



Göğüs Röntgeni Görüntülerinden Akciğer Hastalıklarının Sınıflandırılması için Farklı Derin Öznitelikler ile Beslenen Destek Vektör Makinesi

Araştırma Makalesi/Research Article

 Hüseyin ÜZEN*¹,  Hüseyin FIRAT²

¹Bilgisayar Mühendisliği, Bingöl Üniversitesi, Bingöl, Türkiye

²Bilgisayar Mühendisliği, Dicle Üniversitesi, Diyarbakır, Türkiye

huzen@bingol.edu.tr, huseyin.firat@dicle.edu.tr

(Geliş/Received:26.09.2023; Kabul/Accepted:30.11.2023)

DOI: 10.17671/gazibtd.1366846

Özet— En ölümcül akciğer hastalıklarından üçü olan COVID-19, tüberküloz ve zatürre, rutin olarak göğüs röntgeni (GR) taramaları kullanılarak tespit edilmektedir. Son teknolojik gelişmeler, otomatik teşhis için bilgisayar destekli sistemlerde yeni bir çağ başlatmakta ve önemli faydalar sunmaktadır. Bu çalışma, bu hastalıkları GR'lerden ayırt etmek için tasarlanmış üç aşamalı yeni bir derin öğrenme modeli önermektedir. Modelin ilk aşamasında, derinlemesine ayrılabilir evrişim, geleneksel evrişim ve tam bağlı katmanlar dahil olmak üzere derin özellikleri çıkarmak için bir Evrişimsel Sinir Ağı (ESA) kullanılmaktadır. İkinci aşamada, daha yüksek sınıflandırma başarısı elde etmek için Destek Vektör Makineleri (DVM) sınıflandırıcısı kullanılarak tekrar bir eğitim sürecinden geçirilmektedir. Bu sayede farklı katmanlardan alınan derin özelliklerden daha fazla yararlanılmaktadır. Üçüncü aşamada ise model test edilmektedir. Deneysel çalışmalarda dört sınıftan oluşan GR veri kümesi üzerinde testler gerçekleştirilmiştir. Bu veri kümesi COVID-19, Pnömoni, Normal ve Tüberküloz sınıflarını içermektedir. Kapsamlı deneysel çalışmalar sonucunda önerilen model %99,30 ortalama doğruluk sonucuna ulaşmıştır. Diğer yandan sınıf bazlı sonuçlarda COVID-19 ve Tüberküloz için %100, Normal ve Pnömoni vakaları için ise %98,60 doğruluk oranına ulaşmıştır. Bu sonuçlar COVID-19 ve Tüberküloz sınıflandırması için önerilen modelin çok etkili olduğu görülmektedir. Ayrıca deneysel çalışmaların ikinci bölümünde, önerilen model sonuçları, mevcut modeller ile karşılaştırılmış ve üstün başarılar elde ettiği görülmüştür.

Anahtar Kelimeler— COVID-19, pnömoni, tüberküloz, derin öğrenme, destek vektör makinesi

Support Vector Machine Fed with Different Deep Features for Classification of Lung Diseases from Chest X-Ray Images

Abstract— COVID-19, tuberculosis, and pneumonia, three of the most deadly lung diseases, are routinely detected using chest X-ray (CXR) scans. Recent technological advancements are ushering in a new era of computer-assisted systems for automated diagnosis, offering significant benefits. This study proposes a three-stage deep learning model designed to differentiate these diseases from CXRs. In the initial phase of the model, a Convolutional Neural Network (CNN) is used to extract deep features, including depthwise separable convolution, conventional convolution, and fully connected layers. In the second phase, a Support Vector Machine (SVM) classifier is employed for retraining to achieve higher classification accuracy, maximizing the utilization of deep features from different layers. The third stage involves testing the model. Experimental tests were conducted on a CXR dataset comprising four classes: COVID-19, Pneumonia, Normal, and Tuberculosis. Following comprehensive experimental studies, the proposed model achieved an average accuracy of 99.30%. Moreover, in class-specific results, it reached 100% accuracy for COVID-19 and Tuberculosis, and 98.60% accuracy for Normal and Pneumonia cases, indicating the high effectiveness of the proposed model in classifying COVID-19 and Tuberculosis. Furthermore, in the second part of the experimental studies, the outcomes of the proposed model were compared with existing models, demonstrating superior achievements.

Keywords— COVID-19, pneumonia, tuberculosis, deep learning, support vector machine

1. GİRİŞ (INTRODUCTION)

Her yıl milyonlarca insan COVID-19, Pnömoni ve Tüberküloz (TÜB) gibi akciğer hastalıklarına yakalanmakta ve bu hastalıklar ölümlerine sonuçlanmaktadır. Bu oranın her yıl artması beklenmektedir [1]. Şiddetli akut solunum sendromu koronavirüs 2 (SARS-CoV-2) virüsünün neden olduğu bir hastalık olan Coronavirus 2019 (COVID-19) ciddi bir salgın haline gelmiştir [2] ve COVID-19 vakalarının katlanarak artması dünya genelinde sağlık sistemi üzerinde oldukça fazla bir baskı oluşturmuştur. Benzer şekilde, Pnömoni ve TÜB de yaşamı tehdit eden hastalıklardır [3][4]. Sonuç olarak, bu tür hastalıkların doğru ve zamanında tespiti, uygun tedavi ve hayat kurtarmak için kritik öneme sahiptir [5].

Pnömoni, TÜB ve COVID-19 dahil olmak üzere birçok bulaşıcı akciğer hastalığı, solunum güçlüğü, öksürük ve ateş gibi benzer semptomları paylaşmaktadır. Çeşitli etkenlerin neden olduğu nefes darlığı, ateş, balgam ve öksürük gibi semptomlara yol açmakta ve hastalık ilerledikçe akciğer opaklaşması görülmektedir. Mevcut tedavilere rağmen, pnömoni özellikle çocuklarda önde gelen bir ölüm nedeni olmaya devam etmektedir. TÜB ayrıca öksürük ve nefes darlığı ile kendini göstermekte ve genellikle pnömoni ve COVID-19 ile örtüşmektedir. İlaça dirençli TÜB giderek artan bir endişe kaynağıdır. Bu nedenle, örtüşen semptomlara sahip bu hastalıkları tespit edip sınıflandırarak doğru tedavi yaklaşımını sağlayacak sağlam bir yapay zeka sistemine ihtiyaç vardır [6].

Akciğer hastalığı teşhisi için standart görüntüleme yöntemleri arasında bilgisayarlı tomografi (BT), göğüs röntgeni (GR) ve manyetik rezonans görüntüleme (MRG) taraması yer almaktadır. MRG ve BT taraması akciğer hastalıklarının değerlendirilmesinde altın standart olmasına rağmen, daha pahalıdır, radyasyona maruz kalmayı gerektirir ve tüm dünyada kolayca bulunamaz [7]. Buna karşılık, GR daha ucuzdur, kolayca temin edilebilir ve kardiyotorasik ve pulmoner bozukluklar için en yaygın tanısal görüntüleme tekniklerinden biridir.

Akciğer hastalığının GR görüntüleri farklılaşma zorlukları sunmakta ve genellikle radyologlar arasında yüksek okuyucu değişkenliğine neden olmaktadır [8]. Pandeminin gelecekteki potansiyel dalgalarıyla birlikte radyologların iş yükü artacak ve radyologların nitel değerlendirmesini geliştirebilecek yeni otomatik görüntü analiz araçlarına acil ihtiyaç duyulacaktır. Bu araçlar, tanısal iş akışını desteklemek için GR'nin bölümlerini sınıflandıracak veya bölümlere ayıracaktır. Karar destek sistemleri, klinik karar verme sürecine yardımcı olmak için tasarlanmıştır ve sağlık hizmetlerinde yükselen bir araştırma trendi olarak kendini kanıtlamıştır [9]. Pandeminin son aylarında, pnömoni veya diğer akciğer hastalıklarının otomatik tespiti, özellikle erken tespiti ve sınıflandırılması, hem klinik hem de yapay zeka araştırmacılarının büyük ilgisini çekmiştir.

Yapay zeka tabanlı tıbbi sistemlerin geliştirilmesi ve bunların tıbbi uygulamaya aktarılması, hastaların

tedavisinde giderek daha önemli bir rol oynamaktadır [10]. Teşhis için kan testi sonuçlarına veya biyobelirteçlere dayanan otomatik yöntemlerin [11] yanı sıra, COVID-19 ve diğer akciğer hastalıklarıyla mücadele etmek için doğru, sağlam ve hızlı tespit teknikleri geliştirmek amacıyla giderek artan sayıda derin öğrenme tabanlı yöntem, özellikle de evrimsel sinir ağı (ESA) tabanlı modeller uygulanmakta ve kullanılmaktadır [12]. GR görüntüleri kullanılarak COVID-19, Pnömoni ve TÜB teşhisi üzerine literatürdeki çalışmalardan bazıları aşağıda verilmiştir.

Mamalakis vd. [6] GR görüntülerine dayalı olarak COVID-19, pnömoni, TÜB veya sağlıklı hastaları teşhis etmek için DenResCov-19 adlı yeni bir derin transfer öğrenme modeli geliştirdiler. Model, mevcut DenseNet-121 ve ResNet-50 ağlarından oluşmaktadır. Deneysel çalışmalar sonucunda dört sınıftan oluşan veri seti ile %75,75 F1-skor değeri elde edilmiştir. Qagos vd. [13] verimli bir ESA mimarisi kullanmıştır. Mimari, 6587 GR görüntüsü kullanılarak eğitilmiştir. 128x128 görüntü boyutu ve 100 epok ile ilerleyen mimari, GR görüntülerini dört sınıfa (Normal, COVID-19, Pnömoni ve TÜB) sınıflandırırken %94,53 doğruluk elde edebilmiştir. Bhandari vd. [14] GR görüntüsünü COVID-19, pnömoni ve TÜB olarak sınıflandırmak için bir açıklama oluşturma çerçevesi ile tamamlanan yeni bir hafif tek ESA modeli önerdiler. Önerilen model, 7132 GR görüntüsünden oluşan kamuya açık veri seti üzerinde test edildi. %94,31 test doğruluk değeri elde edilmiştir. Situla vd. [15], GR görüntülerini sınıflandırmak için VGG16 ile bir dikkat mekanizması kullanmışlardır. Yöntemler üç GR görüntü veri kümesi için değerlendirilmiş ve GR görüntülerini dört sınıfa (COVID-19, Normal, Pnömoni bakteriyel ve Pnömoni viral) sınıflandırırken en yüksek doğruluk %85,43 olarak bildirilmiştir. Bashar vd. [16] GR görüntülerini kullanarak COVID-19 ve pnömoni teşhisi için bir derin öğrenme yaklaşımı önermiştir. Bu bağlamda, Kaggle'dan 21165 GR görüntüsü içeren halka açık bir veri seti elde edilmiştir. Bu çalışmada görüntü iyileştirmeleri ve veri artırma yöntemlerinin yanı sıra VGG16, VGG19, GoogleNet gibi çoklu transfer öğrenme algoritmaları kullanılmıştır. Arttırılmış ve geliştirilmiş veri seti üzerinde VGG16 algoritması kullanılarak en yüksek doğruluk %95,63 olarak elde edilmiştir. Szepesi vd. [17] normal ve pnömoni enfeksiyonlu çocukların GR görüntülerini içeren bir veri seti kullanarak InceptionV3 ve ResNet50 gibi transfer öğrenme modelleri geliştirmiştir. ResNet50 %89,06'lık bir doğruluk elde ederken, InceptionV3 %90,94'lük daha yüksek bir doğruluk elde etmiştir. Hwa vd. [18], GR görüntüleri ve canny kenar algılama görüntüleri kullanarak TÜB'yi tespit etmek için topluluk derin öğrenmesini kullanan bir yaklaşım sunmuştur. İki özellik kümesi çıkarılmış, birincisi GR görüntülerinden, ikinci küme ise canny kenar algılama görüntülerinden çıkarılmıştır. Topluluk modeli tarafından doğruluk açısından elde edilen en iyi sonuçlar %89,77 ve duyarlılık %90,91 olmuştur. Ibrokhimov ve Kang [19], GR görüntülerini kullanarak pnömoniyi tespit etmek için bir derin öğrenme teşhis sistemi geliştirmiştir. VGG19 ve ResNet50 gibi önceden eğitilmiş modeller kullanılarak transfer öğrenimi kullanılmıştır. Veri seti 11956 COVID-19 örneği, 11263 viral veya bakteriyel pnömoni ve 10701 normal örnekten

oluşturmuştur. VGG19 modeli, tüm sınıflarda ortalama %96,6 doğruluk elde ederken, ResNet50 modeli %95,85 doğruluk değeri elde etmiştir.

Bu çalışmanın amacı, GR taramalarına dayalı olarak COVID19, pnömoni, TÜB ve sağlıklı hastalar arasında erken otomatik tespit ve ayrımın fizibilitesini test etmektir. Literatürdeki çalışmalara bakıldığında genellikle önceden eğitilmiş modeller kullanılmıştır. Bu modellerin ortak özellikleri güçlü derin öznitelikler ile softmax sınıflandırıcısını birleştirmektir. Bu çalışmanın ana hedefi, GR görüntü sınıflandırma için güçlü derin öznitelikler elde edilmesi ve bu öznitelikler ile beslenen güçlü bir sınıflandırıcı geliştirmektir. Bu doğrultuda derin özniteliklere dayalı yeni bir model önerilmiştir. Önerilen modelin birinci aşamasında derin öznitelikleri elde etmek için geliştirilen bir ESA ile eğitim yapılmaktadır. Bu ağ mimarisi derinlemesine ayarlanabilir evrişim, geleneksel evrişim ve tam bağlı katmanlardan oluşmaktadır. Önerilen modelin ikinci aşamasında bu derin öznitelikler Destek vektör makineleri (DVM) sınıflandırıcısının girişine verilmektedir. Ayrıca bu aşamada DVM sınıflandırıcı derin öznitelikler kullanılarak eğitilmektedir. Önerilen modelin son aşamasında ise test veri seti ile önerilen sistem test edilmektedir. Kaggle platformundan alınan dört sınıflı GR veri kümesi üzerinde yapılan kapsamlı deneysel çalışmalarda önerilen model ortalama %99,30 doğruluk ve %98,90 F1-skoru ile üstün başarı sağlamıştır. Sınıflandırıcı olarak softmax kullanıldığında elde edilen doğruluk değeri %97,59 iken, önerilen modeldeki gibi DVM kullanıldığında ortalama doğruluk değeri %99,30 olarak elde edilmiştir. Literatürde sıklıkla softmax kullanılmaktadır. Bu çalışmada DVM kullanılarak %1,71'lik bir iyileştirme yapılmıştır.

Bu çalışmanın geri kalanı üç ayrı bölümden oluşmaktadır. Kullanılan veri seti ve önerilen yöntem Bölüm 2'de detaylı bir şekilde ele alınmıştır. Bölüm 3'de gerçekleştirilen deneysel çalışmalar ve bu deneysel çalışmaların sonuçları verilmiştir. Son bölüm olan Bölüm 4 ise çalışmanın genel bir özetinin yer aldığı Sonuçlar bölümüdür.

2. MATERYAL VE METOT (MATERIAL AND METHOD)

2.1. Göğüs Röntgeni Veri Kümesi (Chest X-ray Dataset)


Bu çalışmada, Kaggle platformunda halka açık GR görüntüleri kullanılmıştır [20]. Bu veri kümesi dört sınıf içermektedir. Bu sınıflar: COVID-19, Normal (Sağlıklı), Pnömoni ve Tüberküloz (TÜB). Veri kümesinde, COVID-19, Normal, Pnömoni ve TÜB için sırasıyla 576, 1583, 4273 ve 700 görüntü bulunmaktadır. Veri setinde dört sınıfa ait toplam 7132 GR görüntüsü bulunmaktadır. Çalışmada veri kümesi %80 eğitim, %10 test, %10 doğrulama olarak alınmıştır. Bu durumda, 5706 görüntü eğitim için, 713 görüntü test için ve 713 görüntü doğrulama (validation) için kullanılmıştır. Veri kümesinde eğitim için 461 COVID-19, 1266 Normal, 3419 Pnömoni ve 560 TÜB görüntüsü, test için 58 COVID-19, 158 Normal, 427 Pnömoni ve 70 TÜB görüntüsü bulunmaktadır. Bunun yanı sıra validation için 57 COVID-19, 159 Normal, 427

Pnömoni ve 70 TÜB görüntüsü yer almaktadır. Görüntü boyutları tek tip olmadığından dolayı görüntüler $224 \times 224 \times 3$ olarak yeniden boyutlandırılmıştır. Görüntüleri $224 \times 224 \times 3$ gibi standart bir boyuta yeniden boyutlandırmak, görüntü işlemede, özellikle de tek tip giriş boyutlarının gerekli olduğu derin öğrenme gibi görevler için yaygın bir uygulamadır. Literatürde derin öğrenme modelleri için görüntülerin $224 \times 224 \times 3$ olarak yeniden boyutlandırılması bağlamında çift doğrusal (Bilinear), Biküçük ve En yakın komşu enterpolasyon yöntemleri bulunmaktadır. Bunlarda çift doğrusal ve biküçük enterpolasyon yöntemleri sıklıkla tercih edilmektedir. Çift doğrusal yöntemi, orijinal görüntüdeki en yakın dört pikselin ağırlıklı ortalamasını dikkate alarak yeni piksel değerlerini hesaplamaktadır. Çift doğrusal enterpolasyon hızlıdır ancak görüntü kalitesinden bir miktar ödün verebilmektedir. En yakın komşu enterpolasyonuna kıyasla daha düzgün sonuçlar üretme eğilimindedir. Biküçük enterpolasyon, çift doğrusal enterpolasyondan daha karmaşıktır, yeni piksel değerlerini hesaplamak için daha geniş bir piksel komşuluğunu dikkate almaktadır. Daha yavaş bir işlem hızına sahiptir. Bu çalışma kapsamında, girdi GR görüntülerini $224 \times 224 \times 3$ boyutuna yeniden boyutlandırmak için çift doğrusal (Bilinear) enterpolasyon ön işleme yönteminin kullanımı tercih edilmiştir. Şekil 1, veri kümesindeki bazı örnek GR görüntülerini göstermektedir.


2.2. Önerilen Model (Proposed Model)

Bu çalışmada GR görüntü sınıflandırması için 3 aşamalı bir model geliştirilmiştir. Derin özniteliklere dayalı geliştirilen bu model Şekil 2'de verilmiştir.

Önerilen model temel olarak güçlü derin öznitelikler ile beslenen Destek Vektör Makinesi (DVM) sınıflandırıcısıdır. Önerilen model 3 aşamadan oluşmaktadır. Birinci aşamada GR görüntülerinin sınıflandırılma için güçlü derin özniteliklerin elde edilmesini amaçlanmaktadır. Bunun için Derinlemesine Ayrılabilir Evrişim (DAE) [21][22] ve geleneksel evrişim katmanlardan oluşan iki ESA mimarisi paralel olarak giriş görüntüsüne uygulanmaktadır. Daha sonra bu iki mimarinin son katmanlarından ve ara katmanlarından alınan 4 öznitelik haritası birleştirilmektedir. Bu ESA mimarilerinin ayrıntıları Şekil 2'de verilmiştir. Bu yapının temel amacı UNet [23] ve FPNet [24] modellerinde olduğu gibi zengin içerikli öznitelik haritaları elde etmektir. Geleneksel bir ESA mimarisinde ilk katmanlarda kenar, renk ve doku gibi mekânsal öznitelikler içerirken son katmanlarda anlamsal öznitelikler içermektedir [25][26]. Şekil 2'de önerilen bu yapı sayesinde GR görüntülerindeki hastalıkları sınıflandırmak için daha kapsamlı derin öznitelikler elde edilmesi sağlanmıştır. Ayrıca Şekil 2'de görüleceği üzere öznitelik çıkartma katmanları DAE ve geleneksel evrişim katmanları paralel olarak uygulanmıştır. Şekil 3'te geleneksel evrişim katmanı ve DAE katman yapıları verilmiştir.




Şekil 1. Dört farklı sınıfa ait örnek GR görüntüleri
(Sample CXR images of four different classes)



Şekil 2. GR sınıflandırması için önerilen model. Burada verilen s, ç ve f sırası ile stride (atlama) değeri, çekirdek boyutu ve filtre sayısını temsil etmektedir. Diğer yandan GOH ve TB sırası ile global ortalama havuzlama ve tam bağlı katmanları göstermektedir

(Proposed model for CXR classification. Here s, ç and f represent the stride value, kernel size and number of filters, respectively. On the other hand, GAP and FC represent global average pooling and fully connected layers, respectively)



Şekil 3. (a) Derinlemesine ayrılabilir evrişim ve (b) geleneksel evrişim işlemi

(a) Depthwise separable convolution and (b) traditional convolution operation)

DAE katmanı ConvMixer [27] ve MobileNet [28] mimarilerinde kullanılan ve her kanala bağımsız filtre uygulamasını sağlayan etkili bir evrişim bloğudur. Şekil 3(a)'da verilen DAE bloğunda temel olarak girdiye derinlemesine evrişim ve sonrasında noktasal evrişim katmanı uygulanmaktadır. Şekil 3(b)'de görüleceği üzere geleneksel evrişim işleminde girdi bir bütün olarak ele alınmakta ve tüm kanallar ilişkilendirilerek bir evrişim işlemi çıktısı elde edilmektedir. Şekil 3(a)'da verilen derinlemesine evrişim işleminde, girişin her kanalı için bağımsız olarak evrişimler gerçekleştirilen ve her kanalı ayrı ayrı işlerken uzamsal bilgileri korunmaktadır. Bu evrişim ile uzamsal özelliklere uyum sağlanarak daha iyi özellik çıkarımı gerçekleştirilmektedir. Diğer yandan derinlemesine evrişim işlemi sonunda kanallar arasındaki ilişkiyi değerlendirmek içinde bir noktasal evrişim işlemi uygulanmaktadır. Noktasal evrişim, derinlemesine evrişim çıkışından türetilen doğrusal bir kombinasyon aracılığıyla çeşitli kanallardaki ayrıntıları birleştirmek için 1x1 çekirdeklerin kullanılmasını içermektedir. Birincil işlevi, uzamsal boyutları korurken veya potansiyel olarak azaltırken özellik haritasının derinliğini genişletmektir. Sıklıkla 'darboğaz' katmanı olarak adlandırılan noktasal evrişim, kanal sayısını azaltarak hesaplama karmaşıklığının azaltılmasına yardımcı olmaktadır [29]. Şekil 2'de verilen birinci aşamadaki omurga ağında her DAE katman sonrasında ReLU aktivasyon fonksiyonu uygulanmaktadır.

Önerilen modelde tasarlanan omurga ağında geleneksel evrişim ve DAE katman sonunda çeşitli boyutlarda derin öznetelikler elde edilmektedir. Elde edilen bu öznetelikler nihai öznetelik vektörü elde etmek için birleştirilmiştir. Birleştirme işleminde öncelikle her öznetelik haritasına Global Ortalama Havuzlama (GOH) katmanı uygulanmaktadır. Daha sonra 8 nöronlu bir Tam Bağlı (TB) katman uygulanmaktadır. Bu sayede her öznetelik haritası için 8 adet öznetelik elde edilmektedir. Son olarak, bu öznetelikler birleştirilerek 32 adet derin öznetelik elde

edilmektedir. Birleştirme işleminin formülasyonu Denklem (1)'de verilmiştir..

$$K_i = TB^{n_{\text{öron}}=8}(GOH(F_i))$$

$$F_{\text{nihai}} = \text{concat} \begin{bmatrix} K_{DAE1} \\ K_{DAE2} \\ K_{GE1} \\ K_{GE2} \end{bmatrix} \quad (1)$$

Burada verilen F_i omurga ağından elde edilen öznetelik haritalarıdır. Şekil 2'de gösterildiği gibi F_i öznetelikleri için 2 adet geleneksel evrişim çıktısı ve 2 adet DAE katman çıktısı kullanılmıştır. Bu öznetelikler öncelikle GOH katmanı ile vektörleştirilmiştir. Daha sonra 8 nöronlu TB katmanı uygulanmıştır. Sonuç olarak her bir öznetelik haritası için 8 değerden oluşan K_i öznetelik vektörü elde edilmiştir. Birleştirme işleminin son aşamasında tüm vektörler keras kütüphanesinde bulunan birleştirme (concat) katmanı ile birleştirilerek 32 adet değere sahip nihai öznetelik vektörü (F_{nihai}) elde edilmiştir.

Bu öznetelikleri en iyi değere optimize etmek için ağ mimarisinin sonunda softmax sınıflandırıcı uygulanarak ağ mimarisinin parametreleri eğitilmektedir. Sonuç olarak birinci aşamada GR görüntü sınıflandırması için güçlü bir birleştirilmiş Derin Öznetelik Vektörü (DÖV) elde edilmektedir.

Birçok sınıflandırma probleminde derin özneteliklere softmax sınıflandırıcısı uygulanmaktadır [29][30]. Bunun yanında bazı aşırı öğrenme problemi ile başa çıkmak için DVM ve karar ağacı gibi geleneksel makine öğrenme gibi yöntemler uygulanmıştır. Bu sayede daha yüksek başarılar sağlanmıştır [31]. Bu çalışmalara benzer olarak önerilen yaklaşımın ikinci aşamasında birleştirilmiş özneteliklere DVM sınıflandırıcı uygulanmıştır.

DVM, sınıflandırma ve regresyon görevleri için kullanılan güçlü bir denetimli makine öğrenme algoritmasıdır. Birincil hedefi, sınıflar arasındaki mesafeyi maksimuma çıkarırken veri noktalarını farklı sınıflara en iyi şekilde ayıran bir hiper düzlem bulmaktır. DVM algoritmasında hiper düzlem, daha yüksek boyutlarda bir alt uzaydır. DVM, verileri sınıf etiketlerine göre en iyi şekilde ayıran hiper düzlemi bulmayı amaçlamaktadır. Diğer yandan destek vektörleri, hiper düzleme en yakın olan ve hiper düzlemin konumunu ve yönelimini doğrudan etkileyen veri noktalarıdır. Önerilen modelin ikinci aşamasında DVM sınıflandırıcısı eğitim veri kümesi ile eğitilmiştir. Önerilen modelin üçüncü aşamasında geliştirilen sistem test edilmiştir. Yapılan deneysel çalışmalarda DVM sınıflandırıcısı softmax sınıflandırıcısına göre %1,71 daha yüksek doğruluk değeri sağladığı görülmüştür. Bu sonuçlar GR görüntü sınıflandırması için DVM modelinin etkili olduğunu kanıtlamıştır.

3. DENEYSEL ÇALIŞMALAR VE SONUÇLARI (EXPERIMENTAL STUDIES AND RESULTS)

Bu bölümde deneysel çalışmalarda kullanılan hiperparametreler, kullanılan değerlendirme ölçütleri, deneysel çalışmalardan elde edilen sınıflandırma sonuçları ve bu sonuçların tartışılması sunulmaktadır.

3.1. Parametre Ayarları (Parameter Settings)

Deneysel çalışmalar 11 GB RTX 3080 ti GPU, 64 GB RAM ve i9-9900KF işlemci ve Ubuntu 20.04 işletim sistemine sahip bir bilgisayarda gerçekleştirilmiştir. Derin öğrenme modeli Keras-TensorFlow kütüphanesi kullanılarak tasarlanmıştır. Deneysel çalışmalarda kullanılan hiperparametrelerden, adım sayısı (epochs) 100, yığın boyutu (batch size) 16 ve öğrenme oranı (learning rate) 0,0001 olarak ayarlanmıştır. Bu değerler yapılan birkaç deneme sonucunda en iyi eğitim senaryosu olarak kabul edilmiştir. Çalışmada veri kümesi %80 eğitim %10 test, %10 doğrulama olarak alınmıştır. Yani; 7132 GR görüntüsünden 5706 görüntü eğitim için, 713 görüntü test için ve 713 görüntü validation (doğrulama) için kullanılmıştır. Buna ek olarak önerilen modelin eğitiminde optimizasyon için Adam modeli kullanılmıştır.

3.2. Değerlendirme ölçütleri (Evaluation Criteria)

Değerlendirme ölçütleri, bir modelin tahminlerinin etkinliğinin nicel ve nesnel bir ölçüsünü sağlamaktadır. Ayrıca sınıflandırma performansını değerlendirmek için de gereklidirler. Bu ölçütler, her biri kendi güçlü yönleri ve sınırlamaları olan modelin performansı hakkında farklı perspektifler sağlamaktadır. Önerilen modelin etkinliği F1-skoru (F1-score), duyarlılık (recall), kesinlik (precision) ve sınıflandırma doğruluğu (accuracy) gibi değerlendirme ölçütleri kullanılarak ölçülmektedir. Önemli bir performans değerlendirme ölçütü olan doğruluk, tıbbi teşhislerde, özellikle dengesiz veri kümelerinde (bir hastalığın diğerlerinden daha yaygın olabileceği durumlarda) genel doğruluğu ölçerken, doğruluk tek başına doğru bir tablo sunmayabilir. Örneğin, Tüberküloz vakalarının COVID-19 veya zatürreden daha yaygın olduğu bir veri setinde, modelin Tüberküloz vakalarını doğru şekilde tanımlarken, potansiyel olarak COVID-19 veya zatürre vakalarını eksik veya yanlış sınıflandırarak yüksek doğruluk elde edilebilmektedir. Bu tıbbi bağlamda kesinlik, belirli bir hastalığın, o hastalık olarak tahmin edilen tüm durumlar arasında doğru şekilde tanımlanmasının önemini vurgulamaktadır. Örneğin, COVID-19 için yüksek hassasiyet, modelin tahmin edilen COVID-19 vakaları arasında gerçek COVID-19 vakalarını doğru bir şekilde tanımlama ve hatalı pozitifleri en aza indirme yeteneğini göstermektedir. Duyarlılık, modelin veri kümesi içindeki belirli bir hastalığın tüm örneklerini yakalama yeteneğine odaklanmaktadır. Tıbbi teşhisler için yüksek duyarlılık, modelin belirli bir hastalık için yüksek oranda gerçek pozitif vakayı başarılı bir şekilde tespit etmesi ve yanlış negatifleri azaltması anlamına gelmektedir. F1 skoru, kesinlik ve duyarlılığı dengelemekte ve her iki ölçümü de eşit şekilde dikkate alan

tek bir ölçüm sunmaktadır. Eşit olmayan bir sınıf dağılımı olduğunda veya hem yanlış pozitiflerin hem de yanlış negatiflerin en aza indirilmesi gerektiğinde özellikle değerlidir.

Doğruluk, yöntem tarafından üretilen doğru tahminlerin yüzdesini ölçmektedir. Doğru tahminlerin sayısının yapılan toplam tahmin sayısına bölünmesiyle belirlenmektedir. Doğruluk değerinin hesaplanması Denklem (2)'de detaylandırıldığı şekilde yapılmaktadır. Önerilen yöntemle yapılan tüm pozitif tahminlerdeki doğru pozitiflerin oranının bir ölçüsü olan kesinlik, doğru pozitiflerin sayısının doğru pozitifler ve yanlış pozitiflerin toplamına bölünmesiyle belirlenmektedir. Kesinlik değerinin hesaplanması Denklem (3)'teki gibidir. Duyarlılık, doğru pozitiflerin sayısının doğru pozitifler ve yanlış negatiflerin toplamına bölünmesiyle belirlenmektedir. Duyarlılık Denklem (4)'teki gibi formüle edilmektedir. Duyarlılık ve kesinliğin harmonik ortalaması olan F1 skoru, özellikle sınıflar dengesiz olduğunda duyarlılık ve kesinliği dengelemek için vazgeçilmez bir ölçüttür. Hem kesinliği hem de duyarlılığı yakalayan tek bir puan sağlayarak genel model performansı değerlendirmesi için güçlü bir ölçüt haline getirmektedir. F1 skoru Denklem (5)'te belirtildiği şekilde hesaplanmaktadır [32][33].

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (2)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4)$$

$$F1 - \text{skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

Tüm bu değerlendirme ölçütleri karışıklık matrisinden çıkarılmaktadır. Bir karışıklık matrisinin açıklayıcı bir gösterimi Şekil 4'te görülebilmektedir. Standart bir karışıklık matrisinde dört ana unsur bulunmaktadır: Gerçek Pozitifler (TP): Bunlar, gerçek kategorinin olumlu olduğu ve modelin bunu doğru bir şekilde olumlu olarak tahmin ettiği durumları ifade etmektedir. Gerçek Negatifler (TN): Bunlar, gerçek kategorinin negatif olduğu ve modelin bunu negatif olarak doğru bir şekilde tahmin ettiği durumları temsil etmektedir. Yanlış Pozitifler (FP): Bu örnekler, gerçek kategori negatif olduğunda ortaya çıkar, ancak model bunu yanlış bir şekilde olumlu olarak tahmin etmektedir. Yanlış Negatifler (FN): Bunlar, gerçek kategorinin olumlu olduğu, ancak modelin hatalı bir şekilde olumsuz olarak tahmin ettiği durumlardan kaynaklanmaktadır [34].

		Gerçek	
		Pozitif (P)	Negatif (N)
Tahmin	Pozitif (P)	TP	FP
	Negatif (N)	FN	TN

Şekil 4. Karışıklık Matrisi (Confusion Matrix)

3.3. Deneysel Sonuçlar (Experimental Results)

Önerilen modelin sınıflandırma performansını analiz etmek için dört sınıflı (COVID19, Normal, Pnömoni ve TÜB) GR görüntüleri veri kümesi üzerinde kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Deneysel çalışmalarda önerilen modelin başarısını test etmek için test veri kümesi kullanılmıştır. Önerilen modelin karışıklık matrisi Şekil 5'te verilmiştir. Test veri kümesinde 58 COVID19 GR görüntüsünden tamamının, 158 Normal GR görüntüsünden 151'inin, 427 pnömoni GR görüntüsünden 424'ünün ve son olarak 70 TÜB görüntüsünden tamamının doğru tahmin edildiği görülmektedir. 158 Normal GR görüntüsünden 7'si pnömoni ve 427 pnömoni GR görüntüsünden 3'ü Normal görüntü olarak yanlış sınıflandırılmıştır. Toplamda 713 GR görüntüsünden 703'ünün doğru bir şekilde tahmin edildiği görülmektedir. Karışıklık matrisinden her bir sınıf için TP, TN, FP ve FN değerleri incelendiğinde, COVID-19 için TP:58, TN:645, FP:0 ve FN:0'dır. Bu sonuçlara göre COVID-19 için doğruluk değeri %100'dür. Normal GR görüntülerinin yer aldığı sınıf için TP:151, TN:552, FP:3 ve FN:7'dir. Bu durumda, Normal sınıfı için elde edilen doğruluk değeri %98,60 olmaktadır. Pnömoni sınıfı için TP:424, TN:279, FP:7 ve FN:3'tür. Pnömoni sınıfının doğruluk değeri %98,60'tır. Son olarak TÜB sınıfı için TP: 70, TN:633, FP ve FN ise 0'dır. Bu sonuçlara göre TÜB sınıfının doğruluk değeri %100 olmaktadır. Bu dört sınıfın bazlı doğruluk değerlerinin ortalaması %99,30 olarak elde edilmektedir.

58	0	0	0
0	151	7	0
0	3	424	0
0	0	0	70

Şekil 5. Önerilen modelin karışıklık matrisi
(Confusion matrix of the proposed model)

Önerilen modelin sınıf bazlı değerlendirme ölçütleri Tablo 1'de verilmiştir. Tablo 1 incelendiğinde önerilen modelin COVID19 ve TÜB görüntülerini %100 doğruluk, kesinlik, duyarlılık ve F1-skoru ile tespit ettiği görülmektedir. Benzer şekilde kullanılan GR veri kümesinde normal görüntüler %98,60 doğruluk, %98,05 kesinlik, %95,57 duyarlılık, %96,79 F1-skoru elde ederken, pnömoni %98,60 doğruluk, %98,38 kesinlik, %99,30 duyarlılık, %98,84 F1-skoru elde etmiştir. Sınıf bazlı sonuçlara bakıldığında, önerilen modelin COVID-19 ve TÜB hastalıklarını başarılı bir şekilde tespit edebildiği görülmektedir.

Önerilen model literatürden son yıllarda yapılmış farklı deneysel çalışmalar ile karşılaştırılmış ve sonuçlar Tablo 2'de verilmiştir. Tablo 2 incelendiğinde, Qagos vd. [13], GR görüntülerinin sınıflandırılması için evrişim, max-pooling, toplu normalleştirme, bırakma (dropout) ve sınıflandırma katmanı olarak da softmax kullanarak yeni bir ESA modeli önermiştir. Önerilen model 3x3 evrişimlerden oluşmaktadır. Bu ESA mimarisinin performansını test etmek için dört sınıftan (TÜB, COVID-19, Normal ve pnömoni) oluşan GR görüntü veri kümesi üzerinde gerçekleştirilen deneysel çalışmalar sonucunda %94,53 doğruluk değeri elde etmiştir. Benzer şekilde GR görüntüleri kullanılarak gerçekleştirilen diğer çalışmaların sonuçları şu şekildedir. Qagos vd. [13], aynı ESA mimarisini kullanarak üç sınıflı (normal, COVID-19 ve pnömoni) GR veri kümesi üzerinde ESA modeli ile %95,02 elde ettiler. Bhandari vd. [14], beş 2 boyutlu evrişim, dört max-pooling, beş dropout katmanı ve softmax sınıflandırıcısından oluşan bir ESA modeli kullanarak GR görüntülerini sınıflandırmıştır. Bu ESA modeli ile dört sınıflı GR veri kümesi üzerinde geliştirilen deneysel çalışmalar sonucunda %94,31 doğruluk sonucu bulunmuştur. Sitaula vd. [15], GR görüntülerinin sınıflandırılması için dikkat tabanlı bir VGG modeli önermiştir. Önerilen model, önceden eğitilmiş DL modeline (VGG-16) ve dikkat modülüne dayanmaktadır. Bu model son katmanında sınıflandırıcı olarak softmax kullanılmaktadır. Önerilen dikkat tabanlı VGG16 modeli ile dört sınıflı GR veri kümesi üzerinde gerçekleştirilen deneysel çalışmalar sonucunda %85,43 doğruluk değeri elde edilmiştir. Liu vd. [35], iki sınıflı (TÜB ve normal) GR veri kümesi üzerinde transfer öğrenme ile AlexNet ve GoogLeNet mimarileri kullanılarak %85,68 doğruluk değeri elde etmişlerdir. Her iki modelde de son sınıflandırma katmanı olarak softmax sınıflandırıcısı kullanılarak %85,68 doğruluk değeri elde edilmiştir. Rahimzadeh vd. [36], GR görüntülerinin sınıflandırılması için bir topluluk öğrenimi modeli oluşturmaktadır. Bu topluluk öğrenimi modeli Xception ve ResNet50 modellerinden oluşmaktadır. Her iki model birleştirildikten sonra son sınıflandırıcı katmanı olarak softmax kullanılmaktadır. Önerilen topluluk öğrenimi modelinin performansını test etmek için üç sınıflı (normal, COVID-19 ve pnömoni) GR veri kümesi kullanılmıştır. Bu topluluk öğrenimi modeli ile %91,40 doğruluk değeri bulunmuştur. Khan vd. [37], dört sınıflı GR veri kümesi üzerinde ESA tabanlı CoroNet kullanılarak sınıflandırma işlemini gerçekleştirdiler. Önerilen CoroNet, dört sınıflı GR görüntülerini sınıflandırmak için derin bir evrişimli sinir ağı modelidir. Bu modelin son sınıflandırıcı katmanında softmax kullanılmaktadır. Önerilen CoroNet modeli ile gerçekleştirilen deneysel çalışmalar sonucunda %89,60 doğruluk değeri bulunmuştur. Shastri vd. [38], açık olarak erişilebilen bir veri kümesi yardımıyla GR dijital görüntülerini kullanarak COVID-19 hastalığını tespit etmeye yönelik bir CheXImageNet modeli tanıttılar. Önerilen model, evrişim, max-pooling, toplu normalleştirme, dropout katmanlarından oluşmaktadır. Diğer ESA modellerinden farklı olarak aktivasyon fonksiyonu olarak Leaky_ReLU kullanılmıştır. Son sınıflandırıcı katmanında ise softmax kullanılmıştır. Üç

sınıflı (normal, COVID-19, pnömoni) GR veri kümesi ile gerçekleştirilen deneysel çalışmalar sonucunda %93 doğruluk sonucu bulunmuştur. Al-Timemy vd. [39], beş sınıflı GR veri kümesi üzerinde ResNet50 ve alt uzay ayırt edici sınıflandırıcı topluluğu modelini kullanarak sınıflandırma işlemi gerçekleştirmiştir. Derin öznetelik hesaplaması için ResNet50'den ve alt uzay ayırt edici sınıflandırıcı topluluğundan oluşan yeni bir boru hattı, %91,6'lık bir tespit doğruluğu elde ederek beş sınıfın sınıflandırılmasında en iyi performansı gösterdi. Bunun yanı sıra üç sınıftan (COVID-19, normal ve TÜB) oluşan bir veri kümesi üzerinde aynı model kullanılarak %98,6 doğruluk değeri elde ettiler. Asif vd. [40], üç sınıflı GR veri kümesi üzerinde derin ESA ve transfer öğrenmeli InceptionV3 birlikte kullanılarak %93 doğruluk değerini bulmuştur. Önerilen modelin son sınıflandırıcı katmanı diğer çalışmalarda da olduğu gibi softmax'tir. Metwally vd. [41], dört sınıflı 7135 GR görüntüsü içeren veri kümesi

üzerinde önceden eğitilmiş EfficientNetB0, Xception ve NasnetLarge modeli kullanılarak %91,3 doğruluk değeri bulunmuştur. Literatürdeki yöntemler incelendiğinde hepsinin son sınıflandırıcı katmanında softmax kullanıldığı görülmüştür. Bundan yola çıkarak, önerilen modelin son katmanında iki farklı sınıflandırıcı (softmax ve DVM) kullanılarak deneysel çalışmaların sonuçları verilmiştir. Son katmanda softmax sınıflandırıcı kullanılarak dört sınıflı GR veri kümesi üzerinde %97,59 doğruluk değeri elde edilirken, son katmanda DVM kullanılarak yine aynı veri kümesi üzerinde %99,30 doğruluk değeri elde edilmiştir. Bizim önerdiğimiz derin özneteliklere dayalı ESA modelinde son sınıflandırıcı olarak DVM kullanılmaktadır. DVM kullanımının sınıflandırma doğruluğunu %1,71 arttırdığı görülmektedir. Tablo 2'deki tüm modeller incelendiğinde son sınıflandırıcı olarak DVM'nin kullanıldığı önerilen modelimizin açık bir şekilde başarılı olduğu görülmektedir.

Tablo 1. Önerilen modelin sınıf bazlı sonuçları(Class-based results of the proposed model) (%)

Değerlendirme ölçütü	COVID19	NORMAL	PNÖMONİ	TÜB	Ortalama
Doğruluk	100	98,60	98,60	100	99,30
Kesinlik	100	98,05	98,38	100	99,10
Duyarlılık	100	95,57	99,30	100	98,71
F1-skor	100	96,79	98,84	100	98,90

Tablo 2. Önerilen modelin son teknoloji yöntemlerle karşılaştırılması

(Comparison of the proposed model with state-of-the-art methods)

Referans çalışma	Sınıf isimleri ve örnek sayısı	Sınıf sayısı	Model	Doğruluk (%)
Qagos vd. [13]	Normal = 1583, COVID19 = 576 Pnömoni = 4273, TÜB = 155	4	Özel ESA	94,53
Qagos vd. [13]	Normal = 1341, COVID19 = 864 Pnömoni = 1345	3	Özel ESA	95,02
Bhandari vd. [14]	Normal = 1583, COVID19 = 576 Pnömoni = 4273, TÜB = 700	4	Özel ESA	94,31
Sitaula vd. [15]	Normal = 310, Bakteriye Pnömoni = 330, Viral Pnömoni = 327, COVID19 = 284	4	Dikkat tabanlı VGG	85,43
Liu vd. [35]	TÜB = 4248, Normal = 453	2	Transfer öğrenme ile AlexNet ve GoogLeNet	85,68
Rahimzadeh vd. [36]	Normal = 8851, COVID19 = 180 Pnömoni = 6054	3	Topluluk Öğrenimi (Xception ve ResNet50)	91,40
Khan vd. [37]	Normal = 310, Bakteriye Pnömoni = 330, Viral Pnömoni = 327, COVID19 = 284	4	ESA tabanlı CoroNet	89,60
Shastri vd. [38]	Normal = 1341, COVID19 = 864 Pnömoni = 1345	3	CheXImageNet model	93,00
Al-Timemy vd. [39]	Normal = 439, COVID19 = 435 Bakteriye Pnömoni = 439, Viral Pnömoni = 439, TÜB = 434	5	ResNet50 özellikleri ve altuzay ayırt edici sınıflandırıcı topluluğu	91,60
Asif vd. [40]	Normal = 1341, COVID19 = 864 PNEUMONIA = 1345	3	Derin ESA + transfer öğrenmeli Inception V3	93,00
Metwally vd. [41]	Normal = 1583, COVID19 = 576 Pnömoni = 4273, TÜB = 703	4	Önceden eğitilmiş EfficientNetB0, Xception ve NasnetLarge	91,3
Önerilen Model	Normal = 1583, COVID19 = 576 Pnömoni = 4273, TÜB = 700	4	Derin özneteliklere dayalı ESA modeli + Softmax	97,59
Önerilen Model	Normal = 1583, COVID19 = 576 Pnömoni = 4273, TÜB = 700	4	Derin özneteliklere dayalı ESA modeli + DVM	99,30

4. SONUÇ (CONCLUSION)

COVID-19, pnömoni ve TÜB tedavi edilmediğinde veya yanlış yönetildiğinde ölümcül olabilmektedir. GR görüntüleri, bu tür akciğer hastalıklarının teşhisi için en sık kullanılan görüntüleme yöntemidir. Bu görüntülerin yorumlanması için uzmanlara ihtiyaç duyulmaktadır. Hasta sayısı arttıkça, az sayıda olan bu uzmanlar aşırı çalışmak zorunda kalmakta ve bu süreçte tanıların gecikmesine ve sonuçların zamanında rapor edilmemesine neden olmaktadır. Ayrıca, bu hastalıkların öznel doğası nedeniyle, uzmanların aynı GR görüntüsü yorumu için farklı sonuçlar üretmesi muhtemeldir. Akciğer hastalıklarının tedavisi, özellikle bir durum gözden kaçarsa ve ileride ek sağlık hizmeti maliyetleri gerektirirse pahalı olabilmektedir. Aynı zamanda, bu tür sorunların üstesinden gelmek için, çoklu akciğer hastalıklarının tespiti için otomasyon, teşhis sürecini kolaylaştırmaya yardımcı olabilmekte ve sağlık hizmeti sağlayıcılarının yalnızca uzmanlara güvenmeden tedavi konusunda daha bilinçli kararlar almasını sağlayabilmektedir. Bu, bekleme sürelerinin kısaltılmasına, hasta sonuçlarının iyileştirilmesine ve uzmanların üzerindeki yükün azaltılmasına yardımcı olurken daha hızlı ve daha verimli teşhisler yapılmasını sağlayabilmektedir. Bu doğrultuda son yıllarda bilgisayar destekli teşhis oldukça önemli rol oynamaktadır. Bu çalışmada, enfekte hastaların GR görüntülerini kullanarak pnömoni, COVID19 ve TÜB'ü tespit etmek ve teşhis etmek için yeni bir derin öğrenme modeli önerilmektedir. Bu model, derin özelliklere dayalı yeni bir modeldir ve üç aşamadan oluşmaktadır. Bu modelin ilk aşamasında, eğitim amacıyla derin özellikler elde etmek için özel olarak tasarlanmış bir ESA mimarisi kullanılmaktadır. Bu ESA mimarisi, derinlemesine ayarlanabilir evrişim, geleneksel evrişim ve tamamen bağlantılı katmanları kapsamaktadır. Önerilen modelin bir sonraki aşamasında, bu derin özellikler DVM olarak bilinen bir sınıflandırıcı için girdi olarak kullanılmaktadır. Ayrıca, bu aşamada, DVM sınıflandırıcısı derin özellikler kullanılarak eğitilmektedir. Son olarak, bu yenilikçi modelin sonuç aşamasında, bir test veri kümesi kullanılarak modelin performansının bir değerlendirilmesi yapılmaktadır. Önerilen modelin performans analizi için halka açık bir platform olan Kaggle'da dört sınıf (COVID-19, Pnömoni, normal ve TÜB) ve 7132 GR görüntüsü içeren bir veri kümesi üzerinde deneysel çalışmalar gerçekleştirilmiştir. Önerilen model, GR'lerde belirtilen hastalıkları %99,30'luk ortalama doğruluk, %99,10 kesinlik, %98,71 duyarlılık ve %98,90 F1 skor değerleri ile tespit etmiştir. Ayrıca sınıf bazlı doğruluk değerleri incelendiğinde, önerilen model COVID19 ve TÜB hastalıklarını %100 doğrulukla tespit ederken, pnömoni hastalığını %98,60 doğruluk ile tespit etmiştir. Aynı zamanda önerilen modelde kullanılan DVM sınıflandırıcısının aksine çoğu derin öğrenme modellerinin son katmanında sınıflandırıcı olarak kullanılan softmax sınıflandırıcısı ile de deneysel çalışmalar yapılmıştır. Önerilen modelde DVM yerine, softmax sınıflandırıcısı kullanıldığında %97,59 doğruluk değeri bulunmuştur. DVM ile karşılaştırıldığında, DVM sınıflandırıcısının

%1,71 daha başarılı sonuç ürettiği görülmektedir. Son olarak, literatürdeki benzer son teknoloji çalışmalar ile karşılaştırmalı analizler, önerilen modelin diğer alternatif çalışmalardan daha iyi performans gösterdiğini ortaya koymaktadır. Bu nedenle önerilen model, klinisyenlerin COVID-19, TÜB ve pnömoni vakalarını daha doğru tespit etmelerine yardımcı olabilmektedir. Yakın gelecekteki araştırma doğrultusunda, öncelikle önerilen modelin farklı veri kümelerindeki performansları incelenecektir. Bunun yanı sıra, bu çalışmada bahsedilmeyen diğer akciğer hastalıklarını, önerdiğimiz modele dayanarak tespit etmeyi ve sınıflandırmayı amaçlamaktayız.

KAYNAKLAR (REFERENCES)

- [1] D. Visca, C. W. M. Ong, S. Tiberi et al., "Tuberculosis and COVID-19 interaction: A review of biological, clinical and public health effects", *Pulmonology*, 27(2), 151–165, 2021.
- [2] A. E. Gorbalenya, S. C. Baker, R. S. Baric et al., "The species Severe acute respiratory syndrome-related coronavirus: classifying 2019-nCoV and naming it SARS-CoV-2", *Nature Microbiology*, 5(4), 536–544, 2020.
- [3] S. R. Islam, S. P. Maity, A. K. Ray, and M. Mandal, "Deep learning on compressed sensing measurements in pneumonia detection", *International Journal of Imaging Systems and Technology (IMA)*, 32(1), 41–54, 2022.
- [4] A. H. van't Hoog, H. K. Meme, K. F. Laserson et al., "Screening strategies for tuberculosis prevalence surveys: The value of chest radiography and symptoms", *PLoS One*, 7(7), 1–9, 2012.
- [5] H. Abdul, S. Hashmi, and H. M. Asif, "Early detection of COVID-19", *Frontiers in Medicine*, 2020.
- [6] M. Mamalakos, A. J. Swift, B. Vorselaars et al., "DenResCov-19: A deep transfer learning network for robust automatic classification of COVID-19, pneumonia, and tuberculosis from X-rays", *Computerized Medical Imaging and Graphics*, 94(October), 102008, 2021.
- [7] A. A. Soltan, S. Kouchaki, T. Zhu et al., "Artificial intelligence driven assessment of routinely collected healthcare data is an effective screening test for COVID-19 in patients presenting to hospital", *medRxiv*, 2020.
- [8] G. J. Williams, P. Macaskill, M. Kerr et al., "Variability and accuracy in interpretation of consolidation on chest radiography for diagnosing pneumonia in children under 5 years of age", *Pediatric Pulmonology*, 48(12), 1195–1200, 2013.
- [9] D. Stacey, F. Legare, K. Lewis et al., "Decision aids for people facing health treatment or screening decisions", *Cochrane Database of Systematic Reviews*, 2017(4), 14651858, 2017.
- [10] H. Greenspan, R. San José Estépar, W. J. Niessen, E. Siegel, and M. Nielsen, "Position paper on COVID-19 imaging and AI: From the clinical needs and technological challenges to initial AI solutions at the lab and national level towards a new era for AI in healthcare", *Medical Image Analysis*, 66(April), 101800, 2020.
- [11] S. Lalmuanawma, J. Hussain, and L. Chhakchhuak, "Applications of machine learning and artificial intelligence for Covid-19 (SARS-CoV-2) pandemic: A review", *Chaos, Solitons and Fractals*, 139, 110059, 2020.

- [12] M. S. Ahmed, A. Rahman, F. AlGhamdi et al., “Joint Diagnosis of Pneumonia, COVID-19, and Tuberculosis from Chest X-ray Images: A Deep Learning Approach”, *Diagnostics*, 13(15), 2023.
- [13] N. N. Qaqos and O. S. Kareem, “COVID-19 Diagnosis from Chest X-ray Images Using Deep Learning Approach”, **3rd International Conference on Advanced Science and Engineering (ICOASE 2020)**, Duhok, 110–116, 23-24 Aralık, 2020.
- [14] M. Bhandari, T. B. Shahi, B. Siku, and A. Neupane, “Explanatory classification of CXR images into COVID-19, Pneumonia and Tuberculosis using deep learning and XAI”, *Computers in Biology and Medicine*, 150(September), 106156, 2022.
- [15] C. Sitaula and M. B. Hossain, “Attention-based VGG-16 model for COVID-19 chest X-ray image classification”, *Applied Intelligence*, 51(5), 2850–2863, 2021.
- [16] A. Bashar, G. Latif, G. Ben Brahim, N. Mohammad, and J. Alghazo, “COVID-19 pneumonia detection using optimized deep learning techniques”, *Diagnostics*, 11(11), 1–18, 2021.
- [17] P. Szepesi and L. Szilágyi, “Detection of pneumonia using convolutional neural networks and deep learning”, *Biocybernetics and Biomedical Engineering*, 42(3), 1012–1022, 2022.
- [18] S. K. T. Hwa, M. H. A. Hijazi, A. Bade, R. Yaakob, and M. S. Jeffree, “Ensemble deep learning for tuberculosis detection using chest X-ray and canny edge detected images”, *IAES International Journal of Artificial Intelligence*, 8(4), 429–435, 2019.
- [19] B. Ibrokhimov and J.-Y. Kang, “Deep Learning Model for COVID-19-Infected Pneumonia Diagnosis Using Chest Radiography Images”, *BioMedInformatics*, 2(4), 654–670, 2022.
- [20] Internet: JTIPTJ, Chest X-Ray (Pneumonia,Covid-19,Tuberculosis), Kaggle. [Online]. Available: <https://www.kaggle.com/datasets/jtiptj/chest-xray-pneumoniacovid19tuberculosis?select=train>, 20.09.2023.
- [21] H. Üzen, M. Turkoglu, M. Aslan, and D. Hanbay, “Depth-wise Squeeze and Excitation Block-based Efficient-Unet model for surface defect detection”, *The Visual Computer*, 2022.
- [22] H. Firat, M. E. Asker, and D. Hanbay, “Depthwise Separable Convolution Based Residual Network Architecture for Hyperspectral Image Classification”, *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknoloji*, 10(2), 242–258, 2022.
- [23] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation”, in *Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2015*, 234–241, 2015.
- [24] S. Seferbekov, V. Iglovikov, A. Buslaev, and A. Shvets, “Feature pyramid network for multi-class land segmentation”, **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, Salt Lake City, UT, USA, 18-22 June, 272–275, 2018.
- [25] F. Meng, X. Wang, F. Shao, D. Wang, and X. Hua, “Energy-efficient gabor kernels in neural networks with genetic algorithm training method”, *Electronics*, 8(1), 2019.
- [26] A. Mahendran and A. Vedaldi, “Visualizing Deep Convolutional Neural Networks Using Natural Pre-images”, *International Journal of Computer Vision*, 120(3), 233–255, 2016.
- [27] A. Trockman and J. Z. Kolter, “Patches Are All You Need?”, 1–16, 2022.
- [28] A. G. Howard, M. Zhu, B. Chen et al., “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications”, 2017.
- [29] M. E. Asker, “Hyperspectral image classification method based on squeeze-and-excitation networks, depthwise separable convolution and multibranch feature fusion”, *Earth Science Informatics*, 1427–1448, 2023.
- [30] M. Türkoğlu, K. Hanbay, I. S. Sivrikaya, and D. Hanbay, “Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması”, *BEÜ Fen Bilimleri. Dergisi*, 9(1), 334–345, 2020.
- [31] M. F. Özdemir and D. Hanbay, “A Novel Covid-19 Detection System Based on PSO and Hybrid Feature Using Support Vector Machines”, *Journal of Computer Science, IDAP-2022*, 120–129, 2022.
- [32] Y. Ha, Z. Du, and J. Tian, “Fine-grained interactive attention learning for semi-supervised white blood cell classification”, *Biomedical Signal Processing and Control*, 75(September), 103611, 2022.
- [33] A. Naseri and A. Rezaei Nasab, “Automatic identification of minerals in thin sections using image processing”, *Journal of Ambient Intelligence and Humanized Computing*, 2021.
- [34] H. Firat, “Classification of microscopic peripheral blood cell images using multibranch lightweight CNN-based model”, *Neural Computing and Application*, 2023.
- [35] C. Liu, Y. Cao, M. Alcantara et al., “TX-CNN: Detecting tuberculosis in chest X-ray images using convolutional neural network”, **2018 25th IEEE International Conference on Image Processing (ICIP)**, 7-10 Ekim, Atina, 2314–2318, 7-10 Ekim, 2018.
- [36] M. Rahimzadeh and A. Attar, “A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2”, *Informatics in Medicine Unlocked*, 19, 100360, 2020.
- [37] A. I. Khan, J. L. Shah, and M. M. Bhat, “CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images”, *Computer Methods and Programs in Biomedicine*, 196, 105581, 2020.
- [38] S. Shastri, I. Kansal, S. Kumar, K. Singh, R. Popli, and V. Mansotra, “CheXImageNet: a novel architecture for accurate classification of Covid-19 with chest x-ray digital images using deep convolutional neural networks”, *Health and Technology*, 12(1), 193–204, 2022.
- [39] A. H. Al-Timemy, R. N. Khushaba, Z. M. Mosa, and J. Escudero, “An Efficient Mixture of Deep and Machine Learning Models for COVID-19 and Tuberculosis Detection Using X-Ray Images in Resource Limited Settings”, *Studies in System, Decision and Control*, 358(December), 77–100, 2021.
- [40] S. Asif, Y. Wenhui, H. Jin, and S. Jinhai, “Classification of COVID-19 from Chest X-ray images using Deep Convolutional Neural Network”, **2020 IEEE 6th International Conference on Computer and Communications (ICCC)**, Chengdu, 426–433, 11-14 Aralık, 2020.

- [41] M. A. H. Metwally, **Automatic Detection and Multi-Class Classification of COVID-19, Pneumonia, and Tuberculosis Diseases in Chest X-ray Images Using Deep Learning Techniques**, Yüksek Lisans Tezi, University of Victoria, 2022.