

Normal ve Kronik Hastalıklı Orta Kulak İmgelerinin Evrişimsel Sinir Ağları Yöntemiyle Tespit Edilmesi

Diagnosis of Normal and Chronic Tympanic Membrane with Convolutional Neural Network

Erdal BAŞARAN¹
Ağrı İbrahim Çeçen Üniversite
erdalbasaran085@gmail.com
ORCID: 0000-0001-8569-2998

Zafer CÖMERT²
Samsun Üniversitesi
zcomert@samsun.edu.tr
ORCID: 0000-0001-5256-7648

Abdulkadir ŞENGÜR³
Fırat Üniversitesi
ksengur@gmail.com
ORCID: 0000-0003-1614-2639

Ümit BUDAK⁴
Bitlis Eren Üniversitesi
ubudak@beu.edu.tr
ORCID: 0000-0003-4082-383X

Yüksel ÇELİK⁵
Karabük Üniversitesi
yuksecelik@karabuk.edu.tr
ORCID: 0000-0002-7117-9736

Mesut TOĞAÇAR⁶
Fırat Üniversitesi
mtogacar@firat.edu.tr
ORCID: 0000-0002-8264-3899

Öz

Orta kulak iltihabı kulak zarının arkasında sıvı birikmesi olarak bilinmektedir. Orta kulak iltihabının uzun süreli tedaviye yanıt vermemesi ve kulak zarının delinmesi ile karakterize olan kronik orta kulak iltihabı işitme kaybına bile sebep olabilen ciddi bir rahatsızlıktır. Bu çalışmada gerekli etik kurulu izni alındıktan sonra Özel Van Akdamar Hastanesinde gönüllü hastalardan otoskop cihazı ile elde edilen 598 adet normal orta kulak görüntüsü ve kronik hastalıklı orta kulak görüntüleri ile sınıflandırma işlemi gerçekleştirilmiştir. Son yıllarda yapay zekâ kapsamında değerlendirilen algoritmalar hemen her alanda kullanılmaktadır. Sağlık alanında da tanı ve karar destek sistemleri geliştirilerek başarılı çalışmalar yapılmaktadır. Bu çalışmada yapay zekâ algoritmalarından olan ve özellikle biyomedikal görüntü sınıflandırma çalışmalarında da iyi sonuçlar elde edilen evrişimsel sinir ağı mimarilerinden olan AlexNet,

VGG16, VGG19, GoogleNet, ResNet18, ResNet50, ResNet101 modelleri kullanılmıştır. Deneysel çalışmalar sonucu VGG19 mimarisi ile %97.2067 başarı oranı elde edilmiştir. Evrişimsel sinir ağları yöntemi normal ve kronik orta kulak görüntülerini ayırt etmede başarılı bir yöntemdir.

Anahtar Sözcükler: Kronik orta kulak iltihabı, Evrişimsel sinir ağları, Sinyal işleme

Abstract

Middle ear inflammation is known as the accumulation of fluid behind the eardrum. Chronic middle ear inflammation, which is characterized by the failure to respond to long-term treatment and perforation of the eardrum, is a serious condition that can even cause hearing loss. In this study, 598 normal middle ear images obtained from the volunteer patients with otoscope device and middle ear images with chronic disease were performed after obtaining the necessary ethics committee permission. In recent years, algorithms evaluated within the scope of artificial intelligence have been

Gönderme ve kabul tarihi: 10.12.2019 - 30.03.2020

Makale türü: Araştırma


used in almost every field. In the field of health, diagnostic and decision support systems are developed and successful studies are carried out. In this study, AlexNet, VGG16, VGG19, GoogleNet, ResNet18, ResNet50, ResNet101 models which are one of the artificial intelligence algorithms and the convolutional neural network architectures which have good results especially in biomedical image classification studies are used. As a result of the experimental studies, 97.2067% success rate was achieved with VGG19 architecture. The convolutional neural network method is a successful method to distinguish between normal and chronic middle ear images.

Keywords: Chronic otitis media, Convolutional neural network, Signal processing

1. Giriş

Orta kulak iltihabı (OKI), kulak zarının arkasında sıvı birikmesi ile oluşan rahatsızlığın genel adıdır. Orta kulak hastalığı genellikle çocuklarda görülmekte ve çocuk doktoruna giden tüm hastaların %10-%15'ini oluşturmaktadır [1]. Hastalığın iletim şeklinde işitme kaybıyla sonuçlanması ve üç aydan uzun süreli tedaviye cevap vermeyen orta kulak rahatsızlığı olarak bilinmektedir [2]. Kronik orta kulak iltihabı (KOKI), işitme kaybının yitirilmesine bile sebep olabileceğinden dolayı dikkatli bir şekilde tedavi edilmesi gereken bir rahatsızlıktır [3]. Hastalığın aktif döneminde akıntı bulunmakta ve akıntılı kronik otitis media denilmektedir. KOKI genellikle erkeklerde, beyaz ırk insanlarda, küçük yaşta çocuklarda, ilk OKI'nin doğumdan sonraki altı ayda geçirilmesi, sigara içilen ortam, ailede geçirilmiş OKI hikâyesi, biberonla beslenme, çevresel faktörler gibi birçok etken etkidir [4].

KOKI tanısının konulabilmesi için otoskopi ile muayene edilmesi gerekmektedir. Uzman tarafından otoskopi ile kulak zarı incelendiği zaman KOKI hastalarında kulak zarında delinme, kulak yolunda akıntı, kulak zarı arkasında orantısız büyüyen doku, kemikçiklerin erimesi gibi fiziksel değişimler gözlemlenir. Normal bir kulak zarı ise gri renkli, ince, konik yapılı ve şeffaf bir görünüme sahiptir. Resim 1'de normal ve kronik kulak zarı görüntüleri görülmektedir.



Resim-1: Kronik(a, b, c) ve Normal (d, e, f) Kulak Zarı Görüntüleri

Son yıllarda hemen her alanda yapay zekâ algoritmaları ile uygulamalar geliştirilmiş ve oldukça etkileyici sonuçlar elde edilmiştir. Sağlık alanında etkili karar destek sistemleri geliştirilmesi için yapılan çalışmalara bakıldığında zaman yapay zekâ kapsamında değerlendirilen birçok algoritma kullanılmıştır [5-9].

KOKI'nin teşhis edilmesi için literatürde bilgisayar temelli yapılan çalışmalara bakıldığında zaman; Heck junior ve diğerleri hesaplamalı bir yöntemle KOKI'de kulak zarı deliğinin boyutunu ölçmüştür. 660 adet hastanın iki kulağının resmi alınarak toplamda 1320 adet resim ile deneysel çalışmayı gerçekleştirmişlerdir. Kulak zarı görüntüsü ekrana gelen oval bir daire ile seçilir ardından perfore olan alan seçili bu bölgenin alanı hesaplanmaktadır [10]. Diğer yandan Chuen-Kai Shie ve arkadaşları 865 orta kulak resmini Normal, akut OKI, seröz OKI ve KOKI olmak üzere 4 adete sınıflandırmışlardır. Görüntü bölütleme yöntemi kullanılarak zar bölgesi alındıktan sonra özellik çıkarma algoritmaları kullanılarak özellik vektörü elde edildikten sonra adaboost yöntemiyle sınıflandırma işlemi gerçekleştirmişlerdir [11]. Hermanus ve arkadaşları orta kulak görüntülerini 5 adete sınıflandırmıştır. Görüntü işleme teknikleri kullanılarak resimdeki perforasyon, kemikcik, kulak zarının rengi, kulak kiri varlığı, orta kulakta sıvı ve ışık yansımaları gibi özellikler elde edilerek karar ağacı yöntemiyle sınıflandırma işlemi gerçekleştirmişlerdir [12]. Başaran ve arkadaşları dokusal özellik çıkarma yöntemi olan gri seviyeli eşleşim matrisi ile elde ettikleri özellik setini yapay sinir ağları yöntemi ile imgeleri sınıflandırmışlardır. Bir başka çalışmada da elde edilen kulak zarı görüntülerinin zar bölgesini bulup sınıflandırmışlardır [13,14]. Cömert, ESA yöntemi

ile elde edilen özellik çıkarma katmanları ile elde edilen özellik setini makine öğrenme algoritmalarının girişine vererek sınıflandırma işlemi gerçekleştirmiştir [15]. Joanna Szaleniec ve arkadaşları KOM hastalığına sahip bireylerin orta kulak ameliyatı geçirdikten sonra yorumlayıcı bir yapay sinir ağı ve knn modeli geliştirmişlerdir. 150 adet hastanın yaş, cinsiyet, preoperatif odyometrik sonuçları, kulak patolojileri ve cerrahi işlemin detayı giriş verisi olarak kullanıldı. Öngörülen çıkış ise ameliyat sonrası işitme eşiği idi. Önerilen model ile YSA ile %84 ve knn ile %75.8 başarı elde edilmiştir [16]. Xin Wang ve arkadaşları klinikten toplamış oldukları 235 adet TM görüntüsü ve internetten toplamış oldukları 40 adet TM olmak üzere toplamda 275 adet otoskopik TM görüntüsünde Efüzyonlu otitis media hastalığının tedavisinde kullanılan timpanoplasti tüpünün varlığının tespit edilmesi çalışması gerçekleştirilmiştir. 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 resmin merkezini tespiti için de k-means algoritması kullanılmıştır. 22 adet özelliğe sahip vektör elde edildikten sonra SVM ile sınıflandırma işlemi gerçekleştirilmiştir [17].

Bu çalışmada normal ve KOKI hastalıklı orta kulak görüntülerini sınıflandırmak için literatürde sık bir şekilde kullanılan ve yüksek doğruluk sonucu elde edilen evrimsel sinir ağları (ESA) yöntemi kullanılmıştır. Bu doğrultuda ESA mimarilerinden olan Alexnet, VGGNet mimarileri, GoogleNet, Resnet mimarileri kullanılmıştır. Deneysel çalışmaları gerçekleştirmek için Van Özel Akdamar

Hastanesinde gönüllü hastalardan otoskop cihazı ile orta kulak imgeleri elde edilmiştir.

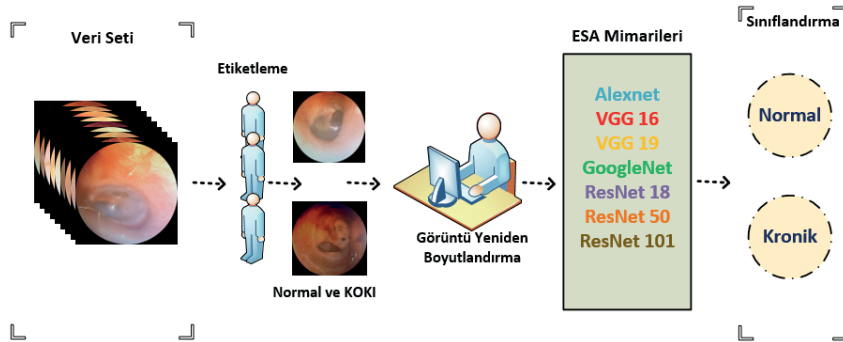
Bu çalışmanın ikinci bölümünde kullanmış olduğumuz veri seti ve önerilen yöntem ile ilgili bilgiler yer almakta olup üçüncü bölümde önerilen yöntemin bulgularına yer verilmiştir. Dördüncü bölümde bulgulara dayanan bir tartışma gerçekleştirilmiştir. Son bölümde ise sonuç cümleleri yer almaktadır.

2. Materyal ve Yöntem

Normal ve KOKI görüntülerini sınıflandırmak için önermiş olduğumuz akış modeli Şekil-1'de görülmektedir. Özgün veri seti elde edilip etiketleme işlemi yapıldıktan sonra, görüntüler yeniden boyutlandırılarak ESA ile sınıflandırılmak üzere ilgili mimarilere giriş olarak uygulanmıştır. ESA ile en etkili sonuçların elde edilmesi için farklı parametre değerleri deneme yanılma yoluyla test edilmiştir.

2.1. Veri Seti

Deneysel çalışmaları gerçekleştirmek için 10/2018 ve 06/2019 tarihleri arasında Van Özel Akdamar Hastanesinde gönüllü hastalardan otoskop cihazı ile orta kulak görüntüleri toplandı. Bu çalışmada elde edilen otoskop imgelerinden 535 adet Normal ve 63 adet KOKI olmak üzere toplamda 598 adet imge dikkate alındı. İmgeler elde edildikten sonra etiketleme işlemi 3 adet uzman tarafından gerçekleştirildi. Oluşturulan özgün veri seti araştırma amacıyla açık hale getirildi. Söz konusu veri seti <http://www.ctganalysis.com/Category/otitis-media> bağlantısı yardımıyla ücretsiz bir şekilde indirilebilmektedir.



Şekil-1: Akış Modeli

2.2. Evrişimsel Sinir Ağları

İleri beslemeli bir yapay sinir ağı modeli olan ESA özellikle bilgisayar görü, görüntü sınıflandırma gibi problemlerde başarılı sonuçlara ulaşabilmektedir [18-21]. Bir ESA modelinde sırasıyla özellik çıkarma katmanı olan evrişim, doğrultulmuş doğrusal birim (ReLU), havuzlama ve tam bağlantı gibi katmanlardan oluşmaktadır. Yapay sinir ağlarında bulunmayan evrişim katmanı filtreler ile görüntüyü soldan sağa ve yukarıdan aşağıya tarayarak bir özellik haritası elde eder [22]. Evrişim işleminin matematiksel formülü Denklem (1)'de belirtilmiştir.

$$(f * h)[m, n] = \sum_j \sum_k h[j, k], f(m - j, n - k) \quad (1)$$

Burada, giriş görüntüsü f ve h filtredir. Çıkış matrisinin satır ve sütun indeksleri sırasıyla m ve n 'dir. J ve k ise filtreye ait konumu ifade etmektedir. Evrişim katmanını çıktılarını doğrultucu birim olarak ReLu takip eder, giriş değerini negatifse sıfıra çeker. Matematiksel olarak Denklem (2)'de gösterilmiştir.

$$f(x) = \begin{cases} 0, & \text{eğer } x < 0 \\ x, & \text{eğer } x \geq 0 \end{cases} \quad (2)$$

Doğrultulmuş birimden sonra parametre sayısını, hesaplama yükünü ve belleği azaltmak için havuzlama katmanı kullanılmaktadır. Bu işlemi yapmak için komşu çıktılara ait maksimum veya ortalama havuzlama işlemi gerçekleştirilir. ESA'nın son katmanı olan tam bağlantı katmanı kendinden önce gelen katmanın bütün alanlarına bağlıdır.

ESA, 2012 yılında yapılan ImageNet yarışması ile ön plana çıkmıştır. Bu çalışmada önceden eğitilmiş ESA mimarileri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Bu mimarilerin ilki olan AlexNet, Krizhevsky ve arkadaşları tarafından 2012 yılındaki ImageNet yarışmasında kullanılmıştır. Bu mimaride 5 evrişim ve havuzlama katmanı, 3 tam bağlantı katmandan oluşmaktadır. Giriş görüntü boyutunu 227×227 piksel olarak almaktadır [23].

VGGNet mimarileri Alexnet mimarisinden daha derin bir yapıya sahiptir. VGG16'da 16 evrişim 3 tam bağlı katman bulunmaktadır. Bu mimari daha derin olan ağların daha iyi ağ olduğu fikrine dayanılarak tasarlanmıştır [24]. VGG19 mimarisinde fazladan 3 adet evrişim katmanı yer

almaktadır [25]. VGGNet mimarileri giriş görüntüsünü 224×224 piksel boyutunda alır.

Bir diğer dikkat çekici model olan GoogleNet mimarisi, iç ağındaki Inception olarak adlandırılan bağlantılar yaparak hesaplama maliyetini düşürmesi ile ön plana çıkan modülleri ihtiva etmektedir. 144 katmandan oluşan GoogleNet mimarisi giriş görüntüsü olarak 224×224 piksel boyutunda resim alır [26].

Microsoft tarafından geliştirilen bir diğer ESA modeli olan ResNet ise, ağların eğitimini kolaylaştırmak için kalıcı bir öğrenme çerçevesi üzerinde durmuştur [27]. Bu modelde kalıntı blokları ve derinliği göze çarpmaktadır. ResNet18, ResNet50 ve ResNet101 mimarileri farklı sayıda hesaplama parametrelerine sahiptir. Bu modellerin derinlikleri sırasıyla 18,50 ve 101 katman sayıları ise 72, 177 ve 347 adet katmandan oluşmaktadır [28]. Giriş görüntüsünü 224×224 piksel olarak alır.

3. Bulgular

Bu çalışmada Van Özel Akdamar Hastanesinde gönüllü hastalardan elde edilen normal sınıfa ait 535 adet orta kulak resmi ve 63 adet KOKI sınıfına ait resim kullanılmıştır. Deneysel çalışmalar NVIDIA Quadro P6000 GPU grafik kartı ve Intel(R) Xeon(R) Gold 6132 @2.60 GHz CPU ile donatılmış bir iş istasyonunda gerçekleştirildi. Yazılım olarak da MATLAB (R2019a) sürümü ile deneysel çalışmalar yapılmıştır.

ESA modellerini kullanarak veri setimizi %70 eğitim ve %30 test olacak şekilde rastgele ayarlanmıştır. Önceden Eğitilmiş modelleri eğitmek için her iterasyonda eğitilecek veri kümesi olan mini topluluk değeri (mini-batch size) 32 olarak ayarlandığı için her döngüde 18 adet resim kullanılmış ve kümelerden oluşan veri setini tamamını eğitmek için maksimum çağrı (max-epoch) da 64 olarak ayarlandığı için eğitim 1152 iterasyonda tamamlanmıştır. ESA mimarilerinde eğitim oranı (learning rate) 1×10^{-4} olarak belirlendi, optimizasyon olarak da skotastik gradyan inişi algoritması kullanıldı.

Modellerin performans sonuçlarını ölçmek için karşıtlık matrisleri elde edildi. Karşıtlık matrisleri Grafik 1'de görülmektedir. Karşıtlık matrisindeki gerçek değerler ve tahmin edilen değerler bulunmaktadır. Karşıtlık matrisinin 4 adet değeri bulunmaktadır. Buradaki doğru pozitif (DP)

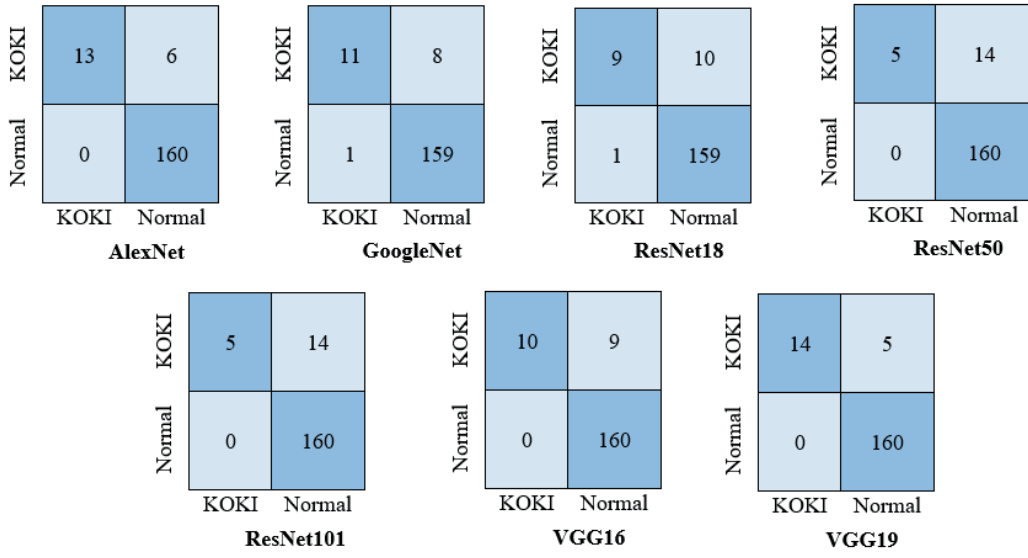
değerler, doğru tahmin edilen ve gerçekte doğru olan, doğru negatif (DN) değerler ise doğru olarak tahmin edilen ve aslında yanlış olan kayıtları, yanlış pozitif (YP) yanlış olarak tahmin edilen ve aslında doğru olan kayıtların sayısını ifade eder. Yanlış negatif (YN) ise yanlış olarak tahmin edilen ve yanlış olan kayıt sayısını ifade etmektedir. Karşıtlık matrisinden elde edilen doğruluk; hasta ve hasta olmayanların doğru bir şekilde teşhis edilme oranını, hassasiyet; doğru pozitiflerin oranını ifade ederken özgüllük ise doğru negatiflerin oranını belirtir. Bu

istatistiksel veri değerlerinin hesaplanması Denklem (3), (4), (5)'te görülmektedir.


$$\text{Doğruluk} = \frac{(DP+DN)}{(DP+YP+YN+DN)} \quad (3)$$

$$\text{Duyarlılık} = \frac{(DP)}{(DP+YN)} \quad (4)$$

$$\text{Özgüllük} = \frac{(DN)}{(DN+YP)} \quad (5)$$




Grafik-1: Modellere Ait Hata matrisleri



Grafik -2: ESA Mimarilerinin Eğitim Süresi

Ağı eğitmek için geçen süreler bakıldığı zaman en erken AlexNet mimarisi ile eğitim 59 dakikada tamamlanmıştır. En geç ise ResNet101 mimari ile 69 dakikada eğitim tamamlanmıştır. ESA mimarilerinin eğitimlerinin tamamlanma süreleri Grafik 2’de görülmektedir.



Grafik-3: AİK Sonuçları
Çizelge-1: ESA Mimarilerinin Doğruluk Oranı

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

İkili sınıflandırma sistemlerinde kullanılan doğru pozitiflerin yanlış pozitiflere olan kesri olarak ifade edilen ayrıcı işletim karakteristik (AİK) grafikleri çıkarıldı. AİK grafiğinin dikey ekseninde duyarlılık yatay ekseninde özgülük oranları yer almaktadır. AİK grafiğinin altında kalan alanın mümkün olduğunca bire yakın olması beklenir. Burada gözlenen en yüksek değer 0.9872 ile VGG16 mimarisine ait iken gözlenen en düşük değer ise ResNet50 mimarisi ile 0.9151 oranına sahiptir.

Toplamda 598 görüntü ile 7 farklı ESA mimarisi kullanılarak sınıflandırma işlemi gerçekleştirildi. En yüksek başarı oranı %97.2067 ile VGG19 mimarisi ile elde edilirken, en düşük doğruluk oranı ise ResNet50 ve ResNet101 mimarileri ile %92.1788 sonucu elde edildi.

Model performansını test etmenin önemli ölçütlerinden biri de k-katlamalı çapraz doğrulama (k-fold cross validation) yöntemidir. Bu yöntemde veri setinin kısıtlı olduğu durumlarda oldukça faydalı olmaktadır. Model verininin k-1 kısmını eğitim kalanını test için kullanmaktadır [29]. Bu çalışmada k değeri 5 seçilerek performans sonuçlarına bakıldı. Sonuçlar incelendiğinde en yüksek doğruluk oranı %96.65 ile VGG16 mimarisine ait iken en düşük değer ise %93.33 ile ResNet18 mimarisine aittir.

5-katlı çapraz doğrulama ile modellerin eğitim sürelerine bakıldığı zaman en yüksek eğitim süresi 369 dk ile VGG16 mimarisine ait iken en düşük eğitim süresi ise 113 dk ile ResNet18 mimarisine aittir. Modellere ait 5-katlamalı çapraz doğrulama sonuçları Çizelge-2'de görülmektedir.

Çizelge-2: 5-Katlı Çapraz Doğrulama Sonuçları ve Eğitim Süreleri

ESA Mimarileri	Doğruluk Oranları (%)	Eğitim Süresi (dk)
AlexNet	96.4883	3.4141e+03
VGG16	96.6555	3.6953e+03
VGG19	95.4849	3.8535e+03
GoogleNet	95.0000	6.3141e+03
ResNet18	93.3333	1.1329e+03
ResNet50	94.1667	1.3771e+03
ResNet101	94.1667	1.3744e+03

Çizelge-3 Önceden yapılan çalışmalar

Kullanılan Yöntem	Veri Sayısı	Sınıf Sayısı	Başarı Oranı (%)
Yerel ikili özellikler, aktif kontur bölütleme, adaboost [11]	865	4	88.06
Götüntünün özellikleri, karar ağacı [12]	486	5	80.61
Gri seviyeli eş oluşum matrisi, görüntü özellikleri, yapay sinir ağları [13]	223	2	76.14
ESA, görüntü arttırma, bölge tespiti [14]	282	2	87.97
	1692	2	90.48
Yapay sinir ağları, Karar ağaçları, kişisel, cerrahi ve odyometrik özellikler [16].	150	2	%84
Destek vektör makinası, GLCM, HOG, Wavelet, SIFT, LBP [17]	275	2	%90
ESA, Makine öğrenmesi [15]	956	8	99.47
Bu çalışma (ESA)	598	2	97.2067

4. Tartışma

Bu çalışmada derin öğrenme yöntemlerinden olan ve biyomedikal alanda yaygın olarak kullanılan ESA mimarileri ile Normal ve KOKI ikili sınıflandırma işlemi gerçekleştirilmiştir. Bu bölümde kullanılan yöntem ve veri sayısının başarı oranına etkisi irdelenecektir. Önceki çalışmalarda kullanılan veri sayısı ve başarı oranı Çizelge-3’de görülmektedir.

Otitis media ile ilgili yapılan çalışmalara bakıldığı zaman paylaşımına açık bir veri seti olmadığını, ilk olarak araştırma grubumuz tarafından veri setinin paylaşımına açılarak bu alana kazandırılmıştır.

KOKI tanısına yönelik literatürde yapılan çalışmalara bakıldığı zaman daha önce görüntülere ait öznelikler elde edilerek Adaboost, karar ağaçları, yapay sinir ağları, destek vektör makinaları gibi çeşitli makine öğrenme algoritmaları

kullanılmıştır. Bununla beraber ESA modelinde ham veri algoritmanın girişine verilerek sınıflandırma işlemi gerçekleştirilir. ESA ile yapılan çalışmaların makine öğrenme algoritmalarına göre daha yüksek doğruluk sonucu elde edildiği görülmektedir.

Görsel özellikler yardımıyla özellik seti elde edildikten sonra makine öğrenmesi ile yapılan çalışmalara bakıldığı zaman GLCM, LBP, HOG, SIFT [11,13,17] gibi güçlü dokusal özellikler çıkarılmıştır. Bunların yanı sıra görüntüdeki ortalama renk değeri, earwax varlığı, odyometrik sonuçlar [12, 16] gibi çeşitli görsel özellikler yardımıyla özellik vektörü çıkarılmış ve makine öğrenmesi ile yapılan çalışmaların başarı oranı maksimum %90 olduğu görülmektedir. ESA ile yapılan ve özellikleri konvolüsyon katmanıyla

otomatik çıkarılarak yapılan çalışmaların doğruluk oranlarının çok daha yüksek olduğu görülmektedir.

ESA modellerinin başarı oranını artırması kullanılan veri setinin büyüklüğü önem arz etmektedir. Bu çalışmadaki karışıklık matrisleri incelendiği zaman Normal sınıftan olan görüntü sayısı KOKI'ye göre daha fazla olduğundan dolayı gerçek ve tahmin edilen değer oranının Normal sınıfında daha iyi olduğu görülmektedir. Aynı zamanda Başaran [14] ve diğerlerinin yaptığı çalışma incelendiği zaman imge artırma yöntemi kullanılarak daha büyük veri seti ile başarı oranının arttığı görülmektedir. Yöntem olarak ESA kullanılan çalışmalarda veri sayısının artmasıyla başarı oranının arttığı görülmektedir. Cömert [15], ESA ve makine öğrenmesi kullanarak yapmış olduğu hibrit çalışmada başarı oranının daha da arttığı görülmektedir. Özellik çıkararak sınıflandırma işlemi yapılan çalışmalarda da veri sayısının artmasıyla başarı oranının arttığı görülmektedir.

Verisetimizi %70 eğitim ve %30 test olarak ayırdığımız zaman en yüksek doğruluk oranı VGG19 modeli iken 5 katlı çapraz doğrulama ile en yüksek doğruluk oranına sahip model ise VGG16 modeli olduğu görülmektedir. Veri setinin çok fazla sayıda olmadığından dolayı bu sonuçların elde edildiği düşünülmektedir.

Sonuçlar kullanmış olduğumuz yöntemin umut vaat eden sonuçlara erişildiğini doğrulamıştır.

5. Sonuç

KOKI tedavi edilmediği takdirde 5 duyu organımızdan biri olan işitme duyusunun yitirilmesine bile sebep olabileceğinden dolayı bu hastalığın erken tanısı ve tedavisi oldukça önem arz etmektedir.

Veri setimizde yer alan Normal ve KOKI imgelerinin ESA modeli kullanılarak %97.2067 başarı oranı ile tanı işlemini kolaylaştıracağı sonuçlar elde edilmiştir. Çalışmada kullanılan veri seti araştırmacıların erişimine açılmıştır.

Gelecek çalışmalarda özellikle KOKI sınıfına ait imge sayısı artırılarak farklı yöntemler ile deneysel çalışmalar yapılması planlanmaktadır.

Veri Seti Erişimi

Bu çalışmada kullanılan veri seti araştırma grubumuza ait olan web sayfası üzerinden erişilebilir. <http://www.ctganalysis.com/Category/otitis-media>.

Kaynakça

- [1] T. Tham, L. Rahman, and P. Costantino, "Efficacy of a non-invasive middle ear aeration device in children with recurrent otitis media: A randomized controlled trial protocol," *Contemp. Clin. Trials Commun.*, vol. 12, pp. 92–97, Dec. 2018.
- [2] R. Gün, "Kronik süperatif otitis mediada yas, hastalık süresi ve kolesteatom varlığının sensorinöral isitme kaybı ile ilişkisi," *Dicle Tıp Dergisi*, , Sayı 2 , vol. Cilt: 36, no. sayı 2, pp. 117–122, 2009.
- [3] E. Yorgancılar *et al.*, "Complications of chronic suppurative otitis media: a retrospective review," *Eur. Arch. Oto-Rhino-Laryngology*, vol. 270, no. 1, pp. 69–76, 2013.
- [4] O. Pakır, "Kronik süperatif otitis mediada medikal Tedavinin cerrahi tedavinin zamanlamasındaki Rolü," Zonguldak Üniversitesi, 2015.
- [5] Z. Cömert and A. F. Kocamaz, "Fetal Hypoxia Detection Based on Deep Convolutional Neural Network with Transfer Learning Approach," in *Software Engineering and Algorithms in Intelligent Systems*, 2019, pp. 239–248.
- [6] E. Deniz, A. Sengür, Z. Kadiroğlu, Y. Guo, V. Bajaj, and Ü. Budak, "Transfer learning based histopathologic image classification for breast cancer detection," *Heal. Inf. Sci. Syst.*, vol. 6, no. 1, p. 18, 2018.
- [7] Z. Cömert, A. Şengür, Y. Akbulut, Ü. Budak, A. F. Kocamaz, and V. Bajaj, "Efficient approach for digitization of the cardiocography signals," *Phys. A Stat. Mech. its Appl.*, vol. 537, p. 122725, Jan. 2020.
- [8] Ü. Budak, Y. Guo, E. Tanyildizi, and A. Şengür, "Cascaded deep convolutional encoder-decoder neural networks for efficient liver tumor segmentation," *Med. Hypotheses*, vol. 134, p. 109431, Jan. 2020.
- [9] U. Budak, V. Bajaj, Y. Akbulut, O. Atila, and A. Sengur, "An Effective Hybrid Model for EEG-Based Drowsiness Detection," *IEEE Sens. J.*, vol. 19, no. 17, pp. 7624–7631, 2019.
- [10] D. D. Heck Junior, V., Wangenheim, A.v., Abdala, "Computational Techniques for Accompaniment and Measuring of Otology Pathologies," pp. 0–5, 2007.

- [11] C. K. Shie, H. T. Chang, F. C. Fan, C. J. Chen, T. Y. Fang, and P. C. Wang, "A hybrid feature-based segmentation and classification system for the computer aided self-diagnosis of otitis media," *2014 36th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBC 2014*, pp. 4655–4658, 2014.
- [12] H. C. Myburgh, W. H. Van Zijl, D. Swanepoel, S. Hellström, and C. Laurent, "EBioMedicine Otitis Media Diagnosis for Developing Countries Using Tympanic Membrane Image-Analysis," vol. 5, pp. 156–160, 2016.
- [13] E. Başaran, A. Şengür, Z. Cömert, Ü. Budak, Y. Çelik, and S. Velappan, "Normal and Acute Tympanic Membrane Diagnosis based on Gray Level Co-Occurrence Matrix and Artificial Neural Networks," in *2019 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 2019, pp. 1–6.
- [14] E. Başaran, Z. Cömert, and Y. Çelik, "Convolutional neural network approach for automatic tympanic membrane detection and classification," *Biomed. Signal Process. Control*, vol. 56, p. 101734, Feb. 2020.
- [15] C. Zafer, "Fusing fine-tuned deep features for recognizing different tympanic membranes," *Biocybern. Biomed. Eng.*, Nov. 2019.
- [16] J. Szaleniec *et al.*, "Artificial neural network modelling of the results of tympanoplasty in chronic suppurative otitis media patients," *Comput. Biol. Med.*, vol. 43, no. 1, pp. 16–22, 2013.
- [17] X. Wang, T. A. Valdez, and J. Bi, "Detecting tympanostomy tubes from otoscopic images via offline and online training," *Comput. Biol. Med.*, vol. 61, pp. 107–118, 2015.
- [18] V. Bajaj, M. Pawar, V. K. Meena, M. Kumar, A. Sengur, and Y. Guo, "Computer-aided diagnosis of breast cancer using bi-dimensional empirical mode decomposition," *Neural Comput. Appl.*, 2017.
- [19] Z. Zhao, Y. Zhang, Z. Comert, and Y. Deng, "Computer-Aided Diagnosis System of Fetal Hypoxia Incorporating Recurrence Plot With Convolutional Neural Network," *Front. Physiol.*, vol. 10, p. 255, 2019.
- [20] M. Toğaçar, B. Ergen, and Z. Cömert, "Detection of lung cancer on chest CT images using minimum redundancy maximum relevance feature selection method with convolutional neural networks," *Biocybern. Biomed. Eng.*, Nov. 2019.
- [21] M. Toğaçar and B. Ergen, "Deep Learning Approach for Classification of Breast Canser," in *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, 2018, pp. 1–5.
- [22] A. Feng-Ping and L. Zhi-Wen, "Medical image segmentation algorithm based on feedback mechanism convolutional neural network," *Biomed. Signal Process. Control*, vol. 53, p. 101589, Aug. 2019.
- [23] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*, 2012, pp. 1097–1105.
- [24] A. Arı, "Derin Öğrenme Tabanlı Beyin Mr Görüntülerinden Beyin Tümörlerinin Tespit Edilmesi Ve Sınıflandırılması," İnönü University, 2019.
- [25] F. İ. Eyiokur, D. Yaman, and H. K. Ekenel, "Sketch classification with deep learning models," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 2018, pp. 1–4.
- [26] C. Szegedy *et al.*, "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1–9.
- [25] Y. Altuntaş, A. F. Kocamaz, Z. Cömert, R. Cengiz, and M. Esmeray, "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)*, 2018, pp. 1–5.
- [27] A. Gómez-Ríos, S. Tabik, J. Luengo, A. Shihavuddin, B. Krawczyk, and F. Herrera, "Towards highly accurate coral texture images classification using deep convolutional neural networks and data augmentation," *Expert Syst. Appl.*, vol. 118, pp. 315–328, Mar. 2019.
- [28] S. Raghun, N. Sriraam, Y. Temel, S. V. Rao, and P. L. Kubben, "EEG based multi-class seizure type classification using convolutional neural network and transfer learning," *Neural Networks*, Jan. 2020.
- [29] Z. Cömert and A. Kocamaz, "A Study of Artificial Neural Network Training Algorithms for Classification of Cardiotocography Signals," *Bitlis Eren Univ. J. Sci. Technol.*, vol. 7, no. 2, pp. 93–103, Dec. 2017.