



Araştırma Makalesi

## COVID-19 veri seti kullanarak ön-eğitilmiş modellerin sınıflandırma performanslarının karşılaştırılması

Melisa Uçkuner\*<sup>1</sup>, Hamza Erol<sup>2</sup>

<sup>1</sup>Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Mersin, Türkiye

<sup>2</sup>Mersin Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

### ÖZ

**Anahtar Kelimeler:**  
sınıflandırma  
covid-19  
makine öğrenmesi  
öğrenme aktarımı  
ön-eğitilmiş modeller

COVID-19, 2019 yılında Çin'in Wuhan kentinde ortaya çıkan ve SARS-CoV-2 virüsünün neden olduğu bir salgındır. Bu salgın, virüsün yüksek bulaşıcılığa sahip olmasından dolayı hızlı bir şekilde tüm dünyaya yayılmaktadır. SARS-CoV-2 virüsünün oluşturduğu semptomlar, diğer hastalıklarla benzerlik gösterebilmekte ve bu virüse maruz kalanların hastalıkları viral pnömöni ile karıştırılabilmektedir. Bundan dolayı hastalığın teşhisinde, doktorlara ve araştırmacılara yardımcı olmak için bilgisayar destekli teşhis sistemlerinden faydalanılmaktadır. Bu çalışmada, 3 sınıf içeren COVID-19 veri seti, öğrenme aktarımı yöntemi kullanılarak sınıflandırılmıştır. Veri setinin %80'i eğitim, %20'si test verisi olarak ayrılmıştır. Ön-eğitilmiş modeller kullanılarak oluşturulan sınıflandırıcılar eğitilmiş ve elde edilen modellerin test verisi için doğruluk oranları InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2, DenseNet201 tabanlı modeller için sırasıyla %98.6, %98.7, %99.3, %97.8, %98.7 ve %98.0 olarak hesaplanmıştır. Bu sonuçlar, ön-eğitilmiş modeller kullanılarak oluşturulan sınıflandırıcıların, COVID-19 salgınında teşhis aşamasında doktorlara yardımcı olabileceğini göstermektedir.

## Comparison of the classification performances of pre-trained models using the COVID-19 data set

**Keywords:**  
classification  
covid-19  
machine learning  
transfer learning  
pre-trained models

### ABSTRACT

COVID-19 is a pandemic that originated in Wuhan, China in 2019 and is caused by SARS-CoV-2 viruses. The pandemic quickly spread all over the world due to the high contagiousness of the virus. Symptoms exhibited by SARS-CoV-2 viruses can be similar to other diseases and diseases of those exposed to the virus can be confused with viral pneumonia. Therefore, computer-aided diagnosis (CAD) systems are used to assist doctors and researchers in the diagnosis of the disease. In this study, the COVID-19 data set, which includes 3 classes, was classified using the transfer learning method. 80% of the data set is separated as training and 20% as test data. Classifiers constructed using pre-trained models were trained and the accuracy rates for the test data were obtained as %98.6, %98.7, %99.3, %97.8, %98.7 and %98.0 for InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2, DenseNet201 models, respectively. These results show that the proposed classifiers based on pre-trained models can assist doctors in the diagnosis of the COVID-19 outbreak.

### 1. GİRİŞ

İnsanoğlunun afetlerle mücadelesi, insanlığın varoluşunun başından itibaren günümüze kadar devam etmektedir. Bakterilerin ve virüslerin neden

olduğu biyolojik afetler de doğal afetler arasında yer almaktadır. Son zamanlarda yaşanan en büyük biyolojik afetlerden birisi, 2019 yılında Çin'in Wuhan kentinde ortaya çıkan ve Dünya Sağlık Örgütü tarafından pandemi olarak kabul edilen COVID-19

\*Sorumlu Yazar

[\\*melisauckuner@gmail.com](mailto:melisauckuner@gmail.com)  
ORCID ID 0000-0003-2955-4456  
[herol@mersin.edu.tr](mailto:herol@mersin.edu.tr)  
ORCID ID 0000-0001-8983-4797

e-ISSN: 2717-8579  
Geliş Tarihi: 17/05/2021; Kabul Tarihi: 18/06/2021

Bilgisayar Bilimleri ve Teknolojileri Dergisi

salgındır. Viral bir salgın olan COVID-19, henüz aşı çalışmaları tam olarak sonlanmamış ve tedavisi olmayan bir hastalık olup, hızlı yayılma ve viral pnömoni (viral zatürre) ile karıştırılma gibi zorlayıcı özelliklere sahiptir. Son yıllarda teknolojinin gelişmesiyle birlikte bilgisayar destekli teşhis (BDT) yöntemlerinin yaygın kullanım alanına erişmesi, COVID-19 hastalığının tespitinde de bilgisayar destekli sistemlerin kullanılabilirliğini göstermektedir. BDT sistemlerinin hızlı ve güvenilir sonuç vermesi, hızla yayılan COVID-19 viral salgınının tespitinde kullanılarak doktorlara yardımcı sistemlerin geliştirilmesine motivasyon oluşturmaktadır. BDT sistemlerinin gelişmesinde, son zamanlarda popüler bir noktaya ulaşan derin öğrenme yöntemi ve evrişimli sinirsel ağları (ESA) büyük rol oynamaktadır. Derin öğrenme modelleri, görüntülerin ve videoların sınıflandırılması başta olmak üzere birçok alanda yaygın bir şekilde kullanılmakta ve yeni fikirlerin geliştirilmesine kolaylıklar sağlayan bir kapı aralamaktadır. Literatürde, COVID-19 salgınının tespiti için makine öğrenmesi yöntemlerini kullanan çeşitli yöntemler bulunmaktadır (Rochmawati vd., 2020; Mishra vd., 2020; Tabik vd., 2020; Wang vd., 2020; Chowdhury vd., 2020). Rochmawati ve arkadaşları tarafından yapılan çalışmada (Rochmawati vd., 2020) bir klinik semptom veri seti kullanılarak COVID-19 semptomları, karar ağacı algoritması ile sınıflandırılmaktadır. Mishra ve arkadaşları (Mishra vd., 2020) ise COVID-19 hastalığının tespitinde, x-ray röntgen verilerinin sınıflandırması için CovAI-Net olarak adlandırdıkları iki aşamalı bir evrişimsel sinir ağı (ESA) modeli önermişlerdir. Veri seti sınıflandırması konusunda yapılan bir diğer çalışma, Tabik ve arkadaşları tarafından (Tabik vd., 2020) yapılmıştır. Önerilen çalışmada, homojen ve dengeli şekilde oluşturdukları veri seti, öğrenme aktarımı yöntemi kullanılarak sınıflandırılmış ve %97.72 oranında doğruluğa ulaşılmıştır (Tabik vd., 2020). Wang ve arkadaşları (Wang vd., 2020), bilgisayarlı tomografi ile elde edilen görüntüleri kullanarak, COVID-19 sınıflandırması yapan ve DeCoVNet olarak adlandırdıkları bir ESA modeli önermişlerdir. Önerdikleri model (Wang vd., 2020), %90.1'lik bir doğrulukla tahminlerini gerçekleştirmektedir. Bu konuda yapılan bir diğer çalışmada (Chowdhury vd., 2020) çeşitli kaynaklardan elde edilen 3487 adet x-ray röntgen görüntüleri, ön-egitimli derin öğrenme modelleri kullanılarak sınıflandırılmıştır. Yapılan çalışmada (Chowdhury vd., 2020), %98.3'lük doğruluğa erişilmiştir.

Bu çalışmada, COVID-19 salgını için oluşturulan 3 sınıflı x-ray röntgen görüntülerinin öğrenme

aktarımı tabanlı sınıflandırıcı kullanılarak sınıflandırılması amaçlanmıştır. 6 farklı ön-egitimli model kullanılarak oluşturulan sınıflandırıcının karşılaştırması yapılarak modellerin performansları yorumlanmıştır.

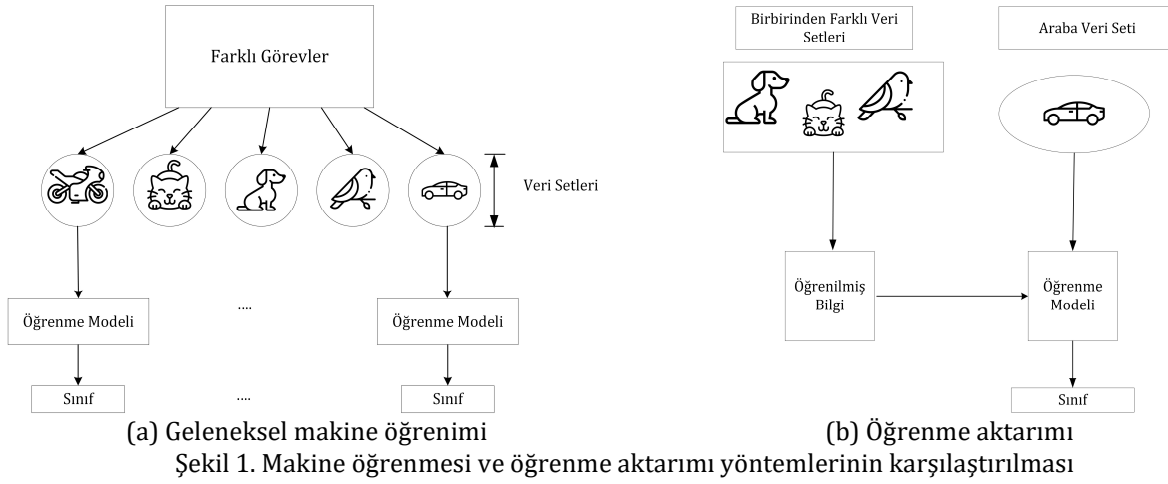
## 2. ÖĞRENME AKTARIMI YÖNTEMİ

Öğrenme aktarımı (transfer öğrenmesi), özel amaçlar için geliştirilen derin öğrenme modelleri ile elde edilen özelliklerin, diğer makine öğrenmesi yöntemlerinde giriş olarak kullanılması ile oluşturulan öğrenme yapısı olarak tanımlanmaktadır.

Öğrenme aktarımı, bir probleme çözüm arama veya bir durumdan elde edilen sonuçları bilgi olarak saklayıp, farklı ama ilişkili problemlere ya da durumlara bilginin aktarılmasıdır. Aktarılan bilginin, farklı durumda da çözüme olumlu yönde etkili olması için genel bilgiler içermesi gerekmektedir. Probleme özgü özelliklerin kullanılması, negatif yönde bilgi aktarımına sebep olabilmektedir. Bu sebeple, hem kaynak hem de uygulanacak problemlere uygun olan bilgiler aktarılmalıdır.

İnsanlar, günlük hayatta karşılaştıkları sorunlarda elde ettikleri bilgileri başka durumlarda kullanmaktadır. Elde edilen bilgi, yeni bilgiler elde edilmesi için ilk adım ya da başlangıç olarak düşünülmektedir. Başlangıçta mevcut olan bilgi sayesinde yeni bilgi öğrenimi, hızlı ve kolay bir şekilde gerçekleşmektedir.

Geleneksel makine öğrenmesi, farklı veri setlerinin öğrenimi için farklı modellerin kullanılmasına dayanmaktadır. Her veri setinin özelliği birbirinden farklı olduğundan, bu farklılığa uygun şekilde modeller geliştirilmesi önemlidir. Ayrıca geliştirilen modellerin eğitilmesinde, veri setine ait özellik çıkarımının daha önceden yapılması da modelin yüksek doğruluğa hızlı bir şekilde erişmesi için gereklidir. Öğrenme aktarımı yönteminde ise bu özellik çıkarımı, geleneksel makine öğrenmesi yöntemlerinin aksine model içerisinde yapılmaktadır. Böylece modelin eğitilmesi ve test edilmesi aşamasında ayrıca özellik çıkarımı yapmaya gerek olmamakta, işlenmemiş veri doğrudan modele uygulanabilmektedir. Ayrıca, öğrenme aktarımında kullanılan ön-egitimli modeller, daha önceden çeşitli veri setleri ile eğitildiklerinden dolayı eğitilmiş ağırlıklara sahiptir. Böylece ön-egitimli ağlar kullanılarak yüksek doğruluklara hızlı bir şekilde ulaşılabilir. Şekil 1(a)'da geleneksel makine öğrenimine ve Şekil 1(b)'de öğrenme aktarımına ilişkin görsel yer almaktadır.



Şekil 1’de görüldüğü gibi, geleneksel makine öğrenmesinde oluşturulan modeller, her bir veri seti için ayrı ayrı olacak şekilde sıfırdan eğitilmektedir. Öğrenme aktarımı sürecinde aktarılacak bilgi ile bu bilginin aktarılma zamanı ve aktarım yöntemi önemlidir. Aktarılacak bilginin belirlenmesi, ilk ve en önemli aşama olup, kullanılacak veriye göre değişmektedir. Kaynak veriden aktarılacak olan bilgi, ortak özellikler içermelidir. Aktarılacak bilginin sadece kaynağa özgü olması, kullanılacak veri seti için bir yarar sağlamamakta, hatta negatif bilgi aktarımına sebep olabilmektedir. Bundan dolayı, aktarılan bilgi genel olmalıdır. Bilginin aktarılma zamanı, iki veri setinin birbirinden çok farklı olması veya ortak özelliklerinin olması durumlarında farklılıklar göstermektedir. Bu zaman, çok farklı veri setlerinde eğitimin başarısını düşürebildiği gibi, ortak özelliklerin kullanılmasında performansı yükseltmektedir. Aktarım yöntemi olarak var olan modeller direkt kullanılabilir gibi, modeller üzerinde katmanlar ya da parametreler değiştirilip yeni modeller elde edilerek bilgi aktarımı gerçekleştirilebilir.

Öğrenme aktarımı, bahsedildiği gibi eğitilmiş modellerin edindiği bilginin kullanılmasıyla gerçekleştirilmektedir. Literatürde birçok derin öğrenme modeli bulunmasına rağmen bu çalışmada InceptionV3, Xception, ResNet152V2, DenseNet201, InceptionResNetV2, ve VGG19 modelleri tercih edilmiştir.

Derin öğrenme modellerinde, ağların derinlikleri arttıkça hesaplama karmaşıklığı da meydana gelmektedir. Hesaplama esnekliği sağlamak ve karmaşıklığı azaltmak için kullanılan yollardan biri, matrislerin boyutlarını havuzlama katmanları ile azaltmaktır. Ancak bu durumda ilgili katmanın derinliği azalmamaktadır. Katman derinliğini azaltmak için Szegedy vd. tarafından önerilen çalışmada (Szegedy vd., 2016),  $1 \times 1$  boyutunda evrişim katmanı kullanılması önerilmiştir. Önerilen katmanın kullanılmasıyla, matris derinliği sınırlandırılabilir ve işlem karmaşıklığı azaltılabilir. Modüllerden oluşan InceptionV3 modelinde modüller, *Inception* olarak adlandırılan farklı boyutlarda evrişim ve

maksimum havuzlama katmanlarından oluşmaktadır.

Xception mimarisi (Chollet, 2017), *Inception* mimarisindeki standart *Inception* modüllerinin *derinlemesine ayrılabilir evrişim katmanları* ile değiştirilmesiyle oluşturulmuş bir uzantıdır. Xception modelinde çapraz-özellik haritası korelasyonları  $1 \times 1$  boyutundaki evrişim katmanı sayesinde elde edilmektedir. Ardından, her kanal için uzamsal korelasyonlar ise klasik  $3 \times 3$  veya  $5 \times 5$  boyutlarındaki evrişim katmanlarıyla hesaplanmaktadır. Burada uygulanan yöntem, derinlemesine ayrılabilir evrişimleri temsil etmektedir.

ESA’da katman sayısının artırılmasının, modelin doğruluğunu sürekli olarak artırmadığı ve doyuma ulaştırıldığını görülmesi, ResNet mimarisinin önerilmesinde önemli rol oynamıştır. ResNet mimarisi (He vd., 2016), mevcut katmana daha önceki katmanlardan artık değerlerin (residual value) eklenmesine dayanmaktadır. Artık değerler, ResNet mimarisinde doğrusal ve ReLU (rectified linear unit) katmanları arasında iki katmanda bir eklenecek şekilde oluşturulmaktadır. Böylece daha derin ağlar oluşturulurken eğitim daha hızlı yapılmakta ve ağ başarısı artırılmaktadır.

Literatürde yer alan derin öğrenme modellerinden bir diğeri, DenseNet olarak adlandırılan, Huang ve arkadaşları tarafından önerilen yoğun bağlantılı evrişimsel ağlardır (Huang vd., 2017). DenseNet mimarisinde, ResNet mimarisinden farklı olarak daha önceki katmanlardan gelen bilgiler, daha sonraki katmanlarla toplanmak yerine birleştirilmektedir. Bu yöntem, özelliklerin yeniden kullanılması ve gradyan kaybolma sorununu azaltma gibi avantajlar sunmaktadır (Wang ve Zhang, 2020).

Inception-ResNet modeli, Inception mimarisinde yer alan *Inception* modülleri ile ResNet mimarisinin performansından esinlenilerek oluşturulan hibrid bir modeldir (Szegedy vd., 2017). Bu hibrid modelde *inception* modülleri, artık *inception* modüllerine dönüştürülmektedir.


VGG mimarisi, başlangıcından sonuna doğru yükseklik ve genişlik boyutlarının azaldığı ancak

derinliğin arttığı basit bir ağ mimarisidir (Huang vd., 2018). Bu modelin diğer modellere göre ayırt edici özelliği, evrişim katmanlarının ikili veya üçlü gruplar olarak kullanılmasıdır. VGG19 modeli, 16 evrişim katmanı, 5 havuzlama katmanı ve 3 tam bağlı katmandan oluşmaktadır.

### 3. MATERYAL VE METHOD

Öğrenme aktarımında amaç, yeni veri setine ait özelliklerin, ön-egitilmiş modeller aracılığı ile çıkarımının sağlanması ve bu özelliklerin, farklı makine öğrenmesi yöntemlerinde kullanılarak amaca uygun yeni modellerin eğitilmesidir. Bunun

için veri setinin ve bu sete uygun olabilecek ön eğitilmiş modellerin seçimi önemlidir. Bu çalışmada, COVID-19 Radiography Database (URL-1) adlı veri seti kullanılmıştır. Katar Üniversitesi, Dhaka Üniversitesi ile Pakistan ve Malezya'dan katılımcıların oluşturduğu bir araştırmacı grubu, medikal doktorlarla iş birliği kurarak COVID-19 ve viral pnömoni hastalığına sahip insanlardan elde edilen göğüs röntgeni içeren veri seti oluşturmuşlardır. Oluşturulan veri setine sağlıklı hastaların röntgenlerini de ekleyen araştırmacılar, 3 sınıflı bir veri seti elde etmişlerdir. Bu sınıflara ait örnek röntgen görselleri Şekil 2'de verilmektedir.



Şekil 2. (a) Covid, (b) normal ve (c) viral pnömoni sınıflarına ait röntgen görsellerinden örnekler

Bu çalışma kapsamında COVID-19 Radiography Database veri setinin öğrenme aktarımı yöntemi kullanılarak sınıflandırılmasında, 6 farklı ön eğitilmiş model kullanılmıştır. Seçilen veri setine ait bilgiler Tablo 1'de verilmiştir.

Tablo 1. Veri setinin özellikleri

Parametre	Değer
Sınıf Adedi	3
Sınıflar	covid, normal, viral pnömoni
Görüntü Adedi	2905

Tablo 2'de ise veri setine ait her bir sınıfın içerdiği görüntü adedi verilmektedir.

Tablo 2. Sınıflardaki görüntü sayısı

Sınıf	Görüntü Adedi
covid	219
normal	1341
viral pnömoni	1345

Farklı ön eğitilmiş modeller kullanılarak oluşturulan yeni yapay sinir ağı (YSA) tabanlı sınıflandırıcı modelin yapısı, Şekil 3'te görselleştirilmiştir. Ele alınan modellerin çıkışlarına, Şekil 3'te görüldüğü gibi 4 yeni sinirsel katman eklenmiştir. Eklenen bu katmanların ağırlıkları ile ele alınan modellerin bazı katmanlarına ait ağırlıklar, COVID-19 veri setine göre yeniden eğitilmiştir. Bu çalışmada ele alınan modeller, modellerin katman

sayıları ve giriş görüntü boyutları Tablo 3'te verilmiştir.

Tablo 3. Kullanılan ön-egitilmiş modellere ilişkin bilgiler

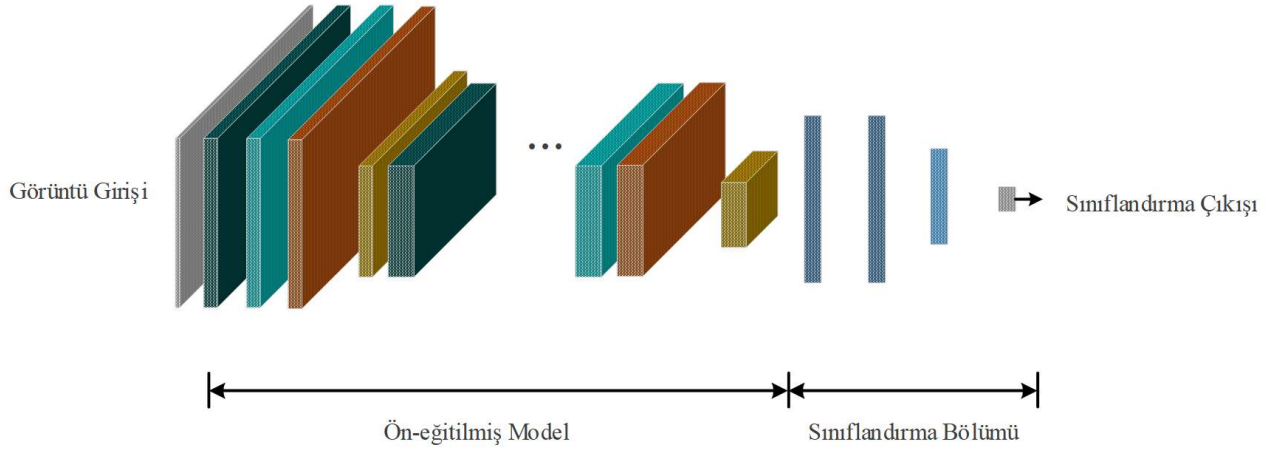
Ön-egitilmiş Model	Toplam Katman Sayısı	Giriş Görüntü Boyutu
InceptionV3	316	299x299
ResNet152V2	52	224x224
Xception	171	299x299
InceptionResNetV2	825	299x299
DenseNet201	709	224x224
VGG19	47	224x224

Oluşturulan sınıflandırıcının eğitimi için veri setinin %80'ine karşılık gelen 2325 adet görüntü, testi için ise %20'sine karşılık gelen 580 adet görüntü kullanılmıştır. Eğitim sırasında, tüm eğitim verilerinin ağı gösterilme sayısı (epok) 100 ve alt örneklerin sayısı ise 32 olarak seçilmektedir. Derin öğrenme uygulamalarında öğrenme işlemi, aslında bir optimizasyon problemidir. Öğrenme aşamasında kullanılan algoritmalar arasında global çözüme yaklaşım anlamında başarı ve performans farklılıkları bulunmaktadır. Bu sınıflandırma çalışmasında, sınıflandırıcı modelin ağırlıklarının eğitiminde optimizasyon algoritması olarak Adam algoritması seçilmiştir.

Eğitim aşamasında kullanılan optimizasyon algoritmalarının en iyi çözüme yaklaşmasını

sağlayan parametrelerden biri, öğrenme katsayısıdır. Öğrenme katsayısının değeri, optimizasyon işleminin hızını ters orantılı olarak etkilerken, yerel minimum noktalara takılma

durumunda da rol oynamaktadır. Bu çalışmada, Adam optimizasyon algoritması için öğrenme katsayısı 0.00146 olarak belirlenmektedir.



Şekil 3. Ön-eğitilmiş model kullanılarak oluşturulan sınıflandırıcı modeli

Hata fonksiyonu, tahmin edilen değerin asıl değere yakınlığına ilişkin bir değer döndürmektedir. Tahmin edilen değer, gerçek değere ne kadar yakınsa, hata fonksiyonunun sonucu da o kadar küçük olmaktadır. Bu çalışmada hata fonksiyonu olarak, çok sınıf içeren sınıflandırma problemlerine uygun olduğu için kategorik çapraz entropi seçilmektedir. Önerilen öğrenme aktarımı modellerinin eğitiminde kullanılan parametreler ve bu parametrelerin aldığı değerler Tablo 4'te verilmiştir.

Tablo 4. Modeller tarafından kullanılan parametreler ve değerleri


Parametre	Değer
Eğitim Verisi Oranı	%80 (2325 adet)
Doğrulama Verisi Oranı	%20 (580 adet)
Epok Sayısı	100
Alt Örnek Sayısı (Batch Size)	32
Optimizasyon Algoritması	Adam
Öğrenme Katsayısı	0.00146
Hata Fonksiyonu	Kategorik çapraz entropi


Tablo 3 ve Tablo 4'te verilen bilgiler kullanılarak oluşturulan öğrenme aktarımı modellerinin eğitimi, veri boyutunun büyüklüğünden ve eğitilecek parametre sayısının fazlalığından dolayı CPU üzerinde uzun zaman almaktadır. Bu sorunu aşmak için bu çalışmada oluşturulan modeller, Tesla T4 GPU donanımı kullanılarak eğitilmiştir. Bu sayede eğitim süreleri, GPU kullanmadan ulaşılabilecek sürelerle kıyasla yaklaşık olarak 15 ile 30 kat arasında kısaltılmıştır.

#### 4. BULGULAR VE TARTIŞMA

GPU üzerinde yapılan eğitim sürecinden elde edilen hata ve doğruluk grafikleri her model için ayrı ayrı oluşturulmuştur. Eğitim süreci InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2 ve DenseNet201 öğrenme aktarımı modelleri için yaklaşık olarak, sırasıyla, 9000, 10200, 10500, 5300, 9600, 8800 saniye sürelerinde tamamlanmıştır.

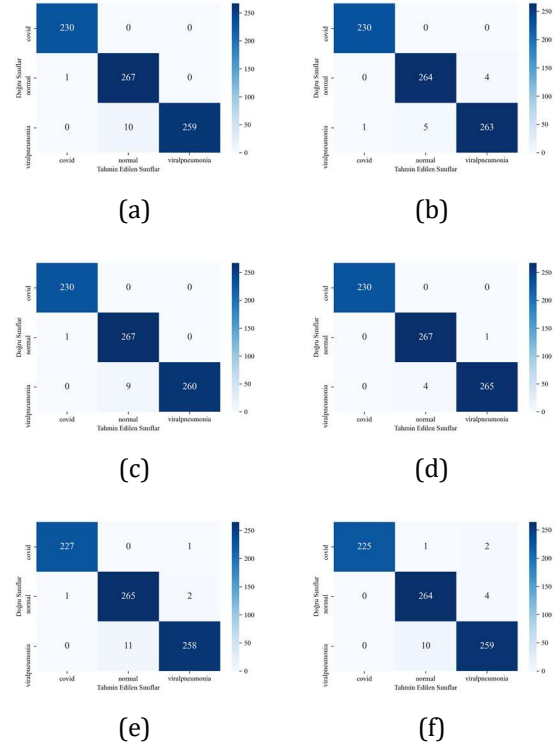
Şekil 4'te, InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 kullanılan sınıflandırıcı modellerin eğitimi için, sırasıyla, epoka karşılık hata ve doğruluk grafikleri verilmiştir.





**Şekil 4.** InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 kullanılarak oluşturulan modeller için, sırasıyla, epoka karşılık (a, c, e, g, i, k) hata ve (b, d, f, h, j, l) doğruluk grafikleri

Şekil 4'te görüldüğü gibi, ilk epok için elde edilen en yüksek hata değeri VGG19'a dayalı model ile elde edilmişken, en düşük hata değeri ise DenseNet201'e dayalı model ile elde edilmiştir. ResNet152V2 kullanılan modelin hatayı minimize etme hızının, diğer modellere kıyasla daha düşük olduğu görülmektedir. Xception ve VGG19 kullanılan modeller ise yüksek doğruluk değerlerine en hızlı ulaşan modeller olmuşlardır. Şekil 4'te veriler grafikler kullanılarak, bu çalışmada kullanılan modellerin performansları, hata ve doğruluk açısından birbirleriyle ayrıca kıyaslanabilir. Şekil 5 (a) – (f)'de ise sırasıyla, InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 kullanılarak eğitilen öğrenme aktarımı modellerinin test verisi için elde edilen karışıklık matrisleri verilmiştir. Şekil 5 (a) – (f)'de görüldüğü gibi InceptionV3, ResNet152V2, Xception, InceptionResNetV2, DenseNet201 ve VGG19 modelleri kullanılarak eğitilen sınıflandırıcı modelleri, sırasıyla, 11, 10, 10, 5, 15 ve 17 adet veriyi yanlış sınıflandırmıştır. Bu doğrultuda en iyi sınıflandırma, InceptionResNetV2 kullanılarak oluşturulan model ile elde edilmiştir. Covid sınıfının doğru tahmini, diğer sınıflara göre daha önemlidir. Buna göre, InceptionResNetV2 ile oluşturulan sınıflandırıcı modeli, covid sınıfının tamamını doğru tahmin etmiştir. Yine covid sınıfının doğru sınıflandırılması açısından karşılaştırma yapıldığında, InceptionV3, Xception ve ResNet152V2 ile oluşturulan modellerin DenseNet201 modelinden daha iyi sınıflandırdığı görülmektedir.



**Şekil 5.** (a) InceptionV3, (b) ResNet152V2, (c) Xception, (d) InceptionResNetV2, (e) DenseNet201 ve (f) VGG19 kullanılarak eğitilen öğrenme aktarımı modelinin doğrulama verisiyle elde edilen karışıklık matrisi

VGG19 ile oluşturulan model ise tüm modeller arasında covid sınıfını en çok yanlış sınıflandıran model olarak görülmektedir. Tablo 5'te görüldüğü gibi, eğitilen öğrenme aktarımı modellerinin test verisi için doğruluk oranları InceptionV3, Xception, InceptionResNetV2, VGG19, ResNet152V2, DenseNet201 tabanlı sınıflandırıcı modeller için sırasıyla %98.6, %98.7, %99.3, %97.8, %98.7 ve %98.0 olarak hesaplanmaktadır.

## 5. SONUÇLAR

Bu çalışmada, COVID-19 salgını sürecinde elde edilen göğüs röntgenlerinden oluşan 3 sınıflı veri setinin, öğrenme aktarımı yöntemi ile sınıflandırılması yapılmıştır. Bunun için öncelikle veri seti, kullanılacak öğrenme aktarımı modeline göre yeniden boyutlandırılarak ön işlemden geçirilmiştir. Daha sonra, ön-eğitilmiş modeller kullanılarak yeni sınıflandırıcı modeller oluşturulmuştur. Ön-eğitilmiş modellerde başlangıç ağırlıkları olarak ImageNet veri seti için elde edilmiş ağırlıklar kullanılmıştır. Ayrıca ele alınan modellerin bazı katmanları, yeniden eğitilebilir katman olarak belirlenerek eğitim performansı artırılmıştır. Oluşturulan sınıflandırıcı modelleri, Tesla T4 GPU donanımı kullanılarak eğitilmiştir. Eğitim işlemi sonunda elde edilen modeller, test verileri kullanılarak test edilmiştir.

**Tablo 5.** Eğitilen öğrenme aktarımı modellerinin performanslarına ilişkin sayısal sonuçlar

Model	Doğruluk	Sınıflar	TN	TP	FN	FP
InceptionResNetV2 + YSA	0.993	Covid	537	230	0	0
		Normal	495	267	1	4
		Viral Pnömoni	497	265	4	1
Xception + YSA	0.987	Covid	536	230	0	1
		Normal	490	267	1	9
		Viral Pnömoni	498	260	9	0
ResNet152V2 + YSA	0.987	Covid	536	230	0	1
		Normal	494	264	4	5
		Viral Pnömoni	494	263	6	4
InceptionV3 + YSA	0.986	Covid	536	230	0	1
		Normal	489	267	1	10
		Viral Pnömoni	498	259	10	0
DenseNet201 + YSA	0.980	Covid	536	227	1	1
		Normal	486	265	3	11
		Viral Pnömoni	493	258	11	3
VGG19 + YSA	0.978	Covid	537	225	3	0
		Normal	486	264	4	11
		Viral Pnömoni	490	259	10	6

Önerilen 6 farklı modelden en yüksek doğruluğu veren sınıflandırıcı, %99.3 doğruluk oranıyla InceptionResNetV2 tabanlı model olmuştur.

Bu çalışma, öğrenme aktarımı yönteminin, hızlı bir şekilde yayılan COVID-19 salgınının tespitinde röntgen görüntüleri kullanarak, doktorlara ve araştırmacılara yardımcı olabileceğini göstermektedir. Bu sonuçlarla birlikte, hiper parametre optimizasyonu yapılarak ve daha farklı model yapıları kullanılarak veri setinin daha başarılı bir şekilde sınıflandırılmasının mümkün olabileceği değerlendirilmektedir.

#### KAYNAKÇA

Rochmawati, N., Hidayati, H. B., Yamasari, Y., Yustanti, W., Rakhmawati, L., Tjahyaningtijas H. P. A. ve Anistiyasari Y. (2020). Covid symptom severity using decision tree. *2020 Third International Conference on Vocational Education and Electrical Engineering (ICVEE)*, 1-5.

Mishra, M., Parashar, V. ve Shimpi, R. (2020). Development and evaluation of an AI System for early detection of Covid-19 pneumonia using X-ray (Student Consortium). *2020 IEEE Sixth International Conference on Multimedia Big Data (BigMM)*, 292-296.

Tabik S., Gómez-Ríos, A., Martín-Rodríguez, J. L., Sevillano-García, I., Rey-Area, M., Charte, D., Guirado, E., Suárez, J. L., Luengo, J., Valero-González, M. A., García-Villanova, P., Olmedo-

Sánchez, E. & Herrera, F. (2020). COVIDGR dataset and COVID-SDNet methodology for predicting COVID-19 based on chest x-ray images. *in IEEE Journal of Biomedical and Health Informatics 2020*, 24(12), 3595-3605.

Wang, X., Deng, X., Fu, Q., Zhou, Q., Feng J., Ma, H., Liu, W. & Zheng, C. (2020) A weakly-supervised framework for covid-19 classification and lesion localization from chest ct. *in IEEE Transactions on Medical Imaging 2020*, 39(8), 2615-2625.

Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub Z. B., Islam, K. R., Khan, M. S., Iqbal, A., Emad, N. A., Reaz, M. B. I. & Islam M. T. (2020). Can AI help in screening viral and COVID-19 pneumonia?. *IEEE Access 2020*, 8, 32665-132676.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. & Wojna, Z. (2016) Rethinking the inception architecture for computer vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.

Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251-1258.



Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. *Thirty-First AAAI Conference on Artificial Intelligence*, 31(1).

Huang, G., Liu, Z., Maaten, L. v. d., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

Wang, S., ve Zhang Y. (2020). DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification. *ACM Transactions on Multimedia Computing Communications and Applications*, 16(2), 1-19.

Huang Z., Nasrullah, W. J., Song S., Mateen M. (2018). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, 11(1).

URL-1:

<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>

[Eriřim Tarihi: 15.11.2020]