



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.gov.tr/politeknik>



Yapay sinir ağı tabanlı model ile x-ray görüntülerinden Covid-19 teşhisi

Covid-19 diagnosis from x-ray images with artificial neural network based model

Yazar(lar) (Author(s)): Kubilay ATAŞ¹, Atakan KAYA², Indrit MYDERRİZİ³

ORCID¹: 0000-0002-3307-866X

ORCID²: 0000-0001-8176-3576

ORCID³: 0000-0002-2112-7911

To cite to this article: Ataş K., Kaya A. ve Myderrizi I., “Yapay sinir ağı tabanlı model ile x-ray görüntülerinden Covid-19 teşhisi”, *Journal of Polytechnic*, 26(2): 541-551, (2023).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Ataş K., Kaya A. ve Myderrizi I., “Yapay sinir ağı tabanlı model ile x-ray görüntülerinden Covid-19 teşhisi”, *Politeknik Dergisi*, 26(2): 541-551, (2023).

Erişim linki (To link to this article): <http://dergipark.gov.tr/politeknik/archive>

DOI: 10.2339/politeknik.861536

Yapay Sinir Ağı Tabanlı Model ile X-ray Görüntülerinden Covid-19 Teşhisi

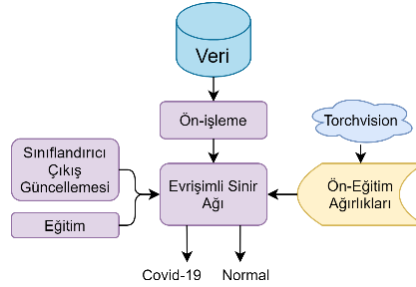
Covid-19 Diagnosis From X-ray Images With Artificial Neural Network Based Model

Önemli noktalar (Highlights)

- ❖ Yapay sinir ağı tabanlı teşhis modeli / Artificial neural network based diagnosis model
- ❖ İkili sınıflandırma yöntemi / Binary classification method
- ❖ Göğüs X-ray görüntülerinin eğitim için ön-işlenmesi / Pre-processing of chest X-ray images for training
- ❖ ImageNet veri kümesinde ön-eğitilmiş ağların bilgi transferi / Knowledge transferring from pre-trained networks using ImageNet dataset

Grafik Özet (Graphical Abstract)

Bu çalışmada, X-ray görüntülerinden Covid-19 teşhisi için yapay sinir ağı tabanlı model gerçekleştirilmiş ve doğrulanmıştır. / In this study, an artificial neural network based model has been developed and validated for Covid-19 diagnosis from X-ray images.



Şekil. Uygulanan yapay sinir ağı tabanlı model / **Figure.** Applied artificial neural network based model

Amaç (Aim)

Bu çalışmanın temel amacı, uygulanan yapay sinir ağı tabanlı modelini kullanarak hızlı Covid-19 teşhisi ile hastalığın yayılımının engellenmesidir. / The main purpose of this study is to prevent the spread of the Covid-19 disease by using artificial neural network based model for fast diagnosis.

Tasarım ve Yöntem (Design & Methodology)

Bu çalışmada uygulanan yapay sinir ağı tabanlı model, dört farklı yapay sinir ağı ile gerçekleştirilerek doğrulanmıştır. / In this study, the applied artificial neural network based model is validated by using four different artificial neural network.

Özgünlük (Originality)

Bu çalışmada kullanılan ağlar, bu modele ve probleme ilk kez uygulanmıştır. / The artificial neural networks used in this study are applied to this model and problem for the first time.

Bulgular (Findings)

DeneySEL sonuçlar, modelde kullanılan ağlarda ResNeXt-101(32×8d)'nin daha başarılı olduğunu göstermiştir. / The experimental results have showed that the ResNeXt-101(32×8d) achieved better performance compared with other networks in the model.

Sonuç (Conclusion)

Geliştirilen model ile Covid-19 teşhisi %94,79 doğruluk performans metriği ile başarılı bir şekilde gerçekleştirilmiştir. / Covid-19 diagnosis is achieved with 94,79% accuracy performance metric by using developed model.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Yapay Sinir Ağı Tabanlı Model İle X-ray Görüntülerinden Covid-19 Teşhisi

Araştırma Makalesi / Research Article

Kubilay ATAŞ¹, Atakan KAYA¹, Indrit MYDERRIZI^{2*}

¹İstanbul Gelişim Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, İstanbul, Türkiye

²İstanbul Gelişim Üniversitesi, Uygulamalı Bilimler Fakültesi, Havacılık Elektrik ve Elektronik Bölümü, İstanbul, Türkiye
(Geliş/Received : 15.01.2021 ; Kabul/Accepted : 01.12.2021 ; Erken Görünüm/Early View: 15.12.2021)

ÖZ

Dünyadaki koronavirüs hasta sayısı her geçen gün artmaktadır. Hastalığın ortaya çıkışının üzerinden bir seneden fazla zaman geçmesine rağmen istatistiklere göre henüz hasta sayısındaki zirve görülmemiştir. Hasta sayısındaki artışın zamana yayılması hastane doluluk oranlarının tehlikeli boyutlara ulaşmasını önlemek için önemlidir. Bu nedenle virüsü taşıyan bireylerin hızlıca teşhis edilerek hastalık geçene kadar toplumdan soyutlanmaları gerekmektedir. Bu çalışmada X-ray görüntüsü kullanılarak yapılabilecek hızlı hastalık teşhisi için kapsamlı bir yapay sinir ağı tabanlı model önerilmiştir. Koronavirüsün akciğerler dokularında yarattığı tahribattan yararlanılarak teşhis işlemi saniyeler içerisinde yapılabilmektedir. Çalışmaya konu olan model, X-ray görüntülerini ön-işlemlerden geçirerek iyileştirmekte ve çoğullamaktadır. DenseNet201, ResNeXt-101(32×8d), VGG-19bn ve Wide-ResNet101-2 ağları kullanılarak eğitim yapıldıktan sonra görüntüden Covid-19 pozitif veya negatif olarak teşhis konulmasını sağlamaktadır. Çalışmada elde edilen en iyi sonuç %94.79 genel doğruluk oranıyla ResNeXt-101(32×8d) ağı kullanılarak gerçekleştirilmiştir.

Anahtar Kelimeler: Covid-19, hastalık teşhisi, x-ray, yapay sinir ağları.

COVID-19 Diagnosis From X-ray Images With Artificial Neural Network Based Model

ABSTRACT

The number of coronavirus patients around the world is increasing day by day. Although more than one year has passed since the emergence of the disease, statistics show that the peak number of patients have not reached yet. The spread of the increase in the number of patients over time is important to prevent hospital occupancy rates from hitting dangerous levels. For this reason, people carrying the virus should be diagnosed quickly and isolated from society until the disease is over. In this study, a comprehensive artificial neural network-based model has been proposed for rapid disease diagnosis using X-ray images. Using the damage created by the coronavirus in the lung tissues, the diagnosis can be made within seconds. The model subject to study improves and augments X-ray images by pre-processing. After training is performed using DenseNet201, ResNeXt-101(32×8d), VGG-19bn and Wide-ResNet101-2 networks, Covid-19 positive or negative diagnosis is provided from the image. The best result obtained in the study is achieved by using ResNeXt-101(32×8d) network with an overall accuracy rate of 94.79%.

Keywords: Covid-19, disease diagnosis, x-ray, artificial neural network

1. GİRİŞ (INTRODUCTION)

Covid-19, 2019 yılının son aylarında Çin'de ortaya çıkarak kısa zamanda tüm dünyaya yayılmış ve bir pandemi halini almıştır. 2021 yılının başlangıcı itibariyle, Dünya Sağlık Örgütü'nün (DSÖ) verilerine göre yaklaşık 83.3 milyonu aşan teyit edilmiş vaka ve 1.8 milyonun üzerinde virüse bağlı ölüm görülmektedir. Halihazırda yüksek bulaşıcılık oranına sahip olan virüs, geçirdiği mutasyonlar ile bulaşıcılık oranını artırarak salgının kontrol altına alınmasını zorlaştırmaktadır. Virüsün hızlı yayılımı hastanelerdeki doluluk oranını artırarak hastalığı ağır seyreden bireylere sağlık hizmetlerinin verilmesini engellemekte ve istenmeyen sonuçlara neden olmaktadır. Bu nedenlerden dolayı

virüse sahip bireylerin hızlıca tespit edilerek toplumdan izole edilmesi, salgının kontrol altına alınmasında ve sağlık hizmetlerinin aksamamasında hayati önem taşımaktadır.

Covid-19 teşhisinde viral nükleik asit testi tutarlı sonuçlar veren temel bir yöntem olsa da laboratuvarların uygunluğu ve kalitesi gibi faktörler bu testin yaygın olarak yapılmasını engellemektedir [1]. Hastalığın etkisi akciğerler üzerinde oldukça fazla olduğundan dolayı, X-ray ve Bilgisayarlı Tomografi (BT) görüntülerinin kullanımı ile yapılan teşhislerin hem tutarlı hem de hızlı olacağı ve viral nükleik asit testlerinin yarattığı dezavantajların ortadan kaldırılacağı düşünülmektedir. Li vd. [2], hastalığın henüz başlangıç aşamasında bile virüse bağlı patolojik bulguların X-ray ve BT taramaları ile kolayca tespit edilebildiğini göstermektedir. X-ray taraması hızlı, ucuz ve yaygın bir yöntem olduğu için

*Sorumlu Yazar (Corresponding Author)
e-posta : imyerrizi@gelisim.edu.tr

görece yüksek radyasyon veren fakat daha kolay doğru teşhis sağlanmasına yardımcı olan BT taramalarına oranla daha çok tercih edilmektedir [3]. Bu nedenle bu çalışmada X-ray görüntüleri üzerine uygulamalar gerçekleştirilmiştir. Blain vd. [4] ise akciğer görüntülerindeki opasitenin hastalık teşhisinde kullanılıp kullanılmayacağı ve bu bulguların yaş ve komorbidite ile olan korelasyonunu incelemişlerdir. Alınan sonuçlar ile radyologların incelemeleri ve test sonuçları karşılaştırılmış, Cohen'in kappa analizi metrik olarak kullanılmıştır. Elde edilen sonuçlar doğrultusunda X-ray görüntülerindeki koronavirüse bağlı deformasyonların yaş ve komorbidite ile bağlantılı olduğu ve Covid-19 salgınında X-ray görüntülerini kullanmanın mümkün olduğu belirtilmiştir. Zhang vd. [5] olası yeni salgınların erkenden teşhis edilip yayılımının engellenmesi için güvene-dayalı anomali algılama (GDAA) yöntemini önermişlerdir. Yöntemde viral pnömoni anomali olarak kabul edilip, bakteriyel pnömoni ve normal görüntüleri tek bir sınıf gibi düşünülmüştür. Çalışma genel olarak viral pnömoni hastalıkları tespiti için tasarlanırsa da Covid-19 verileri üzerinde de başarılı sonuçlar vermiştir. %83.61 AUC ve %71.7 duyarlılık değerleri elde edilmiştir.

Covid-19 hastalığının ortaya çıkmasının ardından bu hastalığın teşhisinde X-Ray görüntüleme yöntemi ile taranan görüntülerin derin öğrenme yöntemleri yardımıyla analiz edilmesi biyomedikal alanında ilgi çekici bir çalışma konusu haline gelmiş ve Wang vd. [6] hastalığın teşhisi için COVID-Net isimli bir derin öğrenme ağ yapısı önermişlerdir. Çalışmada X-Ray görüntüleri kullanılmış, VGG-19 ve ResNet-50 ile yapılan karşılaştırmada %93.3 genel doğruluk oranına sahip teşhis başarısı elde edilerek bu iki ağa karşı daha tutarlı sonuçlara sahip olunduğu belirtilmiştir. Sharma vd. [7] veri setini Covid-19 hastası, Covid-19 olmayan hasta, pnömoni, tüberküloz ve normal olmak üzere 5'e ayrılarak sınıflandırma yapmışlardır. Sınıflandırmada CovidPred model kombinasyonları kullanılmış ve CLoDSA açık-kaynak kodlu veri artırma/zenginleştirme aracından [8] yararlanılmıştır. Görüntülerin histogram eşitleme, gama düzeltme, döndürme gibi işlemlerden geçirilerek elde edilen yeni halleri de veri setine eklenmiştir. Validasyon genel doğruluk sonuçları %93.8 seviyesinde olmakla birlikte harici veri üzerinde yapılan sınıflandırma %50 civarında seyrederek hastalık teşhisi için yeterli performansı sağlayamamıştır. Gao [9] ise yaptığı çalışmada modifiye edilmiş bir VGG-19 ağı kullanarak normal, bakteriyel pnömoni, Covid-19'a bağlı pnömoni ve diğer virüslere bağlı pnömoni şeklinde yapılan sınıflandırmada ortalama 0.96 f1-skor başarısı sağlamıştır. Abbas vd.'nin yaptığı [10] çalışmada ise 3 aşamalı bir derin öğrenme yapısı sunularak etiketli medikal görüntü azlığının dezavantajı giderilmeye çalışılmış ve bu bağlamda bir sınıflandırma yapılmıştır. Bu aşamalar ayrışma (decomposition), aktarma (transfer) ve birleşme (composition) maddelerinden oluşmaktadır. Çalışmada %95.12'lik doğruluk, %97.91 duyarlılık ve %91.87 özgüllük metrik sonuçları elde edilmiştir.

Pereira vd. [11] çoklu-sınıf ve hiyerarşik sınıflandırma olmak üzere iki çeşit sınıflandırma yapmış, sırasıyla 0.65 ve 0.89 f1-skor sonuçlarını almışlardır. Çalışmada veri setindeki örnekler gerçek duruma uygun olacak yaklaşıklıkta oranlanarak gerekli sınıflarda veri artırım yöntemleri kullanılmıştır. Bu çalışmada özellikle X-ray görüntülerindeki doku bilgilerinden yararlanılarak eğitim sağlanmıştır. Jain vd. [12] 6432 X-ray görüntüsüne sahip geniş bir veri kümesi kullanarak Inception V3, Xception ve ResNeXt modellerini eğitmiş ve en iyi sonucu veren modelin %97.97'lik doğruluk metriğine sahip Xception olduğunu belirtmişlerdir. Üstelik eğitim sırasında 14 epoch kullanılarak oldukça kısa bir eğitim sürecinin ardından bu sonuçlara ulaşılmıştır. Minaee vd. [13] birden fazla açık-kaynaklı veri setlerini kullanarak 5000 X-ray görüntüsünden oluşan kendi veri setlerini hazırlamışlardır. Bu veri seti kullanılarak yapılan eğitimlerde ResNet18, ResNet50, SqueezeNet ve DenseNet-121 ağları kullanılmıştır. Yapılan test sonuçlarına göre AÇK (alıcı çalışma karakteristiği) eğrisi çıkarılmış ve eğrinin altında kalan alanlara göre sırasıyla 0.989, 0.990, 0.992 ve 0.976 değerlerini elde etmişlerdir. Ayrıca her dört model için de duyarlılık metriğinin yaklaşık %98 ve özgüllük metriğinin %90 civarında olduğu belirtilmiştir. Bu veriler ışığında her dört ağın da yaklaşık aynı başarıma sahip olduğu fakat SqueezeNet'in çok az bir farkla daha iyi sonuç verdiği söylenebilmektedir.

Sonuçları Covid-19 negatif ve pozitif olmak üzere iki sınıfa ayıran Hemdan vd. [14] COVIDX-Net yapısını önermişlerdir. Bu yapıda VGG-19, DenseNet121, InceptionV3, ResNetV2, Inception-ResNet-V2, Xception ve MobileNetV2 ağları incelenmiş ve en iyi sonucun 0.91'lik f1-skor ile DenseNet121'e ait olduğu belirtilmiştir. Eğitim ve test işlemleri 25 adet Covid-19 pozitif ve 25 adet normal X-ray görüntüsü kullanılarak toplam 50 görüntü içeren küçük bir veri seti kullanılarak gerçekleştirilmiştir. Bu çalışmanın aksine Luz vd. [15] ise 13800 X-ray görüntüsünden oluşan geniş bir veri seti kullanarak Covid-19, normal ve pnömoni sınıflandırması yapmışlardır. EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3, EfficientNetB4, EfficientNetB5, MobileNet, MobileNetV2, ResNet-50, VGG-16 ve VGG-19 modelleri kullanılarak gerçekleştirilen çalışmada en iyi sonucu veren model %93.9'luk genel başarıyı ve %96.8'lik duyarlılık değeri ile EfficientNetB3 modeli olmuştur. Ayrıca bu model 48 MB'lık boyutu ile 11 ağ arasında 6. Sırada yer almaktadır. Bu nedenle çalışmada rakiplerine göre tercih edilebilirliğinin yüksek olduğu belirtilmektedir. Ayrıca Kaya vd. [16] de BT görüntüsü kullanarak yaptıkları Covid-19 ve normal veri sınıflandırmasında EfficientNetB3 ağının 0.98'lik f1-skor değeriyle VGG-16, ResNet-50 ve MobileNetV2 ağlarına göre daha iyi sonuç verdiğini belirtmişlerdir.

Çalışmalarda genellikle referans olarak tercih edilen VGG16 ağından yararlanarak, Civit-Masot vd. [17] yaptıkları çalışmada toplam 396 X-ray görüntüsüne sahip ve Covid-19, normal ve pnömoni olmak üzere 3 sınıftan

oluşan veri seti üzerinde incelemeler gerçekleştirmişlerdir. Veri setine histogram ön-işlemi uygulanarak ön-işlemlenmiş ve ön-işlemlenmiş sonuçlar karşılaştırılmış ve sonuçların f-1 skor bazında yaklaşık eşit ve 0.86 civarında olduğu görülmüştür. Çalışmada Covid-19 sınıfı başarımlarının normal ve pnömoni sınıf başarımlarına oranla daha iyi olduğu da görülmektedir. Histogram eşitleme yapılarak gerçekleştirilen sınıflandırmada Covid-19 duyarlılık metriği 1.0 değerine ulaşmıştır. Bu da Covid-19 pozitif olan bir hastaya yanlışlıkla başka bir tanı konulmadığını ve yapının özellikle biyomedikal uygulamalar için güzel sonuçlar verdiğini göstermektedir.

Derin öğrenmeyi sadece sınıflandırma için değil aynı zamanda SVM sınıflandırmada temel almak üzere özellik çıkarımı için de kullanan Ismael ve Şengür [18], derin özellik çıkarımı, ön-egitimli evrimsel sinir ağlarının (ESA) ince ayarı ve geliştirilen ESA'ın uçtan uca eğitimi metodlarını kullanarak X-ray görüntülerinden Covid-19 teşhisi yapmışlardır. Ayrıca görüntülerin yerel doku özellikleri ve destek vektör makineleri (DVM) kullanılarak yapılan sınıflandırma sonuçlarını da derin öğrenme yöntemleri ile karşılaştırarak bir referans noktası oluşturmuşlardır. Çalışmalar neticesinde derin öğrenme tabanlı sistemlerin genel olarak klasik özellik tanımlayıcı ve DVM kullanılarak yapılan sınıflandırmalardan daha iyi olduğu ve en iyi sonucun da ResNet50 ağından çıkarılan özelliklerin doğrusal çekirdek fonksiyonlu DVM sınıflandırıcı kullanılarak yapılan ve %94.7'lik bir genel doğruluk başarımları veren yapı olduğu belirtilmiştir. Afshar vd. [19] kapsül ağ yöntemlerini kullanarak COVID-CAPS yöntemini önermişlerdir. Yöntemin normal ESA tabanlı ağlara göre daha az eğitim parametresi gerektirdiği belirtilmektedir. Ön-egitim olmadan gerçekleştirilen çalışmada COVID-CAPS yöntemi %95.7 genel başarımları, %90 duyarlılık ve %95.8 özgüllük sonucunu vermiştir. X-ray görüntüleri kullanılarak yapılan ön-egitim parametrelerinin "öğrenme aktarımı" yöntemiyle COVID-CAPS yönteminde kullanılmasında ise genel başarımları %98.3'e ve özgüllük %98.6'ya çıkmış, duyarlılık %80'e gerilemiştir.

Bu çalışmada standart ağların daha farklı varyasyonları olan ResNeXt-101(32x8d), DenseNet201, Wide-ResNet101-2 ve VGG-19bn ağları kullanılarak gerçekleştirilen bir yapı örneği sunulmuştur. Ağların girişinde veri artırma ve ön-işlem yöntemleri ile sınıflandırmayı kolaylaştıracak adımlar gerçekleştirilerek başarımları artırılmaya çalışılmış ve elde edilen sonuçlar Covid-19 pozitif ve Covid-19 negatif olarak iki sınıfa göre teşhis edilmiştir.

Makalenin 2. kısmında kullanılan ağlardan bahsedilmiş, uygulanan yöntem ve model açıklanmıştır. 3. kısımda yapılan deneysel çalışmalar anlatılmış ve bu deneylerden elde edilen sonuçlar sunulmuştur. Son kısımda ise elde edilen sonuçlarla ilgili değerlendirme ve sonraki çalışmalar için yorumlar eklenmiştir.

2. UYGULANAN YÖNTEM VE YAPAY SİNİR AĞI TABANLI MODEL (APPLIED METHODOLOGY AND ANN BASED MODEL)

Bu bölümde uygulanan yöntemde kullanılan yapay sinir ağı tabanlı modelin eğitimi için veri kümesinden, ağın iyi eğitilebilmesi için gerekli olan ön-işlem ve veri çoğullama basamaklarından, eğitilen modelin yapısından, model yapısında kullanılan ve karşılaştırılması yapılan ağların özelliklerinden bahsedilmiştir.

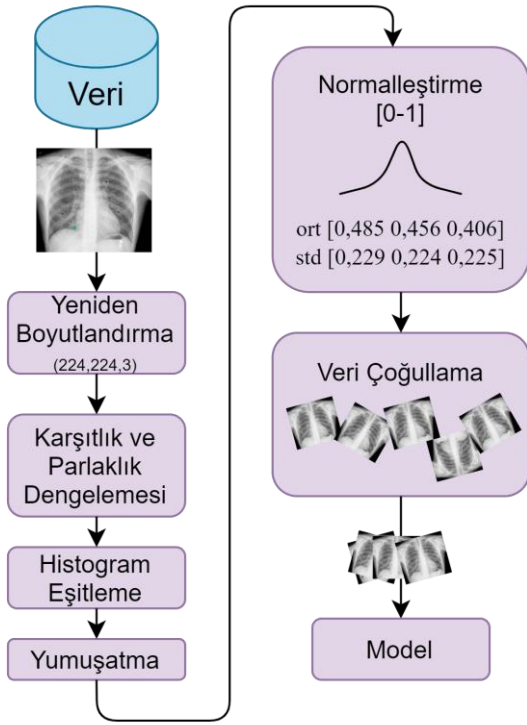
2.1 Veri Kümesi (Data Set)

Covid-19 hastalığı Dünya genelinde hızla yaygınlaşmaya başladığında Cohen vd. [20] web tabanlı olarak çeşitli kuruluşlarca paylaşımına açılan göğüs radyoloji görüntülerini bir araya getirerek bir veri kümesi oluşturmuşlardır. Bu veri kümesi ön-düzlem (frontal) ve yan-düzlem (lateral) görüntülerden oluşmaktadır. Bu görüntülerle birlikte toplayabildikleri ölçüde hastaların kanındaki oksijen oranları, hastalığın kaçınıcı gününde oldukları, solunum zorluğu çekip çekmedikleri vb. gibi verileri de veri kümesine eklemişlerdir. Ayrıca hastalığın bakteri kaynaklı, virüs kaynaklı olduğunun bilgisini ve hastalığa neden olan etkeni (SarsCov2, Mers, Covid-19, Zatürre vb.) de veri kümesine eklemişlerdir. Yaptıkları çalışmada, yayınladıkları veri kümesiyle ilgili geniş bir istatistiki bilgi paylaşımında bulunmuşlardır.

Bizim çalışmamızda, bu veri kümesinden ön-düzlemde sırttan öne doğru (posterior-anterior) çekilen görüntüler kullanılmıştır. Bu görüntüler içerisinde Covid-19 bulgusu olanlar 'Covid' sınıfını, herhangi bir hastalık bulgusu olmayanlar 'Normal' sınıfını oluşturmuştur. Görüntülerin çoğunluğu 3 bantlı olan Kırmızı-Yeşil-Mavi (KYM) formatında olmasına karşın bazı görüntüler 4 bantlı Camgöbeği-Eflatun-Sarı-Siyah (CESS) formatındadır. Bu formattaki görüntüler ön-işlem aşamasındayken KYM görüntülere çevrilerek kullanılmıştır. Test edilen her bir evrimsel sinir ağı %20 si doğrulama %80'i eğitim için ayrılan 326 görüntü kullanılarak eğitilmiş ve görüntülerin tamamıyla test edilmiştir.

2.2 Ön İşleme ve Veri Çoğullama (Pre-processing and Data Augmentation)

Modelin eğitilmesi için hazırlanan görüntüler, modele giriş olarak uygulanmadan önce ön-işlem aşamasında bazı işlemlerden geçirilmektedir. Bunlar sırasıyla yeniden boyutlandırma, karşıtlık ve parlaklık dengelemesi, histogram eşitleme ve yumuşatma işlemleridir. Şekil 1.'de ön-işleme aşaması ve veri çoğullaması aşamalarının şeması verilmiştir. Görüntüler modele 16'şarlık görüntü paketleri halinde gönderilmeden önce yeniden boyutlandırılarak 224x224 boyutuna getirilir ve bu görüntülerin karşıtlık ve parlaklık parametreleri ortalama bir değere getirilir. Sonrasında histogram eşitleme her bir görüntüye uygulanır. Ardından yumuşatma işlemiyle görüntüdeki keskin geçişler yumuşatılmış olur. Son adımda ise her bir görüntünün 0-1 değerleri arasında normalize edilme işlemi vardır. Bu işlem Gauss dağılımı kullanılarak, görüntülerin her bir bandı için ayrı ayrı yapılır. Bu işlem



Şekil 1. Ön işleme ve veri çoğullama (Pre-processing and data augmentation)

yapılırken, ön eğitilmiş ağların eğitimi sırasında kullanılan ortalama ve standart sapma değerleri olan ve sırasıyla KYM bantları için ayrı ayrı kullanılan [0.485 0.456 0.406] ortalama değerleri ile [0.229 0.224 0.225] standart sapma değerleri kullanılır.

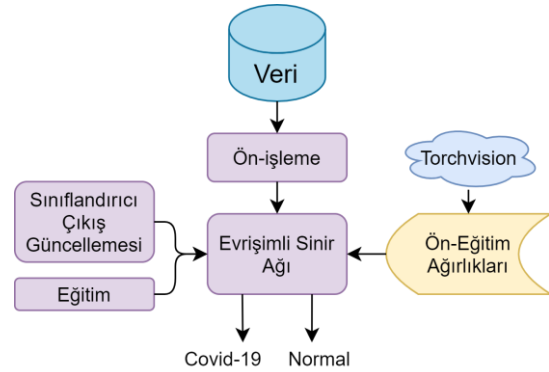
Derin öğrenme yapılarında en önemli parametrelerden biri de veridir. Derin öğrenme modelinin başarısı, eğitildiği verinin içeriğiyle oldukça ilişkilidir. İyi bir veri kümesinin, gerçek hayatta karşılaşılabilecek birbirinden farklı tüm olasılıkları olabildiğince içermesi gerekmektedir. Ancak gerçek hayatta çoğu problem için tüm olasılıkları bir araya getirmek oldukça zordur. Bu nedenle elde bulunan verilerin, birbirinden farklı olasılıkları içermesi için çeşitli benzetimler yapılır. Görüntü işleme metotları sayesinde, ağın iyi eğitilmesini sağlayamayacak kadar az veri bulunmasına rağmen, bu veriler çoğullanabilir. Görüntülerde yaygın olarak kullanılan veri çoğullama yöntemlerinden bazıları şunlardır; geometrik dönüştürme, kaydırma, kırpma, döndürme, renk uzayı dönüşümleri, görüntü karıştırma, rastgele silme [21].

Bu çalışmada görüntüler ağların girişine uygulanmadan önce, ön-işleme kısmında çeşitli işlemlere maruz kalmaktadır. Uygulanan görüntüler veri çoğullama aşamasındayken ± 30 dereceye kadar rastgele döndürme, yatay eksene göre rastgele aynalama ve görüntünün herhangi bir kesitinin büyütülerek orijinal görüntüye

eklenmesiyle oluşturulan rastgele gürültüler eklenerek, veri çeşitliliğinin artması sağlanmıştır.

2.3 Model

Karşılaştırma için oluşturulan Şekil 2’de gösterilen modelde, yapay sinir ağlarının eğitilmesi ve karşılaştırılması için kullanılan ve 1000 farklı görüntü sınıfından oluşan, ImageNet [22] veri kümesi üzerinde ön-eğitilmiş olan ağlar sınanacağı için, modelin giriş nöronu sayıları bu ağlar ile tam örtüşmelidir. Ön eğitilmiş olan bu ağların mimari yapıları, genelde (224,224,3) boyutunda giriş nöronu sayısı içerirler. Eğitildikleri bu veri kümesi 1000 farklı sınıfa ait görüntülerden oluştuğu için de çıkış nöronu sayıları 1000 olmaktadır. Pytorch’un torchvision.models kütüphanesindeki bu ağlar, çıkış katmanıyla birlikte veya çıkış katmanı içermeden çağrılabilirler. Bu çalışmada kullanılan ağlar, çıkış nöronlarıyla birlikte çağırılmışlardır. Olması gerektiği gibi, ağların kullanmış olduğu (224,224,3) giriş boyutu kullanılmıştır. ImageNet veri kümesinin içeriğinde 1000 adet sınıf için etiketlenmiş görüntüler olduğundan dolayı bu veri kümesiyle eğitilmiş olan ağların mimari yapısında çıkış nöronu sayısı 1000’dir. Bizim problemimiz ikili sınıflandırma problemi olduğu için, çıkış nöronu sayısının 2 olarak güncellenmesi gerekmektedir. Bu nedenle modelimizde kullandığımız her bir ağın sonuna ek katmanlar eklemek yerine, mimari yapılarında halihazırda bulunan sınıflandırıcı yapılarındaki çıkış nöronu sayısının 2’ye düşürülmesi yeterli görülmüştür. Modelde, veri kümesinden eğitim için hazırlanan görüntüler ön-işleme aşamasından geçirilerek ağın girişine uygulanırlar ve her bir görüntü için hazırlanmış sınıf etiketlerine göre ağın eğitimine başlanır.



Şekil 2. Uygulanan modelin yapısı (Structure of applied model)

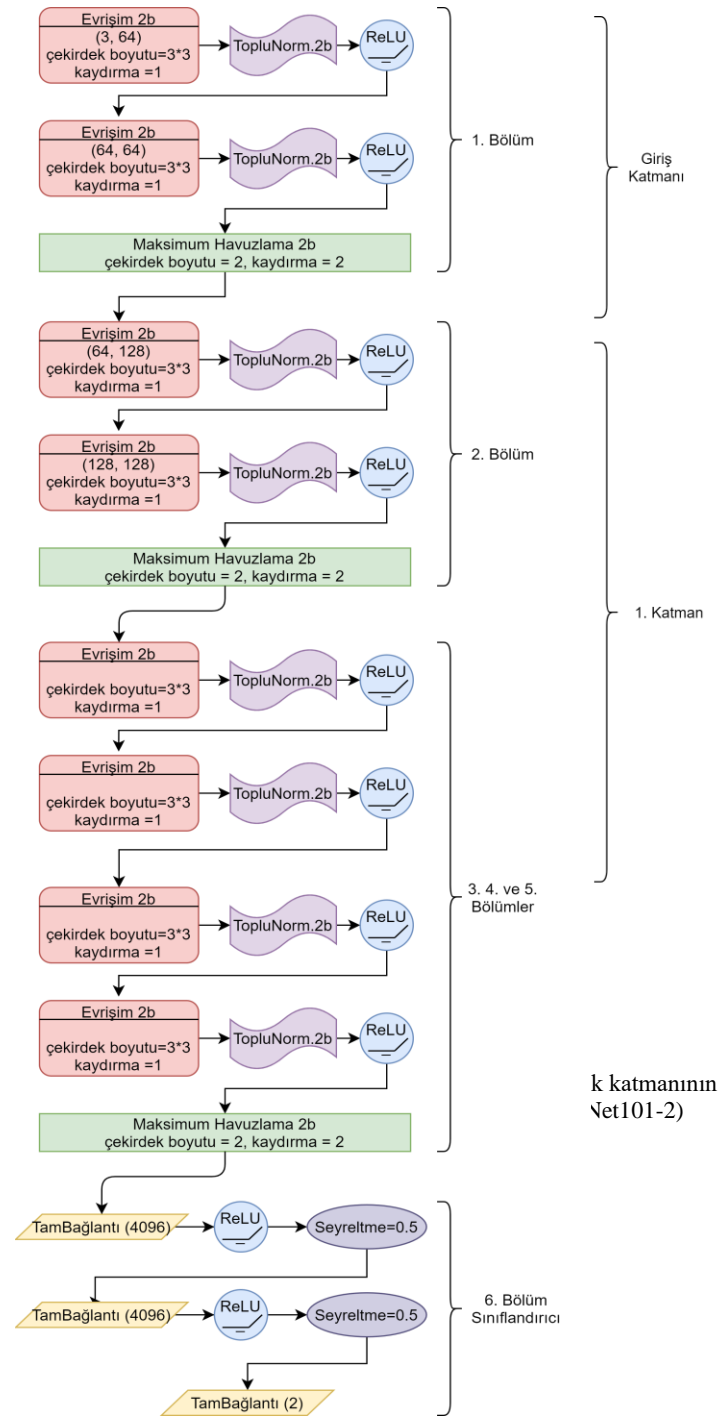
2.4 Kullanılan Ağlar (Applied Networks)

Modelin yapısında uygulanan ilk evrişimli sinir ağı VGG-19bn’dir [23]. VGG, AlexNet’in geliştirilmiş bir sürümüdür. İki ağ arasındaki temel fark, evrişimli işlem boyutlarıdır. AlexNet’de 11x11, 5x5, 3x3 filtre boyutları varken, VGG yapısında sadece 3x3 filtre boyutu

kullanılmıştır. VGG-19bn yapısında toplamda 16 evrişimli katman vardır. Bu katmanlar bir diğerine maksimum havuzlama, toplu normalleştirme, 'ReLU' aktivasyon fonksiyonu gibi yapılarla bağlanırlar. Bu yapılar toplamda 19 adet ağırlık matrisi oluşmasını sağladığı için ağın ismi VGG19 olarak verilmiştir. Bu isme ek olarak getirilen 'bn' ise toplu normalleştirmeyi temsil etmektedir. Yapı 6 kısımda incelenebilir. Yapının ilk iki bölümü, 2 adet 3x3 evrişimli katman ve hemen arkasına maksimum havuzlama katmanı eklenerek inşa edilmiştir. Ancak birinci bölüm 64 kanallı 224x224 görüntü boyutu içerirken, ikinci bölüm 128 kanal ve 112x112 görüntü boyutuna sahiptir. Sonraki üç bölüm benzer yapıda olup farklı olarak, 2 yerine 4 evrişimli katman içerirler. Son bölüm genelde sınıflandırıcı olarak adlandırılır. Bu bölümde, iki boyutlu olan matris bilgi 4096 elemanlı vektör oluşturularak tek boyuta indirgenir. Bu vektör sırasıyla 4096, 4096 ve 1000 ebatlarındaki 3 adet tam bağlı katman içerisine beslenir. Bu katmanlar arasında 'ReLU' aktivasyon fonksiyonu ve %50 oranında nöron çıkarma işlemleri uygulanmaktadır. Son katmandan sonra softmax aktivasyon fonksiyonu yardımı ile sınıflandırma sonucu alınmaktadır. VGG-19bn evrişimsel sinir ağı mimari yapısı Şekil 3.'te gösterilmektedir.

Derin öğrenme yöntemleriyle ilgili gün geçtikçe yeni çalışmalar yapılmakta, yeni sınıma mekanizmaları geliştirilmekte ve ortaya atılan yeni yöntemler sınamaktadır. Bu sınıma mekanizmaları arasında revaçta olan ImageNet veri kümesi yarışmasında iyi sonuçlar gösteren diğer iki evrişimsel sinir ağı mimarisi de Wide-ResNet101-2 mimarisi [24] ve ResNeXt-101(32x8d) mimarisidir [25]. Wide-ResNet101-2 mimarisi ResNet mimarilerinin geliştirilmiş versiyonlarından biridir. ResNet'e adını kazandıran artık bağlantıların çeşitlendirilmesiyle oluşturulmuştur. Şekil 4.'te bu artık bağlantılardan bazıları gösterilmiştir.

Wide-ResNet101-2 mimarisi, Resnet mimarilerinde olduğu gibi öncelikle bir giriş katmanından ve arkasından gelen 4 katmandan oluşmaktadır. Bu katmanlardan sonra ise çıkış katmanı bulunmaktadır. Giriş katmanında 7x7 çekirdek boyutuna sahip evrişim katmanı bulunmaktadır. Bu katmandan sonra toplu normalleştirme katmanı ve 'ReLU' aktivasyon fonksiyonu bulunmaktadır. Sonrasında ise 3x3 boyutlarında çekirdeğe sahip olan maksimum havuzlama kısmı gelmektedir. Bu giriş kısmının ardından, çeşitli artık bağlantılara sahip olan 4 adet katman bulunmaktadır. Bu katmanlardan her birinde darboğaz denilen yapılar bulunmaktadır. Bahsi geçen bu 4 katmanın her birinin ilk basamağında bilgi iki kola ayrılırken 'artık bağlantı'da bir evrişim katmanından ve toplu normalleştirme katmanından geçer ancak sonraki basamaklardaki yapıda doğrudan bağlantı sağlanmıştır. Bu yapı Şekil 5.'te ayrıntılı olarak görülmektedir. Ağın birinci katmanında 3 darboğaz yapısı bulunurken, ikinci üçüncü ve dördüncü katmanlarda sırasıyla 4, 23 ve 3 darboğaz yapısı bulunmaktadır. Bu katmanların ardında, bir ortalama havuzlama işlemi ve tam bağlı katmandan oluşmak üzere, çıkış katmanı bulunmaktadır.

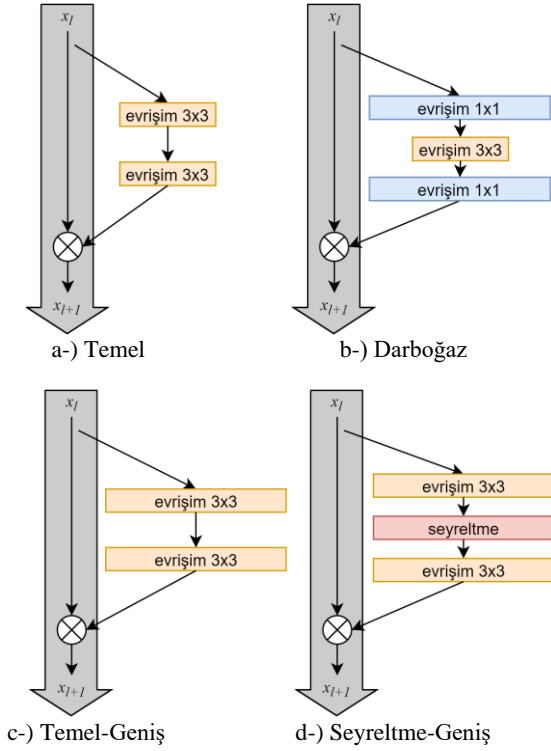


Şekil 3. VGG-19bn ağı mimari yapısının temsilidir (Represented structure of VGG-19bn)

ResNeXt-101(32x8d) ağı mimarisi ise Wide-ResNet101-2 mimarisi ile hemen hemen aynı yapıdadır. Şekil 5.'te görülen katman yapısı ve Wide-ResNet101-2'deki katman sayıları ve darboğaz yapılarının sayısı aynıdır. ResNeXt-101(32x8d) ağı yapısında farklılık gösteren durum, darboğazların sayıları ve derinlikleri ve burada kullanılan evrişim katmanlarının boyutlarıdır. Wide-ResNet101-2 ağındaki darboğaz yapısı tek daldan oluşurken ResNeXt-101(32x8d) ağındaki darboğaz yapısı 32 daldan oluşur ve bu dallar birbirine paralel yapıdadır. Bu dallanma yapısına Grublama (Aggregating) adı

verilmektedir ve Şekil 6.'da temsili bir darboğaz yapısı görülmektedir. Bu fikrin motivasyon kaynağı, büyük derin öğrenme ağlarında dağıtık Grafik İşlemci Birimlerini (GİB) etkin bir şekilde kullanmak üzere geliştirilmiş Gruplanmış Evrişim Katmanı'dır [26].

Modelde sıranan bir diğer ağ ise DenseNet201 ağıdır [27]. Bu ağın yapısında, her birinde Dense Katmanı adı verilen yapılar barındıran Dense Blok'lar bulunur. Her bir Dense Blok'unun barındırdığı Dense Katmanlarının kendinden sonraki bütün katmanlara bağlantısı vardır.

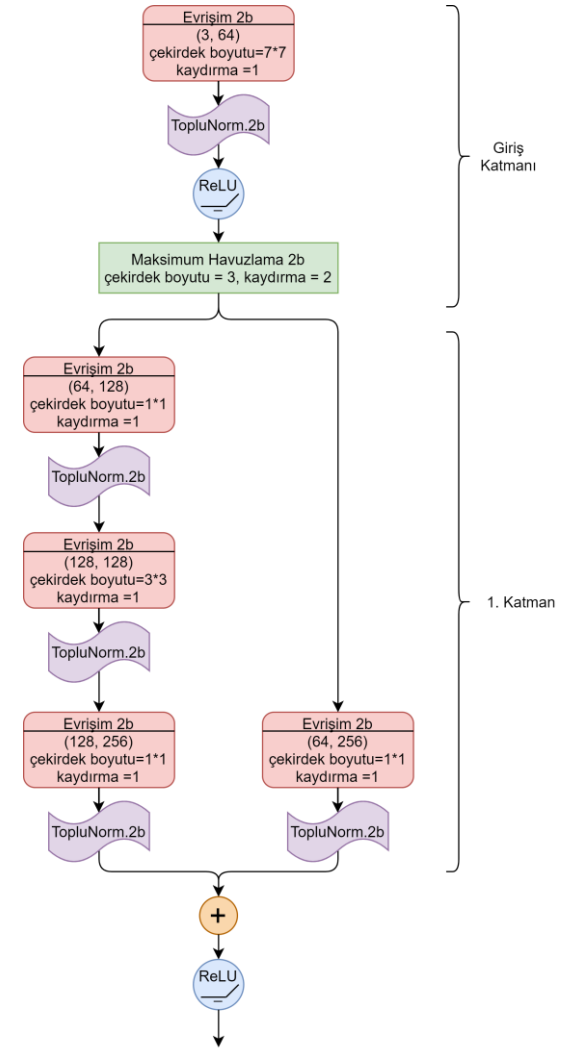


Şekil 4. Bazı artık bağlantı türleri [24]. (Some residual connection types)

Şekil 7.'de bir Dense Katmanı'nın yapısı yer almaktadır. Her bir Dense Blok'unun bir sonrakiyle bağlantısını Geçiş Katmanı adı verilen yapı sağlar.

Dense Katmanı, kendinden önceki Dense Katmanlarından gelen bilgileri birleştirmek için Birleştirme bloğuna sahiptir. Bu bloktan sonra Toplu Normalleştirme bloğu yer almaktadır. Bilgi bu bloklardan geçtikten sonra 'ReLU' aktivasyon fonksiyonuna giriş olarak uygulanır. Buradan alınan veri sırasıyla evrişim, 'ReLU' aktivasyon fonksiyonu ve tekrar evrişim katmanlarından geçerek Dense Katmanındaki işlemlerini tamamlamış olur ve mimari yapının izin verdiği doğrultuda sonraki Dense Katmanlarına gönderilir.

Dense Bloklarını birbirine bağlayan Geçiş Katmanının yapısında ise, yine diğer katmanlardan gelen bilgileri birleştirmek için, verileri ilk karşılayan Birleştirme bloğu olur. Ardından sırasıyla Toplu Normalleştirme bloğu, 'ReLU' aktivasyon fonksiyonu, evrişim bloğu ve ortalama havuzlama bloğu bulunmaktadır. Şekil 8.'de 6



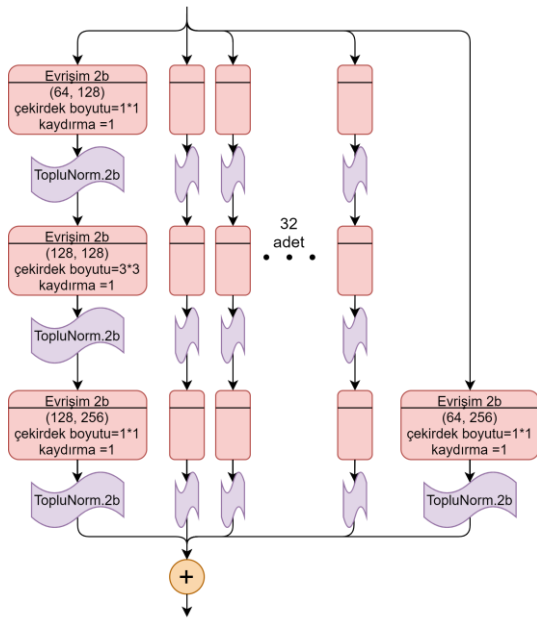
Şekil 5. Wide-ResNet101-2 ağının giriş ve ilk katmanının yapısı (Input and first layer of Wide-ResNet101-2)

Dense Katmanından oluşan bir Dense Bloğunun yapısı gösterilmiştir.


Modelde kullanılan DenseNet201 ağının mimarisi incelendiğinde 4 adet Dense Bloğuna sahip olduğu görülmektedir. Bu bloklardan birincisinde 6 adet Dense Katmanı yer almaktadır. İkinci, üçüncü ve dördüncü bloklarda ise sırasıyla 12, 48 ve 32 adet Dense Katmanının yer aldığı görülür. Son olarak bir toplu normalleştirme katmanı ve ardından bir tam bağlı katman ile sınıflandırıcı yapısı bulunmaktadır.

2.5 Performans Metrikleri (Performance Metrics)

Yapay sinir ağlarının eğitimi sırasında, eğitimin kalitesinin ölçülmesi için birkaç parametreden faydalanılmaktadır. Genel olarak eğitim kalitesi, eğitim hatası (train loss), eğitim doğruluğu (train accuracy), doğrulama hatası (validation loss) ve doğrulama doğruluğu (validation accuracy) parametreleri gözlemlenerek ölçülmektedir. Eğitim kalitesinin ölçülmesinde kullanılan bu parametrelerin hesaplanması, çözüm aranan probleme göre çeşitlilik



Şekil 6. ResNeXt-101(32x8d) mimarisindeki darboğaz yapısı (Bottleneck structure of ResNeXt-101(32x8d) architecture)



Şekil 7. Dense Katmanının yapısı (Structure of Dense Layer)

gösterebilmektedir. Sınıflandırma problemlerinde eğitim doğruluğu, ağın tahmin ettiği sınıf ile gerçek sınıfların yüzde kaçının örtüştüğü hesaplanarak ölçülmektedir. Benzer bir yöntemle eğitim hatası için, tahmin edilen sınıf ile gerçek sınıf karşılaştırılarak hata yüzdesi hesaplanmaktadır. Ancak eğitim hatası hesaplanırken farklı yöntemler de uygulanabilmektedir. İki'den fazla sınıf içeren problemlerin çözümünde çapraz entropi (cross entropy), ikili sınıflandırma problemlerinde ise ikili çapraz entropi (binary-cross entropy) bu yöntemlere örnek gösterilebilir. Çapraz entropi, belirli bir rastgele değişken veya olay kümesi için iki olasılık dağılımı

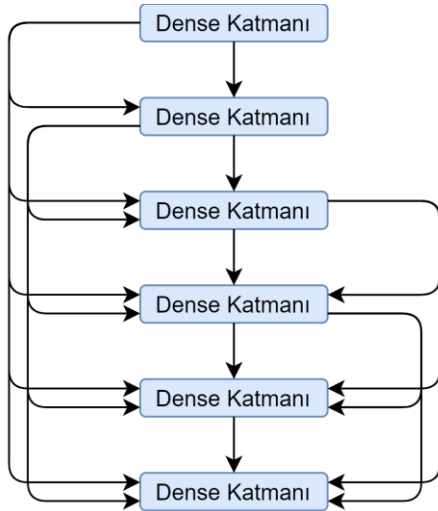
arasındaki farkın bir ölçüsüdür. Bir sınıflandırma probleminde çapraz entropi hata fonksiyonu kullanılmasının, ağın daha hızlı eğitilmesinin yanı sıra çözümün geliştirilmesine de katkı sağladığı görülmüştür [28]. Doğrulama doğruluğu ve doğrulama hatası, eğitim doğruluğu ve eğitim hatasına benzer yöntemlerle hesaplanır. Buradaki fark, doğrulama için kullanılan verilerin genelde eğitim aşamasında hiç kullanılmamış olmasıdır. Böylelikle ağın daha önce hiç görmediği veriler karşısında nasıl davranacağını ölçülmesinde önemli bir rol oynar. Bununla birlikte bu metrikler, bir ağın gerçek dünyadan gelen veriler karşısındaki performansının ölçülmesinde genellikle yeterli değildir. Özellikle tıp alanında, bir karar verme sisteminin verdiği sonuçlar çok önemlidir. Covid pozitif olmayan bir hastanın covid pozitif olarak tahmin edilmesi, halk sağlığı açısından riskli bir durum içermemektedir. Ancak bunun tam tersi bir durumda, halk sağlığı büyük bir tehlikeyle karşı karşıya gelebilir. Bu gibi durumlarda, gerçek dünya problemlerine karşı performans ölçülmesinde daha uygun istatistiksel veriler sağlamak amacıyla F1-Skoru ve karışıklık matrisi gibi testler uygulanmaktadır. İkili sınıflandırma problemlerinin istatistiksel performans analizinde F1-Skoru, test doğruluğunun bir ölçüsü olarak duyarlılık (sensitivity) ve kesinlik (precision) değerlerinden hesaplanmaktadır. Kesinlik, doğru sınıflandırılmış pozitif vakaların sayısının, tahmin edilen pozitif vakaların toplam sayısına bölünmesiyle elde edilir ve Denklem 1'de gösterilmiştir. Duyarlılık ise Denklem 2'de gösterildiği gibi doğru sınıflandırılmış pozitif vaka sayısının, toplam pozitif vaka sayısına bölünmesiyle hesaplanmaktadır. F1-Skoru ise kesinlik ve duyarlılığın ağırlıklı ortalamasıdır ve Denklem 3'deki gibi hesaplanmaktadır. Bu eşitliklerde, DP doğru sınıflandırılmış pozitif vaka sayısını, YP yanlış sınıflandırılmış pozitif vaka sayısını ve YN yanlış sınıflandırılmış negatif vaka sayısını temsil etmektedir.

Karışıklık matrisi (confusion matrix) ise genellikle makine öğrenmesindeki sınıflandırma problemlerinde ağın performansını görselleştirmek için kullanılan bir tablodur. Matrisin her satırı, tahmin edilen bir sınıftaki örnekleri temsil ederken, her sütun gerçek bir sınıftaki örnekleri temsil eder (veya tam tersi) [29].

$$Kesinlik = \frac{DP}{DP + YP} \quad (1)$$

$$Duyarlılık = \frac{DP}{DP + YN} \quad (2)$$

$$F1 = 2 * \frac{Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (3)$$




Şekil 8. 6 Dense Katmanından oluşan bir Dense Bloğunun yapısı (DenseBlock structure consisted of 6 Dense Layer)

3. DENEYSSEL SONUÇLAR (EXPERIMENTAL RESULTS)

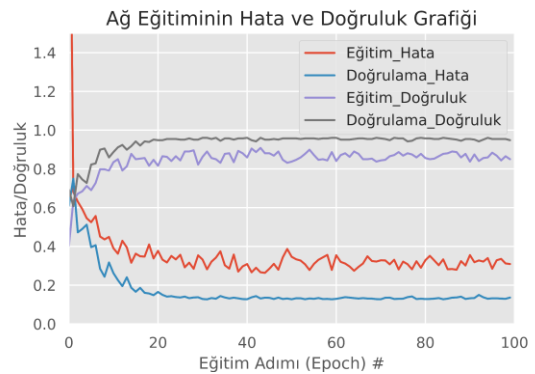
Bu çalışmada, Covid-19 bulgusu olan ve olmayan görüntülerin sınıflandırılması için VGG-19bn, DenseNet201, ResNeXt-101(32×8d) ve Wide-ResNet101-2 ağları seçilmiş ve Şekil 2’de önerilen modele uygulanarak sonuçları karşılaştırılmıştır. ImageNet veri kümesinde eğitilmiş ve PyTorch torchvision.model kütüphanesinde kullanıma sunulmuş olan bu ağlar, ön eğitilmiş ağırlıklar ile birlikte probleme özgü biçimde yeniden düzenlenerek kullanılmıştır. Ön eğitilmiş ağların ağırlıkları, önerilen modeldeki ağların başlangıç değerleri olarak kullanılmıştır ve eğitim sırasında hiçbir parametre sabitlenmemiştir. Çalışmaya konu olan problem ikili sınıflandırma problemi olduğu için, kullanılan ağların çıkış nöronu sayıları 1000’den 2’ye indirilmiştir. Oluşturulan bu yapı Google Colab platformunda eğitilerek, her bir evrişimli sinir ağı mimarisinden alınan sonuçlar karşılaştırılmıştır. Çalışmada 180 Covid-19 pozitif ve 146 Covid-19 negatif görüntü test verisi olarak kullanılmıştır. Ağların eğitimlerinde elde edilen eğitim ve doğrulama hata ve doğruluk grafikleri DenseNet201, ResNeXt-101(32×8d), VGG-19bn ve Wide-ResNet101-2 için sırasıyla Şekil 9, Şekil 10, Şekil 11 ve Şekil 12’de gösterilmiştir.

Hata ve doğruluk grafikleri incelendiğinde her 4 ağ için de yaklaşık 20 eğitim döngüsünden (epoch) sonra değerlerin doyuma ulaştığı, doğruluk değerlerinin başlangıçtan daha yüksek değerlere ve hata değerlerinin de başlangıçtan daha düşük değerlere yakınsadığı görülmektedir. Sonuçlar daha detaylı incelendiğinde ise ResNeXt-101(32×8d) ağının çalışmada kullanılan diğer ağlara göre her anlamda daha iyi sonuç verdiği görülmektedir.

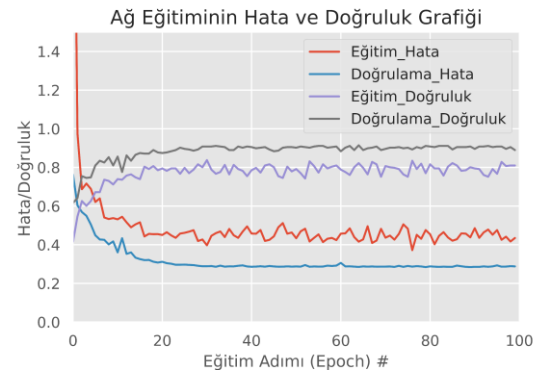
ResNeXt-101(32×8d)’nin genel doğruluğu 94.79% ve hastalık teşhisi uygulamalarında önemli bir parametre olan duyarlılık metriği 0.9452’dir. Çizelge 1’de her bir




Şekil 9. DenseNet201 ağ eğitiminin hata ve doğruluk grafiği (Loss and accuracy graph of DenseNet201 network training)



Şekil 10. ResNeXt-101(32×8d) ağ eğitiminin hata ve doğruluk grafiği (Loss and accuracy graph of ResNeXt-101(32×8d) network training)



Şekil 11. VGG-19bn ağ eğitiminin hata ve doğruluk grafiği (Loss and accuracy graph of VGG-19bn network training)



Şekil 12. Wide-ResNet101-2 ağ eğitiminin hata ve doğruluk grafiği (Loss and accuracy graph of Wide-ResNet101-2 network training)

Çizelge 1. Ağ performans metriklerinin karşılaştırılması (Comparison of the network performance metrics)

	Specificity (Özgüllük)	Sensitivity (Duyarlılık)	Accuracy (Doğruluk)	F1-Score (F1-Skor)	Class Number (Sınıf Sayısı)	Test Data Number (Test Veri Sayısı)
ResNeXt-101(32×8d)	0.95	0.9452	0.9479	0.945	2	326
DenseNet201	0.9444	0.8904	0.9202	0.92	2	326
Wide-ResNet101-2	0.9278	0.8699	0.9018	0.90	2	326
VGG-19bn	0.9056	0.8699	0.8896	0.89	2	326
DeTraC Deep CNN [10]	0.9187	0.9791	0.9512	NA	3	529
COVID-Net [6]	NA	0.91	0.933	NA	3	300
EfficientNetB3 [15]	NA	0.968	0.939	NA	3	231

ağın ve diğer çalışmaların sonuçlarının verilen performans metriklerine göre detaylıca karşılaştırılması görülmektedir. Şekil 13'teki karışıklık matrisi (confusion matrix) çalışmadaki sonuçları daha detaylı olarak göstermektedir. Karışıklık matrisi incelendiğinde ResNeXt-101(32×8d) ağının Covid-19 pozitif olan 8 hastanın negatif ve negatif olan 9 hastanın Covid-19 pozitif olarak teşhis edildiği görülmektedir. ResNeXt-101(32×8d) ağında yanlışlıkla pozitif olarak teşhis edilen hastaların sayısı yanlışlıkla negatif olarak teşhis edilen hastaların sayısından daha fazladır. Çalışmadaki diğer ağlar için bu durum tam tersi sonuç vermiştir. Yüksek doğruluk ve düşük yanlış-negatif teşhis oranıyla ResNeXt-101(32×8d) gerçek uygulamalar için tercih edilebilir sonuçlar vermiştir. Çalışmadaki bütün ağlar için 100 eğitim döngüsü boyunca eğitim gerçekleştirilmiş ve öğrenme oranı başlangıç değeri 0.001 olarak belirlenmiştir. Öğrenme oranı bunun ardından her 7 eğitim döngüsünde bir 10^{-3} ile çarpılarak binde birine düşürülmüştür. Öğrenme oranının düşük olması sonuçların belirli bir değere yakınsamasının ardından doğruluğun yakınsanma değerinin çevresinde dolaşmasını sağlamaktadır. Öğrenme oranının giderek düşürülmesiyle de eğitimin ileri aşamalarında optimal parametre değerleri için daha yerel arama yapılmasını sağlamaktadır. Yakınsamanın ardından oluşan doğruluk ve hata değeri dalgalanmaları tolere edilebilir seviyededir.

ResNext101_3 2x8d	WideResNet 101_2	Tahmin Edilen Sınıf			
DenseNet201	VGG_19_bn	Covid-19	Negatif	Covid-19	Negatif
Gerçek Sınıf	Covid-19	138	8	127	19
	Negatif	9	171	13	167
	Covid-19	130	16	127	19
	Negatif	10	170	17	163

Şekil 13. Ağların karışıklık matrisleri (Confusion matrices of the networks)

4. SONUÇLAR VE TARTIŞMA (RESULTS AND CONCLUSION)

Bu makalede X-ray görüntülerinden Covid-19 teşhisi için yapay sinir ağı tabanlı bir model önerilmiştir. Modelde eğitim görüntülerine, ağların girişine uygulanmadan önce, ön-işlem ile veri artırma yöntemleri uygulanmış ve elde edilen yeni görüntüler eğitim için kullanılmıştır. Ağların ilk parametreleri daha önce eğitilmiş olan ağlardan sağlanarak eğitim sıfırdan gerçekleştirilmemiştir. Model 4 farklı yapay sinir ağları ile gerçekleştirilmiş ve ağlar Covid-19 pozitif ve Covid-19 negatif olmak üzere 2 farklı sınıfı ayırmak için eğitilmiş ve doğrulanmıştır.

Yapılan çalışmada 4 ağdan 3'ünün sonuçlarında %90'ın üzerinde genel doğruluk başarımları sağlanmıştır. ResNeXt-101(32×8d) ise bu bağlamda %94.79'luk başarımları ile karşılaştırılan ağlar arasında en iyi sonucu vermiştir. Ayrıca ResNeXt-101(32×8d) ağı, hastalık teşhisi uygulamalarında önem arz eden duyarlılık metriği bazında da %94.52'lik başarımları ile diğer 3 ağdan ortalama %6'lık daha iyi başarımları sağlamıştır. ResNeXt-101(32×8d) ağının yapısı daha önceki başlıklarda detaylıca anlatılmıştır. Bu ağın 32 paralel darboğaz yapısına sahip olması, daha yüksek boyutlarda çekirdek yapısına sahip olması, ele alınan X-ray görüntülerinden diğer ağlara karşın daha nitelikli özellikler çıkarabilmesini sağlamıştır. Bu özellik çıkarımı sayesinde daha doğru sınıflandırma performansı gösterebilmiştir.

Çizelge 1'de performans sonuçları gösterilen diğer ağlar ile ResNeXt-101(32×8d) ağı, F1 skoru değeri ve özgüllük değerleri paylaşılmadığı için birebir karşılaştırma yapılamamıştır. Ancak önceki başlıklarda da değinildiği üzere F1 skoru performansı, Covid-19 gibi toplum sağlığını ciddi derecede etkileyebilme potansiyeline sahip bir hastalığın tespit edilmesinde, sadece özgüllük, sadece kesinlik veya sadece doğruluk performans değerlendirmelerine göre daha gerçekçi bir sonuç sunabilmektedir.

Yapılan çalışmada elde edilen sonuçlara göre X-ray görüntülerinden yapılan teşhisin umut vadeci olduğu ve tek başına karar verici mekanizma olma konusunda

henüz yetersiz olsa da doktorlara ve radyologlara Covid-19 hastalığının tespiti konusunda önemli ölçüde yardımcı olabileceği düşünülmektedir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni veya yasal özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Kubilay ATAŞ: Deneyle ilgili gerçekleştirmiş ve sonuçları analiz etmiştir.

Atakan KAYA: Deneyle ilgili gerçekleştirmiş ve sonuçları analiz etmiştir.

İndrit MYDERRİZİ: Sonuçları analiz etmiştir ve makalenin yazımını sağlamıştır.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu makalede herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Wang S., Kang B., Ma J., Zeng X., Xiao M., Guo J., ... & Xu B., "A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19)", *MedRxiv*, (2020).
- [2] Oh Y., Park S., Chul J., "Deep Learning COVID-19 Features on CXR using Limited Training Data", *IEEE Transactions on Medical Imaging*, 39, 2688-2700, (2020).
- [3] Narin A., Kaya C., Pamuk Z., "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural Networks", *arXiv preprint arXiv:2003.10849*, (2020).
- [4] Blain M., Kassin M. T., Varble N., Wang X., Xu Z., Xu D., ... , Di Meglio L., "Determination of disease severity in COVID-19 patients using deep learning in chest X-ray images", *Diagn Interv Radiol.*, (2020).
- [5] Zhang J., Xie Y., Pang G., Liao Z., Verjans J., Li W., ... & Xia Y., "Viral Pneumonia Screening on Chest X-rays Using Confidence-Aware Anomaly Detection" *IEEE transactions on medical imaging*, (2020).
- [6] Wang L., Lin Z. Q., Wong A., "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images", *Scientific Reports*, 10(1), 1-12, (2020).
- [7] Sharma A., Rani S., Gupta D., "Artificial intelligence-based classification of chest X-ray images into COVID-19 and other infectious diseases", *International journal of biomedical imaging*, (2020).
- [8] Casado-García A., Domínguez C., García-Domínguez M., Heras J., Ines A., Mata E., Pascual V., "CLODSA: a tool for augmentation in classification, localization, detection, semantic segmentation and instance segmentation tasks", *BMC Bioinformatics*, 20(1): 323, (2019).
- [9] Gao T., "Chest X-ray image analysis and classification for COVID-19 pneumonia detection using Deep CNN", *medRxiv*, (2020).
- [10] Abbas A., Abdelsamea M. M., Gaber M. M., "Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network", *arXiv preprint arXiv:2003.13815*, (2020).
- [11] Pereira R. M., Bertolini D., Teixeira L. O., Silla Jr C. N., Costa Y. M., "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios", *Computer Methods and Programs in Biomedicine*, 105532, (2020).
- [12] Jain R., Gupta M., Taneja S., Hemanth D. J., "Deep learning based detection and analysis of COVID-19 on chest X-ray images", *Applied Intelligence*, 1-11, (2020).
- [13] Minaee S., Kafieh R., Sonka M., Yazdani S., Soufi G. J., "Deep-covid: Predicting covid-19 from chest x-ray images using deep transfer learning", *arXiv preprint arXiv:2004.09363*, (2020).
- [14] Hemdan E. E. D., Shouman M. A., Karar M. E., "Covid-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images", *arXiv preprint arXiv:2003.11055*, (2020).
- [15] Luz E. J. D. S., Silva P. L., Silva R., Silva L., Moreira G., Menotti D., "Towards an Effective and Efficient Deep Learning Model for COVID-19 Patterns Detection in X-ray Images", *CoRR*, (2020).
- [16] Kaya A., Ataş K., Myderrizi I., "Implementation of CNN based COVID-19 classification model from CT images", *IEEE 19th World Symposium on Applied Machine Intelligence and Informatics*, Slovakia, 201-206, (2021).
- [17] Civit-Masot J., Luna-Perejón F., Domínguez Morales M., Civit, A., "Deep learning system for COVID-19 diagnosis aid using X-ray pulmonary images", *Applied Sciences*, 10(13), 4640., (2020).
- [18] Ismael A. M., Şengür A., "Deep learning approaches for COVID-19 detection based on chest X-ray images", *Expert Systems with Applications*, 164, 114054., (2020).
- [19] Afshar P., Heidarian S., Naderkhani F., Oikonomou A., Plataniotis K. N., Mohammadi A., "Covid-caps: A capsule network-based framework for identification of covid-19 cases from x-ray images", *arXiv preprint arXiv:2004.02696*, (2020).
- [20] Cohen, J. P., Morrison, P., Dao, L., Roth, K., Duong, T. Q., & Ghassemi, M. Covid-19 image data collection: Prospective predictions are the future. *arXiv preprint arXiv:2006.11988*. (2020).
- [21] C. Shorten, T. M. Khoshgoftaar, "A Survey on Image Data Augmentation for Deep Learning," *Journal of Big Data* 6, 60, (2019).
- [22] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. Imagenet: A large-scale hierarchical image database. In **2009 IEEE conference on computer vision and pattern recognition**, 248-255, (2009).
- [23] Simonyan, K., & Zisserman, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. (2014).
- [24] Zagoruyko, S., & Komodakis, N. Wide residual networks. *arXiv preprint arXiv:1605.07146*. (2016).
- [25] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. Aggregated residual transformations for deep neural networks. In **Proceedings of the IEEE conference on**

- computer vision and pattern recognition** ,1492-1500, (2017).
- [26] Krizhevsky, A., Sutskever, I., & Hinton, G. E. Imagenet classification with deep convolutional neural networks. **Communications of the ACM**, 60(6), 84-90. (2017).
- [27] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. Densely connected convolutional networks. **In Proceedings of the IEEE conference on computer vision and pattern recognition** , 4700-4708, (2017).
- [28] Bishop, C. M. "Pattern recognition and machine learning; 2nd printing." **Springer**, ISBN 10: 0387310738 New York, (2010).
- [29] Powers, D.M., "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation." **arXiv preprint** arXiv:2010.16061. (2020).