğitim süresi 111.467 dk gerekirken test etmek içinse 0.4215 dk geçmiştir. TM imgelerine gürültü eklenmesi sonucunda doğruluk oranını arttırdığı fakat bunun sonucunda model üst üste binen birden fazla zar bölgesini tespit ettiği bu durumun da sadece tek bölge tespit edilmesinin arzulandığı önerilen model için ideal bir yaklaşım olmadığı belirlenmiştir.

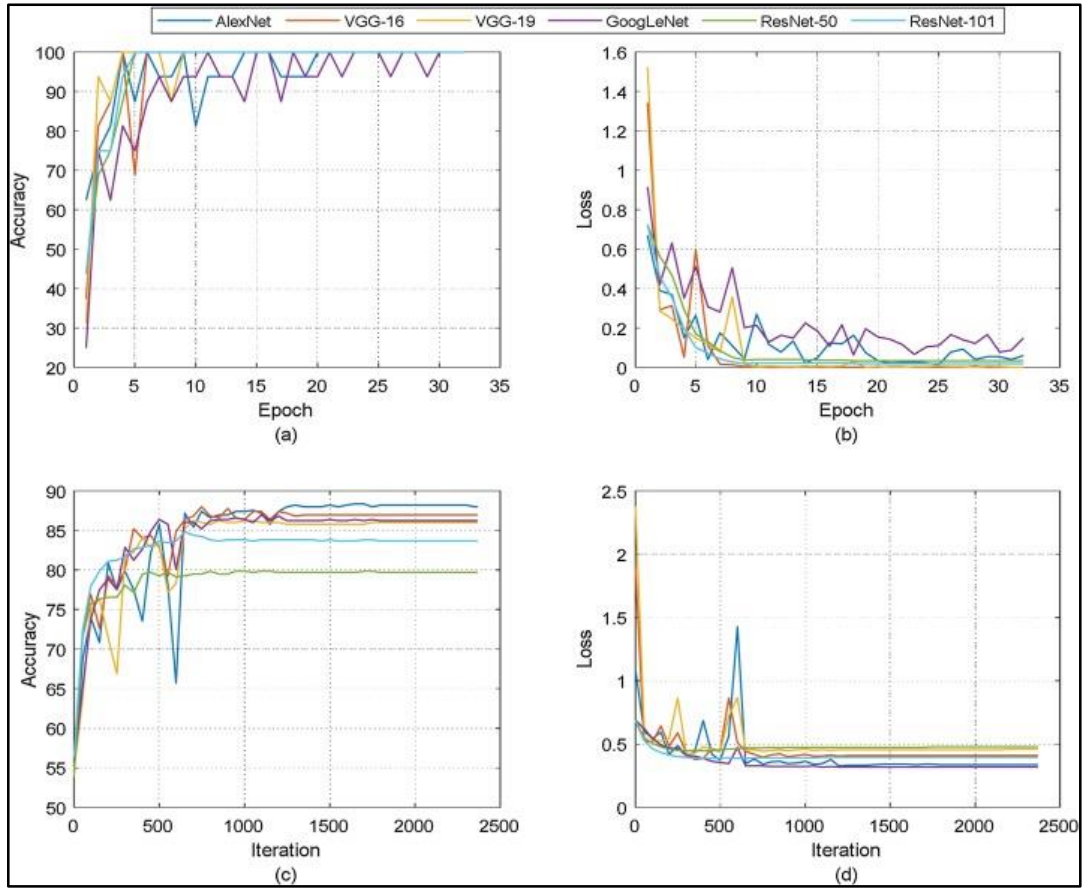


Şekil 5. 18. a) Orijinal veri kümesi, b) artırılmış veri kümesi, c) gauss gürültüsü ile artırılmış veri kümesi ve d) tuz ve biber gürültüsü ile artırılmış veri kümesi için maksimum dönem sayısını göz önünde bulunduran hassasiyet ve geri çağırma eğrileri.

Şekil 5.18'deki grafiklerde görüldüğü üzere otomatik TM algılama görevinin sonuçları, modelin TM'ı başarılı bir şekilde tespit edebildiğini ve gürültüye karşı dirençli olduğunu göstermektedir. Veri setindeki örnek sayısının artırılması model performansını artırmıştır. Bununla birlikte, model eğitim süresinde 19.37 dakikadan 529.56 dakikaya da önemli bir artış olmuştur. Bunun nedeni, veri kümesindeki mini batch boyutu değeri ve örnek sayısıdır. Mini batch boyutu Faster-R CNN mimarisinde sabittir ve eşit olmalıdır.

Sınıflandırma işlemi gerçekleştirilmek için ilk olarak orijinal ve artırılmış TM veri seti transfer öğrenme modelleri ile ayrı sınıflandırma işlemi gerçekleştirilmiştir. Modeller ayrıca tespit edilen zar bölgesi de modellerin girişine verilmiştir. Zar bölgesi tespit edilemeyen imgeler ise orijinal hali ile sınıflandırmaya konulmuştur.

Derin öğrenme modelleri ile deneysel çalışmalar neticesinde öğrenme oranı 1×10^{-4} , öğrenme oranı düşürme katsayısı 0.1 ve öğrenme oranı düşürme periyodu da 8 olarak belirlenmiştir. Böylece epoch sayısına bağlı olarak veriler güncellenerek bu farklı hiper parametreler denenerek sonuçlarına bakılmıştır. Tüm modellerde optimizasyon yöntemi olarak skotastik gradyan azalmalı moment kullanılmıştır. Eğitim veri setinde 1184 adet TM görüntüsü ve mini-batch boyutu 16 olduğundan dolayı her döngüde 74 adet TM görüntüsü eğitilir. Epoch boyutu da 32 olarak belirlendiğinden dolayı toplamda 2368 iterasyonda eğitim tamamlanacaktır. Öğrenme oranı 1×10^{-4} , öğrenme oranı düşürme katsayısı 0.1 ve öğrenme oranı düşürme periyodu da 8 olarak ayarlandığından dolayı öğrenme oranı 1×10^{-4} ve 1×10^{-8} arasında değişmektedir.



Şekil 5. 19. Orijinal veri seti ile eğitim ve test örneklerinin doğruluk ve maliyet grafikleri. a) eğitim doğruluğu b) eğitim maliyeti c) test doğruluğu d) test maliyeti.

Şekil 5.19 (a), (b)'de modellerin epoch sayısına bağlı olarak doğruluk (accuracy) ve (c) ve (d)'de ise maliyet (loss) grafikleri verilmiştir. Modeller 1000 iterasyonda yakınsama değerini 14. epochta yakaladığı, bu noktadan sonra önemli bir değişme

olmadığı açıkça görülmektedir. Buda gösteriyor ki bu noktadan sonra eğitim maliyeti ciddi oranda düşürülebilir.

Model eğitiminde kullanılan derin öğrenme temelli tüm transfer öğrenme modelleri ile iyi sonuçlar elde edilmiştir. Arttırılmış veri seti ile transfer öğrenme modelleriyle eğitim sonucunda elde edilen karmaşıklık matrisleri ve performans metrikleri Şekil 5.20 ve Çizelge 5.20’de verilmiştir. %87.97 doğruluk oranı ile en iyi sonuca AlexNet modeli ile erişilmiştir. Diğer transfer öğrenme modelleri olan VGG-16, VGG-19, GoogLeNet, ResNet-50 ve ResNet-101 modelleri ile de sırasıyla %86.98, %86.00, %86.19, %84.62 ve %85.01 doğruluk oranı elde edilmiştir. Model başarısını değerlendirme de hassasiyetlik ölçütü önemli bir performans metriğidir. Hassasiyet ile modelin anormal TM görüntüleri ayırt etmedeki başarısını göstermektedir. ResNet-101 modeli %82.17 hassasiyet ile diğer modellere nazaran üstün olmasına rağmen AlexNet modelinin performans ve maliyet bakımından diğer modellere nazaran daha üstündür. AlexNet modeli ile eğitim süresine bakıldığı zaman sadece 5.32 dk’ da eğitim işlemini gerçekleştirmiştir.

AlexNet		VGG-16		VGG-19	
187 ^a	18 ^b	186 ^a	22 ^b	186 ^a	27 ^b
43 ^c	259 ^d	44 ^c	255 ^d	44 ^c	250 ^d
GoogLeNet		ResNet-50		ResNet-101	
186 ^a	26 ^b	177 ^a	25 ^b	189 ^a	35 ^b
44 ^c	251 ^d	53 ^c	252 ^d	41 ^c	242 ^d

Şekil 5. 20. Önceden eğitilmiş derin transfer öğrenme modelleri ile eğitilmiş arttırılmış imgeler ile edilen karmaşıklık matrisi a) Doğru pozitif b) Yanlış pozitif c) Yanlış negatif d) Doğru negatif.

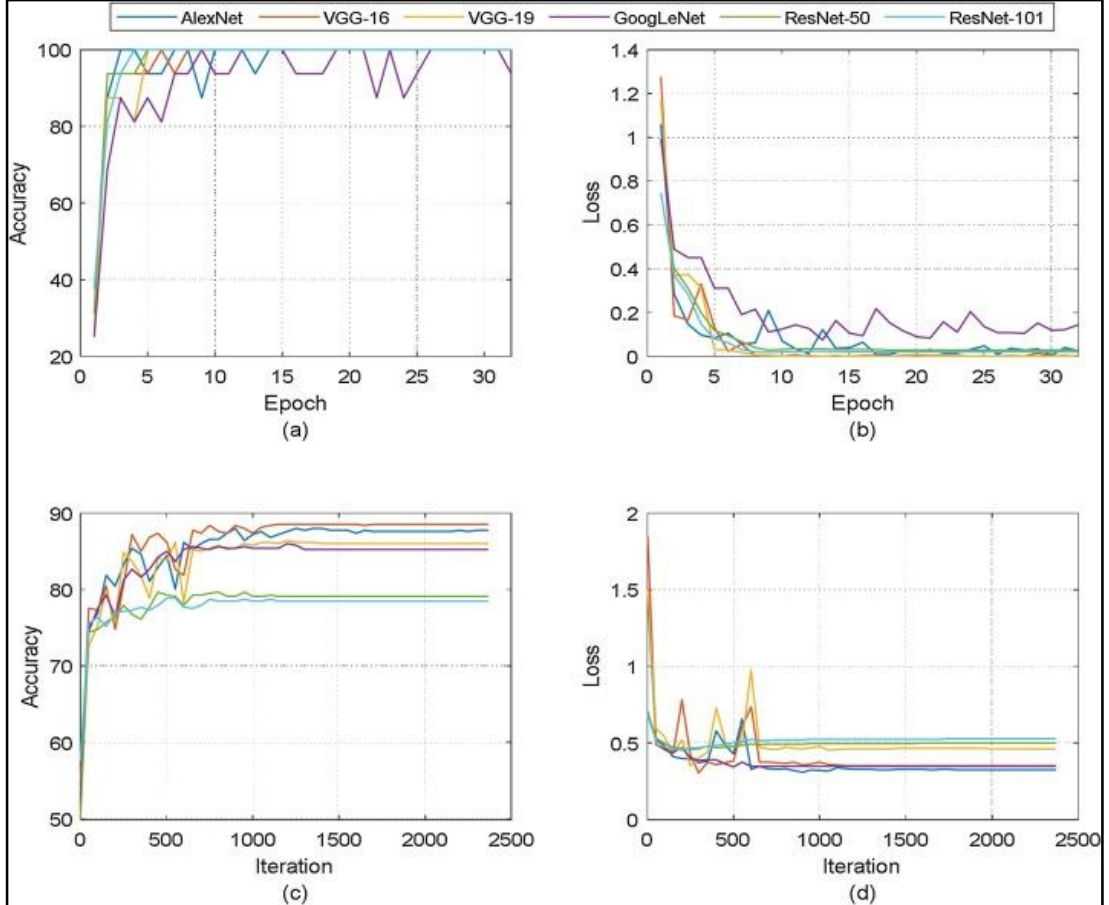
Çizelge 5. 20. Arttırılmış imgeler transfer öğrenme performans sonuçları.

Model	Doğruluk Oranı(%)	Hassasiyet (%)	Özgünlük (%)	F-Skor (%)	AUC	Eğitim süresi (dk)
AlexNet	87.97	81.30	93.50	85.98	0.9392	5.32
VGG-16	86.98	80.87	92.06	84.93	0.9478	17.36

Çizelge 5.20. (Devam ediyor)

VGG-19	86.00	80.87	90.25	83.97	0.9346	19.11
GoogLeNet	86.19	80.87	90.61	84.16	0.9393	10.12
ResNet-50	84.62	76.96	90.98	81.94	0.9210	20.84
ResNet-101	85.01	82.17	87.37	83.26	0.9323	26.32

Zar bölgesi otomatik olarak bulunan TM parçaları sınıflandırma işleminin ikinci aşamasında transfer öğrenme modellerinin girişine verilmiştir. Modellerin eğitim ve test işlemleri epoch ve iterasyona göre doğruluk oranları ve maliyet değişimleri grafikleri Şekil 5.20’de, karmaşıklık matrisleri ve karmaşıklık matrisinden elde edilen performans metrikleri sırasıyla Şekil 5.21. ve Şekil 5.22’te verilmiştir.



Şekil 5. 21. Zar bölgesi bulunan TM parçaları ile transfer öğrenme girişine verilen modellerin eğitimi a) Eğitim doğruluğu b) Eğitim maliyeti c) Test doğruluğu d) Test maliyeti.

AlexNet		VGG-16		VGG-19	
182 ^a	14 ^b	199 ^a	27 ^b	187 ^a	28 ^b
48 ^c	263 ^d	431 ^c	250 ^d	43 ^c	249 ^d
GoogLeNet		ResNet-50		ResNet-101	
190 ^a	35 ^b	179 ^a	33 ^b	179 ^a	37 ^b
40 ^c	242 ^d	51 ^c	244 ^d	51 ^c	240 ^d

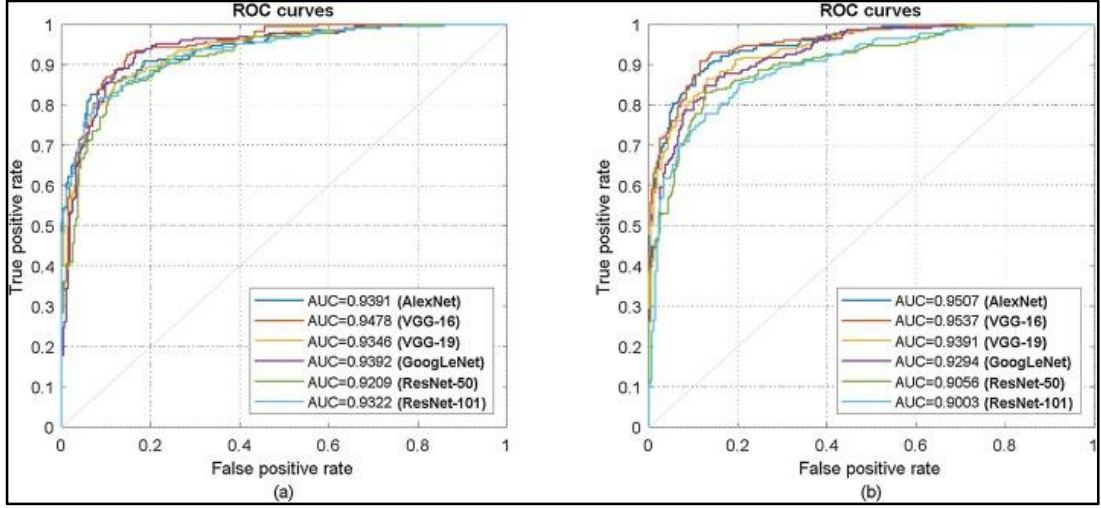
Şekil 5. 22. Zar bölgesi tespit edilen TM parçaları ile transfer öğrenme girişine verilen modellere ait karmaşıklık matrisi a) Doğru pozitif b) Yanlış pozitif c) Yanlış negatif d) Doğru negatif.

Çizelge 5. 21. Zar bölgesi tespit edilen TM parçaları ile transfer öğrenme girişine verilen modellere ait karmaşıklık matrisinden elde edilen performans metrikleri.

Model	Doğruluk Oranı(%)	Hassasiyet (%)	Özgüllük (%)	F-Skor (%)	AUC	Eğitim süresi (dk)
AlexNet	85.22	77.08	91.99	87.29	80.85	92.64
VGG-16	85.93	80.99	90.04	90.48	86.84	93.50
VGG-19	85.81	78.90	91.55	90.01	86.97	92.53
GoogLeNet	82.97	77.86	87.22	86.76	83.98	89.06
ResNet-50	80.96	74.47	86.36	84.39	81.64	86.68
ResNet-101	80.37	77.86	82.46	84.22	80.46	87.33

Çizelge 5.21’de görüldüğü üzere tüm transfer öğrenme modelleri ile oldukça iyi sonuçlar elde edilmiştir. VGG-16 modeli, sırasıyla % 88.56, % 86.52 ve % 90.25 doğruluk, duyarlılık ve özgüllük ile en iyi sınıflandırma performansına sahiptir. AlexNet, VGG-19, GoogLeNet, ResNet-50 ve ResNet-101 modellerinin doğruluğu sırasıyla % 87.77, % 86.00, % 85.21, % 83.43 ve % 82.64’ tür. VGG-16 modelinin eğitimi 17.20 dakikalık bir sürede tamamlanmıştır. Deneysel sonuçlar, derin ESA modellerinin otomatik olarak tespit edilen TM bölgesiyle beslenmesinin model performanslarını arttırdığını göstermektedir. Yalnızca ResNet modelinin performans sonuçları azalmıştır. İki farklı deneysel çalışma ile sınıflandırma sonucu elde edilen modellerin AİK eğrileri Şekil 5.23’te verilmiştir. Şekil 5.23’te VGG-16 modelinin

0.9537'nin en iyi AİK değerine ulaştığını, diğer derin CNN modellerinin ise AİK değerleri > 0.90 olduğunu gösterir.



Şekil 5. 23. Modellerin AİK eğrileri. (a) Arttırılmış numunelerle beslenen modeller. (b) Modeller otomatik olarak algılanan TM parçaları ile beslenir.

Son olarak, model başarısını doğrulamak için ek deneysel çalışmalar yapılmıştır. Bu deneylerde, orijinal ve otomatik olarak algılanan TM parçaları, farklı bir bölme oranı ile ayrılarak, % 50 eğitim ve % 50 test setleri ve 10 kat çapraz doğrulama tekniği elde etmek için ayrı ayrı ele alınmıştır.

Çizelge 5. 22. Arttırılmış imgelerin sınıflandırma sonuçları.

Modeller	%50 Eğitim %50 test sonuçları			10-katlı çapraz doğrulama sonuçları		
	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)
AlexNet	82.62	71.09	92.20	86.64	79.03	92.96
VGG-16	83.33	77.86	87.87	90.24	86.24	93.07
VGG-19	82.27	72.65	90.26	90.24	85.80	93.93
GoogLeNet	82.86	76.56	88.09	88.00	85.54	90.04
ResNet-50	81.79	72.91	89.17	87.47	85.28	89.28
ResNet-101	83.33	79.16	86.79	89.06	87.89	90.04

Çizelge 5.22'de Arttırılmış TM imgeler ile yapılan deneysel çalışmaların sonuçları göz önünde bulundurulduğunda, tüm derin ESA modelleri ile elde edilen sonuçlar

görülmektedir. VGG-16 modeli ile % 90.24 doğruluk oranı ile tatmin edici bir sonuç elde edilmiştir.

Son deneysel çalışmada veri seti eğitim ve test olarak eşit iki parçaya bölünmüştür ve 10-katlı çapraz doğrulama sonuçları incelenmiştir. VGG-16 modeli ile % 90.48 doğruluk değeri ile en iyi sonuçlar elde edilmiştir. 10-katlı çapraz doğrulama yöntemi ile sonuçlara bakıldığında TM parçaları beslenen modellerin performanslarında artış olduğu Çizelge 5. 23.'te görülmektedir.

Çizelge 5. 23. Tespit edilen TM parçaları ile beslenmiş sınıflandırma sonuçları.

Modeller	%50 Eğitim %50 test sonuçları			10-katlı çapraz doğrulama sonuçları		
	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)
AlexNet	85.22	77.08	91.99	87.29	80.85	92.64
VGG-16	85.93	80.99	90.04	90.48	86.84	93.50
VGG-19	85.81	78.90	91.55	90.01	86.97	92.53
GoogLeNet	82.97	77.86	87.22	86.76	83.98	89.06
ResNet-50	80.96	74.47	86.36	84.39	81.64	86.68
ResNet-101	80.37	77.86	82.46	84.22	80.46	87.33

OM teşhisine yönelik yapılan bilgisayar temelli tüm çalışmalar Çizelge 5.24' te gösterilen çeşitli veri kümeleri, yöntemler ve doğruluk performansı metrikleri alınarak karşılaştırılmıştır.

Çizelge 5. 24. OM teşhis edilmesine yönelik yapılan diğer çalışmalar.

Yıl	Yazar	Yöntem	Veri sayısı	Sınıf sayısı	Doğruluk oranı (%)
2011	Mironica vd [24]	Global image features, kNN, DT, LDA, Naïve Bayes, MLN, SVM	186	2	73.11
2011	Vertan vd [17]	Renk veri dağılımı, Bayes decision rule	100	3	59.90
2013	Kuruvila vd [19]	Vocabular and grammer, decision tree	181	3	89.9

Çizelge 5.24. (Devam ediyor)

2014	Chuean Kai vd[21]	Active contour segmentation, LBP and HOG features, and AdaBoost	865	4	88.06
2016	Hermanus vd [7]	Görsel özellikler, Decision tree	486	5	80.61
2017	Huang and Huang [20]	Image processing, visual features, depth-First search algorithm	20	3	70.00
2018	Hermanus vd [22]	Visual features, DT, neural networks	389	5	81.58

Çizelge 5.24' te yapılan çalışmalarda farklı veri setleri ve yöntemler kullanıldığından dolayı tam olarak bir karşılaştırma yapılamamaktadır. OM teşhisine yönelik yapılan çalışmalar incelendiği zaman çoğunlukla kulak zarı görüntülerindeki görsel özelliklerin bir kombinasyonuna ve geleneksel makine öğrenme tekniklerini kullanarak sınıflandırdıklarını açıkça göstermektedir. Bu çalışmada otomatik olarak TM bölgesine odaklanan ve özellik çıkarma ve seçim süreçlerini ortadan kaldıran uçtan uca derin öğrenme modeli geliştirilmiştir. Model doğrudan giriş otoskop görüntülerine dayanarak bir karar verir. TM, otoskop görüntülerinde altta yatan bozukluğun görsel ipuçlarının çoğunu içermektedir. Ayrıca, endoskopik kameranın dairesel görüş alanının etrafındaki siyah arka plan görüntülerdeki en görünür özelliktir [17]. Bu durumdan dolayı bazı araştırmacılar active contour gibi bazı segmentasyon yöntemlerine başvurmuştur [21]. Bazı çalışmalar ise bu süreci manuel olarak gerçekleştirmiştir [17]. Önerdiğimiz yaklaşımda TM bölgesini tespit etmek için Faster-R CNN yöntemini kullanılmıştır. Ayrıca, dijital otoskop görüntülerinden zahmetli özellik çıkarma ve seçme işlemleri olmadan sınıflandırmak için transfer öğrenme modelleri benimsenmiştir. Bu nedenle bu çalışmada otoloji için tamamen sezgisel bir teşhis modeli elde edilmiştir.

Derin ESA modellerinin klinik karar destek sistemlerinde başarılı bir şekilde uygulanması zordur, çünkü modeller sağlam teşhis sonuçları elde etmek için makul büyüklükte veri setleri gerektirir [240]. Kliniklerden büyük ölçekli verilerin toplanması oldukça pahalı ve zor bir iş, hatta bazen imkânsızdır [241]. Karar destek sistemleri KBB alanında teşhise yönelik aktif olarak kullanılmamakta ve tam olarak benimsenmemiştir. Ancak, günlük klinik uygulamalarda tutarlı ve sezgisel bir teşhis sisteminin kullanılması, doktorun teşhis doğruluğunu arttırmakla beraber yanlış tanı oranını azaltır, karar verme sürecini destekler, standart ve objektif muayeneler yapmak gibi çeşitli avantajlar sunar.

BÖLÜM 6

SONUÇ VE ÖNERİLER

OM, orta kulağın iltihaplanmasının genel adıdır. Bu hastalık dünyada çok yaygın bir şekilde görülmekte ve tedavi edilmediği takdirde işitme duyusunun yitirilmesi ile sonuçlanabilen ciddi bir hastalıktır.

Bu doktora tez çalışmasında OM teşhisine yönelik yapılan literatür çalışmaları derinlemesine incelenmiş ve bu hastalığın teşhisine yönelik kliniklerde gözlemciler tarafından yapılan görsel incelemeler ve kişiden kaynaklı hatalar olduğu açıktır. Her hastanede yeterli ve deneyimli uzmanlar olmadığı da bilinmektedir. Bu sebeple bu hastalıkta hayati önem arz eden zar bölgesinin tespiti ve hızlı bir şekilde tanı konması için normal ve hastalıklı görüntüleri sınıflandırma işlemi yapan çalışmalar yapılmıştır.

Bu tez çalışması kapsamında, “Van Özel Akdamar Hospital” hastanesinde gerekli yasal izinler alınarak standart bir otoskopi cihazı kullanarak gönüllü hastalardan toplanan görüntüler ile deneysel çalışmalar yapılmış ve araştırmacılara açık kaynak olarak sunulmuştur.

Hesaplamalı bir yaklaşım olarak, AOM TM ve normal TM otoskop görüntülerini sınıflandırmak için GLCM ve YSA kombinasyonuna dayanan bir tanı modeli önerilmiştir. Deneysel sonuçlar, sadece GLCM tarafından sağlanan doku özelliklerinin kullanılmasının, sağlam ve tutarlı bir sistem sağlamak için yeterli olmadığını göstermiştir. Bununla birlikte, R, G ve B kanalının RKO değerlerinin ve doku özelliğinin bir kombinasyonu, modelin verimliliğini artırmıştır. Sonuç olarak, en iyi sonuçlar ortalama doğruluk % 76.14, Hassaslık % 70.75 ve Özgüllük % 80.07 ile GDA algoritması ile sağlanmıştır. Sonuç olarak, G kanalından çıkarılan doku

özellikleri AOM için daha verimli sonuçlar vermiştir. Teşhis ayrıca, RGB kanallarının ortalama renginin ve doku özelliklerinin kombinasyonu, otomatik normal ve AOM TM tespiti için umut verici sonuçlar vermiştir.

Normal ve Anormal TM görüntülerinin sınıflandırmak için özellik çıkarma algoritmalarından GSEM, YGH, YİÖ gibi algoritmalar kullanılarak her biri ayrı ayrı incelenmiş ve sadece bu özelliklerden biri ile yapılan sınıflandırma sonuçlarına bakıldığı zaman en yüksek doğruluk oranı YİÖ özelliklerinin DVM yöntemiyle sonuçlar 5-katlı çapraz doğrulama yöntemiyle elde edilmiştir. YİÖ yöntemi ile doğruluk, hassasiyet ve özgüllük değerleri sırasıyla % 76.33, % 76.54 ve % 76.87' olarak elde edilmiştir.

Özellik çıkarma algoritmalarından GSEM, YGH ve YİÖ ile elde edilen özellik vektörlerine RKO özelliği de eklendiği zaman en yüksek performans metrikleri YİÖ özelliklerine eklenmesiyle elde edilmiştir. YİÖ özelliklerine RKO özellikleri eklendikten sonra doğruluk hassasiyet ve özgüllük değerleri sırasıyla % 78.67, % 78.85 ve % 79.17 olarak belirlenmiştir.

COM ve Normal TM görüntülerini ayırt etmek için derin ESA temelli transfer öğrenme modellerinden AlexNet, VGG-16, VGG-19, GoogLeNet ve ResNet-50 kullanılmıştır. En yüksek doğruluk sonuçları VGG-19 modeli ile % 97.2067 doğruluk oranı elde edilmiştir.

Zar bölgesinin tespit edilmesi derin öğrenme temelli yöntemlerden Faster-R CNN ve YOLO yöntemi kullanılmıştır. 1692 adet arttırılmış TM imgesiyle Faster-R CNN yöntemiyle % 75.85 doğruluk oranı elde edilirken, YOLO yönteminin transfer öğrenme yöntemlerinden VGG-16 ve ResNet-50 modelleriyle eğitilmesi sonucu % 93 doğruluk oranı elde edilmiştir.

Özgün bir model önerisi ile zar bölgesi tespit eden ve ardından Normal ve Anormal TM görüntülerini sınıflandıran bir yöntem geliştirilmiştir. Transfer öğrenme yöntemiyle zar bölgesi ile de beslenen öğrenme sonucu Normal ve Anormal TM imgeleri % 90.48 başarı oranı ile sınıflandırılması VGG-16 modeli ile elde edilmiştir. Bu yaklaşım ile potansiyel olarak gelecekteki KBB alanında kullanılabileceği,

hekimlerin tanı doğruluğunu artıracığı ve genel yanlış tanı oranı azaltmak için klinik karar destek sistemi olarak kullanılabileceği düşünülmektedir.

Gelecekte TM görüntülerinden yeni özellikler elde edilerek sınıflandırıcıların performanslarının artırılması hedeflenmektedir. Zar bölgesinin tespit edilmesine ve derin öğrenmenin farklı katmanlarının özellikleri de kullanılarak sınıflandırma performansının artırılması ve klinik karar destek uygulamalarının geliştirilmesi, yeni evrimsel modeller kullanılarak test edilmesi, optimizasyon algoritmaları üzerinde çalışmalar ve mobil bir uygulama geliştirilmesi amaçlanmaktadır.

KAYNAKLAR

1. Roosner, B., Teele DW., Klein JO., "Epidemiology of otitis media during the first seven years of life in children in greater Boston: a prospective, cohort study", *Pubmed*, 160: 83–94, (1989).
2. Marom, T., Bobrow M., Eviatar E., Oron Y., and Ovnat S., "Adherence to acute otitis media diagnosis and treatment guidelines among Israeli otolaryngologists", *International Journal Of Pediatric Otorhinolaryngology*, 95, 63-68, (2017). <https://doi.org/10.1016/j.ijporl.2017.02.003>
3. Sezgin, Z., "Efüzyonlu otitis media : tanı ve tedavi yaklaşımlarına genel bakış otitis media with effusion : overview of diagnosis and treatment approaches", *Pediatric Practice And Research*, 4, 1: 1–11, (2016).
4. Robert H. E., Mathew N. M., Harvey L. C., Marcus D. A., Mark G., "Validation of tele-otology to diagnose ear disease in children", *International Journal Of Pediatric Otorhinolaryngology*, 69, 6:739–744, (2005). [doi:https://doi.org/10.1016/j.ijporl.2004.12.008](https://doi.org/10.1016/j.ijporl.2004.12.008).
5. Mousseau, S., Lapointe A., and Gravel J., "Diagnosing acute otitis media using a smartphone otoscope; a randomized controlled trial", *The American Journal Of Emergency Medicine*, 36, 10: 1796–1801,(2018). [doi: 10.1016/j.ajem.2018.01.093](https://doi.org/10.1016/j.ajem.2018.01.093).
6. Wu V., Sattar J., Cheon S., and Beyea J. A., "Ear disease knowledge and otoscopy skills transfer to real patients: a randomized controlled trial", *Journal of Surgical Education.*, 75, 4: 1062–1069, (2018), [doi: 10.1016/j.jsurg.2017.12.011](https://doi.org/10.1016/j.jsurg.2017.12.011).
7. Myburgh, H. C., Van Zijl, W. H., Swanepoel, D., Hellström, S., & Laurent, C. "Otitis media diagnosis for developing countries using tympanic membrane image-analysis", *Ebiomedicine*, 5: 156-160. (2016).
8. Yu-kai, H., Chia-ping H., "A depth-first search algorithm based otoscope application for real-time otitis media image interpretation", *18 th International Conference on Parallel and Distributed Computing, Applications and Technologies (PDCAT)*, Taipei,170–175, (2017), [doi: 10.1109/PDCAT.2017.00036](https://doi.org/10.1109/PDCAT.2017.00036).
9. Szaleniec, J., Wiatr, M., Szaleniec, M., SkłAdzień, J., Tomik, J., Oleś, K., & Tadeusiewicz, R. "Artificial neural network modelling of the results of tympanoplasty in chronic suppurative otitis media patients", *Computers in biology and medicine*, 43(1): 16-22. (2013).
10. Kalender, N., and Özdemir, L., "Yaşlılarda sağlık hizmetlerinin sunumunda tele-tıp kullanımı" , *Anadolu Hemşirelik ve Sağlık Bilimleri Dergisi*, vol:17, 50–58, (2014).
11. Biagio, L., Swanepoel, D. W., Laurent, C., & Lundberg, T. "Video-otoscopy recordings for diagnosis of childhood ear disease using telehealth at primary health

- care level", *Journal of telemedicine and telecare*, 20(6), 300-306. (2014).
12. Sezer, B., Elcin M., "Tıp eğitiminde simülasyon", *Eğitim Teknolojileri Okumaları*, 39, Sakarya, 443–452, (2017).
13. Thone, N., Winter M., García-Matte R. J., and González C., "Simulation in otolaryngology: a teaching and training tool" , *Acta Otorrinolaringol*, vol: 68, no: 2,115–120, 2017, doi: 10.1016/j.otoeng.2017.02.007.
14. Stepniak, C., Wickens, B., Husein, M., Paradis, J., Ladak, H. M., Fung, K., and Agrawal, S. K. "Blinded randomized controlled study of a web-based otoscopy simulator in undergraduate medical education". *The Laryngoscope*, 127(6), 1306-1311,(2017).
15. Wu, V., and Beyea, J. A. "Evaluation of a web-based module and an otoscopy simulator in teaching ear disease", *Otolaryngology–Head and Neck Surgery*, 156(2), 272-277. doi: 10.1177/0194599816677697.
16. Oyewumi, M., Brandt, M. G., Carrillo, B., Atkinson, A., Iglar, K., Forte, V., and Campisi, P. "Objective evaluation of otoscopy skills among family and community medicine, pediatric, and otolaryngology residents", *Journal of surgical education*, 73(1), 129-135. doi: 10.1016/j.jsurg.2015.07.011.
17. Vertan, C., Gheorghe, D. C., and Ionescu, B. "Eardrum color content analysis in video-otoscopy images for the diagnosis support of pediatric otitis", *In ISSCS 2011-International Symposium on Signals, Circuits and Systems*, Iasi, 1-4, (2011), doi: 10.1109/ISSCS.2011.5978676.
18. L. Cheng, J. Liu, C. E. Roehm, and T. A. Valdez, "Enhanced video images for tympanic membrane characterization", *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Boston, 4002–4005, (2011), doi: 10.1109/IEMBS.2011.6090994.
19. Kuruvilla, A., Li, J., Yeomans, P. H., Quelhas, P., Shaikh, N., Hoberman, A., and Kovačević, J., "Otitis media vocabulary and grammar", *In 2012 19th IEEE International Conference on Image Processing*, Orlando, 2845-2848, (2012).
20. Huang, Y., and Huang, C. P., "A depth-first search algorithm based otoscope application for real-time otitis media image interpretation", *In 2017 18th International Conference on Parallel and Distributed Computing, Applications and Technologies*, Taipei, 170-175, (2017), doi: 10.1109/PDCAT.2017.00036.
21. Shie, C. K., Chang, H. T., Fan, F. C., Chen, C. J., Fang, T. Y., and Wang, P. C., "A hybrid feature-based segmentation and classification system for the computer aided self-diagnosis of otitis media", *In 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Taipei, 4655-4658, (2014), doi: 10.1109/EMBC.2014.6944662.
22. Myburgh, H. C., Jose, S., Swanepoel, D. W., and Laurent, C., "Towards low cost

automated smartphone-and cloud-based otitis media diagnosis", *Biomedical Signal Processing and Control*, 39, 34-52, (2018).

23. Martinello, M., Spinoulas, L., Tomic, I., Karygianni, S., Frossard, P., Haralam, M. A., and Hoberman, A., "Bulged eardrum detection from 3d data", *In 2018 25th IEEE International Conference on Image Processing (ICIP)*, Athens, 136-140, (2018).

24. Mironică, I., Vertan, C., and Gheorghe, D. C., "Automatic pediatric otitis detection by classification of global image features", *In 2011 E-Health and Bioengineering Conference (EHB)*, Iasi, 1-4, (2011)

25. Wang, X., Valdez, T. A., and Bi, J., "Detecting tympanostomy tubes from otoscopic images via offline and online training", *Computers in biology and medicine*, 61, 107-118, (2015)

26. Valdez, T. A., Spegazzini, N., Pandey, R., Longo, K., Grindle, C., Peterson, D., and Barman, I., "Multi-color reflectance imaging of middle ear pathology in vivo. Analytical and bioanalytical chemistry", *Analytical and Bioanalytical Chemistry*, 407(12), 3277-3283., (2015), doi: 10.1007/s00216-015-8580-y.

27. Hu, L., Li, W., Lin, H., Li, Y., Svanberg, K., Zhao, G., and Svanberg, S., "Optical detection of otitis media using modified spectroscopic otoscope", *In 2018 Asia Communications and Photonics Conference (ACP)*, 1-4, (2018), Hangzhou, doi: 10.1109/acp.2018.8595778.

28. Lau, J. Y., Nguyen, M. H. T., Liang, W., and Tan, K. K., "Application of design of experiments to feature selection in ventilation tube applicator", *In IECON 2015-41st Annual Conference of the IEEE Industrial Electronics Society*, Yokohama, 4277-4282, (2015).

29. Gao, W., Liang, W., and Tan, K. K., "Automated tube insertion on tympanic membrane based on vision-servo and tactile sensing", *In IECON 2014-40th Annual Conference of the IEEE Industrial Electronics Society*, 2706-2711, Dallas, (2014), doi: 10.1109/IECON.2014.7048889.

30. Gao, W., Liang, W., and Tan, K. K., "Kalman filter based vision-servoing alignment system for human ear surgery", *In 2015 World Congress on Industrial Control Systems Security (WCICSS)*, London, 83-88, (2016), doi: 10.1109/WCICSS.2015.7420331.

31. Lee, J. Y., Choi, S. H., and Chung, J. W., "Automated Classification of the Tympanic Membrane Using a Convolutional Neural Network", *Applied Sciences*, 9(9), 1827., doi: 10.3390/app9091827.

32. Devranoğlu, İ., "Dış ve orta kulak cerrahisi 1.Baskı", Editör: İrfan Devranoğlu, 0-4, *Deomed Yayıncılık*, İstanbul, (2011).

33. Hüseyinoğlu A., "Kıkırdak timpanoplastilerde aurikular greft donör alanlarının morbidite ve kozmetik görünüşe etkisinin incelenmesi", Tıpta Uzmanlık Tezi, *Trakya*

Universitesi Tıp Fakültesi Kulak Burun Boğaz Hastalıkları Anabilim Dalı, 3-12 2012.

34. Koçyiğit M., “Otoskopik muayene yöntemlerinin karşılaştırılması”, Tıpta Uzmanlık Tezi, *Trakya Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Anabilim Dalı*, 9-17 2008.

35. Bayrak S., “Efüzyonlu otitis mediada modifiye politizerizasyon yönteminin etkinliği”, Tıpta Uzmanlık Tezi, *Ankara Üniversitesi Tıp Fakültesi KBB Anabilim Dalı*, 19-29 2013.

36. Borsa, B.A., Kaplan, H.H., Aldağ, M.E., Dengiz, Y., Hanay, A., ve Tandoğan, B., “Otitis eksterna ve otitis media hastalarında etken mikroorganizmaların ve antibiyotik duyarlılıklarının belirlenmesi”, *Ankem Dergisi*, 30, 2, 48-52, 2016, doi:10.5222/ankem.2016.048.

37. Ada M., “Dış kulak yolu ve orta kulak iltihapları”, *Solunum Yolu Enfeksiyonları Sempozyumu*, İstanbul, 19-35 (2000).

38. Mammadov, A., “Malign eksternal otit hastalarda prognozu olumsuz etkileyen faktörlerin ve tedavi etkinliğinin araştırılması”, Tıpta Uzmanlık Tezi, *Çukurova Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Anabilim Dalı*, Adana, 4-14 (2011).

39. Madan, G., “Orta kulak patolojisi sonrası cerrahi uygulanan hastalarda preoperatif temporal kemik bt bulguları ile perioperatif bulgularının karşılaştırılması”, Yüksek Lisans Tezi, *Afyon Kocatepe Üniversitesi Sağlık Bilimleri Enstitüsü Anatomi Anabilim Dalı*, Afyon, 10-18, (2015).

40. Vollandri, G., Di Puccio, F., Forte, P., and Carmignani, C., "Biomechanics of the tympanic membrane", *Journal of biomechanics*, 44(7), 1219-1236., (2011), doi: 10.1016/j.jbiomech.2010.12.023.

41. Sanna, M., Russo, A., Caruso, A., Tabibah, A., and Piras, G., "Color atlas of endo-otoscopy examination, diagnosis, treatment", Editör: Mairo Sanna, *Theime*, Stuttgart, 65-69, 117-120, (2017).

42. Tieso, S., Fantini, L.V., Messina, F., Cacavelos, N., Farelli, G., Zavala, L.G., Tieso, M., Iezzi, S., and Bosio, F.D., " Tympanic membrane physiology", *22nd International Congress on Acoustics, ICA 2016*, Buenos Aires, 1-8, (2016).

43. Lundberg, T., “Assessment of tympanic membrane a study of children with otitis media in general practice”, Ph D. Thesis, *Umeå University, Faculty of Medicine, Department of Public Health and Clinical Medicine, Family Medicine*, 1-16, (2014).

44. Özbay, E., “Laringofaringeal Reflüsü Olan Hastalarda Tuba Esutachi, Orta Kulak İşitme Fonksiyonlarının Değerlendirilmesi”, Yüksek Lisans Tezi, *Başkent Üniversitesi Sağlık Bilimleri Enstitüsü Odyoloji Anabilim Dalı*, Ankara, 2-13, (2018).

45. Alberti, P. W., "The anatomy and physiology of the ear and hearing", *Occupational exposure to noise: Evaluation, prevention, and control*, 53-62, (2001).
46. Yıldırım, M., "Ratlardaki travmatik timpanik membrane perforasyonlarında lokal ve sistemik ozon tedavisinde histopatolojik olarak değerlendirilmesi", Tıpta Uzmanlık Tezi, *Sağlık Bilimleri Üniversitesi Bağıcılar Eğitim ve Araştırma Hastanesi Kulak Burun Boğaz ve Baş Boyun Cerrahisi Kliniği*, İstanbul, 2-3, (2017).
47. Keseroglu, K., ve Bayir, O., "Orta kulağın endoskopik anatomisi", *Türkiye Klinikleri*, 9,1, 5-10, (2016).
48. Kurnaz, S., Bora, F., Yücel, Z., Ceylan, S., Akagün, F., ve Erdoğan, A.F., "Kronik otitis media orta kulak kemik zincir patolojilerinin değerlendirilmesi", *KBB ve BBC Dergisi*, 19(2), 71-72, 2009.
49. Serttaş, M., "Mikro elektromekanik sistem ile orta kulak kemikciklerinin hareketinin algılanması", Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Elektronik Haberleşme Mühendisliği Anabilim Dalı*, İstanbul, 5-10, 2018.
50. Seibert, J. W., and Danner, C. J., "Eustachian tube function and the middle ear", *Otolaryngologic Clinics of North America*, 39(6), 1221-1235, (2006), doi.org/10.1016/j.otc.2006.08.011.
51. Poe, D. S., Pyykkö, I., Valtonen, H., and Silvola, J., "Analysis of eustachian tube function by video endoscopy", *Otology & Neurotology*, 21(5), 602-607, (2000).
52. Bashiruddin, J., Martiastini A, R., Alviandi, W., & Prihartono, J., "Conformity between sonotubometry and tympanometry in examining eustachian tube ventilatory function in adults with normal hearing", *JPhCS*, 1073(2), 022023., (2018), doi: 10.1088/1742-6596/1073/2/022023.
53. Tysome, J. R., & Sudhoff, H., "The role of the eustachian tube in middle ear disease", *In Advances in Hearing Rehabilitation*, 81, 146-152, (2018)
54. Murphy, K. M., "A review of techniques for the investigation of otitis externa and otitis media", *Clinical techniques in small animal practice*, 16(4), 236-241, (2001). doi: https://doi.org/10.1053/svms.2001.27601.
55. Longo, K., Peterson, D., and Valdez, T. A., "Bi modal approach using spectroscopy and digital imaging to assist otitis media diagnosis", *In 2014 40th Annual Northeast Bioengineering Conference (NEBEC)*, Boston, 1-2, (2014). doi: 10.1109/NEBEC.2014.6972859.
56. Rovers, M. M., Schilder, A. G. M., Zielhuis, G. A., and Rosenfeld, R. M., "Otitis media," *Lancet*, 363, 9407, 465-473, (2004), doi: 10.1016/S0140-6736(04)15495-0.
57. Coleman, A., Cervin, A., "Probiotics in the treatment of otitis media, the past, the present and the future", *International Journal Pediatr Otorhinolaryngol*, 116:135-140, (2019). doi:10.1016/j.ijporl.2018.10.023

58. Öz, F., Kaytaz, A., Aksoy, E., "Otitis media", *Toplumdan Edinilmiş Enfeksiyonlara Pratik Yaklaşımlar*, 61, 71–84, (2008).
59. Libwea, J. N., Kobela, M., Ndombo, P. K., Syrjänen, R. K., Huhtala, H., Fointama, N., and Palmu, A. A., "The prevalence of otitis media in 2–3 year old Cameroonian children estimated by tympanometry", *International journal of pediatric otorhinolaryngology*, 115, 181-187, (2018), doi: 10.1016/j.ijporl.2018.10.007.
60. Lundberg, T., De Jager, L. B., Swanepoel, D. W., and Laurent, C. "Diagnostic accuracy of a general practitioner with video-otoscopy collected by a health care facilitator compared to traditional otoscopy". *International journal of pediatric otorhinolaryngology*, 99, 49-53, (2017), doi: <http://dx.doi.org/10.1016/j.ijporl.2017.04.045>.
61. Nwokoye, N. N., Egwari, L. O., and Olubi, O. O., "Occurrence of otitis media in children and assessment of treatment options", *The Journal of laryngology and otology*, 129(8), 779–783, (2015). <https://doi.org/10.1017/S0022215115001127>
62. Fang, T. Y., Rafai, E., Wang, P. C., Bai, C. H., Jiang, P. L., Huang, S. N., ... and Chang, C. H., "Pediatric otitis media in Fiji: survey findings 2015", *International journal of pediatric otorhinolaryngology*, 85, 50-55, doi: 10.1016/j.biopsycho.2011.03.008.
63. Kørvel-Hanquist, A., Koch, A., Lous, J., Olsen, S. F., and Homøe, P., "Risk of childhood otitis media with focus on potentially modifiable factors: A Danish follow-up cohort study", *International journal of pediatric otorhinolaryngology*, 106, 1-9, (2018). doi: 10.1016/j.ijporl.2017.12.027.
64. Shah, M. U., Sohal, M., Valdez, T. A., and Grindle, C. R. "iPhone otoscopes: Currently available, but reliable for tele-otoscopy in the hands of parents?", *International journal of pediatric otorhinolaryngology*, 106, 59-63, (2018), doi: 10.1016/J.IJPORL.2018.01.003.
65. Lin, J., Hafrén, H., Kerschner, J., Li, J. D., Brown, S., Zheng, Q. Y., and Zhang, Y., "Panel 3: Genetics and Precision Medicine of Otitis Media", *Otolaryngology–Head and Neck Surgery*, 156, 41-50, (2017). doi: 10.1177/0194599816685559.
66. Kumari, M. S., Madhavi, J., Krishna, N. B., Meghanadh, K. R., and Jyothy, A. "Prevalence and associated risk factors of otitis media and its subtypes in South Indian population", *Egyptian Journal of Ear, Nose, Throat and Allied Sciences*, 17(2), 57-62, (2016).
67. Lundberg, T., Biagio, L., Laurent, C., Sandström, H., and Swanepoel, D. W., "Remote evaluation of video-otoscopy recordings in an unselected pediatric population with an otitis media scale", *International journal of pediatric otorhinolaryngology*, 78(9), 1489-1495., (2014). doi: <http://dx.doi.org/10.1016/j.ijporl.2014.06.018>.

68. Saini, A., Saroch, M., and Gargi, G., "Endoscopic transcanal myringoplasty: Is learning curve a myth?", *Journal of otology*, 13(3), 101-104, (2018). doi: 10.1016/J.JOTO.2018.05.002.
69. Rimon, O., Avraham, Y., Sharabi-Nov, A., Luder, A., Krupik, D., and Gilbey, P., "Video-otoscopy in children and patient-centered care: A randomized, controlled study", *International journal of pediatric otorhinolaryngology*, 79(12), 2286-2289. (2015). doi: 10.1016/J.IJPORL.2015.10.026.
70. Damery, L., Lescanne, E., Reffet, K., Aussedat, C., and Bakhos, D., "Interest of video-otoscopy for the general practitioner", *European annals of otorhinolaryngology, head and neck diseases*, 136(1), 13-17., (2019).doi: 10.1016/J.ANORL.2018.10.016.
71. Ji, Y. B., Moon, I. S., Bark, H. S., Kim, S. H., Park, D. W., Noh, S. K., and Jeon, T. I. "Terahertz otoscope and potential for diagnosing otitis media", *Biomedical optics express*, 7(4), 1201-1209, (2016). doi: 10.1109/IRMMW-THz.2016.7758453.
72. Monroy, G. L., Won, J., Dsouza, R., Pande, P., Hill, M. C., Porter, R. G., and Boppart, S. A., "Automated classification platform for the identification of otitis media using optical coherence tomography", *NPJ digital medicine*, 2(1), 1-11, (2019). doi: 10.1038/s41746-019-0094-0.
73. Koçyiğit, M., Giran Öртеkin, S., ve Çakabay, T. "Otitis media, sınıflandırma ve tedaviye yaklaşım prensipleri", *İstanbul Kanuni Sultan Süleyman Tıp Dergisi (IKSST)*, 8(2), 65-70., (2016), doi: 10.5222/iksst.2016.065.
74. Roy, E., Hasan, K. Z., Haque, F., Siddique, A. K. M., and Sack, R. B., "Acute otitis media during the first two years of life in a rural community in Bangladesh: a prospective cohort study", *Journal of health, population, and nutrition*, 25(4), 414. (2007).
75. McCormick, D. P., Jennings, K., Ede, L. C., Alvarez-Fernandez, P., Patel, J., and Chonmaitree, T., "Use of symptoms and risk factors to predict acute otitis media in infants", *International journal of pediatric otorhinolaryngology*, 81, 55-59., (2016), doi: <http://dx.doi.org/10.1016/j.ijporl.2015.12.002>.
76. Soysal, A., "Akut orta kulak iltihabi tani ve tedavisi", *Ankem Dergisi*, 26,2, 104–106, 2012.
77. Pitaro, J., Waissbluth, S., Quintal, M. C., Abela, A., and Lapointe, A., "Characteristics of children with refractory acute otitis media treated at the pediatric emergency department", *International journal of pediatric otorhinolaryngology*, 116, 173–176. (2019). <https://doi.org/10.1016/j.ijporl.2018.10.045>
78. Foglé-Hansson, M., "Acute otitis media. aspects of diagnosis and prophylaxis", Ph D. Thesis, *Department of Otorhinolaryngology Clinical Sciences*, Lund University, Lund, 3-5, (2006).

79. Kontiokari, T., Koivunen, P., Niemelä, M., Pokka, T., and Uhari, M., "Symptoms of acute otitis media", *The Pediatric infectious disease journal*, 17(8), 676-679, (1998).
80. Çiftçi, E., Doğru, Ü., "Viruslar ve akut otitis media", *Ankara Üniversitesi Tıp Fakültesi Mecmuası*, 56,1, 31–38, (2003).
81. Daşar, T.N., "Akut Otitis Media Tanılı Çocuklarda Nazofarengeal Pnömonok Taşıyıcılığı", Tıpta Uzmanlık Tezi, *Marmara Üniversitesi Tıp Fakültesi Çocuk Sağlığı ve Hastalıkları Anabilim Dalı*, İstanbul, 6-8, (2018).
82. Núñez-Batalla, F., Jáudenes-Casabón, C., Sequí-Canet, J. M., Vivanco-Allende, A., and Zubicaray-Ugarteche, J. "Diagnosis and treatment of otitis media with effusion: CODEPEH recommendations", *Acta Otorrinolaringologica (English Edition)*, 70(1), 36-46, (2019).
83. Edetanlen, E. B., and Saheeb, B. D., "Otitis media with effusion in Nigerian children with cleft palate: incidence and risk factors", *British Journal of Oral and Maxillofacial Surgery*, 57(1), 36-40, (2019). doi: 10.1016/j.bjoms.2018.11.015.
84. Els, T., and Olwoch, I. P., "The prevalence and impact of otitis media with effusion in children admitted for adeno-tonsillectomy at Dr George Mukhari Academic Hospital, Pretoria, South Africa", *International journal of pediatric otorhinolaryngology*, 110, 76-80, (2018).
85. Yildiz, S., ve Canbulat, N., "Çocuklarda akut otitis media oluflumunda bir risk faktörü: beslenme", *Hemşirelikte Eğitim ve Araştırma Dergisi*, 5, 2, 22–28, 2008.
86. Sürmelioglu, Ö., Dağkiran, M. O., Tarkan, Ö., ve Özdemir, S., "Efüzyonlu Otitis Media: Tanı ve Tedavi", *Arşiv Kaynak Tarama Dergisi*, 22(2), 194-208, (2013).
87. Özkarakaş, H., "Kocaeli ilkokullarında bölgelere göre EOM prevalansı (+) (Ön Çalışma Raporu)", *K.B.B. ve Baş Boyun Cerrahisi Dergisi*, 3, 99–101, (1995).
88. Tan, K. K., Liang, W., Lim, H. Y., and Gan, C. W., "Mechatronic design of an office-based ventilation tube applicator for patients with otitis media with effusion", *In 2013 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, Wollongong, 1448-1453, (2013).
89. S. Bakır, "KBB notları", *Salih Bakır*, Ankara, Derman Tıbbi Yayıncılık, 51,(2015).
90. Sezgin, Z., ve Külekçi, M., "Kronik otitis media da kulak zarı perforasyonları ve kemik zincir patolojilerinin işitme kayıpları ile ilişkisi", *Journal of Contemporary Medicine*, 6, 4, 266–276, (2016), doi: 10.16899/ctd.71218.
91. Gün, R., "Kronik süpuratif otitis mediyada yas, hastalık süresi ve kolesteatom varlığının sensorinöral işitme kaybı ile ilişkisi", *Dicle Tıp Dergisi*, 2,36,117–122, (2009).

92. Arbağ,H., Keleş, B., Uyar,Y., ve Öztürk,K., “Kronik otitis media komplikasyonlarının tanı ve tedavi özellikleri”, *Elektronik Kulak Burun Boğaz ve Baş Boyun Cerrahisi Dergisi*,1,3–7, (2002).
93. Pakır, O., “Kronik süperatif otitis mediada medikal Tedavinin cerrahi tedavinin zamanlamasındaki rolü”, Tıpta Uzmanlık Tezi, *Zonguldak Bülent Ecevit Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Hastalıkları ve Baş Boyun Cerrahisi Anabilim Dalı*, Zonguldak,13-27, (2015).
94. Yaşar, N. G., “Kronik otit hastalarında koklear implant performansının ve cerrahi sonuçların değerlendirilmesi”, Tıpta Uzmanlık Tezi, *Gazi Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Anabilim Dalı*, Ankara, 22-34, (2018).
95. Aksoy, S., “Kolesteatomlu ve kolesteatomsuz kronik Otitis media’lı hastaların preoperatif Bilgisayarlı tomografisinde görülen yumuşak doku dansitelerinin hounsfield unit değerleri ayırıcı tanı ve takipte kullanılabilir mi?”, *Tıpta Uzmanlık Tezi, Sağlık Bilimleri Üniversitesi Ankara Dışkapı Yıldırım Beyazıt Sağlık Uygulama Ve Araştırma Merkezi Kulak Burun Boğaz Kliniği*, Ankara, 21-39, (2018).
96. Teleke, Y. C., “Kronik otitis media tanılı hastalarda vestibuler Fonksiyonların vıdeo head impulse test ile değerlendirilmesi”, Tıpta Uzmanlık Tezi, *Yıldırım Beyazıt Üniversitesi Kulak Burun Boğaz ve Baş Boyun Cerrahisi Anabilim Dalı*, Ankara, 23-27, (2018).
97. Öktemer, T., Kemaloğlu, Y., Özbilen, S., ve Tutar, H., "Kronik otitis media cerrahisinde greft başarısını etkileyen faktörler", *Osmangazi Tıp Dergisi*, 38(3), 46-54., doi: 10.20515/otd.42547.
98. Şen, A., “Kronik otitis media tanısı ile opere Edilen olgularda preoperatif Bilgisayarlı tomografi bulguları ile operasyon bulgularının karşılaştırılması”, Tıpta Uzmanlık Tezi, *Harran Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Hastalıkları Anabilim Dalı*, Şanlıurfa, 9-19, (2010).
99. Atilla, N. E., “Kronik otitis medialı olguların işitme restorasyonlarında; perikondrium-kartilaj greftli torp şaft ucuna, perikondrium kartilaj greft ilavesinin işitme sonuçları üzerine etkisi”, Tıpta Uzmanlık Tezi, *Atatürk Üniversitesi Tıp Fakültesi Kulak Burun Boğaz Anabilim Dalı*, Erzurum, 29-31, (2015).
100. İ. T. Ediz Yorgancılar, Salih Bakır, Vefa Kınış, Ramazan Gün, Musa Özbay, “Konjenital kolesteatomlu kronik otitis mediaya bağlı gelişen bilateral mastoidit”, *Dicle Tıp Dergisi*, 39 (3): 434–436, (2012), doi: 10.5798/diclemedj.0921.2012.03.0175.
101. Derundere, Ü., “Kolesteatomlu kronik otitis medialı olgularda YRBT’nin tanı değeri”,Tıpta Uzmanlık Tezi, *İstanbul Eğitim ve Araştırma Hastanesi Rayoloji Kliniği*, İstanbul, 7-24, (2005).

102. Cesur,S., Yılmaz, M.S., Güven, M., ve Yeniay,M., "*Cholesteatoma: A Case Report*", *Sakarya Üniversitesi Eğitim ve Araştırma Hastanesi Kulak Burun Boğaz Kliniği Olgu Sunumu*, 4(2), 96–99, (2014).
103. Gürsel, B., Ayhan, K., “Timpanoskleroz,” *Türkiye Klinikleri.*, 2, 99–101, (2001).
104. Asm, S., Tabik, S., Herrera, F., Gómez-Ríos A., Luengo, J., and Krawczyk, B., “Towards highly accurate coral texture images classification using deep convolutional neural networks and data augmentation”, *Expert Systems with Applications*, 118: 315–328, (2018), doi: 10.1016/j.eswa.2018.10.010.
105. Shi, Z., Liu, M., Cao, Q., Ren, H., & Luo, T., "A data augmentation method based on cycle-consistent adversarial networks for fluorescence encoded microsphere image analysis", *Signal Processing*, 161, 195-202, (2019). doi:<https://doi.org/10.1016/j.sigpro.2019.02.028>.
106. Abad, M., Hashimoto, H., Zhou, H., Morales, M. G., Chen, B., Bassel-Duby, R., and Olson, E. N., "Notch inhibition enhances cardiac reprogramming by increasing MEF2C transcriptional activity", *Stem cell reports*, 8(3), 548-560, (2017). doi: 10.1016/j.stemcr.2017.01.025.
107. Greenspan, H., Frid-Adar, M., Klang, E., Diamant, I., Amitai, M., and Goldberger, J., “GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification”, *Neurocomputing*, 321: 321–331, (2018), doi: 10.1016/j.neucom.2018.09.013.
108. Tustison, N. J., Avants, B. B., Lin, Z., Feng, X., Cullen, N., Mata, J. F., Flors, L., Gee, J. C., Altes, T. A., Mugler Iii, J. P., and Qing, K. "Convolutional Neural Networks with Template-Based Data Augmentation for Functional Lung Image Quantification", *Academic radiology*, 26(3), 412–423, (2019). <https://doi.org/10.1016/j.acra.2018.08.003>
109. Pardo, J. M., Moya-Albor, E., Ortega-Ibarra, G., and Brieva, J. "Freezing front velocity estimation using image processing techniques", *Measurement*, 151, (2020). 107085.doi: 10.1016/J.MEASUREMENT.2019.107085.
110. Kang, M., Zhang L., and Tang, W., “Study on three-dimensional topography modeling of the grinding wheel with image processing techniques”, *International Journal Mechanical Science*,167:105-241, (2020), doi: 10.1016/J.IJMECSCI.2019.105241.
111. Zhang, X., and Dahu, W., "Application of artificial intelligence algorithms in image processing", *Journal of Visual Communication and Image Representation*, 61: 42-49, (2019).doi: 10.1016/J.JVCIR.2019.03.004.
112. Abdolmaleky, M., Naseri, M., Batle, J., Farouk, A., and Gong, L. H. "Red-Green-Blue multi-channel quantum representation of digital images", *Optik*, 128: 121-132, (2017). doi: 10.1016/J.IJLEO.2016.09.123.

113. Herrero-Latorre, C., Barciela-García, J., García-Martín, S., and Peña-Crecente, R. M. Detection and quantification of adulterations in aged wine using RGB digital images combined with multivariate chemometric techniques", *Food chemistry*: X, 3, 100046., (2019). doi: 10.1016/J.FOCHX.2019.100046.
114. Ni, T., Zhou, R., Gu, C., and Yang, Y., "Measurement of concrete crack feature with android smartphone APP based on digital image processing techniques", *Measurement*, 150, 107093, (2020). doi: 10.1016/J.MEASUREMENT.2019.107093.
115. Megha, P., Swarna, M., Sowmya, V., and Soman, K. P., "Low contrast satellite image restoration based on adaptive histogram equalization and discrete wavelet transform", *International Conference on Communication and Signal Processing (ICCSP)*, Melmaruvathur, 402-406, (2016). doi: 10.1109/ICCSP.2016.7754166.
116. Görkem, L., Erkan, U., "Tuz-biber gürültüsünde tekrarsız medyan filtre," *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6,2: 11–19, 2017.
117. Çivicioğlu, P., Alçı, M., "Görüntülerdeki Gauss Gürültüsünü Gidermek İçin Akım Taşıyıcılı Ortalama Alıcı Süzgeç Devresinin Tasarımı", *Elektrik-Elektronik Bilgisayar Mühendisliği Sempozyumu*, Bursa,1-4, 2002.
118. Choras, R. S., "Image feature extraction techniques and their applications for CBIR and biometrics systems", *International journal of biology and biomedical engineering*, 1(1), 6-16, (2007).
119. Yuan, H., Li, J., Lai, L. L., and Tang, Y. Y., "Low-rank Matrix Regression for Image Feature Extraction and Feature Selection". *Information Sciences*, 522:214-226 doi: 10.1016/J.INS.2020.02.070.
120. Sthevanie, F., and Ramadhani, K. N., "Spoofing detection on facial images recognition using LBP and GLCM combination", *Journal of Physics: Conference Series*, 971,1, 12014, (2018)
121. Siqueira, F. R., Schwartz, W. R., and Pedrini, H., "Multi-scale gray level co-occurrence matrices for texture description", *Neurocomputing*, 120, 336-345. (2013), doi: 10.1016/J.NEUCOM.2012.09.042.
122. Haralick, R. M., Shanmugam, K., and Dinstein, I. H., "Textural features for image classification", *Transactions on systems, man, and cybernetics*, (6): 610-621, (1973).
123. Park, Y., and Guldmann, J. M., "Measuring continuous landscape patterns with Gray-Level Co-Occurrence Matrix (GLCM) indices: An alternative to patch metrics?", *Ecological Indicators*, 109, 105802, (2020). doi: 10.1016/J.ECOLIND.2019.105802.
124. Ojala, T., Pietikainen, M., and Maenpaa, T., "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns", *Transactions on pattern analysis and machine intelligence*, 24(7): 971-987, (2002). doi: 10.1109/TPAMI.2002.1017623.

125. Güner, A., Alçin, Ö. F., and Şengür, A., "Automatic digital modulation classification using extreme learning machine with local binary pattern histogram features", *Measurement*, 145: 214-225. doi: 10.1016/J.MEASUREMENT.2019.05.061.
126. Hu, N., Ma, H., and Zhan, T., "Finger vein biometric verification using block multi-scale uniform local binary pattern features and block two-directional two-dimension principal component analysis", *Optik*, 208, 1-7, 163664. doi: 10.1016/J.IJLEO.2019.163664.
127. Al-Nima, R. R. O., Abdullah, M. A., Al-Kaltakchi, M. T., Dlay, S. S., Woo, W. L., and Chambers, J. A., "Finger texture biometric verification exploiting multi-scale sobel angles local binary pattern features and score-based fusion", *Digital Signal Processing*, 70, 178-189, (2017).
128. Dalal, N., and Triggs, B., "Histograms of oriented gradients for human detection", *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, 1, 886-893, 1, (2005). doi: 10.1109/CVPR.2005.177.
129. Yan, X., Zhang, Y., Zhang, D., and Hou, N., "Multimodal image registration using histogram of oriented gradient distance and data-driven grey wolf optimizer," *Neurocomputing*, 392: 108-120, (2020), doi: 10.1016/J.NEUCOM.2020.01.107.
130. Abbasi, S., and Tajeripour, F., "Detection of brain tumor in 3D MRI images using local binary patterns and histogram orientation gradient", *Neurocomputing*, 219, 526-535, Jan. 2017, doi: 10.1016/J.NEUCOM.2016.09.051.
131. Hemmatian, B., Casal, J., Planas, E., Hemmatian, B., and Rashtchian, D., "Prediction of BLEVE mechanical energy by implementation of artificial neural network", *Journal of Loss Prevention in the Process Industries*, 63, 104021, (2020), doi: 10.1016/J.JLP.2019.104021.
132. Albarqi, M., Alsulami, R., and Graham, J., "Automated data processing of neutron depth profiling spectra using an Artificial Neural Network", *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 953, 163217. doi: 10.1016/J.NIMA.2019.163217.
133. Pan, Y., Pan, Z., Wang, Y., and Wang, W., "A new fast search algorithm for exact k-nearest neighbors based on optimal triangle-inequality-based check strategy", *Knowledge-Based Systems*, 189, 105088. (2020), doi: 10.1016/J.KNOSYS.2019.105088.
134. Rico-Juan, J. R., Valero-Mas, J. J., and Calvo-Zaragoza, J., "Extensions to rank-based prototype selection in k-Nearest Neighbour classification", *Applied Soft Computing*, 85, 105803., (2019). doi: 10.1016/J.ASOC.2019.105803.
135. Mueller, P., Salminen, K., Nieminen, V., Kontunen, A., Karjalainen, M.,

- Isokoski, P., ... and Leikkala, J., "Scent classification by K nearest neighbors using ion-mobility spectrometry measurements", *Expert Systems with Applications*, 115, 593-606., (2019). doi: 10.1016/J.ESWA.2018.08.042.
136. Shao, M., Wang, X., Bu, Z., Chen, X., and Wang, Y., "Prediction of energy consumption in hotel buildings via support vector machines", *Sustainable Cities and Society*, 102128. (2020). doi: 10.1016/J.SCS.2020.102128.
137. Chen, Y., "Mining of instant messaging data in the Internet of Things based on support vector machine", *Computer Communication*, 154: 278–287, (2020), doi: 10.1016/J.COMCOM.2020.02.080.
138. Wen, L., and Cao, Y., "Influencing factors analysis and forecasting of residential energy-related CO2 emissions utilizing optimized support vector machine", *Journal of Cleaner Production*, 250, 119492, (2020), doi: 10.1016/J.JCLEPRO.2019.119492.
139. Kim, D., Kang, S., and Cho, S., "Expected margin-based pattern selection for support vector machines", *Expert Systems with Applications*, 139, 112865., (2020). doi: 10.1016/J.ESWA.2019.112865.
140. Kuang, H., Liu, C., Chan, L. L. H., and Yan, H., "Multi-class fruit detection based on image region selection and improved object proposals", *Neurocomputing*, 283: 241-255. doi: <https://doi.org/10.1016/j.neucom.2017.12.057>.
141. Kawazoe, Y., Shimamoto, K., Yamaguchi, R., Shintani-Domoto, Y., Uozaki, H., Fukayama, M., and Ohe, K., "Faster r-cnn-based glomerular detection in multistained human whole slide images", *Journal of Imaging*, 4(7), 91. doi: 10.3390/jimaging4070091.
142. Nida, N., Irtaza, A., Javed, A., Yousaf, M. H., and Mahmood, M. T., "Melanoma lesion detection and segmentation using deep region based convolutional neural network and fuzzy C-means clustering", *International journal of medical informatics*, 124, 37-48. (2019). doi: <https://doi.org/10.1016/j.ijmedinf.2019.01.005>.
143. Yang, S., Fang, B., Tang, W., Wu, X., Qian, J., and Yang, W., "Faster R-CNN based microscopic cell detection", *In 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC)*, Shenzhen, 345-350, doi: 10.1109/SPAC.2017.8304302.
144. Körez, A., ve Barış, N., "İnsansız hava aracı (İHA) görüntülerindeki yayaların faster R-CNN algoritması ile otomatik tespiti", *2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, 1-4., doi: 10.1109/ISMSIT.2018.8567273.
145. Huang, H., Wang, C., Liu, S., Sun, Z., Zhang, D., Liu, C., and Xu, R., "Single spectral imagery and faster R-CNN to identify hazardous and noxious substances spills", *Environmental Pollution*, 258, 113688-113688., doi: 10.1016/J.ENVPOL.2019.113688.

146. Wu, X., Sahoo, D., and Hoi, S. C. H., "Recent advances in deep learning for object detection", *Neurocomputing*, Jan. 2020, doi: 10.1016/J.NEUCOM.2020.01.085.
147. Girshick, R., Donahue, J., Darrell, T., and Malik, J., "Rich feature hierarchies for accurate object detection and semantic segmentation", <https://arxiv.org/abs/1311.2524> (2020)
148. Girshick, R., "Fast R-CNN", *International Conference on Computer Vision (ICCV)*, Las Condes, 1440–1448, (2015), doi: 10.1109/ICCV.2015.169.
149. Li, J., Zhang, D., Zhang, J., Zhang, J., Li, T., Xia, Y., Yan, Q., Xun, L., "Facial Expression Recognition with Faster R-CNN", *Procedia Computer. Science*, 107, 135–140, (2017), doi: 10.1016/J.PROCS.2017.03.069.
150. Ren, S., He, K., Girshick, R., and Sun, J., "Faster r-cnn: Towards real-time object detection with region proposal networks", *Advances in neural information processing systems*, Montreal, 91-99, (2015). doi: 10.1109/TPAMI.2016.2577031.
151. Quan, L., Feng, H., Lv, Y., Wang, Q., Zhang, C., Liu, J., and Yuan, Z., "Maize seedling detection under different growth stages and complex field environments based on an improved Faster R–CNN", *Biosystems Engineering*, 184, 1-23, (2019). doi: 10.1016/J.BIOSYSTEMSENG.2019.05.002.
152. Huang, H., Zhou, H., Yang, X., Zhang, L., Qi, L., and Zang, A. Y., "Faster R-CNN for marine organisms detection and recognition using data augmentation", *Neurocomputing*, 337, 372-384., doi: 10.1016/J.NEUCOM.2019.01.084.
153. Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. "You only look once: Unified, real-time object detection", *In Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, 779-788, (2016).
154. Chen, R. C., "Automatic License Plate Recognition via sliding-window darknet-YOLO deep learning", *Image and Vision Computing*, 87, 47-56., doi: 10.1016/J.IMAVIS.2019.04.007.
155. Li, J., Su, Z., Geng, J., and Yin, Y. "Real-time detection of steel strip surface defects based on improved yolo detection network", *IFAC-PapersOnLine*, 51(21), 76-81. doi: 10.1016/J.IFACOL.2018.09.412.
156. Huang, Z., Wang, J., Fu, X., Yu, T., Guo, Y., and Wang, R., "DC-SPP-YOLO: Dense connection and spatial pyramid pooling based YOLO for object detection", *Information Sciences*, 522:241-258, (2020). doi: 10.1016/J.INS.2020.02.067.
157. Liu, C., Tao, Y., Liang, J., Li, K., and Chen, Y., "Object detection based on YOLO network", *In 2018 IEEE 4th Information Technology and Mechatronics Engineering Conference (ITOEC)* (pp. 799-803) IEEE (2018, December). Doi:

10.1109/ITOE.2018.8740604.

158. Fitch, F. B., "Warren S. McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity", *Bulletin of Mathematical Biophysics*, 5 (1943): 115-133. *The Journal of Symbolic Logic*, 9(2), 49-50. (1944).

159. Hubel, D. H., and Wiesel, T. N., "Receptive fields of single neurones in the cat's striate cortex", *The Journal of Physiology*, 148(3): 574-591 (1959). Doi: 10.1113/jphysiol.1959.sp006308.

160. Fukushima, K., "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, 36(4): 193-202 (1980). Doi: 10.1007/bf00344251.

161. LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P., "Gradient-based learning applied to document recognition", *Proceedings of the IEEE*, 86(11): 2278-2324 (1998). Doi: 10.1109/5.726791.

162. Krizhevsky, A., Sutskever, I., and Hinton, G. E., "Imagenet classification with deep convolutional neural networks", *In Advances in Neural Information Processing Systems*, 1: 1097-1105 (2012).

163. Liu, Y. H., "Feature extraction and image recognition with convolutional neural networks", *In Journal of Physics: Conference Series*, 1087: 6, 062032 (2018, September). Doi: 10.1088/1742-6596/1087/6/062032.

164. Kim, P., "Matlab deep learning", *With Machine Learning, Neural Networks and Artificial Intelligence*, 130 (2017).

165. Wang, F., Zhang, Z., Liu, C., Yu, Y., Pang, S., Duić, N., ... and Catalão, J. P., "Generative adversarial networks and convolutional neural networks based weather classification model for day ahead short-term photovoltaic power forecasting", *Energy Conversion And Management*, 181: 443-462 (2019).

166. Lumini, A., and Nanni, L., "Deep learning and transfer learning features for plankton classification", *Ecological Informatics*, 51: 33-43 (2019). Doi: 10.1016/J.ECOINF.2019.02.007.

167. Gülcü, A., and Kuş, Z., "Konvolüsyonel sinir ağlarında hiper-parametre optimizasyonu yöntemlerinin incelenmesi", *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(2): 503-522 (2019). Doi: 10.29109/gujsc.514483.

168. Smithson, S. C., Yang, G., Gross, W. J., and Meyer, B. H., "Neural networks designing neural networks: multi-objective hyper-parameter optimization", *In Proceedings of the 35th International Conference on Computer-Aided Design*, (pp. 1-8) (2016, November). Doi: 10.1145/2966986.2967058.

169. ZahediNasab, R., & Mohseni, H., "Neuroevolutionary based convolutional neural network with adaptive activation functions", *Neurocomputing*, 381: 306-313 (2020).

Doi: 10.1016/J.NEUCOM.2019.11.090.

170. Özcan, T., and Baştürk, A., "Static image-based emotion recognition using convolutional neural network", *In 2019 27th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4) IEEE (2019, April). Doi: 10.1109/SIU.2019.8806408.

171. Isa, I. S., Saad, Z., Omar, S., Osman, M. K., Ahmad, K. A., and Sakim, H. M., ""Suitable MLP network activation functions for breast cancer and thyroid disease detection", *In 2010 Second International Conference on Computational Intelligence, Modelling and Simulation* (pp. 39-44) IEEE (2010, September). Doi: 10.1109/CIMSiM.2010.93.

172. Roy, S. K., Manna, S., Dubey, S. R., and Chaudhuri, B. B., "LiSHT: Non-parametric linearly scaled hyperbolic tangent activation function for neural networks", *arXiv preprint arXiv:1901.05894* (2019).

173. Anastassiou, G. A., "Multivariate hyperbolic tangent neural network approximation", *Computers & Mathematics with Applications*, 61(4): 809-821 (2011). Doi: <https://doi.org/10.1016/j.camwa.2010.12.029>.

174. Xu, B., Wang, N., Chen, T., and Li, M., "Empirical evaluation of rectified activations in convolutional network", *arXiv preprint arXiv:1505.00853* (2015).

175. Chu, M. G., Min, B., Kwon, S., Park, G., Kim, S., and Huy, N. X., "Determination of an infill well placement using a data-driven multi-modal convolutional neural network", *Journal of Petroleum Science and Engineering*, 106805, (2019). Doi: 10.1016/J.PETROL.2019.106805.

176. Li, T., Zhang, Z., and Chen, H., "Predicting the combustion state of rotary kilns using a convolutional recurrent neural network", *Journal of Process Control*, 84, 207-214. (2019), Doi: 10.1016/J.JPROCONT.2019.10.009.

177. Baştürk, A., Yükeşi, M. E., Badem, H., and Çalışkan, A., "Deep neural network based diagnosis system for melanoma skin cancer", *In 2017 25th Signal Processing and Communications Applications Conference (SIU)*, (pp. 1-4) IEEE (2017, May). Doi: 10.1109/SIU.2017.7960563.

178. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R., "Dropout: a simple way to prevent neural networks from overfitting", *The Journal of Machine Learning Research*, 15(1): 1929-1958 (2014).

179. Talo, M., "Pneumonia detection from radiography images using convolutional neural networks", *In 2019 27th Signal Processing and Communications Applications Conference (SIU)*, (pp. 1-4) IEEE, (2019, April).

180. Gürkaynak, C. D., and Arica, N., "A case study on transfer learning in convolutional neural networks", *In 2018 26th Signal Processing and Communications Applications Conference (SIU)*, (pp. 1-4) IEEE, (2018, May). Doi:

10.1109/SIU.2018.8404642.

181. Poernomo, A., & Kang, D. K., "Biased dropout and crossmap dropout: learning towards effective dropout regularization in convolutional neural network", *Neural Networks*, 104: 60-67 (2018). Doi: <https://doi.org/10.1016/j.neunet.2018.03.016>.

182. Kim, Y. C., Kim, K. R., and Choe, Y. H., "Automatic myocardial segmentation in dynamic contrast enhanced perfusion MRI using Monte Carlo dropout in an encoder-decoder convolutional neural network", *Computer Methods and Programs in Biomedicine*, 185: 105150 (2020). Doi: <https://doi.org/10.1016/j.cmpb.2019.105150>.

183. Kızrak, M. A., and Bolat, B., "Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım", *International Journal of InformaticsTechnologies*, 12(2): 103-109 (2019). Doi: 10.17671/gazibtd.495730.

184. Yi, D., Lei, Z., Liao, S., and Li, S. Z., "Deep metric learning for person re-identification", In *2014 22nd International Conference on Pattern Recognition* (pp. 34-39) IEEE. (2014, August).

185. Liang, J., Xu, Y., Bao, C., Quan, Y., and Ji, H., "Barzilai–Borwein-based adaptive learning rate for deep learning", *Pattern Recognition Letters*, 128, 197-203 (2019). Doi: 10.1016/J.PATREC.2019.08.029.

186. Kostopoulos, A. E., and Grapsa, T. N., "Self-scaled conjugate gradient training algorithms", *Neurocomputing*, 72(13-15), 3000-3019 (2009). Doi: 10.1016/J.NEUCOM.2009.04.006.

187. Rao, S. S., "Engineering Optimization: Theory and Practice", *John Wiley & Sons*, 5th Edition. 5-6 (2020).

188. Yadav, M., Kr Purwar, R., and Jain, A., "Design of CNN architecture for Hindi characters", *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 7(3): 47-61 (2018). Doi: <http://dx.doi.org/10.14201/ADCAIJ2018734761>.

189. Ruder, S., "An overview of gradient descent optimization algorithms", *arXiv preprint arXiv:1609.04747* (2016).

190. İşcan, M., and Sever, M., "Gradient descent based classification of road induced disturbances for active suspension systems", In *2017 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, (pp. 1-4) IEEE (2017, April). Doi: 10.1109/EBBT.2017.7956762.

191. Yazan, E., and Talu, M. F., "Comparison of the stochastic gradient descent based optimization techniques", In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)* IEEE, (pp. 1-5), (2017, September). Doi: 10.1109/IDAP.2017.8090299.

192. Seyyarer, E., Uçkan, T., Hark, C., Ayata, F., İnan, M., and Karci, A., "Applications and comparisons of optimization algorithms used in convolutional neural networks", *In 2019 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-6) (2019, September). Doi: 10.1109/IDAP.2019.8875929.
193. Kouzehgar, M., Tamilselvam, Y. K., Heredia, M. V., and Elara, M. R., "Self-reconfigurable façade-cleaning robot equipped with deep-learning-based crack detection based on convolutional neural networks", *Automation in Construction*, 108: 102959. (2019). Doi:10.1016/J.AUTCON.2019.102959.
194. Zhang, N., Lei, D., and Zhao, J. F., "An improved adagrad gradient descent optimization algorithm", *In 2018 Chinese Automation Congress (CAC)* (pp. 2359-2362) IEEE. (2018). Doi: 10.1109/CAC.2018.8623271.
195. Do, D. T., Lee, J., and Nguyen-Xuan, H., "Fast evaluation of crack growth path using time series forecasting", *Engineering Fracture Mechanics*, 218: 106567 (2019). Doi: 10.1016/J.ENGFRACTMECH.2019.106567.
196. Ruder, S., "An overview of gradient descent optimization algorithms", *arXiv preprint arXiv:1609.04747* (2016).
197. Zeiler, M. D., "Adadelta: an adaptive learning rate method", *arXiv preprint arXiv:1212.5701* (2012).
198. Peris, Á., and Casacuberta, F., "Online learning for effort reduction in interactive neural machine translation", *Computer Speech & Language*, 58: 98-126 (2019). Doi: 10.1016/J.CSL.2019.04.001.
199. Wang, S., Wang, X., Wang, S., and Wang, D., "Bi-directional long short-term memory method based on attention mechanism and rolling update for short-term load forecasting", *International Journal of Electrical Power & Energy Systems*, 109, 470-479. (2019). Doi: 10.1016/J.IJEPES.2019.02.022.
200. Nhu, V. H., Hoang, N. D., Nguyen, H., Ngo, P. T. T., Bui, T. T., Hoa, P. V., ... and Bui, D. T., "Effectiveness assessment of keras based deep learning with different robust optimization algorithms for shallow landslide susceptibility mapping at tropical area", *Catena*, 188: 104458 (May 2020). Doi: 10.1016/J.CATENA.2020.104458.
201. Ding, Y., Zhang, Y., Kim, K., Tran, A., Wu, Z., and Christofides, P. D., "Microscopic modeling and optimal operation of thermal atomic layer deposition", *Chemical Engineering Research and Design*, 145: 159-172 (May 2019). Doi: 10.1016/J.CHERD.2019.03.004.
202. Gazel, S. E. R., and BATI, C. T., "Derin sinir ağları ile en iyi modelin belirlenmesi: Mantar verileri üzerine keras uygulaması", *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29(3), 406-417 (2019). Doi: 10.29133/yyutbd.505086.
203. Chang, Z., Zhang, Y., and Chen, W., "Electricity price prediction based on hybrid

model of adam optimized LSTM neural network and wavelet transform", *Energy*, 187: 115804 (2019). Doi: 10.1016/J.ENERGY.2019.07.134.

204. Kingma, D. P., and Ba, J., "Adam: A method for stochastic optimization", *arXiv preprint arXiv*, 1412.6980 (2014).

205. Toğaçar, M., and Ergen, B., "Deep learning approach for classification of breast cancer," in *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, 1–5, (2018). Doi: 10.1109/IDAP.2018.8620802.

206. Han, D., Liu, Q., and Fan, W., "A new image classification method using CNN transfer learning and web data augmentation", *Expert Systems with Applications*, 95: 43-56 (2018). Doi: 10.1016/J.ESWA.2017.11.028.

207. Long, M., Zhu, H., Wang, J., and Jordan, M. I., "Deep transfer learning with joint adaptation networks", In *Proceedings of the 34th International Conference on Machine Learning* - Volume 70 (pp. 2208-2217) JMLR. org (2017, August).

208. Türkoğlu, M., and Hanbay, D., "Plant disease and pest detection using deep learning-based features", *Turkish Journal of Electrical Engineering & Computer Sciences*, 27(3): 1636-1651 (2019).

209. Gündüz, G., and Cedimoğlu, İ. H., "Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini", *Sakarya University Journal of Computer and Information Sciences*, 2(1): 9-17 (2019).

210. Rangarajan, A. K., Purushothaman, R., and Ramesh, A., "Tomato crop disease classification using pre-trained deep learning algorithm", *Procedia computer science*, 133: 1040-1047 (2018). Doi: 10.1016/J.PROCS.2018.07.070.

211. Vogado, L. H., Veras, R. M., Araujo, F. H., Silva, R. R., and Aires, K. R., "Leukemia diagnosis in blood slides using transfer learning in CNNs and SVM for classification", *Engineering Applications of Artificial Intelligence*, 72: 415-422 (2018). Doi: 10.1016/J.ENGAPPAL.2018.04.024.

212. Fu, Y., and Aldrich, C., "Froth image analysis by use of transfer learning and convolutional neural networks", *Minerals Engineering*, 115: 68-78 (2018). Doi: 10.1016/J.MINENG.2017.10.005.

213. Lu, S., Lu, Z., and Zhang, Y. D., "Pathological brain detection based on AlexNet and transfer learning", *Journal of Computational Science*, 30: 41-47 (2019). Doi: 10.1016/J.JOCS.2018.11.008.

214. Fei, Z., Yang, E., Li, D. D. U., Butler, S., Ijomah, W., Li, X., and Zhou, H., "Deep convolution network based emotion analysis towards mental health care" *Neurocomputing* (2020). Doi: 10.1016/J.NEUCOM.2020.01.034.

215. Dietlmeier, J., McGuinness, K., Rugonyi, S., Wilson, T., Nuttall, A., and

- O'Connor, N. E., "Few-shot hypercolumn-based mitochondria segmentation in cardiac and outer hair cells in focused ion beam-scanning electron microscopy (FIB-SEM) data", *Pattern Recognition Letters*, 128: 521-528 (2019). Doi: 10.1016/J.PATREC.2019.10.031.
216. Arı, A., "Derin öğrenme tabanlı beyin MR görüntülerinden beyin tümörlerinin tespit edilmesi ve sınıflandırılması", Doktora Tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya, 56-60 (2019).
217. Rauf, H. T., Lali, M. I. U., Zahoor, S., Shah, S. Z. H., Rehman, A. U., and Bukhari, S. A. C., "Visual features based automated identification of fish species using deep convolutional neural networks", *Computers and Electronics in Agriculture*, 167: 105075 (2019). Doi: 10.1016/J.COMPAG.2019.105075.
218. Eyiokur, F. İ., Yaman, D., and Ekenel, H. K., "Sketch classification with deep learning models", *In 2018 26th Signal Processing and Communications Applications Conference (SIU)*, (pp. 1-4) IEEE (2018, May). Doi: 10.1109/SIU.2018.8404417.
219. Hu, Q., Ohata, E. F., Silva, F. H., Ramalho, G. L., Han, T., and Rebouças Filho, P. P., "A new online approach for classification of pumps vibration patterns based on intelligent IoT system", *Measurement*, 151: 107138 (2020). Doi: 10.1016/J.MEASUREMENT.2019.107138.
220. Ha, I., Kim, H., Park, S., and Kim, H., "Image retrieval using BIM and features from pretrained VGG network for indoor localization", *Building and Environment*, 140: 23-31 (2018). Doi: 10.1016/J.BUILDENV.2018.05.026.
221. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... and Rabinovich, A., "Going deeper with convolutions", *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1-9), (Jun. 2015). Doi: 10.1109/CVPR.2015.7298594.
222. Özdemir, R., Koç, M., "Yeni bir veri kümesi (RidNet) kullanarak kontrolsüz ortamda yüz ifadesi tanımanın derin öğrenme yöntemleri ile iyileştirilmesi", *Bilecik Şeyh Edebali Üniversitesi Fen Bilim. Derg.*, 6 (2), 384-396, (2019). Doi: 10.35193/bseufbd.645138.
223. Wang, R., Li, W., and Zhang, L., "Blur image identification with ensemble convolution neural networks", *Signal Processing*, 155: 73-82 (2019). Doi: 10.1016/J.SIGPRO.2018.09.027.
224. Altuntaş, Y., Kocamaz, A. F., Cömert, Z., Cengiz, R., and Esmeray, M., "Identification of haploid maize seeds using gray level co-occurrence matrix and machine learning techniques", *In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP)* (pp. 1-5), (2018, September). Doi: 10.1109/IDAP.2018.8620740.
225. Li, H., Wu, X. J., and Durrani, T. S., "Infrared and visible image fusion with

ResNet and zero-phase component analysis", *Infrared Physics & Technology*, 102: 103039 (2019). Doi: 10.1016/J.INFRARED.2019.103039.

226. Deng, X., Liu, Q., Deng, Y., and Mahadevan, S., "An improved method to construct basic probability assignment based on the confusion matrix for classification problem", *Information Sciences*, 340: 250-261 (2016). Doi: 10.1016/J.INS.2016.01.033.

227. Luque, A., Carrasco, A., Martín, A., and de las Heras, A., "The impact of class imbalance in classification performance metrics based on the binary confusion matrix", *Pattern Recognition*, 91: 216-231 (2019). Doi: 10.1016/J.PATCOG.2019.02.023.

228. Ozenne, B., Subtil, F., and Maucort-Boulch, D., "The precision–recall curve overcame the optimism of the receiver operating characteristic curve in rare diseases", *Journal of clinical epidemiology*, 68(8): 855-859 (2015). Doi: 10.1016/J.JCLINEPI.2015.02.010.

229. Cook, J. A., "ROC curves and nonrandom data", *Pattern Recognition Letters*, 85: 35-41 (2017). Doi: 10.1016/J.PATREC.2016.11.015.

230. Kılıç, S., "ROC analysis in clinical decision making", *Journal of Mood Disorders*, 3(3): 135 (2013). Doi: 10.5455/jmood.20130830051624.

231. Rohani, A., Taki, M., and Abdollahpour, M., "A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I)", *Renewable Energy*, 115: 411-422 (2018). Doi: 10.1016/J.RENENE.2017.08.061.

232. Jiang, P., AND Chen, J., "Displacement prediction of landslide based on generalized regression neural networks with K-fold cross-validation", *Neurocomputing*, 198: 40-47 (2016). Doi: 10.1016/J.NEUCOM.2015.08.118.

233. Kokkinos, Y., and Margaritis, K. G., "Managing the computational cost of model selection and cross-validation in extreme learning machines via Cholesky, SVD, QR and eigen decompositions", *Neurocomputing*, 295: 29-45 (2018). Doi: 10.1016/J.NEUCOM.2018.01.005.

234. Raghuwanshi, B. S., and Shukla, S., "SMOTE based class-specific extreme learning machine for imbalanced learning", *Knowledge-Based Systems*, 187: 104814 (2020). Doi: <https://doi.org/10.1016/j.knosys.2019.06.022>.

235. Thabtah, F., Hammoud, S., Kamalov, F., and Gonsalves, A., "Data imbalance in classification: Experimental evaluation", *Information Sciences*, 513: 429-441 (2020). Doi: <https://doi.org/10.1016/j.ins.2019.11.004>.

236. Hameed, N., Shabut, A. M., Ghosh, M. K., and Hossain, M. A., "Multi-class multi-level classification algorithm for skin lesions classification using machine

learning techniques", *Expert Systems with Applications*, 141: 112961 (2020). Doi: <https://doi.org/10.1016/j.eswa.2019.112961>.

237. Budak, Ü., Cömert, Z., Çıbuk, M., and Şengür, A. "DCCMED-Net: Densely connected and concatenated multi Encoder-Decoder CNNs for retinal vessel extraction from fundus images", *Medical Hypotheses*, 134: 109426 (2020). Doi: <https://doi.org/10.1016/j.mehy.2019.109426>.

238. Li, S., Song, W., Qin, H., and Hao, A., "Deep variance network: An iterative, improved CNN framework for unbalanced training datasets", *Pattern Recognition*, 81: 294-308 (2018). Doi: 10.1016/J.PATCOG.2018.03.035.

239. Jyothi, R., Soans, R. S., and Bhat, P. V., "Automatic classification of toco-signals: An approach towards comprehensive monitoring of labour progress", *In 2016 International Conference on Signal Processing and Communications (SPCOM)* (pp. 1-5). IEEE. (2016, June). doi: 10.1109/SPCOM.2016.7746694.

240. Goggin, L. S., Eikelboom, R. H., and Atlas, M. D., "Clinical decision support systems and computer-aided diagnosis in otology", *Otolaryngology--Head and Neck Surgery*, 136(4_suppl): 21-26 (2007). Doi: 10.1016/j.otohns.2007.01.028.

241. Cömert, Z., and Kocamaz, A. F. "Fetal hypoxia detection based on deep convolutional neural network with transfer learning approach". In Computer Science On-line Conference, *Springer, Cham*, 239-248 (2018, April).

EK AÇIKLAMALAR A.

Etik kurulu kararı

Evrak Tarih ve Sayısı: 13/11/2018-E.18832



T.C.
BİTLİS EREN ÜNİVERSİTESİ REKTÖRLÜĞÜ
Genel Sekreterlik



Sayı : 66073261/050.03/
Konu : Etik Kurulu Kararı

Sayın Erdal BAŞARAN

İlgi 30.10.2018 tarihli ve 9457 evrak kayıt numaralı dilekçeniz.

İlgide kayıtlı dilekçenize istinaden; "Timpanik Membran Görüntü Analizi ve Yapay Zeka Kullanılarak Sanal Pediatrik Otitis Media Tanı Sisteminin Geliştirilmesi" adlı çalışmanız Üniversitemiz Etik İlkeleri ve Etik Kurulunun 08.11.2018 tarih ve 2018/09-I sayılı kararıyla uygun görülmüştür.

Bilgilerinizi ve gereğini rica ederim.

e-imzalıdır
Prof. Dr. Sabir RÜSTEMLİ
Rektör a.
Rektör Yardımcısı

Yazı İşleri Müdürlüğü
Rahve Yerleşkesi Baş Minare Mah. Ahmet Eren Bulvarı
13000 Merkez/BİTLİS
E-Posta : yzisleri@beu.edu.tr
Tel: 0 (434) 222 09 59 Faks: 0 (434) 222 01 01

Ayrıntılı bilgi için iribet : Döne KUŞCU
Unvan : Bilgi İşyeri İşletmeni
Web Adres : www.beu.edu.tr



Bu belge, 5070 sayılı Elektronik İmza Kanununa göre Elektronik imza ile imzalanmıştır.

EK AÇIKLAMALAR B.

Veri setinin paylaşımı

Deneyisel alıřmalarda kullanılan zgn veri seti arařtırmacılara public olarak
Deneyisel alıřmalarda kullanılan zgn veri seti arařtırmacılara public olarak
<http://www.ctganalysis.com/Category/otitis-media> adresinde sunulmuřtur.
adresinde sunulmuřtur.

ÖZGEÇMİŞ

Erdal BAŞARAN 1985 yılında Şırnak'ın İdil ilçesinde doğdu; ilk ve ortaöğrenimini Mardin Midyat'ta tamamladı. 2005 yılında başladığı Sakarya Üniversitesi Eğitim Fakültesi Bilgisayar ve Öğretim Teknolojileri Öğretmenliği bölümünden 2009 yılında mezun oldu. 2012 yılında Ahmet Yesevi Üniversitesi Bilgisayar Mühendisliği bölümünde tezsiz yükek lisansa başladı ve 2014 yılında tamamladı. 2016 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği alanında doktora eğitimine başladı. 2012-2019 yılları arasında Bitlis Eren Üniversitesi Bigi İşlem Daire Başkanlığında çalıştı. Ağustos 2019 yılından itibaren Ağrı İbrahim Çeçen Üniversitesi Eğitim Fakültesi Bilgisayar ve Öğretim Teknolojileri Öğretmenliği bölümünde Araştırma Görevlisi olarak çalışmaktadır.

ADRES BİLGİLERİ

Adres : Ağrı İbrahim Çeçen Üniversitesi Eğitim Fakültesi Bilgisayar ve
Öğretim Teknolojileri Öğretmenliği Bölümü

Tel : +90 506 756 32 69

E-posta : erdalbasaran085@gmail.com