
Araştırma Makalesi / Research Article

Otitis Media İçin Evrimsel Sinir Ağlarına Dayalı Bütünleşik Bir Tanı Sistemi

Zafer CÖMERT*

*Samsun Üniversitesi, Yazılım Mühendisliği Bölümü, Samsun, Türkiye
(ORCID: 0000-0001-5256-7648)*

Öz

Otitis media (OM) bir dizi iltihaplı orta kulak rahatsızlıklarını temsil eden tıbbi bir kavramdır. OM dünya genelinde, özellikle çocukluk çağında, görülen en yaygın hastalıklardan biridir. Klinik pratikte OM tanısı, otoskop cihazıyla elde edilen orta kulak görüntüsünün kulak buran boğaz uzmanları tarafından incelenmesiyle gerçekleştirilir. İncelemenin subjektif olarak yapılması, gözlemciler arasında değişkenliklerin ortaya çıkmasına neden olmaktadır. Aynı zamanda, bu alanda bilgisayar destekli sistemlerinin kullanımının da yeteri kadar yaygın olmadığı görülmektedir. OM rahatsızlıklarının zamanında teşhis edilememesi, hastalıkların ilerlemesine ve buna bağlı olarak da işitme, konuşma ve bilişsel rahatsızlıkların ortaya çıkmasına neden olmaktadır. Tüm bu dezavantajların üstesinden gelmek üzere, bu çalışmada OM teşhisi için önceden eğitilmiş evrimsel sinir ağlarına dayalı bütünleşik bir tanı sistemi önerilmiştir. Deneysel çalışmalar, Özel Van Akdamar Hastanesinde gönüllü hastalardan toplanan ve toplamda beş farklı sınıfa temsil eden 898 adet otoskop imgeleri üzerinde gerçekleştirilmiştir. Sonuç olarak, önerilen model %82.16 sınıflandırma başarısı sağlanmıştır. Evrimsel sinir ağlarına dayalı önerilen modelin sağladığı uçtan uca öğrenme ve yüksek hassasiyetle, OM teşhisinin objektif bir şekilde yapılabilmesi ve tanı sürecinde hekimlerin karar verme sürecinin desteklenmesi sağlanabilir. Önerilen yöntem bu açılardan umut verici sonuçlar üretmiştir.

Anahtar kelimeler: Biyomedikal işaret işleme, Tanı sistemi, Otitis media, evrimsel sinir ağları.

An Integrated Diagnosis System Based on Pretrained Deep Convolutional Neural Networks for Otitis Media

Abstract

Otitis media (OM) is a medical concept representing a range of inflammatory middle ear disorders. OM is one of the most common diseases worldwide, especially in childhood. In clinical practice, the diagnosis of OM is carried out by examining the images of the middle ear obtained via the otoscope device by specialists. The subjective examination leads to arise the variabilities among observers. At the same time, the use of computer-aided systems in this area is not common enough. Failure to diagnose OM disorders in a timely manner leads to the progression of the diseases, the emergence of hearing, speech, and cognitive disorders. To overcome all these disadvantages, an integrated diagnostic system based on the pretrained deep convolutional neural networks is proposed for the diagnosis of OM in this study. Experimental studies were carried out on 898 otoscope images, representing five different classes, collected from volunteer patients admitted to Özel Van Akdamar Hospital. As a result, the proposed model achieved 82.16% classification success. With the end-to-end learning and high sensitivity provided by the proposed model based on convolutional neural networks, OM diagnosis can be realized objectively and physicians' decision-making process can be supported using this system. The proposed method has produced promising results in these respects.

Keywords: Biomedical signal processing, Diagnosis system, Otitis media, Convolutional neural networks.

*Sorumlu yazar: zcomert@samsun.edu.tr

Geliş Tarihi: 02.08.2019, Kabul Tarihi: 18.11.2019

1. Giriş

Otitis media (OM) bir dizi iltihaplı orta kulak rahatsızlığını temsil eden ve orta kulaktaki herhangi bir enflamasyonu işaret etmek üzere kullanılan tıbbi bir kavramdır [1]. OM rahatsızlıkları işitme kaybına neden olan en önemli etkenlerden biridir ve genellikle çocukluk döneminde ortaya çıkmaktadır [2,3].

Etyoloji, süre, fiziki muayene bulguları, çeşitli ve değişen semptomlara bağlı olarak OM farklı kategoriler altında değerlendirilmektedir [4]. OM'nin en yaygın tipleri arasında akut otitis media (AOM), effüzyonlu otitis media (EOM), kronik süperatif otitis media (CSOM) ve kulak kiri (buşon) listelenmektedir [5]. AOM için otalji (kulak ağrısı), ateş, otore (kulak akıntısı), iştahsızlık, kusma ve ishal gibi rahatsızlıkların bir ya da birkaçı beraber görülebilir [6]. Bu rahatsızlıklara ilaveten timpanik membranda (kulak zarında) opasite, bombeleşme, kızarıklık, effüzyon ve pnömotik otoskopide azalmış zar hareketliliği de mutlak suretle gözlemlenmelidir. EOM, AOM'de ifade edilen bulguların gözlemlenmediği effüzyonlu durumları işaret etmektedir ve genellikle AOM sonrasında ortaya çıkmaktadır [7]. CSOM ise altı haftayı aşan kronik inflamasyonu işaret eder ve bu rahatsızlığa perfore (yırtılmış) bir timpanik membran ve otore eşlik eder. Aşılama ve antibiyotik OM rahatsızlıklarının tedavisinde ve önlenmesinde yaygın olarak kullanılmaktadır. Ayrıca, OM türlerinin tespiti ve uygun tedavi programlarının uygulanması için çeşitli kılavuzlar da hali hazırda yayımlanmış durumdadır [8,9].

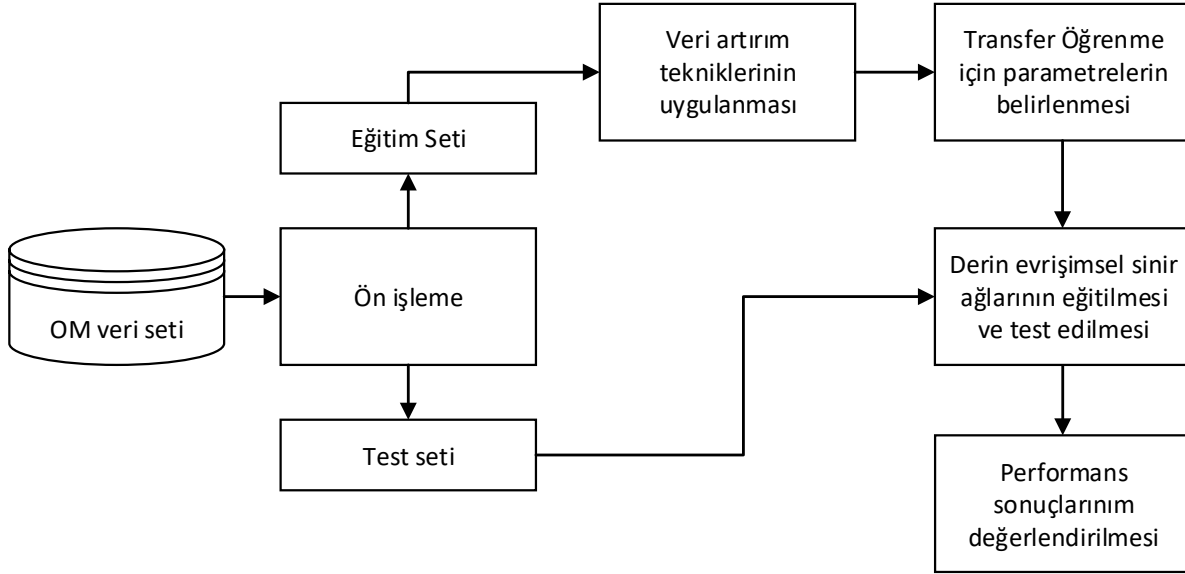
Bilgisayar destekli sistemlerin bu alanda kullanımının oldukça sınırlı olduğu görülmektedir [10]. Literatür incelendiğinde, AOM, EOM ve effüzyon olmayan zarların kategorize edilmesini içeren çok-sınıflı bir sınıflandırma görevi için *kelime* ve *gramer* yapısına dayanan bir model önerilmiştir. Önerilen model, OM hastalıklarına dair olası durumları ifade eden bir *kelime* setine, bir başka ifadeyle özellik setine sahip olup, *gramer* yapısı ise bir karar ağacına dayalı olarak sınıflandırma kurallarını içeren bir yapıyı temsil etmektedir. Karar sürecinde önerilen modelin %89.9'lük bir başarıya sahip olduğu rapor edilmiştir [11]. Bir başka çalışmada renk dağılımları ve imge işleme tekniklerine dayanan bir model önerisi yapılmıştır. Model, renk bileşenlerinin olasılık dağılım fonksiyonunu, Bayesian karar kuralları ve iki regresyon modelini kullanmıştır. Sonuç olarak, tek başına renk bilgisinin kullanımının OM teşhisi için yeterli olmadığı ifade edilmiştir [12]. Bir başka çalışmada, Cyclops Auris Wizard olarak adlandırılmış günlük kliniksel uygulamalar için geliştirilmiş bir araç duyurulmuştur. Söz konusu araç, dijital görüntü işleme ve geometri tekniklerini kullanarak kulak zarındaki yırtılma oranını ölçebilmektedir [13]. Segmentasyon, özellik çıkarımı, özellik seçimi ve sınıflandırma adımlarını izleyen hibrit bir sistem başka bir çalışmada önerilmiştir. AdaBoost topluluk öğrenme algoritmasını kullanan model %88.06 sınıflandırma doğruluğu sağlamıştır [14]. Global imge özellikleri ve altı farklı makine öğrenmesi algoritmasının OM teşhisi üzerindeki başarımları bir başka çalışmada incelenmiştir. Deneysel sonuçlar, en iyi performansın %72.04'lük sınıflandırma doğruluğu ile destek vektör makinesi (DVM) tarafından sağlandığını göstermiştir [15]. Bir diğer çalışmada, AOM, EOM, buşon, kulak zarının önündeki yabancı cisimleri ve normal kulak zarını otomatik olarak tanıyabilen bir model duyurulmuştur. Model başarımları %80.6 olarak ifade edilmiştir [16]. Bir başka çalışmada ise, akıllı telefon ve bulut tabanlı bir tanı sistemi önerisi yapılmıştır. İmge işleme ve sinir ağlarına dayalı geliştirilen model, beş farklı OM tipi için %81.58'lik sınıflandırma başarımları sağlamıştır [17].

Günümüzdeki gelişmiş imge işleme ve yapay zekâ destekli uygulamalarda yaşanan ilerlemeler nedeniyle işaretler üzerinde, bir başka ifadeyle sinyallere ve imgelere dayalı bilgisayar destekli analizlerde, kayda değer mesafeler kat edilmiştir. Bu kapsamda, günden güne popüleritesi artan yöntemlerden biri de evrimsel sinir ağlarıdır ve bu ağlar geniş bir uygulama alanına sahiptir [18–23]. Bu noktadan hareket ile bu çalışmada, önceden eğitilmiş evrimsel sinir ağlarına dayalı entegre bir OM tanı modeli önerilmiştir. Bu kapsamda, AlexNet [24], VGG-16, VGG-19 [25], GoogLeNet [26], ResNet-18, ResNet-50, ResNet-101 [27] ve Inception-v3 [28] ağları kullanılmıştır. Önerilen model hem objektif bir değerlendirmenin yapılabilmesi hem de karar verme sürecinde alan uzmanlarını desteklemesi açısından umut verici sonuçlar üretmiştir.

Bu çalışmanın geriye kalan bölümleri şu şekilde organize edilmiştir: Bölüm 2'de çalışmaya konu olan veri seti ve kullanılan yöntemler özetlenmiştir. Bölüm 3'de elde edilen bulgular sunulmuştur. Bölüm 4'de deneysel parametreler ve ilgili çalışmalar dikkate alınarak bir tartışma sunulmuştur. Bölüm 5'de ise sonuç ifadelerine yer verilmiştir.

2. Materyal ve Metotlar

Bu çalışmada toplamda beş sınıftan oluşan OM türlerinin otomatik tespiti için evrimsel sinir ağlarına dayalı entegre bir model önerisi yapılmıştır. Önerilen modelin blok şemasına Şekil 1’de yer verilmiştir.



Şekil 1. Önerilen modelin blok şeması

Otoskop görüntüleri önerilen modele girdi olarak uygulanmadan önce bir ön işleme sürecinden geçirilmiştir. Bunun temel nedeni önceden eğitilmiş evrimsel sinir ağlarının sabit boyutta bir veri girişi kabul etmesidir. Bir başka ifadeyle, ön işleme aşamasında sadece otoskop görüntülerinin yeniden boyutlandırılması sağlanmıştır. Sonraki adımda, sadece eğitim setinde kullanılan otoskop görüntüleri üzerinde, çevrimdışı stratejiyle imge artırma yöntemleri uygulanmıştır. Daha sonra, transfer öğrenme stratejisiyle derin evrimsel sinir ağları eğitilmiş ve son adımda performans sonuçları değerlendirilmiştir.

2.1. Veri Seti

Bu çalışmada toplada beş sınıftan oluşan ve 898 adet otoskop görüntüsünden oluşan bir veri seti kullanılmıştır. İlgili veri seti, 10/2018 ve 06/2019 tarihleri arasında Özel Van Akdamar Hastanesinde muayene olan gönüllü hastalardan toplanmıştır. Kayıtların toplanması için gerekli olan etik kurul kararı/izni yetkili mercilerden alınmıştır.

Tablo 1. OM veri setinde kayıtların sınıflar arasındaki dağılımı

Sınıf	Kayıt Sayısı
AOM	119
Buşon	140
CSOM	63
Eksterna	41
Normal	535
Toplam	898

Kayıtların sınıflar arasındaki dağılımlarına Tablo 1’de yer verilmiştir. Orijinal veri seti aslında 958 imge ve dokuz sınıf içermesine rağmen, yetersiz kayıt sayısı nedeniyle sadece Tablo 1’de ifade edilen sınıflar ve kayıtlar dikkate alınmıştır.

Kayıtlar standart bir otoskop cihazı yardımıyla toplanmıştır. Hastalardan alınan görüntüler bir USB arayüzü ile bilgisayara aktarılmıştır. Her bir rahatsızlık türü için ayrı bir klasör oluşturularak söz konusu kayıtların ilgili klasöre yerleştirilmesi sağlanmıştır. Aynı hastalardan alınan ardışık görüntüler,

yetersiz ışık, el titremesi vb. nedenlerle kalitesi düşük olan imgeler de veri setinden izole edilmiştir. Kayıtların sınıflandırılması alan uzmanları tarafından yapılmıştır.


2.2. İmge Artırım Teknikleri

Veri artırım ya da imge artırım teknikleri, evrimsel sinir ağı gibi eğitim aşamasında fazla veriye ihtiyaç duyan ağların eğitiminde, veri sayısının yeterli olmaması durumunda kullanılan verimli yöntemlerdir [29]. Bu kapsamda aynalama, döndürme, ölçekleme, kesme, geçiş ve gürültü gibi yöntemler, yaygın bir şekilde kullanılmaktadır. Dahası, daha gelişmiş artırım yöntemleri arasında rekabetçi ağlar, interpolasyon ve makine öğrenmesi gibi farklı yöntemler de kullanılmaktadır [30]. Veri artırımının eğitim öncesinde yapılması çevrimdışı; eğitim sırasında yapılması ise çevrimiçi veri artırım stratejisi olarak ifade edilmektedir.

Tablo 2. Artırım sonrası verilerin eğitim ve test setlerine göre dağılımı

Sınıf	Eğitim seti	Test seti
AOM	664	36
Buşon	784	42
CSOM	352	19
Eksterna	232	12
Normal	3000	160
Toplam	5032	269

Bu çalışmada, imge artırım yöntemleri olarak sadece aynalama ve döndürme yöntemleri kullanılmıştır. Aynalama yatay ve dikey eksenler yönünde gerçekleştirilmiştir, böylelikle her imgeye ait iki adet ek imge elde edilmiştir. Daha sonra aynalanmış görüntüler üzerine döndürme işlemi sırasında ise 90, 180 ve 270 derecelik açılar kullanılmıştır. Sonuç olarak her bir orijinal imge, toplamda sekiz adet imgeyle temsil edilmiştir. Örnek bir otoskop görüntüsüne ait artırım sonuçlarına Şekil 2’de yer verilmiştir.



Şekil 2. Artırım sonrası örnek bir otoskop görüntüsünün temsili

Deneyisel çalışmada tüm veri seti %70 oranında eğitim ve %30 oranında test seti olarak iki bölüme ayrılmıştır. Veri artırım teknikleri sadece eğitim seti üzerinde uygulanmıştır. Ağın aşırı öğrenmesini engellemek ve benzer imgelerin test kümesinde kullanılmasını engellemek üzere, test veri setinde herhangi bir veri artırım prosedürü uygulanmamıştır. Böylelikle toplamda 5032 adet otoskop görüntüsünün ağların eğitimi için kullanılması sağlanırken; test veri kümesi için sadece 269 adet otoskop görüntüsü dikkate alınmıştır. Bu bağli olarak, artırım yapılmış veri setindeki kayıtların dağılımına Tablo 2’de yer verilmiştir.

2.3. Derin evrişimsel sinir ağları

Evrişimsel sinir ağları, imge gibi iki-boyutlu ızgara-benzeri bir topolojiye sahip veriler üzerinde kullanılabilen sinir ağlarının özel bir türü olarak ifade edilebilir. Bu ağların temel matematiksel arka planı evrişim prosedürüne dayanır. Bir başka ifadeyle, ileri yönlü sinir ağlarından temel farkı genel matris çarpımı yerine, evrişim işlemi kullanmasıdır [19].

Derin öğrenme uygulamalarında genellikle birden fazla boyut vardır. Bu nedenle, giriş dizisi ve çekirdek fonksiyonu çok boyutludur. Ancak, evrişim işlemi aynı anda birden fazla eksen üzerinde uygulanabilmektedir [20]. Dolayısıyla evrişim işlemi Denklem (1)'deki gibi ifade edilebilir.

$$\hat{y}(i, j) = \sum_m \sum_n x(i - m, j - n) \omega(m, n) \quad (1)$$

burada i ve j iki boyutlu girişin indis değerlerini gösterirken m ve n ise çekirdek dizisinin indis değerlerinin göstermektedir.

Evrişim işleminin sonucunda kullanılan filtre/çekirdek yapısına bağlı olarak \hat{y} 'nin boyutu, x 'den küçük olabilir. Buradaki boyut sorununu çözmek üzere *dolgu (padding)* ve *adım (stride)* fonksiyonları kullanılmaktadır.

Havuzlama (pooling) evrişimsel sinir ağlarında kullanılan bir diğer katmandır. Havuzlama katmanı özellik haritasının boyutunu düşürmek üzere kullanılır. *Maksimum-havuzlama* ve *ortalama-havuzlama* bu amaçla kullanılan temel operatörlerdir. Bu fonksiyon Denklem (2)'de gösterildiği gibi modellenebilir:

$$\hat{y}_j^l = \text{down}(\hat{y}_j^{l-1}) \quad (2)$$

Evrişimsel sinir ağları seyrek etkileşim, parametre paylaşımı ve geçiş eşdeğerliği gibi özellikleriyle yüksek bir genelleştirme performansı sergilemektedir [19]. Klasik sinir ağlarında her çıkış düğümü giriş düğümüyle bir bağlantıya sahiptir. Ancak, evrişimsel sinir ağlarında bu bağlantılar seyrek olabilmektedir. Bir başka ifadeyle, her giriş düğümüyle çıkış düğümü arasında doğrudan bir bağlantı olmayabilir. Parametre paylaşımında ise mimaride yer alan bir parametrenin ağırlığı model içindeki birden fazla nöronda da kullanılabilir. Son olarak, geçiş eşdeğerli şu şekilde ifade edilebilir: eğer girişte bir geçiş (transition) varsa, çıkışta da aynı yöntemle bir geçiş elde edilebilir. Yani, lokal ayırt edici özelliklerin oluşturulduğu bir aktivasyon haritası, evrişim işlemiyle, aynı yolla, çıkışa doğru iletilebilir.

Özetle evrişimsel sinir ağları bir dizi evrişim, havuzlama ve tam bağlı katmandan meydana gelen ileri beslemeli yapay sinir ağlarının özel bir türü olarak değerlendirilebilir. Bu ağların eğitimi sırasında, Gradyan iniş optimizasyon algoritmaları ya da bu algoritmaların RMSProp ve ADAM gibi türevlerinden faydalanılır [20,30]. Gradyan iniş algoritmalarının temel amacı maliyet fonksiyonunu (\mathcal{L}) minimize etmektedir. Bu amaçla, giriş değerleri ve çıkış değerleri, $f(x)$ ile ifade edilen bir modelin maliyet fonksiyonunu minimize etmek için kullanılır. Burada, x giriş değerlerini ve y çıkış değerlerini temsil eder. Denetimli öğrenme yöntemlerinde yapılan tahmin Denklem (3)'deki gibi modellenir.

$$\hat{y} = f(x) \quad (3)$$

Dolayısıyla maliyet fonksiyonu $\mathcal{L}(y, \hat{y})$ olarak tanımlanır. Daha açık bir ifadeyle, maliyet fonksiyonu modelin çıktısıyla, hedef değer arasındaki fark olarak tanımlanır. Bu durumda, Denklem (3), $\mathcal{L}(y, f(x))$ şeklinde düzenlenebilir. Modeller, ağırlıklara (ω) sahip olduğundan ve optimizasyon işlemleri ağırlıklar dikkate alınarak yapıldığından, modeli temsil eden $f(x)$ fonksiyonu $f_\omega(x)$ şeklinde yazılır. Maliyet fonksiyonunu minimize etmek amacıyla, parametre alanındaki en dik iniş yönünü bulmak için ağırlıkların gradyanları (eğimleri) kullanılır [31]. Ağırlık vektörü ω yinelemeli bir şekilde Denklem (4)'de ifade edildiği gibi güncellenir.

$$\omega_t = \omega_{t-1} - \eta * g_t \quad (4)$$

$$g_t = \nabla_w \mathcal{L}(f_\omega(x), y) \quad (5)$$

burada t anındaki gradyan, g_t , Denklem (5)'deki gibi tanımlanır. $\eta \in (0,1)$ olmak üzere, η güncellemelerdeki adım oranını/ölçüsünü gösteren öğrenme oranıdır ve ∇_w ağırlık vektörüne bağlı gradyan olarak tanımlanır. Maliyet fonksiyonu $\mathcal{L}(f_w(x), y)$ farklı formlarda kullanılabilir. Basit bir regresyon problemi için maliyet fonksiyonu kare hataların toplamı şeklinde tanımlanır ve Denklem (6)'daki gibi açıklanır.

$$\mathcal{L} = \frac{1}{2} \sum_i^N (\hat{y}_i - y_i)^2 = \frac{1}{2} \sum_i^N (f_w(x_i) - y_i)^2 \quad (6)$$

burada N toplam kayıt sayısını göstermektedir.

Stokastik gradyan iniş algoritmasında ise verinin bütünü yerine sadece bir alt kümesi kullanılır. Güncelleme sırasında verinin rastgele sıralanmasını dikkate alır ve Denklem (7)'deki gibi tanımlanır.

$$\mathcal{L} = \frac{1}{2} \sum_i^M (f_w(x_i) - y_i)^2 \quad (7)$$

burada $1 \leq M < N$ 'dir. Çalışma kapsamında kullanılan ağlarda optimizasyon algoritması olarak Stokastik momentumlu gradyan iniş algoritması kullanılmıştır.

Daha önce ifade edildiği üzere, bu çalışma kapsamında önceden eğitilmiş ve iyi bilinen derin evrişimsel sinir ağları kullanılmıştır. AlexNet bu modellerden öncü olarak kabul edilebilir. Bu model, imgelerin giriş boyutunun 227×227 boyutunda olmasını gerektirir. Mimarinin derinliği 8'dir ve 61 milyon hesaplamalı parametreye sahiptir [24].

VGG-16 ve VGG-19 modelleri ise ağ derinliğinin arttırıldığı, tasarım ve derinlik kavramlarını ön plana alan ve yaygın bir şekilde kullanılan derin evrişimsel sinir ağlarından biridir. Model giriş boyutu olarak 224×224 boyutundaki imgelerin kullanılmasını zorunlu kılmaktadır. VGG-16 138 milyon ve VGG-19 144 milyon hesaplamalı parametreye sahiptir [25].

Önemli ve dikkat çekici bir diğer model ise GoogLeNet'dir. Inception modülüyle ağ içinde kısa bağlantıların yapılabilirdiği ve hesaplama maliyetini düşüren bir modeldir. Sadece 7 milyon hesaplamalı parametreye sahiptir. Giriş boyutu olarak 224×224 boyutundaki imgeleri kabul etmektedir [26].

ResNet modelleri ise kalıcı bir öğrenme çerçevesi niteliğiyle duyurulmuştur. ResNet-18, ResNet-50 ve ResNet-101 sırasıyla 11.7, 25.6 ve 44.6 milyon hesaplamalı parametreye sahiptir. Model temel olarak soyutlama işleminde bozulma problemi üzerinde odaklanmıştır. Mimarisindeki artık bloklar ve derinlik ile diğer modellerden ayrılmaktadır [27].

Inception-v3 çeşitli tasarım prensipleri ile evrişimsel sinir ağlarını büyütmeyi amaçlayan bir modeldir. Daha basit ve daha monolitik mimarilere kıyasla nispeten mütevazı bir hesaplama maliyetine sahip, yüksek performanslı bir ağ yapısı sunmaktadır. Modelin derinliği 48, hesaplamalı parametre sayısı ise 23.9 milyondur. Giriş boyutu olarak imgelerin 299×299 olmasını zorunlu kılmaktadır [28].

2.4. Transfer öğrenme

Evrişimsel sinir ağları yüksek-seviyeli soyutlama temsili için oldukça kullanışlı olarak kabul edilir. Evrişimsel sinir ağlarının her bir katmanında, yeni özellik soyutlaması yapılır ve düşük-seviyeli soyutlamalar sonraki katmanlarda yeniden kullanılabilir ya da oluşturulabilir [18]. Bazı özellikler, örneğin el yazısı tanıma gibi bir problem için verimsiz olabilirken, yüz tanıma gibi başka bir problem alanında önemli olabilir. Bu nedenle mümkün olduğunca çok veri ve sınıf içeren bir veri setiyle eğitilmiş modellerin ağırlıklarından transfer öğrenme metodu ile faydalanılabilir [23]. Transfer öğrenme sınıf sayısının geniş ağlara göreceli az ve veri sayısının kısıtlı olduğu durumlarda oldukça faydalı olabilir.

Bu çalışmadaki transfer öğrenme stratejisi, ağların sadece son birkaç katmanı üzerinde değişiklik yapıp, ilk katmanlardaki ağırlıkların dondurularak kullanılması stratejisine dayanmaktadır. Transfer öğrenme için kullanılan parametreler Tablo 3'de özetlenmiştir. Mini-topluluk-boyutu her bir eğitim iterasyonu için kullanılan kayıt sayısıdır ve eğitim setinin altkümelerinden oluşur. Ağların eğitim sürecinde, maliyet fonksiyonunun değerlendirilmesinde ve ağ ağırlıklarını güncellemede kullanılır. Maksimum çağ, ağ eğitimi için kullanılacak maksimum çağı ifade eder. Bir çağ, tüm eğitim setinin,

eğitim algoritmasından tam geçişini açıklamaktadır. Doğrulama sıklığı iterasyon sayısı ile doğrulama metriklerinin değerlendirilmesi arasındaki sıklığı gösterir. Öğrenme oranı düşürme katsayısı ve öğrenme oranı düşürme periyodu, başlangıç öğrenme oranının, çağ sayısını dikkate alarak güncellenmesini ve dolayısıyla daha verimli bir öğrenmenin gerçekleşmesini sağlar.

Tablo 3. Transfer öğrenme parametreleri ve değeri

Parametre	Değeri
Mini-topluluk-boyutu	32
Maksimum çağ	64
Başlangıç öğrenme oranı	0.0001
Doğrulama sıklığı	50
Öğrenme oranı düşürme katsayısı	0.1
Öğrenme oranı düşürme periyodu	16

2.5. Performans metrikleri

Bu çalışmada, dikkate alınan ağların performanslarını ölçmek üzere hata matrisi ve alıcı-işletim-karakteristiği (AİK) eğrileri kullanılmıştır. Hata matrisi, gerçek ve tahmin edilen kayıtların tutulduğu bir matristir ve temel olarak dört indisten meydana gelir. Doğru pozitif (DP) ve doğru negatif (DN), doğru bir şekilde tanımlanmış pozitif ve negatif kayıtların sayısını ifade ederken, Yanlış Pozitif (YP) ve Yanlış Negatif (YN) yanlış şekilde tahmin edilmiş pozitif ve negatif sınıflara ait kayıtların sayısını temsil etmektedir [32]. Buna göre, hata matrisinden türetilen doğruluk, duyarlılık ve özgüllük metrikleri Denklem (8) – (10) arasında gösterildiği gibi hesaplanır.

$$Doğruluk = \left(\frac{DP + DN}{DP + YP + YN + DN} \right) \quad (8)$$

$$Duyarlılık = \frac{1}{N} \sum_{i=1}^N \left(\frac{DP_i}{DP_i + YN_i} \right) \quad (9)$$

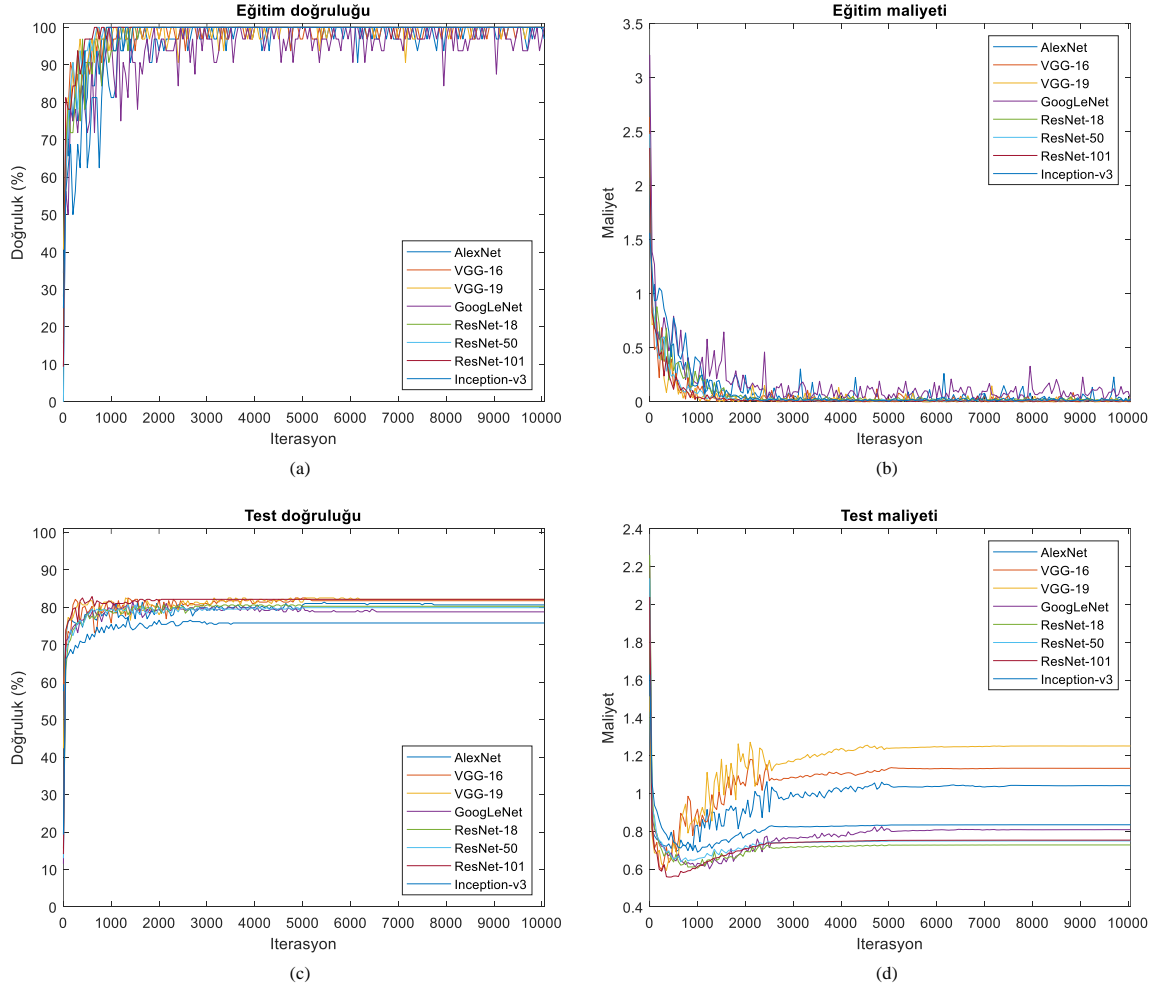
$$Özgüllük = \frac{1}{N} \sum_{i=1}^N \left(\frac{DN_i}{DN_i + YP_i} \right) \quad (10)$$

burada N sınıf sayısını temsil etmektedir.

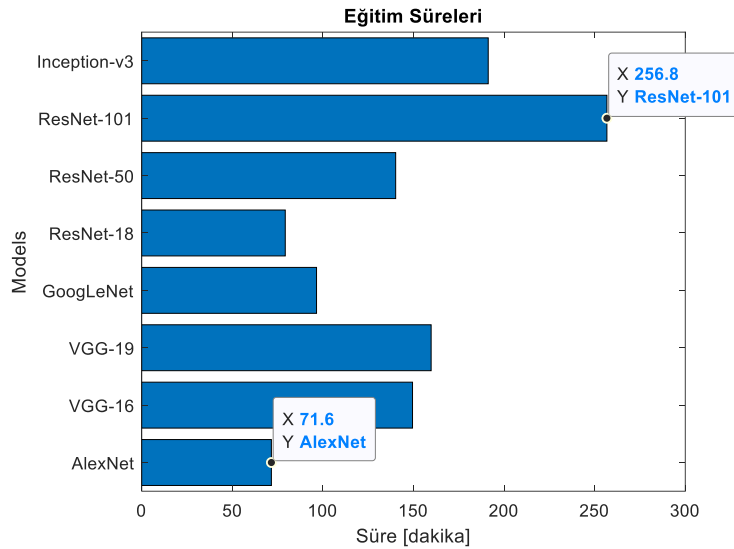
AİK eğrileri modellerin her bir sınıfı ayırt etme başarısını ölçmek üzere kullanılan verimli yöntemlerden biridir. Bu eğrilerin altında kalan alanın olabildiğince bire yaklaşması arzu edilir. Bir başka ifadeyle, AİK eğrilerinin altında kalan alanın (EAA) bire yaklaşması sınıflandırmanın başarılı bir şekilde yapıldığına işaret eder [33–35].

3. Bulgular

Bu çalışmada evrimsel sinir ağlarının OM tanısı üzerindeki başarımı transfer öğrenme yaklaşımı kullanılarak incelenmiştir. Modelleri eğitmek ve test etmek üzere öncelikle veri seti %70 ve %30 oranlarında iki parçaya ayrılmıştır. Daha sonra ağ eğitimlerinin daha verimli olarak gerçekleştirilmesini sağlamak üzere sadece eğitim veri seti üzerinde imge artırım teknikleri uygulanmıştır. Aşırı öğrenmeyi engellemek üzere test seti üzerinde herhangi bir imge artırım yöntemi kullanılmamıştır. Yapılan eğitim ve doğrulama testlerine ait grafiklere Şekil 3’de yer verilmiştir. Veri artırım yöntemlerinin kullanılmasına bağlı olarak toplamda 5032 adet otoskop görüntüsü eğitim için kullanılmıştır. Mini-topluluk-boyutu 32 olarak ayarlandığından döngü başına 157 imge kullanılmış ve maksimum çağ sayısı 64 olarak ayarlandığı için eğitim işlemi toplamda 10048 iterasyonda tamamlanmıştır.



Şekil 3. Eğitim ve test kümeleri için doğruluk ve maliyet grafikleri



Şekil 4. Evrimsel sinir ağlarının eğitimi için geçen zaman

Şekil 3'de görüldüğü gibi eğitim veri setinde veri artırım işleminin yapılmasına bağlı olarak maliyet fonksiyonu sıfıra yaklaştırılabilmektedir. Test grafiklerine bakıldığında, 1000. iterasyondan önce maliyet fonksiyonunda ciddi bir düşüşün olduğu ancak daha sonra yakınsamanın durduğu ve yaklaşık

olarak 6000. iterasyondan sonra eğitim ve test kümesi üzerinde ciddi bir değişimin olmadığı görülmüştür.

Eğitim için harcanan süreler Şekil 4’de görselleştirilmiştir. AlexNet 71.6 dakikayla eğitimi en kısa sürede tamamlayan mimari olurken; ResNet-101 256.8 dakikayla eğitimi en geç sürede tamamlayan mimari olarak tespit edilmiştir.

Eğitim ve doğrulama işlemlerinin ardından elde edilen hata matrisleri Şekil 5’de sunulmuştur. İlgili hata matrislerinden türetilen doğruluk, duyarlılık ve özgüllük metrikleri ise Tablo 4’de rapor edilmiştir.

Hata matrislerindeki her satır ve sütun sırasıyla AOM, buşon, CSOM, OM eksterna ve normal sınıfları temsil etmektedir. Hata matrisleri incelendiğinde evrişimsel sinir ağlarının kayıt sayısı fazla olan sınıfları ayırt etme konusunda daha başarılı olduğu görülmüştür. Bu kapsamda, hata matrislerinde diyagonal örüntünün daha çok AOM, buşon ve normal sınıflar için belirgin olduğu ve göreceli CSOM ve OM eksterna sınıfları için modellerin ayırt etme gücünün daha az olduğu saptanmıştır.

Performans sonuçları incelendiğinde en düşük başarıyı %77.32 sınıflandırma doğruluğu ile Inception-v3 modelinin verdiği, buna karşın en verimli sonuçların %82.16 sınıflandırma doğruluğu ile VGG-19 tarafından üretildiği görülmüştür. Sınıflandırıcı performansında özgüllük değerinin baskın olduğu, ancak duyarlılık değerlerinin ise nispeten daha düşük olduğu gözlemlenmiştir. Bu durumun temel nedeni ise verilerin sınıflar arasındaki dengesiz dağılımı olarak tespit edilmiştir.

AİK eğrileri kayıt sayısı ve kayıtların sınıflar arasındaki dağılımından bağımsız olarak modellerin sınıf bazındaki başarılarını görselleştirmek ve ölçmek için benimsenmiş yöntemlerden biridir. Deneysel çalışmamızda kayıtların sınıflar arasındaki dağılımının eşit olmadığı göz önüne alındığında, daha doğru bulgulara erişmek üzere AİK eğrilerinin yorumlanması önem arz etmektedir. Modellerin AİK eğrilerine Şekil 6’da yer verilmiştir. Buna göre, göre AOM sınıfı için en başarılı sınıflandırma işlemi AlexNet tarafından yapılmıştır ve EAA değeri 0.9435 olarak elde edilmiştir. Buşon sınıfındaki sınıflandırma başarıyı ise AOM kıyasla daha iyi bir görünüme sahiptir. Daha spesifik olarak, buşon sınıfı için en iyi sonuçlar ResNet-18 mimarisine elde edilmiş ve EAA değeri 0.9722 olarak elde edilmiştir. CSOM sınıfındaki kayıt sayısının diğer sınıflara göre daha az olması nedeniyle AİK eğrilerinde genel görünüm diğer sınıflara kıyasla mütevazı kalmıştır. Ancak, ResNet-101 ile 0.9642’lik EAA değeri elde edilmiştir. OM eksterna kayıt sayısının en az olduğu sınıftır; buna karşın en iyi EAA değeri 0.9137 olarak ResNet-101 mimarisine elde edilmiştir. Normal OM sınıfı için genel görünüm iyi olmakla birlikte, en yüksek EAA değeri 0.9357 ile VGG-16 modeli tarafından sağlanmıştır.

Sonuç olarak, derin evrişimsel sinir ağlarının uçtan-uça öğrenme modeliyle OM teşhisinin başarılı bir şekilde yapılabildiği deneysel çalışmalar sonucunda ispatlanmıştır. Farklı derin evrişimsel sinir ağlarının farklı tiplerdeki OM türlerini ayırt etmede umut verici sonuçlar ürettiği görülmüştür.

27	2	1	0	6
0	34	1	0	7
3	1	5	3	7
1	1	0	6	4
7	6	1	1	145

(a) AlexNet

23	3	0	1	9
0	35	0	3	4
3	1	11	1	3
1	0	1	6	4
6	5	3	1	145

(b) VGG-16

23	3	0	1	9
1	37	0	0	4
2	1	11	1	4
0	0	0	8	4
8	8	1	1	142

(c) VGG-19

23	5	1	0	7
2	34	0	0	6
1	0	9	3	6
0	1	0	5	6
9	6	2	2	141

(d) GoogLeNet

22	3	1	0	10
1	35	0	1	5
2	1	11	2	3
0	4	1	3	4
5	7	2	1	145

(e) ResNet-18

19	2	1	0	14
0	38	0	0	4
3	1	9	1	5
0	2	1	5	4
7	4	1	0	148

(e) ResNet-50

20	4	0	0	12
1	34	0	0	7
2	1	10	1	5
0	2	1	6	3
7	8	1	0	144

(e) ResNet-101

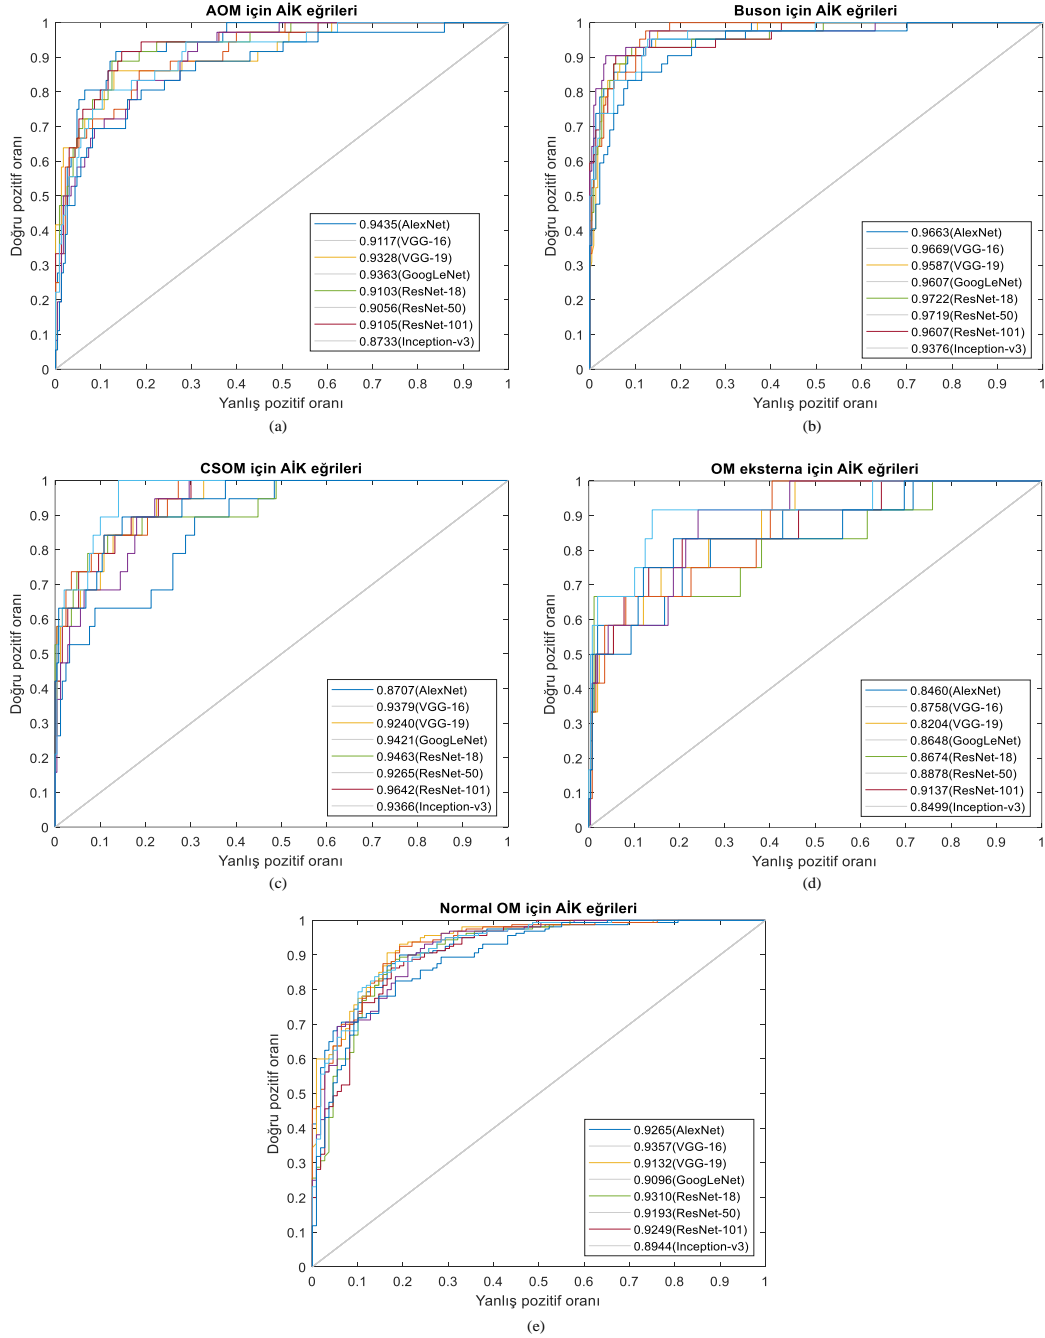
22	1	2	0	11
1	33	0	1	7
2	1	11	1	4
2	2	1	3	4
9	12	0	0	139

(e) Inception-v3

Şekil 5. Modellere ait hata matrisleri

Tablo 4. Performans sonuçları

Modeller	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
AlexNet	80.67	64.58	93.22
VGG-16	81.78	69.15	93.89
VGG-19	82.16	73.06	93.83
GoogLeNet	78.81	64.40	92.70
ResNet-18	80.30	63.59	93.32
ResNet-50	81.41	64.96	93.08
ResNet-101	79.55	65.83	92.63
Inception-v3	77.32	61.89	98.22

**Şekil 6.** Modellerin sınıflara ait AİK eğrileri (a) AOM (b) Buşon (c) CSOM (d) OM eksterna (e) normal

4. Tartışma

Bu bölümde öncelikle literatürde OM teşhisine hesaplamalı yöntemler ile yaklaşan çalışmalar odağa alınmıştır. Daha sonra, kullanılan yöntemler, kayıt sayıları, sınıf sayıları ve sınıflandırma başarımları da dikkate alınarak bir tartışma gerçekleştirilmiştir. Temel amaç otology alanında yapılan hesaplamalı yaklaşımların avantaj ve dezavantajlarını kıyaslamaktır. İlgili çalışmalar Tablo 5’de özetlenmiştir.

Literatürde yer alan ilgili çalışmalar incelendiğinde, genel olarak önışleme, bölütleme, özellik çıkarma, özellik seçme ve makine öğrenmesi yöntemlerine dayalı olarak sınıflandırma işleminin gerçekleştirildiği görülmektedir [11,12,14–17]. Özellik çıkarma ve özellik seçme algoritmaları zaman alıcı ve uygulama açısından maliyetli yöntemlerdir. Derin evrışimsel sinir ağlarına dayalı önerilen model, özellik çıkarma ve özellik seçme algoritmalarını kullanmadan, doğrudan veriden öğrenme imkânı sunmaktadır. Önerilen yöntem bu açıdan büyük bir avantaja sahiptir.

İlgili çalışmalarda kullanılan veri setleri dikkate alınarak bir inceleme gerçekleştirildiğinde, deneysel çalışmalarda özel veri setlerinin kullanıldığı ve ilgili veri setlerine açık erişimin olmadığı görülmektedir. Bu açıdan OM teşhisi için açık erişimli ilk veri seti araştırma gurubumuz tarafından alana kazandırılmıştır. Bu durum, farklı algoritma ve modellerin test edilmesini sağlamak üzere alana önemli bir katkı sağlayacaktır. Veri setlerinde yer alan sınıf sayıları dikkate alındığında ise en az iki en fazla beş sınıfa sahip problemler üzerinde çalışmaların yapıldığı görülmektedir. Önerilen model beş sınıflı sınıflandırma görevinde %82.16 ile en yüksek sınıflandırma doğruluğunu sağlamıştır. Ayrıca deneysel çalışmalarda kullanılan kayıt sayıları göz önüne alındığında, bu açıdan deneysel çalışmaların en geniş veri seti üzerinde gerçekleştirildiği açıktır.

Tablo 5. İlgili çalışmaların kıyaslanması

Yöntemler	Kayıt sayısı	Sınıf sayısı	Doğruluk (%)
Global imge özellikleri, en yakın komşu algoritması, karar ağacı, doğrusal ayırt edici analiz, Naive Bayes, DVM [15].	186	2	73.11
Renk dağılımları, Bayesian karar kuralları [12].	100	3	59.90
Kelime ve Gramer setleri karar ağacı [11].	181	3	89.90
Aktif kontur bölütlemesi, lokal ikili özellikler, AdaBoost [14].	865	4	88.06
Görsel özellikler ve karar ağacı [16].	486	5	80.61
Görsel özellikler, karar ağaçları, sinir ağları [17].	389	5	81.58
Bu çalışma, derin evrışimsel sinir ağları.	898	5	82.16

Derin evrışimsel modellerin karar destek sistemlerinde başarılı bir şekilde kullanımını sağlamak üzere geniş ölçekli veri setlerine ihtiyaç duyulmaktadır. Hastalıklara ait tüm durumları kapsayan bir veri seti elde etmek, pratikte çok zor hatta zaman zaman imkânsızdır. Bu nedenle derin evrışimsel sinir ağları gibi eğitim sırasında geniş ölçekli veri setlerine ihtiyaç duyan modellerin eğitilmesi için yeterli verinin sağlanması ciddi bir zorluk olarak ortaya çıkmaktadır. Bu da önerilen yöntemin en büyük dezavantajıdır. Bu nedenle dokuz farklı OM tipini içeren orijinal veri setindeki dört sınıf, yetersiz veri sayısı nedeniyle bu çalışmada dikkate alınmamıştır. Buna karşın beş sınıflı bir problem olarak ele alınan OM teşhisi için umut verici sonuçlar elde edilmiştir.

5. Sonuç ve Öneriler

OM dünya genelinde sıklıkla karşılaşılan ve yaygın olarak görülen bir rahatsızlıktır. OM hastalıklarının zamanında teşhis edilememesi ve uygun tedavi programının uygulanamaması işitme, konuşma ve bilişsel rahatsızlıklara neden olabilmektedir. Ayrıca alanda, tanı sürecinde gözlemciler arasında değişkenlikler gözlenmekte ve bilgisayar-destekli sistemlerin uzmanlar tarafından yeterince benimsenmediği görülmektedir. Bu dezavantajların üstesinden gelmek üzere bu çalışmada derin evrışimsel sinir ağlarına dayalı bütünleşik bir tanı modeli önerilmiştir.

Sekiz farklı önceden eğitilmiş derin evrışimsel model çalışma kapsamında değerlendirilmiştir. Deneysel çalışmalar, araştırma gurubumuz tarafından oluşturulmuş ve açık-erişimli olarak

araştırmacıların kullanımına açılmış bir veri seti üzerinde gerçekleştirilmiştir. Beş farklı OM türü dikkate alınarak gerçekleştirilen deneysel çalışmalar kapsamında %82.16'lık sınıflandırma doğruluğu elde edilmiştir. Sonuçlar önerilen modelin OM teşhisi için etkin ve verimli bir yöntem olduğunu doğrulamıştır. OM teşhisinin daha objektif bir şekilde gerçekleştirilmesi ve uzmanların tanı sürecini desteklemesi açısından önerilen model umut verici sonuçlar üretmiştir.

Gelecek çalışmalarda farklı derin evrimsel sinir ağı mimarileri dikkate alınarak daha üstün sınıflandırma başarımı verebilecek modellerin geliştirilmesi üzerinde çalışmaların yapılması planlanmaktadır.

Teşekkür

Verilerin toplanması sırasında harcadığı yoğun emeklerden dolayı Erdal BAŞARAN'a ve araştırmaya yön veren katkılarından dolayı Dr. Yüksel ÇELİK'e, ayrıca CTG Araştırma Gurubunun tüm üyelerine teşekkür ederim.

Veri Erişilebilirliği

Bu çalışmada kullanılan veri setine araştırma gurubumuzun web sayfasından erişebilirsiniz. <http://www.ctganalysis.com/Category/otitis-media>.

Kaynaklar

- [1] Vanneste P., Page C. 2016. Otitis media with effusion in children: Pathophysiology, diagnosis, and treatment. A review, *J. Otol.*, 14: 33–39.
- [2] Pichichero M.E. 2013. Otitis Media, *Pediatr. Clin. North Am.*, 60: 391–407.
- [3] Anggraeni R., Carosone-Link P., Djelantik B., Setiawan E.P., Hartanto W.W., Ghanie A., Utama D.S., Lukman E., Winarto S., Dewi A.M.K., Rahardjo S.P., Djamin R., Mulyani T., Mutyara K., Kartasasmita C.B., Simões E.A.F. 2019. Otitis media related hearing loss in Indonesian school children, *Int. J. Pediatr. Otorhinolaryngol.*, 125: 44–50.
- [4] Öz F., Kaytaz A., Aksoy E. 2008. Otitis media, *I.U. Cerrahpasa Tıp Fak. Surekli Tıp Egit, Etkinlikleri*, pp.71–84.
- [5] Shah-Becker S., Carr M. M. 2018. Current management and referral patterns of pediatricians for acute otitis media, *Int. J. Pediatr. Otorhinolaryngol.* 113: 19–21.
- [6] Shaikh N., Kurs-Lasky M., Hoberman A. 2019. Modification of the acute otitis media symptom severity scale, *Int. J. Pediatr. Otorhinolaryngol.* 122: 170–174.
- [7] Edetanlen E.B., Saheeb B.D. 2019. Otitis media with effusion in Nigerian children with cleft palate: incidence and risk factors, *Br. J. Oral Maxillofac. Surg.* 57: 36–40.
- [8] Sanna M., Russo A., Caruso A., Taibah A., Piras G. 2017. *Color Atlas of Endo-Otoscopy*, Thieme.
- [9] Diagnosis and management of acute otitis media. 2004. <https://pediatrics.aappublications.org/content/pediatrics/113/5/1451.full.pdf>. (Erişim Tarihi: 01/08/2019).
- [10] Goggin L.S., Eikelboom R.H., Atlas M.D. 2007. Clinical decision support systems and computer-aided diagnosis in otology, *Otolaryngol. Neck Surg.*, 136: 21–26.
- [11] Kuruvilla A., Shaikh N., Hoberman A., Kovačević J. 2013. Automated diagnosis of otitis media: vocabulary and grammar, *J. Biomed. Imaging.*, 1-15.
- [12] Vertan C., Gheorghe D.C., Ionescu B. 2011. Eardrum color content analysis in video-otoscopy images for the diagnosis support of pediatric otitis, *ISSCS 2011 - Int. Symp. Signals, Circuits Syst. Proc.* pp.129–132.
- [13] Junior H., Comunello E., Costa S., Dornelles C.C. 2007. Computational Techniques for Accompaniment and Measuring of Otology Pathologies, *IEEE Int. Symp. Comput. Med. Syst.*, IEEE, Maribor, Slovenia.
- [14] Shie C.K., Chang H.T., Fan F.C., Chen C.J., Fang T.Y., Wang P.C. 2014. A hybrid feature-based segmentation and classification system for the computer aided self-diagnosis of otitis media, *36th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBC 2014*, pp.4655–4658.

- [15] Mironica I., Vertan C., Gheorghe D.C. 2011. Automatic pediatric otitis detection by classification of global image features, E-Health Bioeng. Conf., pp.1–4.
- [16] Myburgh H.C., van Zijl W.H., Swanepoel D., Hellström S., Laurent C. 2016. Otitis Media Diagnosis for Developing Countries Using Tympanic Membrane Image-Analysis, EBioMedicine., 5: 156–160.
- [17] Myburgh H.C., Jose S., Swanepoel D.W., Laurent C. 2018. Towards low cost automated smartphone- and cloud-based otitis media diagnosis, Biomed. Signal Process. Control., 39: 34–52.
- [18] Altuntaş Y., Cömert Z., Kocamaz A.F. 2019. Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach, Comput. Electron. Agric. 163: 1-11.
- [19] Cömert Z., Kocamaz A.F. 2019. Fetal Hypoxia Detection Based on Deep Convolutional Neural Network with Transfer Learning Approach, R. Silhavy (Ed.), Softw. Eng. Algorithms Intell. Syst., Springer International Publishing, Cham. pp.239–248.
- [20] Zhao Z., Zhang Y., Comert Z., Deng Y. 2019. Computer-Aided Diagnosis System of Fetal Hypoxia Incorporating Recurrence Plot With Convolutional Neural Network, Front. Physiol., 10: 1-14.
- [21] Cıbuk M., Budak U., Guo Y., Ince M.C., Sengur A. 2019. Efficient deep features selections and classification for flower species recognition, Measurement., 137: 7–13.
- [22] Guo Y., Budak Ü., Şengür A. 2018. A novel retinal vessel detection approach based on multiple deep convolution neural networks, Comput. Methods Programs Biomed., 167 : 43–48.
- [23] Deniz E., Sengür A., Kadiroglu Z., Guo Y., Bajaj V., Ü. Budak. 2018. Transfer learning based histopathologic image classification for breast cancer detection. Heal. Inf. Sci. Syst. 6: 1-7 .
- [24] Krizhevsky A., Sutskever I., Hinton G.E. 2012. ImageNet Classification with Deep Convolutional Neural Networks, Proc. 25th Int. Conf. Neural Inf. Process. Syst. - Vol. 1, Curran Associates, Inc. pp.1097–1105, USA.
- [25] Simonyan K., Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. ArXiv Prepr. ArXiv1409.1556.
- [26] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. 2015. Going deeper with convolutions, IEEE Conf. Comput. Vis. Pattern Recognit., IEEE, pp.1–9.
- [27] He K., Zhang X., Ren S., Sun J. 2016. Deep residual learning for image recognition, Proc. IEEE Conf. Comput. Vis. Pattern Recognit., pp. 770–778, Las Vegas, NV, USA.
- [28] Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. 2016. Rethinking the Inception Architecture for Computer Vision, IEEE Conf. Comput. Vis. Pattern Recognition.
- [29] Gómez-Ríos A., Tabik S., Luengo J., Shihavuddin A.S.M., Krawczyk B., Herrera F. 2019. Towards highly accurate coral texture images classification using deep convolutional neural networks and data augmentation, Expert Syst. Appl., 118: 315–328.
- [30] Mesut T., Burhan E. 2019. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması, Fırat Üniversitesi Mühendislik Bilim. Derg., 31: 109–121.
- [31] Lecun Y., Bottou L., Bengio Y., Haffner P. 1998. Gradient-based learning applied to document recognition, Proc. IEEE, pp.2278–2324.
- [32] Cömert Z., Kocamaz A.F. 2018. Open-access software for analysis of fetal heart rate signals, Biomed. Signal Process. Control. 45: 98–108.
- [33] Kazandi M., Sendag F., Akercan F., Terek M.C., Gundem G. 2003. Different types of variable decelerations and their effects to neonatal outcome, Singapore Med. J., 44: 243–247.
- [34] Diker A., Cömert Z., Avcı E. 2017. A Diagnostic Model for Identification of Myocardial Infarction from Electrocardiography Signals, Bitlis Eren Univ. J. Sci. Technol., 7: 132–139.
- [35] Diker A., Cömert Z., Avcı E., Velappan S. 2018. Intelligent system based on Genetic Algorithm and support vector machine for detection of myocardial infarction from ECG signals, 26th Signal Process. Commun. Appl. Conf., pp.1–4.