

Renklendirilmiş BT Görüntülerinden Covid-19 Tespiti İçin Derin Öğrenmeye Dayalı Bir Yöntem

A Deep Learning Based Method for Detecting Covid-19 from Colorized CT Images

Semiha GÜNGÖR¹, Mehmet KAYA¹, Reda ALHAJJ¹

Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

¹Bilgisayar Mühendisliği Bölümü, İstanbul Medipol Üniversitesi, İstanbul, Türkiye

(semihagunor@yahoo.com, kaya@firat.edu.tr, ralhajj@medipol.edu.tr)

Received:

Accepted:

Published:

Özetçe— Aralık 2019'un sonlarından bu yana Çin'in Wuhan kentinde yeni bir koronavirüs hastalığı Covid-19 kaydedildi ve daha sonra dünya çapında pandemik hale geldi. Covid-19'un, alveollerde bıraktığı hasar ve ilerleyen solunum yetmezliğinin bir sonucu olarak ölümle sonuçlanabilir. Klinik tanı için kullanılan transkripsiyon polimeraz zincir reaksiyonu (RT-PCR) altın standart olmasına rağmen testler yanlış negatifler üretebilir. Ayrıca pandemik durumda RT-PCR test kaynaklarının yetersizliği, tanıyı ve tedaviyi de geciktirebilir. Bu koşullar altında göğüs BT görüntülemesi, Covid-19 hastalarının hem tanı hem de prognozu için değerli bir araç haline gelmiştir. Yakın zamanda BT taramalarında Covid-19 tanısını kolaylaştırmak ve sağlık çalışanlarına yardımcı olmak için derin öğrenme teknikleriyle geliştirilmiş birçok çalışma önerilmiştir. Bu makale, DeOldify kütüphanesini kullanarak renklendirilen BT veri seti ile derin öğrenme tekniklerinden DenseNet121'i kullanarak Covid-19'u, Covid-19 olmayan vakalardan ayırt etmeye odaklanmaktadır. Çalışmamızın sonunda %98'lik doğruluk elde edilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Covid-19, DenseNet121, DeOldify.

Abstract— A new coronavirus disease Covid-19 has been recorded in Wuhan, China since late December 2019 and later became a worldwide pandemic. It can result in death as a result of covid-19's damage to the alveoli and progressive respiratory failure. Although transcription polymerase chain reaction (RT-PCR) is the gold standard used for clinical diagnosis, tests can produce false negatives. In addition, in the event of a pandemic, the lack of RT-PCR testing resources may delay diagnosis and treatment. Under these circumstances, Computed Tomography (CT) scans have become a valuable tool for both early diagnosis and prognosis of Covid-19 patients. Recently, many studies developed with deep learning techniques have been proposed to facilitate the diagnosis of Covid-19 in CT scans and to assist healthcare professionals. This paper focuses on distinguishing Covid-19 from non-Covid-19 cases using DenseNet121, one of the deep learning techniques, with the CT dataset colored using the DeOldify library. At the end of our study, an accuracy of 0.98 was obtained.

Keywords: Deep Learning, Covid-19, DenseNet121, DeOldify.

1.Giriş

Covid-19, Aralık 2019'da Çin'in Wuhan kentinde ortaya çıkan, çok kısa sürede tüm dünyayı etkisi altına alarak pandemiye dönüşen ve sağlık hizmetlerinde büyük sorunlara neden olan ciddi bir salgındır. Covid-19, dünya çapında birçok ülkenin karantina kararları almasına ve sayısız sanayi sektörünün iflas

etmesine neden olmuştur. Bu durum, dünya çapında bir mali krize yol açmıştır. Şiddetli akut solunum sendromu Covid-19, enfekte canlılarda önemli solunum yetmezliğine neden olmakta ve hastalığın ilerlemesi durumunda ölümcül sonuçlarla karşılaşmaktadır. Enfeksiyonun en belirgin semptom ve bulguları; Yüksek ateş, kuru öksürük, boğaz ağrısı, baş ağrısı, halsizlik, kas ağrısı, ishal ve nefes darlığı olarak bilinir, ancak bazı senaryolarda semptom yoktur (asemptomatik). Durumu kötüleşen hastalarda şiddetli zatürreye, oksijen yetersizliği nedeniyle akciğerlerde iltihap oluşmasına, ani dolaşım yetmezliğine ve kalp ve damar sistemlerinin organlara yeterli kanı ulaştıramamasına bağlı olarak çoklu organ yetmezliğine neden olmaktadır. Covid-19'un, kronik hastalığı olan, vücut gücü veya bağışıklık sistemi düşük kişileri, sigara kullananları ve yaşlıları daha çok etkilediği bilinmektedir (Pereira et al., 2020).

Covid-19 genellikle solunum, el veya mukozal temas gibi fiziksel temas yoluyla bulaşmaktadır. Hastalığın tedavisinde genellikle antibiyotikler, sıtma ilaçları, ateş düşürücü, öksürük ilaçları ve ağrı kesiciler kullanılmaktadır. Enfekte olan hastanın, şikâyetlerine ve hastalığın şiddetine göre hastaneye yatırılmasına karar verilir (Brunese et al., 2020). Dünya genelinde Covid-19 virüslü hasta sayısı her geçen gün artmaktadır. Dünya Sağlık Örgütü (WHO), 28 Nisan 2021 tarihine kadar 3.128.962 ölüm olduğunu belirtmiştir. Tüm bu bilgiler ışığında sağlık sistemi dikkate alınarak pandemiye tamamen önlemek veya en azından virüsün olası zararını en aza indirmek için hastalığın tespiti ve erken tedaviye başlanması büyük önem taşımaktadır. Şüpheli vakalar, düşük hata ile doğru ve hızlı bir şekilde tespit edilmelidir (Panwar et al., 2020).

Şu anda, COVID-19 teşhisi için gerçek zamanlı bir ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR) tekniği yaygın olarak kullanılmaktadır. COVID-19'u erken evrelerde teşhis etmek için Bilgisayarlı Tomografi (BT) ve röntgen gibi göğüs radyolojik görüntüleme yöntemleri tercih edilmektedir. Bilgisayarlı tomografi ile organlarımızın, kemiklerimizin, yumuşak dokularımızın ve kan damarlarımızın detaylı görüntülerine ulaşılmaktadır. Bu sayede doktorlar içyapıları tanımlayarak içyapıların şekil, boyut, yoğunluk ve dokularını görebilmekte ve oluşan hasarı fark edebilmektedir. Konvansiyonel X-Işınları tüm vücut yapısını kaplarken, BT görüntüleri vücudun belirli bir bölgesinin istenen kesitini üretir. Üretilen bu vücut dilimi sayesinde hastanın durumunun detaylı bir görünümü elde edilir. Bu kapsamlı bilgi, tıbbi bir sorun olup olmadığını belirlemek ve sorunun kapsamını ve tam yerini belirlemek için kullanılabilir.

Bu geleneksel tıp görüntüleme yöntemleri, hastalığın hızla yayılmasını kontrol etmede önemli bir rol oynar. Söz konusu hastalığın hızla yayılması ve birçok ülkede ölüm oranlarının artması, etkin bir tedavi yönteminin geliştirilmesi gerektiğini ortaya koymaktadır. Bu nedenle, teşhis, erken karantina ve takip dahil olmak üzere hastalığın kontrolü zorunlu hale gelir. Bu noktada derin öğrenme teknikleri yukarıdaki bakış açılarına katkı sağlayabilir.

Günümüzde özellikle tıbbi alanda, retinal görüntüleme, göğüs röntgeni ve beyin MRI ve DL teknikleri gibi görüntü veri kümeleri kullanılarak başarılı sonuçlar elde edilmektedir (Khan et al., 2020; Tung-Chen et al., 2020). DL ve Makine Öğrenimi teknikleri birçok uygulamada verilerden kalıp çıkarmak, analiz etmek ve onları tanımak için kullanılır. Bu çalışmada, bazı BT görüntüleri renklendirilerek ve DenseNet121 derin öğrenme yöntemi kullanılarak iki sınıflı (Covid-19 ve NonCOVID-19) bir veri setinden Covid-19 vakalarının belirlenmesi amaçlanmıştır. Böylece, yalnızca renkli veya renkli olmayan bir veri kümesine kıyasla daha doğru sonuçlar elde edilmiştir.

Makalenin devamı şu şekilde düzenlenmiştir: Bölüm 2, ilgili çalışmaları vermektedir. Bölüm 3, yöntem ve tekniğin ayrıntılarını açıklamaktadır. Bölüm 4, çalışmadan elde edilen deneysel sonuçları paylaşmakta ve son olarak Bölüm 5 makaleyi sonlandırmaktadır.

2. İlgili Çalışmalar

Soares ve ark. xDNN, ResNet, GoogleNet, VGG16, AlexNet, Decision Tree ve Adaboost, derin öğrenme yöntemlerini kullanarak Covid-19'u belirlemek için bir çalışma gerçekleştirmiştir. Kullanılan veri seti, 80:20 eğitim ve test için ayrılmıştır. Yapılan çalışmalar sonucunda, xDNN derin öğrenme modeli %97,38 ile en yüksek doğruluk değerine ulaşmıştır (Soares et al., 2020). Cifci, AlexNet ve Inception-V4 modelleriyle COVID-19'u tespit etmeye çalışmıştır. Modeli eğitmek için 4640 (%80) BT

görüntüsü ve test etmek için 1160 (%20) BT görüntüsü kullanılmıştır. Deneysel sonuçlara bakıldığında, AlexNet'in Inception-V4'ten daha iyi performans gösterdiği görülmektedir. AlexNet ile %94,74 doğruluk elde edilmiştir (Cifci, 2020).

Wang ve ark. 1119 BT taramasında patojen tarafından doğrulanmış Covid-19 vakaları üzerinde deneyler yapmıştır. Inception modelini kullanarak derin öğrenmenin transfer öğrenme tekniklerini hayata geçirmişler ve %89,5 doğruluk elde etmişlerdir (Wang et al., 2020). Lawton ve ark. derin öğrenme yöntemleriyle Covid-19'u belirlemek için standart histogram eşitleme ve kontrast sınırlı uyarlanabilir histogram eşitlemenin yanı sıra transfer öğrenme modellerinin performansını değerlendirmişlerdir. Sars Cov 2 CT Scan veri setinde en yüksek performans gösteren model %95,75 ile kontrast sınırlı uyarlanabilir histogram eşitleme ile uygulanan VGG19 olmuştur (Lawton & Viriri, 2021).

Rahimzadeh ve ark. İran'da Covid-19 tespitinde 48260 BT tarama görüntüsünü içeren yeni bir veri seti kullanmıştır. ImageNet veri seti üzerinde eğitilmiş 50 katmanlı bir ağ olan ResNet50V2 ile görüntü sınıflandırması, BT taramasında %98,49 doğruluk elde etmiştir (Rahimzadeh & Attar, 2020). Pathak ve ark. tarafından yapılan çalışmada, derin transfer öğrenmeye dayalı bilgisayarlı tomografi görüntülerinden Covid-19 tespiti yapılmıştır. Geliştirilen model, sırasıyla %96,22 ve %93,01 oranında eğitim ve test doğruluğu elde etmiştir (Pathak et al., 2020).

Bansal ve ark. derin öğrenme yöntemlerinden ResNet50, VGG16, SVM modellerini kullanarak Covid-19'u tespit etmeye çalışmıştır. Kullanılan veri seti, 80:20 eğitim ve test için ayrılmıştır. Böylece 1985 görüntü eğitim için, 496 görüntü test için kullanılmıştır. Eğitim aşamasında 5 kat çapraz doğrulama yöntemi kullanılmıştır. En yüksek doğruluğa sahip model %95,16 ile ResNet50 olmuştur (Bansal et al., 2021). Bukharia ve ark. tarafından yapılan çalışmada, X-Ray görüntülerinden ResNet50 tekniği kullanılarak Covid-19 tespiti yapılmıştır. Tanılama sürecinde modelden sırasıyla %98,18, %98,14, %98,24 ve %98,19 doğruluk, kesinlik, geri çağırma ve F1-Skoru elde edilmiştir (Bukhari et al., 2020).

Jaiswal ve ark. Covid-19'u tespit etmek için derin öğrenme yöntemlerinden DenseNet201, ResNet152V2, VGG16 ve InceptionResNet modellerini kullanmıştır. Yapılan çalışmalar sonucunda DenseNet201 için test doğruluk oranı %96,25 olmuştur (Jaiswal et al., 2020). Silva ve ark. diğerlerinden farklı olarak Sars Cov 2 CT Scan veri seti ve CovidCT veri seti ile çapraz veri seti analizi gerçekleştirmiştir. Çalışmada derin öğrenme modellerinden EfficientNet kullanılmış olup, en yüksek doğruluk oranı %87,68'dir (Silva et al., 2020).

3. Materyal ve Yöntem


Bu bölümde, bu çalışma için kullanılan sistemin veri seti ve mimarisi detaylı olarak açıklanmıştır.

3.1. Veri Seti

Covid-19'un tespiti için açık bir platform olan Kaggle'dan gerçek veriler (BT görüntüleri) alındı. Covid-19'un BT görüntülerinden elde edilen bu veri seti, Covid-19 enfekte ve Normal olmak üzere iki kategoriden oluşmaktadır. Bu çalışmada, önceki çalışmalardan farklı olarak veri setindeki görüntüler DeOldify yöntemiyle renklendirildi ve renklendirilen veri seti orijinal veri seti ile karıştırıldı. Bu sayede eldeki veri sayısı artırıldı.

DeOldify, MIT Lisansını kullanan ücretsiz olarak kullanıcılara sunulan bir ağ mimarisidir ve önceden eğitilmiş bir U-ağa dayalıdır. Siyah beyaz görüntüleri ve gri tonlamalı görüntüleri başarıyla renklendirebilir (Antic, J.: *Deoldify* (2018)). Aslında bir derin öğrenme kütüphanesi olan DeOldify, veri örneklerinin gösterilmesi ile öğrenen ve daha sonra öğrendiği modeli insan müdahalesine ihtiyaç duymadan işlemek için kullanan bir makine öğrenmesi modelidir. Burada da renkli resimler ve onların siyah beyaz versiyonları ile eğitilerek bağlantıyı öğrenmesi sağlandı. Milyonlarca resimle eğitilmiş, bulutların beyaza, ağaçların yeşile boyanması gerektiğini öğrenmiş ve daha önce gördüğü örneklere göre resmi renklendirmiştir. Jeneratör ve ayırıcının geleneksel teknik kullanılarak tek tek eğitilmesine odaklanan NoGAN adlı yeni bir teknik ve GAN teknikleri ile bir eğitim modeli kullanılarak eğitilmiştir. GAN'lar, Jeneratör ve Ayırıcı adı verilen iki derin sinir ağından oluşur. Bu iki ağ birbirine karşı eğitilmiştir. Fotoğraflar konusunda eğitilmiş bir GAN, insan gözlemciler için en azından yüzeysel

olarak orijinal görünen birçok gerçekçi özelliğe sahip yeni fotoğraflar oluşturabilir. Şekil 1. DeOldify ile renklendirilmiş ve karıştırılmış Covid-19 BT tarama görüntülerini göstermektedir.



Şekil 1. DeOldify ile renklendirilip karıştırılan Covid-19 BT tarama görüntülerine örnekler

Modeli oluşturmak için toplam 4962 adet veri kullanılmıştır. Tablo 1, kategori adı, eğitim ve teste dahil edilecek veri sayısı başlıkları ile tüm verileri içermektedir.

Tablo 1. Veri seti

Kategori Adı	Eğitim (%90)	Test (%10)	Toplam
COVID-19	2252	250	2502
Normal	2214	246	2460
			4962

3.2. Veri Arttırma

Bu bölümde Keras kütüphanesi kullanılarak görüntü ön işleme adımları yapılmıştır. Çalışma, veri arttırmaya odaklanmıştır. Veri büyütme, mevcut eğitim verilerinden yapay olarak yeni eğitim verilerinin üretilmesi anlamına gelir. Amaç, eğitim verilerini yeni örneklerle genişletmektir. Örneğin, nesnenin yönünü, konumunu ve hizalamasını değiştirmek. Bu tür bir dönüşüm resimleri korur ve bir doktorun resimleri yorumlamasını engellemez.

3.3. DenseNet

Huang ve ark. tarafından önerilen DenseNet mimarisi, esasen her katmanı diğer her katmana bağlayan yoğun bağlantılar ekleyerek ResNet mimarisini geliştirir (Huang et al., 2016). Katmanlar arasındaki yoğun bağlantı nedeniyle DenseNet olarak adlandırılır. Bu tür yoğun bağlı yapılarda, her katman kendinden önceki her katmandan özellik haritaları alabilir ve özellik haritasını kendinden sonraki her katmana aktarabilir. Böyle bir yapının en büyük avantajlarından biri, düşük sayıda parametreyi sürdürürken özellikleri yeniden kullanabilmesidir. Bu süreç şu şekilde tanımlanabilir:

$$x^l = H([x_0, x_1, \dots, x_{l-1}])$$

Burada 1 katman sayısıdır ve $H(\cdot)$ doğrusal olmayan bir dönüştürücüdür ve Toplu Normalleştirme, ReLU, Havuzlama ve Evrişimden oluşan birleşik bir işlemdir.

Bu çalışmada kullanılan DenseNet121 mimarisinin de aralarında bulunduğu, yaygın olarak kullanılan DenseNet mimarisinin birkaç çeşidi vardır. DenseNet, isteğe bağlı olarak ImageNet üzerinde ön eğitim gerçekleştirebilir. Burada 121, modelin derinliğini göstermektedir.

4. Deneysel Sonuçlar

Deney, ücretsiz olarak erişilebilen Google Colab tarafından sağlanan bir NVIDIA Tesla P4 GPU kullanılarak eğitildi. Model, arka uç olarak Tensorflow ve Python3 derin öğrenme kitaplığı olan Keras kullanılarak uygulandı.

Densenet121, içinde 121 katman bulunan bir modeldir. DenseNet121 ağının her katmanı 64x64x3 giriş görüntüsü ile beslenmiştir. Modelin eğitimi %80 eğitim verisi ile gerçekleştirilmiş, %20'si test için ayrılmıştır. Modelin Convolution ve Pooling bölümlerinden sonra ReLU aktivasyonlu katmanlar gelir. ReLU, çok sık kullanılan aktivasyon fonksiyonu olarak kabul edilebilir ve $F(x) = \max(0, x)$ olarak tanımlanabilir. Son olarak Softmax aktivasyon fonksiyonuna sahip katman gelir. Softmax çıktığı yalnızca [0,1] aralığına eşlemekle kalmaz, aynı zamanda her bir çıktıyı toplamı 1 olacak şekilde eşler. Bu nedenle Softmax'ın çıktısı bir olasılık dağılımıdır.

Sınıflandırma için tam bağlı katmanda sırasıyla Dense (256, ReLU), Batch Normalization (BN), Dense (2, Softmax) katmanları kullanılır. BN, katmanın çıktısını belirli aralıklarla sınırlar ve standart sapmayı zorlar. Bu düzenli olarak çalışarak sinir ağının kararlılığını artırmaya ve eğitimi hızlandırmaya yardımcı olur. Nöronları rastgele atan yoğun katmanlardan önce bir bırakma katmanı da kullanılır. Bırakma katmanı değeri 0,5 olarak ayarlanmıştır. Aşırı beslenmeyi önlemeye yardımcı olan bu katman, sağlam özelliklerin öğrenilmesine yardımcı olur. Yakınsama için tekrar sayısını artırsa da her periyot için eğitim süresi kısaldır. Model optimizasyonu, stokastik gradyan inişli ADAM optimizer ve Kategorik Çapraz entropi kaybı fonksiyonu kullanılarak gerçekleştirilir.

Eğitim sürecinde Epoch=50, Batch Size=64, Öğrenme hızı=0,002 olarak belirlenmiştir. Eğitim sırasında Keras API'sinde bulunan ReduceLROnPlateau kullanılmıştır. Bir metriğin gelişimi durduğunda, ReduceLROnPlateau öğrenme oranını $set_new_lr = lr * \text{faktör}$ değeriyle günceller. Faktör değeri 0,5 ve öğrenme hızının alt sınırı $1e-3$ olarak belirlenmiştir. Bu ayarlamalar sayesinde öğrenme hızı dinamik olarak azaltılır ve kontrol edilir.

4.1. Değerlendirme Metrikleri

Modelin deneysel değerlendirmesini yapmak için karışıklık matrisine dayalı metrikleri kullanıldı. Performans ölçümlerinde Doğruluk, Hassasiyet, Özgüllük, Kesinlik ve F1 skoru kullanılır. Bu değerlendirme ölçütleri, tıbbi görüntüleme sistemlerine yönelik çalışmaları değerlendirirken yaygın olarak kullanılır ve yüksek performans gösterirler. Bu nedenle, bu performans ölçümleri, Covid-19 teşhisinde de kullanılır. Doğruluk, kaç örneğin doğru şekilde sınıflandırıldığını gösterir. Özgüllük, negatif örneklerin doğru tanımlanma oranı ve hassasiyet, pozitif örneklerin doğru tanımlanma oranıdır. Kesinlik, model tarafından tahmin edilen gerçek pozitifleri analiz ederek modelin ne kadar doğru performans gösterdiğini hesaplar. F1-Skoru, hassasiyet ve kesinlik arasındaki dengeyi bulmaya çalışan bir hassasiyet ve kesinlik işlevidir.

Gerçek pozitif (TP): TP, başlangıçta pozitif olan ve ayrıca derin öğrenme modeline göre pozitif tahminlerdir.

Yanlış pozitif (FP): FP, başlangıçta negatif olan ve derin öğrenme modeline göre pozitif olması beklenen tahminlerdir.

Gerçek negatif (TN): TN, başlangıçta negatif olan ve ayrıca derin öğrenme modeline göre negatif tahminlerdir.

Yanlış negatif (FN): FN, başlangıçta pozitif olan ve derin öğrenme modeline göre negatif olması beklenen tahminlerdir.

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

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

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

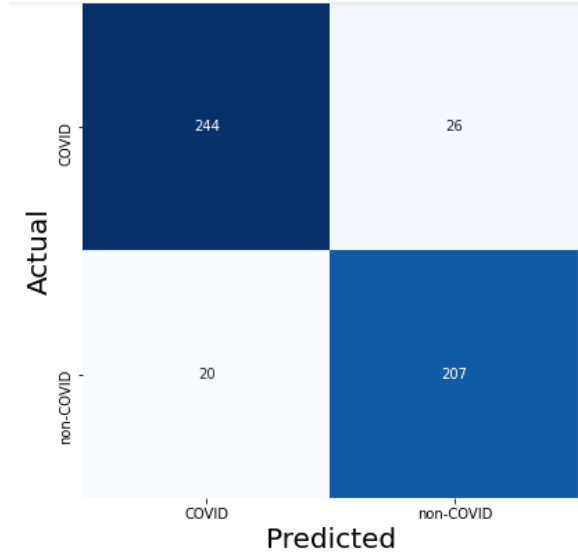
$$\text{Özgüllük} = \frac{TN}{(TN+FP)},$$

$$\text{Hassasiyet} = \frac{TP}{(TP+FN)},$$

$$F1 - \text{Skoru} = \frac{2 * (\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})}$$

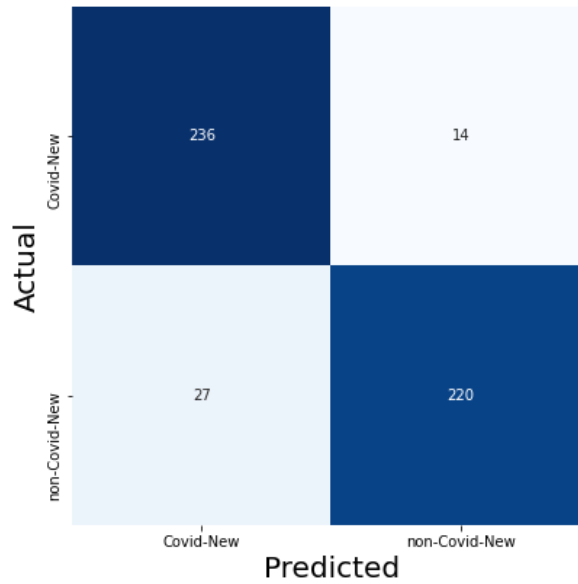
4.2. Sonular

Bu blmde, modelin sınıflandırma performansını lmek iin kullanılan deęerlendirme metriklerini ve yapılan alıřmalar sonucunda elde edilen verileri aıklyoruz. Model Covid-19'u tespit etmek iin hastalık etiketlerini (Covid-19 pozitif veya deęil) tahmin etmek zere tasarlanmıřtır. Renklendirme iřlemine yapmadan nce veri setini DenseNet121 modeli ile alıřtırdığımızda elde ettiğimiz bařarı oranı %90,74 oldu. Bu alıřmaya ynelik karıřıklık matrisi Őekil 2.'de gsterilmiřtir.




Őekil 2. Normal veri seti ile elde ettiğimiz karıřıklık matrisi

Covid-19 tespit oranımızı arttırmak iin veri setini DeOldify Ktphanesi ile renklendirip daha sonra renklendirilmiř veri seti ile alıřmamızı gerekleřtirdik. Gerekleřtirilen bu alıřma sonucunda elde ettiğimiz bařarı oranı %91,75 oldu. Bu alıřmaya ynelik karıřıklık matrisi Őekil 3.'de gsterilmiřtir.



Őekil 3. Renklendirdiğimiz veri seti ile elde ettiğimiz karıřıklık matrisi

Covid-19'u daha yüksek başarı oranı ile tespit etmek için veri seti ile renklendirdiğimiz veri setini karıştırdık. Eğitim için %80 test için %20 olacak şekilde bölümlendirdik. Bu çalışma sonucunda elde ettiğimiz başarı oranı %96,87 oldu. Bu çalışmaya yönelik karışıklık matrisi Şekil 4.'de gösterilmiştir.



Şekil 4. Karıştırdığımız veri seti ile %96,87 başarı elde ettiğimiz karışıklık matrisi

Ölçümler için elde edilen sonuçlar Tablo 2'de gösterilmektedir. Sistem, her metrik için 0,97'nin üzerinde verimlilik değerlerine sahiptir. Bununla birlikte, metriklerin geri kalanı, hem gerçek pozitifleri hem de negatifleri tanımlayan modelin iyi performans gösterdiğini kanıtlayan yüksek değerler sunar. Metrikler, sistemin bu tür görüntülerle bu hastalığın tanımlanmasına oldukça duyarlı olduğunu ve yanlış negatif oranının düşük olduğunu göstermektedir.

Tablo 2. Performans metriklerinin sonuçları

Doğruluk	0.9819
Hassasiyet	0.9879
Özgüllük	0.9758
Kesinlik	0.9761
Duyarlılık	0.9879
F1 - Skoru	0,9819

Çalışmanın başarısını doğrulamak için Şekil 5.'de karışıklık matrisi verilmiştir. Derin öğrenme modelinin son doğruluk düzeyi 0,98 olarak ve kayıp 0,05 olarak kaydedilmiştir.

Actual	covid	246	6
	noncovid	3	242
		covid	noncovid
		Predicted	

Şekil 5. Modelin karışıklık matrisi

5. Sonuç

Bu çalışma, derin öğrenme yöntemlerinden biri olan DenseNet121'in, doktorların Covid-19 vakalarını teşhis etmesine ve BT görüntülerinden doku bozukluğunu otomatik olarak tanımlamasına yardımcı olmak için uygulanabilirliğini göstermiştir. Covid-19 vakalarının BT tarama görüntülerini sınıflandırma sürecinde yüksek performans elde eden sistem, Covid-19 vakalarının erken teşhis edilmesi, izolasyon sağlanması, tedavinin etkinliğinin artırılması, radyologların iş yükünün azaltılması ve salgının kontrol altına alınması konusunda büyük potansiyele sahiptir. Ağların eğitiminde ne kadar çok veri kullanılırsa o kadar güvenilir ve gerçekçi derin öğrenme modeli elde edilebilir. Bu nedenle, BT görüntülerinin farklı akciğer hastalıkları için etiketlenmiş verilerle ve Covid-19 BT görüntüleriyle birleştirilmesinden daha güvenilir sistemlerin oluşturulabileceğini varsayıyoruz.

Teşekkür

Bu çalışma TÜBİTAK tarafından 118C364 numaralı proje kapsamında kısmen desteklenmiştir.

Kaynaklar

- Cifci, M.A. (2020). Deep Learning Model for Diagnosis of Corona Virus Disease from CT Images. *International Journal of Scientific & Engineering Research*, 11(4), 273–278. <http://www.ijser.org>
- Antic, J.: Deoldify (2018). <https://github.com/jantic/DeOldify>. (n.d.).
- Bansal, A., Thakur, G., & Verma, D. (2021). Detection of covid-19 using the ct scan image of lungs. *CEUR Workshop Proceedings*, 2786, 219–227.
- Brunese, L., Mercaldo, F., Reginelli, A., & Santone, A. (2020). Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays. *Computer Methods and Programs in Biomedicine*, 196, 105608. <https://doi.org/10.1016/j.cmpb.2020.105608>
- Bukhari, S. U. khalid, Bukhari, S. S. K., Syed, A., & Shah, S. S. H. (2020). The diagnostic evaluation of convolutional neural network (CNN) for the assessment of chest X-ray of patients infected with COVID-19. *MedRxiv*. <https://doi.org/10.1101/2020.03.26.20044610>
- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2016). *Densely Connected Convolutional Networks*. <https://arxiv.org/abs/1608.06993>
- Jaiswal, A., Gianchandani, N., Singh, D., Kumar, V., & Kaur, M. (2020). Classification of the COVID-

- 19 infected patients using DenseNet201 based deep transfer learning. In *Journal of Biomolecular Structure and Dynamics*. <https://doi.org/10.1080/07391102.2020.1788642>
- Khan, A. I., Shah, J. L., & Bhat, M. M. (2020). 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. <https://doi.org/10.1016/j.cmpb.2020.105581>
- Lawton, S., & Viriri, S. (2021). Detection of COVID-19 from CT Lung Scans Using Transfer Learning. *Computational Intelligence and Neuroscience*, *2021*. <https://doi.org/10.1155/2021/5527923>
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., & Singh, V. (2020). Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons and Fractals*, *138*, 109944. <https://doi.org/10.1016/j.chaos.2020.109944>
- Pathak, Y., Shukla, P. K., Tiwari, A., Stalin, S., & Singh, S. (2020). Deep Transfer Learning Based Classification Model for COVID-19 Disease. *IRBM*. <https://doi.org/10.1016/j.irbm.2020.05.003>
- Pereira, R. M., Bertolini, D., Teixeira, L. O., Silla, C. N., & Costa, Y. M. G. (2020). COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*, *194*, 105532. <https://doi.org/10.1016/j.cmpb.2020.105532>
- Rahimzadeh, M., & Attar, A. (2020). A NEW MODIFIED DEEP CONVOLUTIONAL NEURAL NETWORK FOR DETECTING COVID-19 FROM X-RAY IMAGES. In *arXiv* (Vol. 19, p. 100360). arXiv. <https://doi.org/10.1016/j.imu.2020.100360>
- Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., ... & Xu, B. (2021). A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19). *European radiology*, 1-9.
- Silva, P., Luz, E., Silva, G., Moreira, G., Silva, R., Lucio, D., & Menotti, D. (2020). COVID-19 detection in CT images with deep learning: A voting-based scheme and cross-datasets analysis. In *Informatics in Medicine Unlocked* (Vol. 20). <https://doi.org/10.1016/j.imu.2020.100427>
- Soares, E., Angelov, P., Biaso, S., Froes, M. H., & Abe, D. K. (2020). SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification. *MedRxiv*, 1–8.
- Tung-Chen, Y., Martí de Gracia, M., Díez-Tascón, A., Alonso-González, R., Agudo-Fernández, S., Parra-Gordo, M. L., Ossaba-Vélez, S., Rodríguez-Fuertes, P., & Llamas-Fuentes, R. (2020). Correlation between Chest Computed Tomography and Lung Ultrasonography in Patients with Coronavirus Disease 2019 (COVID-19). *Ultrasound in Medicine and Biology*, *46*(11), 2918–2926. <https://doi.org/10.1016/j.ultrasmedbio.2020.07.003>