

Akıllı Telefon Kullanarak Yapay Zeka Tabanlı Farenjit Tespiti

Artificial Intelligence Based Pharyngitis Detection Using Smartphone

Vakkas DOĞAN¹, Volkan KILIÇ¹

Öz

Burun ve ağız boşluğunun arka duvarında oluşan iltihaplanma farenjit olarak tanımlanmaktadır. Son küresel salgınla birlikte solunum semptomları gösteren farenjit gibi hastalıkların ön teşhisinde mobil teknolojilerin kullanımı gittikçe önem kazanmıştır. Bu çalışmada, geliştirdiğimiz Android tabanlı akıllı telefon uygulamasına gömülü yapay zeka algoritması ile çekilen boğaz görüntülerinden farenjitin tespit edilmesi sağlanmıştır. Yapay zeka yöntemlerinden biri olan derin öğrenmenin Android'e gömülebilmesi ile internet bağlantısı olmaksızın hızlı ve yüksek doğrulukla sonuçlar alınabilmektedir. Popüler derin öğrenme yöntemlerinden Inception-v3, MobileNet-v2, Xception, VGG16, VGG19 ve ResNet50 mimarileri farenjit tespitindeki performanslarını değerlendirmek için eğitilmiştir. Çekilen görüntünün ağız içi veya dışı olduğunun tespitinden sonra ağız içi görüntülerinin farenjit tespiti yapılması gerekmektedir. Bu nedenle sıralı olarak çalışan iki sınıflandırıcı tasarlanmıştır. İlk sınıflandırıcılar MSCOCO veri kümesiyle eğitilirken, ikinci sıradaki sınıflandırıcılar çoğaltma yöntemleri ile genişletilen 131 adet farenjit ve 208 adet farenjit olmayan boğaz görüntüsünün olduğu veri kümesiyle eğitilmiştir. Eğitilen mimariler arasında ResNet50 %96.20 doğrulukla en yüksek performansı göstermiştir. Geliştirdiğimiz 'Farenjit Tanımlama' adlı Android uygulamasına ResNet50 mimarisinin gömülmesiyle kullanıcılar pratik bir şekilde ön teşhis yapabilecek, böylelikle salgından kaynaklı sağlık sistemindeki yükün azaltılmasına katkı sağlayacaktır.

Anahtar Kelimeler: Farenjit, Derin öğrenme, ResNet50, Android, MSCOCO veri kümesi.

Abstract

Pharyngitis is defined as inflammation in the back wall of the nose and mouth cavity. Mobile technologies have received an increasing amount of attention in the recent global epidemic due to their advantage in pre-diagnosis of diseases that show respiratory symptoms such as pharyngitis. In this study, we propose a custom-designed Android application that offers pharyngitis detection based on artificial intelligence using throat images. Deep learning, a subset of artificial intelligence, allows being embedded in Android applications which leads to be giving fast and highly accurate results without an internet connection. Popular deep learning architectures including Inception-v3, MobileNet-v2, Xception, VGG16, VGG19 and ResNet50, have been trained to evaluate their performance in pharyngitis detection. Detection of pharyngitis for the images could be performed after they were verified as inner of the mouth. Therefore, two sequential classifiers were designed. The first classifiers were trained with the MSCOCO dataset, while the second-ranked classifiers were trained with the dataset, including 131 pharyngitis and 208 non-pharyngitis throat images augmented with specific methods. Among the above architectures, ResNet50 showed the highest performance with 96.20% accuracy. By embedding the ResNet50 architecture into our custom-designed Android application named 'Farenjit Tanımlama', users will be able to pre-diagnose in a practical way, thus contributing to reducing the burden on the health system caused by the epidemic.

Keywords: Pharyngitis, Deep learning, ResNet50, Android, MSCOCO dataset.

Received / Geliş	30.03.2021
Accepted / Kabul	03.08.2021
Publication Date	18.08.2021

*Sorumlu Yazar
Corresponding Author

Vakkas DOĞAN
¹ İzmir Katip Çelebi Üniversitesi,
Elektrik ve Elektronik Mühendisliği
Anabilim Dalı,
İzmir, Türkiye

✉ *y200207005@ogr.ikcu.edu.tr

<https://orcid.org/0000-0002-3164-1981>

Volkan KILIÇ
<https://orcid.org/0000-0001-5934-4156>

GİRİŞ

Uzaktan sağlık hizmetlerinde teşhis desteği, hastaların sağlık hizmeti sağlayıcılarına ve diğer hastalara temas süresini en aza indirme sağlaması açısından önem arz etmektedir (1). Son salgın ile birlikte, üst solunum yolu semptomlarının ön teşhisinde mobil uygulamaların kullanımını teşvik edilmiştir (2). Akıllı telefonların kullanımının yaygınlaşmasıyla sağlık alanında kullanılabilecek uygulamaların sayısında artış gözlemlenmiştir. Bu uygulamaların yapay zeka ile desteklenmesiyle uygulama performanslarında kayda değer bir ilerleme sağlanmıştır. Özellikle akıllı telefon kamerasından elde edilen görüntülerin yapay zeka yöntemleriyle işlenmesiyle basit seviyedeki hastalıkların otomatik teşhisi yapılabileceği gibi, uzman doktorların teşhis süresini kısaltacak önemli bilgiler sağlanabilmektedir (3). Bu uygulamaya örnek olarak farenjit gibi üst solunum semptomları gösteren hastalıklar gösterilebilir.

Dünyada her yıl milyonlarca insana hastalık teşhisi konulan farenjit, akut üst solunum yolu enfeksiyonu ile ilişkili yaygın bir durumdur (4). Farenjit, boğazın arkasındaki bademciklerin iltihaplanması ile belirti göstermektedir ve şiddetle boğaz ağrısı şikayetiyle kliniklere başvuru yapılmaktadır (5). Akut farenjitin en yaygın nedeni kendi kendini sınırlayan viral enfeksiyondur. Bununla birlikte, Streptococcus pyogenes bakteriyel enfeksiyözün farenjitin başlıca nedeni ve vakalarının yaklaşık %20-30'unun nedeni (6). Eksüdatif tonsillit ile ateş gibi immün aracılı ve enfeksiyon sonrası komplikasyonlara neden olabilen streptokokal farenjit birbirleriyle bağlantılıdır (7). Bununla birlikte, üst solunum yolu enfeksiyonu olan birçok hasta erken dönemde hastalık etkeni içeren semptomlarını görmezden gelir ve rutin tıbbi ziyaretler gerçekleşmemiş olur (8). Son küresel salgın ile birlikte hastaların klinikleri ziyaret etmelerindeki oranın düşüşü bu gerçeği gözler önüne sermektedir. Birçok hasta çözümü, tıbbi destek almadan kendi imkanlarıyla halledebilme yoluna başvurmuş ve akıllı telefon tabanlı bir izleme sisteminin önemi, uygulanabilirliği ve etkinliği bu nedenle artmıştır (9).

Akıllı telefonlardaki son teknolojik gelişmeler yapay zeka destekli algoritmaların çalışmasına olanak sağlamıştır. Yapay zeka alanında kullanılan derin öğrenme tabanlı akıllı telefon uygulamaları son zamanlarda gittikçe artan bir ilgi görmektedir (10, 11). Bir çalışmada akıllı telefona uyumlu bir ekipman ile boğazdaki streptokokal bademcik görüntüleri k en yakın komşu algoritması (kNN) ile sınıflandırılmıştır (12). Başka bir çalışmada ise derin öğrenme mimarilerinden ResNet50 kullanılmıştır. Yapılan çalışma incelendiğinde sadece ağız içi görüntülerden oluşan, kullanıcının farenjit ya da farenjit olmayan diye sınıflandıran bir sistem önerilmiştir (13). Akıllı telefon ile çekilen görüntüler internet bağlantısıyla bulut sistemi üzerinden sunucuya iletilerek farenjit tespiti yapılmaktadır. Yapılan başka bir çalışmada, farenjit teşhisine yardımcı olmak için sinir ağla-

ından faydalanılmıştır (14). 240 hastanın tıbbi kayıtlarında bulunan otuz sekiz değişken ile beslenen sinir ağı, vakaların %95.4'ünde farenjiti doğru şekilde teşhis etmiştir.


Önerilen çalışmanın diğer çalışmalardan farklı olarak, çekilen görüntüler ilk olarak ağız içi ve ağız içi değil diye sınıflandırılmaktadır. Eğer görüntü ağız içi ise farenjit ve farenjit olmayan diye ikinci bir sınıflandırma yapılmaktadır. Görüntü ağız içine ait değilse kullanıcıya ağızınızın resmini çekmelisiniz diye geri dönüşte bulunulmaktadır. Bununla beraber eğitilen derin öğrenme mimarisi mobil uygulamaya gömülerek internet olmaksızın çalışabilmesi sağlanmıştır. Bu çalışmada, boğaz görüntülerinden farenjiti internet bağlantısına ihtiyaç duymadan derin öğrenme yöntemiyle tespit edebilen kullanıcı dostu bir akıllı telefon uygulaması geliştirilmiştir.

Bu yazının geri kalanı aşağıdaki şekilde düzenlenmiştir: Bölüm 2, veri toplama, veri çoğaltma, çalışmada önerilen derin öğrenme mimarisini ve akıllı telefon uygulamasını açıklamaktadır. Bölüm 3'te önerilen yöntemden elde edilen deneysel sonuçlar açıklanmıştır ve son olarak Bölüm 4'te sonuçlara yer verilmiştir.

GEREÇ ve YÖNTEM

Veri kümesi ve veri çoğaltma

Derin öğrenme yöntemlerinin başarısında veri kümesinin doğrudan etkisi bulunmaktadır. Veri kümesinin genişliği, eğitimdeki başarı oranını artırmaktadır. Bu çalışmada, gelen görüntülerin ağız içine ait olduğunu tespit eden ve daha sonrasında farenjit tespiti yapan iki sınıflandırıcı kullanıldığından, her bir sınıflandırıcı için ayrı veri kümeleri kullanılması gerekmektedir. İlk sınıflandırıcı için içerisinde 118273 adet görüntünün olduğu MSCOCO (Microsoft Common in Context) (15) veri kümesi kullanılmıştır. MSCOCO veri kümesinde 110000 adet görüntü eğitim aşamasında ve 8273 adet görüntü ise test aşamasında kullanılmıştır. İkinci sınıflandırıcı için kullanılan veri kümesi, internetten erişimi herkese açık olan 131 adet farenjit ve 208 adet farenjit olmayan görüntülerden oluşmaktadır (16). Projede kullanılan veri kümesindeki görüntülerden örnekler verilmektedir (Şekil 1). İkinci veri kümesinde kullanılan görüntü sayısının az olması, farenjit ile farenjit olmayan görüntü sayılarındaki eşitsizlik nedeniyle veri çoğaltma işlemi uygulanmıştır. Veri çoğaltma işlemi yapılmadan önce elde bulunan veri kümesi ile derin öğrenme mimarileri eğitilmiştir. Eğitim sırasında toplam 339 adet boğaz görüntüsünden 271 adet boğaz görüntüsü eğitim için kullanılırken test veri kümesi 68 adet boğaz görüntüsüne sahiptir.



Şekil 1: Çalışmada kullanılan veri kümelerinden örnekler (a) farenjit olmayan, (b) farenjit, (c) MSCOCO

Ağız içi görüntülerinde farenjit tespiti yapabilmek için kullanılan veri kümesindeki görüntü sayısının yetersizliği derin öğrenme mimarilerinin sınıflandırma performanslarını olumsuz yönde etkilemiştir. Bunun önüne geçebilmek için, çevirme, döndürme ve parlaklık değişimi gibi temel veri çoğaltma teknikleri ile veri kümesindeki görüntüler artırılmıştır (17). Derin öğrenme mimarisini eğitmeden önce, veri kümesi, sol ve sağ çevirme, %7'den +%7'e genişlik ve yükseklik çevirme, 15°'den 15°'ye rastgele dönüş, %0'dan %15'ye rastgele yakınlaştırma dahil olmak üzere doğrusal dönüşüm kullanılarak artırıldı. Böylelikle, eğitim kümesi için 10000 adet farenjit ve 10000 adet farenjit olmayan boğaz görüntüsü oluşturuldu ve eğitilen mimari, 500 adet farenjit ve 500 adet farenjit olmayan boğaz görüntüsü ile test edilmiştir.

Önerilen derin öğrenme mimarisi

Veri çoğaltmanın ardından derin öğrenme mimarilerini eğitme aşamasına geçilmiştir. Bu çalışmada, özel derin öğrenme mimarisi tasarlanmanın zaman alıcı olması (18) nedeniyle, yaygın derin öğrenme mimarilerinden faydalanılmıştır (19, 20). Bu mimariler, ResNet50, Inception-v3, MobileNet-v2, Xception, VGG16 ve VGG19'u kapsamaktadır. Bu mimarilerin seçiminde benzer çalışmalarda daha önce kullanılmış ve yüksek performans göstermeleri etkili olmuştur (21-24). İki sınıflandırıcı içinde aynı mimarilerden faydalanılmıştır. Ön eğitilmiş olarak indirilen mimariler, eğitim kümesiyle tekrar eğitilmiş olup, doğrulama kümesiyle de eğitimin performansı test edilmiştir.

Mimariler, 180 devir (epoch) ve 20'lik bir batch size ile eğitildi. 0.0001 öğrenme oranına (learning rate) sahip ADAM iyileştiricisi (optimizer) ve çapraz entropi kaybı (cross-entropy) kullanılmıştır.

Derin öğrenme mimarilerinin performansı, alıcı çalışma karakteristik eğrisinin (Receiver Operating Characteristic Curve-ROC) ve hassasiyet-geri çağırma eğrisinin (Precision-Recall Curve-PRC) altındaki alana (Area Under the Curve-AUC) ve doğruluğuna dayalı olarak değerlendirilmiştir. Optimal tanı eşliğinin bir tahmini olan Youden indeksi de kullanılmıştır. Duyarlılık ve özgüllük elde edildikten sonra, Youden indeksi her kesme noktasında hesaplanmıştır. Youden indeksini maksimize eden optimum değer seçilmiştir. Kullanılan performans metrik ve indeksleri aşağıdaki şekilde ifade edilir:

TP, TN, FP ve FN sırasıyla gerçek pozitifleri, gerçek negatifleri, yanlış pozitifliği ve yanlış negatifleri ifade etmektedir. Tanımlanan performans metrik ve indeks değerlerine göre kullanılan altı mimari arasından ResNet50 en iyi performansı göstermiştir.

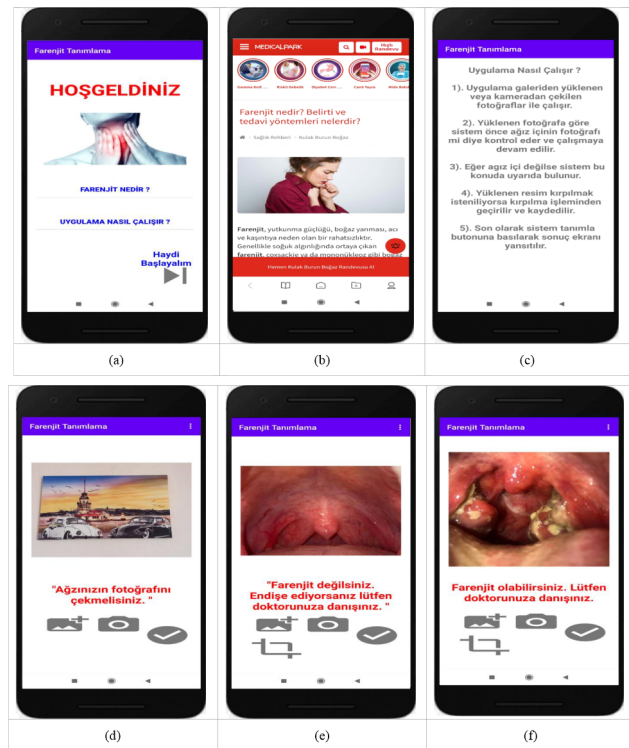
Doğruluk (Accuracy)	[1]
Duyarlılık (Sensitivity)	[2]
Özgüllük (Specificity)	[3]
Hassas (Precision)	[4]
Youden İndeks	[5]

Akıllı telefon uygulaması: farenjit tanımlama

Bu çalışmada, boğaz görüntülerinden farenjit teşhisini yapay zeka destekli yapabilen Android uygulaması geliştirilmiştir. Kullanıcıların testlerini uygulama üzerinden erişebileceği akıllı telefon kamerası ile yapabilmesi için kolay ve kullanıcı dostu bir arayüz tasarlanmıştır.


Tasarım, Android Studio programı kullanılarak yapılmıştır. Android Studio, Google tarafından önerilen ve birçok üst düzey özelliğe sahip bir programlama aracıdır (25). Uygulamanın internet gereksinimi olmadan çalışabilmesi derin öğrenme mimarisinin uygulamanın içerisine gömülmesi gerekmektedir. Bu amaçla Firebase MLKit ve TensorFlow-Lite (Tf-lite) kullanılmıştır. Firebase MLKit, mobil geliştiricilerin uygulamalarına makine öğrenme yeteneklerini eklemelerini kolaylaştıran mobil bir SDK'dır (Software Development Kit-Yazılım Geliştirme Kiti) (26). Tf-lite ise TensorFlow modellerinin mobil cihazlarda, gömülü sistemlerde ve IoT (Internet of Things-Nesnelerin İnterneti) cihazlarda daha verimli çalıştırılması için özelleştirilmiş bir araç setidir (27).

'Farenjit Tanımlama' olarak adlandırılan uygulamanın ana sayfası Farenjit Nedir, Uygulama Nasıl Çalışır ve Test İşlemleri başlıklarından oluşmaktadır. Mobil uygulamanın ana ekranı gösterilmektedir (Şekil 2a). Uygulamaya giriş yapıldığında kullanıcıyı "Farenjit Nedir?" ve "Uygulama Nasıl Çalışır?" adlı iki ana başlık karşılamaktadır. "Farenjit Nedir" başlığına giriş yapıldığında bu başlık kullanıcıyı farenjit ile ilgili bilgi veren sitelere yönlendirmektedir (Şekil 2b). Ek olarak "Uygulama Nasıl Çalışır?" başlığına giriş yapıldığında ise uygulamanın çalışma prensibi üzerine



Şekil 2: Farenjit Tanımlama uygulaması ekran görüntüleri. (a) uygulama ana ekranı, (b) farenjit bilgi ekranı, (c) uygulama nasıl kullanılır ekranı, (d) eklenen resmin ağız içi olmaması örneği, (e) farenjit olmayan kullanıcı örneği, (f) farenjit kullanıcı örneği

kullanıcılara bilgi verilmektedir (Şekil 2c). Ana sayfanın sağ taraf alt kısımda “Haydi Başlayalım” butonuna basıldığında uygulamanın test yaptığı bölüme giriş yapılmaktadır (Şekil 2a). Uygulamaya galeri kısmından görüntü yüklenildiği gibi telefonun kamera özelliği kullanılarak da anlık görüntü alınabilmektedir. Görüntüleri kırpma özelliği sayesinde gereksiz kısımlar görüntüden çıkarılabilmektedir. Galeriden yüklenen ya da kamera kullanılarak çekilen görüntünün ağız içi/ağız içi değil kontrolü yapıldığı bir örnek gösterilmektedir (Şekil 2d). Farenjit olmayan bir görüntü yüklendiğinde alınan sonuç gösterilmektedir (Şekil 2f). Son olarak farenjit olan bir resim yüklendiğinde alınan sonuç gösterilmektedir (Şekil 2e). Kullanıcıya gerekli durumlarda bilgilendirme yapılabilmektedir.



Şekil 3: Farenjit tespiti için ResNet50 derin öğrenme mimarisi eğitimsüreci. (a) Eğitim ve doğrulama kümelerinin doğruluk öğrenme eğrileri. (b) Eğitim ve doğrulama kümelerinin kayıp öğrenme eğrileri.

BULGULAR

Deneysel sonuçlar ve tartışma

İkili sınıflandırma işlemi yapılarak sonuçlar alınmaya çalışılmıştır. İlk sınıflandırma olarak MSCOCO veri kümesi kullanılmıştır. Bu veri kümesi ile ResNet50 %98 doğruluk değeri alınmıştır. Bu veri kümesi içerisinde ağız içi ile ilgili görüntü olmamasına dikkat edilmiştir. Daha sonraki aşamada farenjit tespiti yapacak derin öğrenme mimarileri ilk olarak çoğaltma işlemi yapılmayan orjinal veri kümesi ile eğitildi. Eğitim esnasında 271 adet boğaz görüntüsü eğitim aşamasında ve 68 adet boğaz gö-rüntüsü ise test aşamasında kullanılmıştır. Elde edilen sonuçlar performans metrikleri ile analiz edildiğinde başarı yüzdelерinin düşük olduğu gözlemlenmiştir. Bundan dolayı veri kümesi çoğaltma işlemi yapılmıştır ve derin öğrenme mimarileri tekrardan eğitilmiştir. Optimal tanı eşiği değerinde, ResNet50 modeli farenjiti %96.2 doğruluk, %91.3 duyarlılık ve %95.1

özgüllük ile öngördü. Derin öğrenme mimarilerinin tüm veri kümesinde 4 kat çapraz doğrulama yoluyla performansını göstermektedir (Tablo 1).

	Doğruluk Değeri (%) (Accuracy)	Hassaslık (%) (Sensitivity)	Özgüllük (%) (Specificity)
Inception -v3	89.2	86.2	91.3
MobileNet -v2	87.6	84.6	89.4
VGG16	84.2	89.1	85.2
VGG19	71.7	77.2	74.4
Xception -v1	90.1	92.7	91.7
ResNet50	96.2	91.3	95.1

Tablo 1: Farenjit tespiti için mimarilerin sınıflandırma performansı


Eğitilen mimarilerin performansları karşılaştırıldığında ResNet50 mimarisi ile en yüksek doğrulama doğruluğu elde edilmiştir. Diğer eğitilen mimariler incelendiğinde Xception-v1 90.1%, Inception-v3 89.2%, MobileNet-v2 87.6%, VGG16 84.2% ve VGG19 71.7% doğruluk değerlerine sahip oldukarı gözlemlenmiştir. Bu sonuçlardan dolayı ResNet50 mimarisi kullanılması kararına varılmıştır. Eğitim ve doğrulama kümelerini kullanan derin öğrenme mimarisi olan ResNet50'nin eğitim sürecini göstermektedir (Şekil 3). ResNet50 için eğitim süreci, her eğitim adımı için gerekli ortamlar oluşturularak 1000 devir boyunca yaklaşık 9 saat sürdü. 180. devirden sonra, doğrulama doğruluğu geliştirilmesi ve doğrulama sonucunun çapraz entropisi artmıştır. Bu nedenle, 180 devirlik eğitimin ResNet50 modelinde 0.1 kayıp değerine ulaşması ve bu değer ilerleyen devirler sonucunda sabite yakın bir yol izlemesi 180. devirde eğitilmiş modeli seçmekte etkili olmuştur.

Daha önce yapılan farenjit ile ilgili bir çalışmada (13) veri çoğaltma işlemi yapılmadan ResNet50 ile %92.5 doğruluk değeri elde edilirken GAN (Generative Adversarial Network) yöntemi veri çoğaltma işlemi yapıldıktan sonra doğruluk değeri %95.3 olmuştur. Bizim çalışmamızda ise veri çoğaltma işlemi yapıldıktan sonra doğruluk değeri %96.2 olarak elde edilmiştir. Bir diğer konu ise önerilen mimari bulut sistemleri ile internet gereksinimi duyularak yapılmıştır. Eğitilen derin öğrenme mimarisi bu çalışmada internet gereksinimi olmadan Android içine entegre edilmiştir. Ek olarak bu çalışmada (13) tek sınıflandırma işlemi yapılmakta ve yüklenen ya da çekilen görüntünün ağız içi/değil durumu göz önüne alınmamıştır.

Elde edilen sonuçlar mobil uygulama ile test edildiğinde başarılı sonuçlar sağlanmıştır (Şekil 2). Çeşitli görüntüler galeriden yüklenerek ve telefon kamera-sından çekilerek test etme aşaması tekrarlanarak yapılan çalışmanın doğruluğu kontrol edilmiştir. Yapılan çalışmadaki iş akışı gösterilmektedir (Şekil 4).

Bu çalışmada karşılaşılan bazı sınırlamalar vardır. İlk olarak, derin öğrenme mimarimiz düşük çözünürlüklü görüntüleri analiz etmek durumunda kalmıştır. Görüntü

boyutu veri çoğaltma adımından sonra düzenlenmiştir. Görüntü boyutunun düzenlenmesi, farenjit vakalarının sınıflandırmasını etkileyebilir. Gelecekteki çalışmalarda, daha doğru bir teşhis sağlamak için boğaz görüntüsünün çözünürlüğü iyileştirilmelidir. İkincisi, eğitim ve doğrulama için veri kümeleri sınırlı sayıda boğaz görüntüsü içeriyordu. Erişime açık internet tabanlı kaynaklardan boğaz görüntüleri toplamaya çalışılmasına rağmen, klinik ortamlardan gerçek boğaz görüntüleri veri kümesine dahil edilmemiştir. Bu nedenle, çalışmanın başarı yüzdesini artırmak için daha fazla klinik veri kümesine ihtiyaç duyulmaktadır. Üçüncüsü, internette indirilen farenjit veri kümesi görsel arama motorları aracılığıyla toplanmış olup sadece boğaz resimlerini içermektedir. Bu boğaz resimleri cinsiyet, ırk veya yaş dahil hiçbir metaveri içermiyordu. Önceden yapılan bir çalışmaya göre, bu faktörler farenjit tespit performansında önemli bir etkiye sahiptir (24). Dördüncüsü, veri kümeleri yazarlar tarafından tek tek incelenmesine rağmen, görüntüler veri kümesinde potansiyel olarak kopyalanabilir. Yenilenen görüntüler, doğrulama veri kümesinin bağımsızlığını etkileyecektir. Çalışmanın sınırlamaları, iyi organize edilmiş bir çalışma protokolüne sahip bir akıllı telefonla alınan yeterli sayıda boğaz görüntüsünün bulunması ile aşılmalıdır.



Şekil 4: Akıllı telefon kullanarak farenjit tespiti için derin öğrenme modeli iş akış diyagramı

Yapay zeka tabanlı mobil uygulama ile boğaz görüntüleri kullanılarak farenjit tespiti çalışmasını referans alarak, ilerleyen zamanlarda kulak burun boğaz kliniklerinde bir endoskopi sisteminden (28) görüntüler kullanılarak bilgisayar destekli tanıya genişletilmesi mümkündür. Çalışmanın etkinliğini doğrulamak için, uygulama tabanlı çalışmalar geliştirdikten sonra birçok hasta ile ileriye dönük bir çalışma bir klinikte yapılabilecektir.

SONUÇ

Bu çalışmada, akıllı telefon kullanarak kullanıcılar tarafından çekilen boğaz görüntüleri ile farenjiti tespit etmek için yapay zekaya dayalı mobil uygulama geliştirildi. Veri çoğaltma ile, derin öğrenme mimarisinin sınıflandırma performansını iyileştirmek için yeni boğaz görüntüleri başarıyla oluşturulmuştur. Eğitilen mimariler arasında ResNet50 %96.20 doğrulukla farenjit tespitini yapabildi. Geliştirilen mobil uygulama, farenjitin hızlı bir şekilde teşhisini sağlamış ve böylelikle oluşabilecek muhtemel komplikasyonları önlemek için zaman kazandırabilecektir. Ayrıca bu çalışma, üst solunum yolu semptomları olan hastaların daha rahat bir şekilde teşhis ve tedavi almalarına yardımcı olacak ve salgın mücadelede pozitif bir katkı sağlayacaktır.

Çıkar çatışması: yok

Finansal destek: yok

Yazar katkıları:

Motivasyon / Konsept: VD, VK

Çalışma Tasarımı: VD

Kontrol / Gözetim: VK

Veri Toplanması ve / veya İşlemesi: VD

Analiz ve / veya Yorum: VK

Literatür inceleme: VD

Makalenin Yazılması: VD, VK

Eleştirel İnceleme: VK

KAYNAKLAR

1. Pappot, N., G. Taarnhøj, and H.J.T.J.H. Pappot, Telemedicine and e-health solutions for COVID-19: patients' perspective [published online April 24, 2020]. Telemed JE Health, DOI: <http://doi.org/10.1089/tmj.2020.0099>.
2. Maurrasse, S.E., et al., Telemedicine during the COVID-19 pandemic: a pediatric otolaryngology perspective. Otolaryngology–Head Neck Surgery (SAGE), 2020. 163(3): p. 480-481 DOI: <https://doi.org/10.1177/0194599820931827>.
3. Celik Ertugrul, D. and A.H.J.E.J. Ulusoy, Development of a knowledge-based medical expert system to infer supportive treatment suggestions for pediatric patients. ETRI Journal, 2019. 41(4): p. 515-527 DOI: <https://doi.org/10.4218/etrij.2018-0428>.
4. Van, T.T., K. Mata, and J.D.J.J.o.c.m. Bard, Automated detection of Streptococcus pyogenes pharyngitis by use of colorex strep A CHROMagar and WASPLab artificial intelligence chromogenic detection module software. Journal of clinical microbiology (JCM) 2019. 57(11) DOI:

- <https://doi.org/10.1128/JCM.00811-19>.
5. Shaikh, N., E. Leonard, and J.M.J.P. Martin, Prevalence of streptococcal pharyngitis and streptococcal carriage in children: a meta-analysis. *Pediatrics (APC)* 2010. 126(3): p. e557-e564 DOI: DOI: <https://doi.org/10.1542/peds.2009-2648>.
6. Rao, A., et al., Diagnosis and antibiotic treatment of group a streptococcal pharyngitis in children in a primary care setting: impact of point-of-care polymerase chain reaction. *BMC pediatrics*, 2019. 19(1): p. 1-8 DOI: <https://doi.org/10.1186/s12887-019-1393-y>.
7. Vazquez, M.N. and J.E.J.P.e.m.p. Sanders, Diagnosis and management of group A streptococcal pharyngitis and associated complications. *Pediatric emergency medicine practice (EB Medicine)* 2017. 14(12): p. 1-20.
8. Norton, L.E., et al., Improving guideline-based streptococcal pharyngitis testing: a quality improvement initiative. *Pediatrics (APC)*, 2018. 142(1) DOI: DOI: <https://doi.org/10.1542/peds.2017-2033>.
9. Mustafa, Z., M.J.F.i.C. Ghaffari, and I. Microbiology, Diagnostic methods, clinical guidelines, and antibiotic treatment for group A streptococcal pharyngitis: a narrative review. *Frontiers in Cellular Infection Microbiology (FCIM)* 2020. 10: p. 644 DOI: <https://doi.org/10.3389/fcimb.2020.563627>.
10. de Haan, K., et al., Automated screening of sickle cells using a smartphone-based microscope and deep learning. *NPJ Digital Medicine*, 2020. 3(1): p. 1-9 DOI: <https://doi.org/10.1038/s41746-020-0282-y>.
11. Zulkifley, M.A., et al., Pterygium-Net: a deep learning approach to pterygium detection and localization. *Multimedia Tools Applications (MTAP)* 2019. 78(24): p. 34563-34584 DOI: <https://doi.org/10.1007/s11042-019-08130-x>.
12. Askarian, B., S.-C. Yoo, and J.W.J.S. Chong, Novel image processing method for detecting strep throat (streptococcal pharyngitis) using smartphone. *Sensors (MDPI)* 2019. 19(15): p. 3307 DOI: <https://doi.org/10.3390/s19153307>.
13. Yoo, T.K., et al., Toward automated severe pharyngitis detection with smartphone camera using deep learning networks. *Computers in Biology Medicine (ELSEVIER)* 2020. 125: p. 103980 DOI: <https://doi.org/10.1016/j.compbiomed.2020.103980>.
14. Zhang, S., et al., A flexible bifunctional sensor based on porous copper nanowire@ IonGel composite films for high-resolution stress/deformation detection. *Journal of Materials Chemistry C* 2020. 8(12): p. 4081-4092 DOI: <https://doi.org/10.1039/C9TC06091J>.
15. MSCOCO veri seti. Available from: <https://content.aigion.com/datasets/coco-ms-coco-dataset>.
16. Pharyngitis Dataset 2020 10-06-2020; Available from: <https://data.mendeley.com/datasets/8ynyhnj2kz/1>.
17. Maeda, H., et al., Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone, arvi preprint. arXiv preprint arxiv:.09454, 2018 DOI: <https://doi.org/10.1111/mice.12387>.
18. Ghiasi, V. and M.J.S.A.S. Koushki, Numerical and artificial neural network analyses of ground surface settlement of tunnel in saturated soil. *SN Applied Sciences*, 2020. 2(5): p. 1-14 DOI: <https://doi.org/10.1007/s42452-020-2742-z>.
19. Minaee, S., et al., Deep-covid: Predicting covid-19 from chest x-ray images using deep transfer learning. *Medical image analysis (MIA)*, 2020. 65: p. 101794 DOI: <https://doi.org/10.1016/j.media.2020.101794>.
20. Yoo, T.K., et al., The possibility of the combination of OCT and fundus images for improving the diagnostic accuracy of deep learning for age-related macular degeneration: a preliminary experiment. *Medical biological engineering computing (MBEC)* 2019. 57(3): p. 677-687 DOI: <https://doi.org/10.1007/s11517-018-1915-z>.
21. Gómez-Flores, W., W.C.J.C.i.B. de Albuquerque Pereira, and Medicine, A comparative study of pre-trained convolutional neural networks for semantic segmentation of breast tumors in ultrasound. *Computers in Biology Medicine (ELSEVIER)*, 2020. 126: p. 104036 DOI: <https://doi.org/10.1016/j.compbiomed.2020.104036>.
22. Kassani, S.H., et al. Diabetic retinopathy classification using a modified xception architecture. in *2019 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. 2019. IEEE DOI: 10.1109/ISSPIT47144.2019.9001846.
23. Malsagov, M.Y., et al., Exponential discretization of weights of neural network connections in pre-trained neural networks. *Optical Memory Neural Networks (OMNN)*, 2019. 28(4): p. 262-270 DOI: <https://doi.org/10.3103/S1060992X19040106>.
24. Rounds, J., et al. Probing for Artifacts: Detecting Imagenet Model Evasions. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020.
25. Darwin, I.F., *Android Cookbook: Problems and Solutions for Android Developers*. 2017: " O'Reilly Media, Inc."
26. Sproull, T., D. Shook, and B. Siever. *Machine Learning on the Move: Teaching ML Kit for Firebase in a Mobile Apps Course*. in *Proceedings of the 52nd ACM Technical Symposium on Computer Science Education*. 2021. DOI: <https://doi.org/10.1145/3408877.3432496>.
27. Pienaar, J., *Mlir in tensorflow ecosystem*. 2020.
28. Ribeiro, E., et al., Exploring deep learning and transferlearning for colonic polyp classification. *Computational mathematical methods in medicine (CMMM)* 2016. 2016 DOI: <https://doi.org/10.1155/2016/6584725>.