



Birleştirilmiş Derin Öznitelikleri Kullanarak BT ve X-Ray Görüntülerinden COVID-19 Tespiti

COVID-19 Detection from CT and X-Ray Images Using Deep Feature Fusion

Asuman GÜNAY YILMAZ
Karadeniz Teknik Üniversitesi
Yazılım Mühendisliği
Trabzon, Türkiye
gunaya@ktu.edu.tr
ORCID: 0000-0003-3960-5085

Emine AYAZ
Karadeniz Teknik Üniversitesi
Yazılım Mühendisliği
Trabzon, Türkiye
eminekoch@gmail.com
ORCID: 0009-0008-3512-4640

Muammer TÜRKOĞLU
Samsun Üniversitesi
Yazılım Mühendisliği
Samsun, Türkiye
muammer.turkoglu@samsun.edu.tr
ORCID: 0000-0002-2377-4979

Öz

2019 yılında Çin'in Wuhan kentinde başlayan yeni tip Koronavirüs (COVID-19), solunum yolu enfeksiyonuna neden olan bulaşıcı bir virüsdür. Bu virüs dünyada kısa sürede etkili olmuş ve bir salgına dönüşmüştür. Bu tür bulaşıcı hastalıkların erken teşhisi ve gerekli tedavinin erken süreçte başlatılması çok önemlidir. X-ışını (X-Ray) ve Bilgisayarlı Tomografi (BT) tıbbi radyolojik görüntüleme yöntemleri ile derin öğrenme ve makine öğrenmesi tekniklerinin kullanılması bu hastalığın doğru ve hızlı tespitine yardımcı olmaktadır. Bu çalışmada; normal-COVID-19-pnömoni (zatürre) etiketli X-Ray ve normal-COVID-19 etiketli BT görüntülerini içeren 2 farklı veri kümesi kullanılmıştır. Bununla birlikte; InceptionResNetV2, VGG-16 ve DenseNet121 derin öğrenme mimarileri ve kNN ile SVM sınıflandırıcıları kullanılmıştır. Bu kapsamda 3 farklı çalışma yürütülmüştür. Öncelikle her bir ağın sınıflandırma başarımı incelenmiştir. Daha sonra ağların ürettiği öznitelik vektörleri ayrı ayrı sınıflandırıcılarla işleme sokulmuştur. Son olarak ağların ürettiği öznitelik vektörleri birleştirilmiş ve sınıflandırma işlemi gerçekleştirilmiştir. Sonuç olarak göğüs BT veri kümesindeki COVID-19 ve normal görüntüleri için en yüksek sonuç %98,9 doğruluk ile birleştirilmiş öznitelikler ve kNN sınıflandırıcısı ile elde edilmiştir.

Anahtar sözcükler: COVID-19, derin öğrenme, sınıflandırma, öznitelik birleştirme

Abstract

The new type of Coronavirus (COVID-19), which started in 2019 in Wuhan, China, is an infectious virus that causes respiratory tract infection. This virus became effective in the world in a short time and turned into an epidemic. Early diagnosis of such infectious diseases and initiation of the necessary treatment at an early stage are very important. The use of X-ray (X-Ray) and Computed Tomography (CT) medical radiological imaging methods and deep learning and machine learning techniques help in the accurate and rapid detection of this disease. In this study; Two different datasets were used, including X-Ray images labeled normal-COVID-19-pneumonia (pneumonia) and CT images labeled normal-COVID-19. Inception ResNetV2, VGG-16 and DenseNet121 deep learning architectures and kNN and SVM classifiers are used. In this context, 3 different experiments were carried out. First of all, the classification performance of each network was examined. Then, the feature vectors produced by the networks were separately processed with classifiers. Finally, the feature vectors produced by the networks were combined and the classification process was carried out. As a result, the highest result for COVID-19 and normal images in the chest CT dataset was obtained with the combined features and kNN classifier with 98.9% accuracy.

Keywords: COVID-19, deep learning, classification, feature fusion

1. Giriş

Koronavirüs (COVID-19); hem üst solunum yollarında hem de akciğerlerde enfeksiyona neden olan yeni bir virüsdür. Çin'in

Wuhan kentinde ortaya çıkan COVID-19, artan hareketlilik ve hızlı bulaşıcılık faktörlerine bağlı olarak kısa sürede küresel bir salgın haline gelmiş, tüm dünyada milyonlarca kişinin ölümüne neden olmuştur. COVID-19 tanısı, ilk aşamada PCR veya kan tahlilleri ile doğrulanmaktadır. Son araştırmalar göstermiştir ki, özellikle hastalığın erken döneminde veya viral yük düşük olduğunda, pozitif çıkması gereken PCR testleri negatif çıkabilmektedir. Ancak hastalık tedavisi ve kontrolü için erken teşhis büyük önem taşımaktadır. Bu sebeple X-Ray ve Bilgisayarlı Tomografi (BT) görüntüleme yöntemleri tercih edilmektedir. Çeşitli viral ve bakteriyel pnömoni (zatürre) görüntüleri COVID-19 ile benzerdir ve benzer özellikler içermektedir [1]. Radyologların viral ve bakteriyel pnömoni gibi benzer akciğer hastalıklarını COVID-19'dan ayırt etmesi zordur. Bu benzerlik yanlış tanıları yol açabilmektedir. Bu görüntülere derin öğrenme mimarileri ve makine öğrenmesi sınıflandırma tekniklerinin uygulanması ile hastalığın erken tespitinde çok yüksek oranda tahmin başarısı elde edilebilmektedir.

Bu çalışmada birleştirilmiş derin öznitelikler kullanılarak BT ve X-ray görüntülerinden COVID-19 tespiti gerçekleştirilmiştir. Bu amaçla deneylerde 3 sınıflı (normal, COVID-19, viral pnömoni) akciğer X-ray görüntülerini içeren "COVID-19 Radiography Database" ve 2 sınıflı (normal, COVID-19) BT görüntülerini içeren "SARS-COV-2 Ct-Scan Dataset" veri kümeleri kullanılmıştır. İlk aşamada Inception-ResNetV2, VGG-16 ve DenseNet121 CNN mimarilerinin her iki veri kümesindeki COVID-19 tespiti başarımları incelenmiştir. Daha sonra bu ağlarla üretilen derin özniteliklerin kNN ve SVM sınıflandırıcıları ile başarımları hesaplanmıştır. Son olarak bu derin öznitelikler birleştirilerek sınıflandırma gerçekleştirilmiştir. Bir sonraki bölümde yayınlarda bu konuda yapılan çalışmalar özetlenmektedir.

Yazının devamı şu şekilde planlanmıştır: COVID-19 tespiti ile ilgili yapılan çalışmalar 2. bölümde özetlenmiştir. Çalışmada kullanılan sistem 3. bölümde açıklanmıştır. 4. bölümde elde edilen Bulgular verilmiş, 5. bölümde sonuçlar tartışılmıştır.

2. Yayınlar Özeti

Yayınlarda COVID-19 vakalarının tespitinde çeşitli çalışmalar yapılmıştır. Erdaş ve Ölçer [2]; göğüs röntgeni görüntüleri kullanarak COVID-19 hastalarının teşhisinde CNN mimarilerinden AlexNet kullanmıştır. Çalışmada; halka açık platformlar olan Kaggle ve Github'dan derlenen 3 sınıflı (normal, COVID-19, bakteriyel pnömoni) 150 göğüs X-Ray görüntüsü kullanılmıştır. Sonuçta; pnömoni kaynağının bakteri veya COVID-19 virüsü olup olmadığını ayırt etmede %81,0 doğruluk elde edilmiştir.

Özbay ve arkadaşı [3]; COVID-19 vakalarının tespitinde çeşitli sınıflandırma algoritmalarının ve CNN başarımlarını yöntem karşılaştırmıştır. Çalışmada 2 sınıflı (COVID 19, normal) 2482 göğüs BT görüntüsü kullanılmıştır. Sonuçta CNN modelinin %98,1 doğruluk ile diğer gelişmiş sınıflandırma algoritmalarından daha iyi başarımlar gösterdiği belirlenmiştir. Kutlu ve Camgözlü [4]; COVID-19'un tespiti için CNN derin öğrenme modelleriyle birlikte kNN, SVM gibi sınıflandırıcıları kullanmıştır. Çalışmada "COVID-19 radiography database" veri kümesinde 3 sınıflı (COVID-19, normal ve viral pnömoni)

toplam 3886 X-Ray görüntüsünden yararlanılmıştır. Sonuçta, %99,53 doğruluk oranı ile CNN+SVM en iyi sonucu vermiştir.

Güraksın ve arkadaşları [5]; göğüs X-Ray görüntülerinden COVID-19 teşhisi için AlexNet ve GoogleNet ağlarını tercih etmişlerdir. Eğitim ve test için "Chest X-Ray Images (Pneumonia)" ve "COVID-19 Image Data Collection," açık kaynak veri kümelerinden alınan görüntüler bir araya getirilerek 4 sınıflı (normal, COVID 19, bakteriyel pnömoni ve viral pnömoni) 1670 adet göğüs X-Ray görüntüsünden oluşan bir veri kümesi kullanılmıştır. Çalışmada %98,77 doğruluk ile normal-COVID 19- bakteriyel pnömoni sınıflandırmada en yüksek başarı elde edilmiştir. Hemdan ve arkadaşları [6]; VGG19, DenseNet121, ResNetV2, InceptionV3, InceptionResNetV2, Xception ve MobileNetV2 gibi yedi CNN ağı ile X-Ray görüntülerinden COVID-19 tespiti gerçekleştirmiştir. Çalışmada, 2 sınıflı (COVID 19, normal) 50 adet göğüs X-Ray görüntüsü kullanılmıştır. Sonuçta VGG19 ve DenseNet modelleri, normal ve COVID-19 için sırasıyla %89 ve %91 F1 Değeri ile sınıflandırma başarımı göstermiştir.

Jia ve arkadaşları [7]; BT görüntülerinden COVID-19 teşhisinde ResNet ağını, X-Ray görüntülerinden COVID-19 teşhisinde ise MobileNet ağını kullanmıştır. Çalışmada 5 sınıflı (normal, COVID 19, viral pnömoni, bakteriyel pnömoni, tüberküloz) toplam 7592 X-Ray ve BT görünümü kullanılmıştır. Önerilen yöntemlerle beş sınıflı X-Ray görüntü veri kümesinde %99,6, BT görüntü veri kümesinde %99,3 test doğruluğuna ulaşılmıştır. Şahinbaş ve Çatak [8]; X-Ray görüntüleriyle COVID-19 tespitinde VGG-16, VGG19, ResNet, DenseNet ve InceptionV3 ağlarını kullanmıştır. Çalışmada değişik hastanelerden ve halka açık Github kaynağından elde edilen 2 sınıflı (normal, COVID 19) 140 X-Ray göğüs röntgen görüntüleri kullanılmıştır. En iyi başarımlar, %80'lik sınıflandırma doğruluğu ile VGG-16 modelinde elde edilmiştir.

Sethy ve Behera [9]; COVID-19 tespiti için AlexNet, VGG-16, VGG19, GoogleNet, ResNet18, ResNet50, ResNet101, InceptionV3, InceptionResNetV2, DenseNet201 ve XceptionNet gibi derin öğrenme mimarilerini kullanmıştır. Bu çalışmalar için GitHub, Kaggle ve Open-i tabanlı ve 2 sınıflı (COVID 19 ve Normal) toplam 316 X-Ray görüntüsü kullanılmıştır. Bu derin öğrenme modellerinden elde edilen derin özellikler SVM ile sınıflandırılmış, ResNet50 + SVM sınıflandırma yöntemi ile %95,38 başarımlar sağlanmıştır. Asnaoui ve Chawki [10]; COVID-19 pnömonisinin tespiti ve sınıflandırılması amacıyla VGG-16, VGG19, DenseNet201, Inception_ResNet_V2, Inception_V3, ResNet50 ve MobileNet derin öğrenme modellerinin karşılaştırmasını yapmışlardır. Bu çalışma için; 'chest X-ray & CT dataset' ve 'COVID Chest X-ray Dataset' 'den oluşan iki ayrı veri kümesindeki X-Ray(röntgen) ve BT(bilgisayarlı tomografi) görüntüleri birleştirilerek 3 sınıflı (COVID, normal ve viral pnömoni) toplamda 6087 görüntü kullanılmıştır. Çalışma sonucunda; Inception ResNetV2 ağı %92,18 doğruluk ile en başarılı model olarak belirlenmiştir.


Adrakani ve arkadaşları [11]; COVID 19 ile sağlıklı hastaları ayırt etmek için AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet-18, ResNet-50, ResNet-101 ve Xception modellerini kullanmıştır. Elde edilen başarımların değerlendirilmesinde ResNet-101 %99,51

doğruluk oranı ile en başarılı model olarak belirlenmiştir. Kart ve Başçıftçı [12]; makine öğrenmesi algoritması olan kNN, YSA, RO ve SVM algoritmaları ile COVID-19 hastalığına ait görüntüleri sınıflandırmıştır. Bu çalışmalar için açık kaynaklı 2 sınıflı (normal, COVID-19) "Posteroanterior Chest X-ray (PACXR)" veri kümesindeki 1500 X-Ray görüntüsü kullanılmıştır. Sonuçta en yüksek test başarı oranı %99,8'lük bir oranla SVM algoritmasından elde edilmiştir.


3. Materyal ve Yöntem

3.1 Veri Kümesi

Bu çalışmada; 3 sınıflı X-Ray görüntüleri içeren "SARS-COV-2 Ct-Scan Dataset" [13] ile 2 sınıflı BT görüntüleri içeren "COVID-19 Radiography Database" [14] veri kümeleri kullanılmıştır. Veri kümelerindeki sınıflara ait örnek görüntüler sırasıyla Şekil 1 ve 2'de görülmektedir.



Şekil-1: Akciğer X-Ray görüntüleri



Şekil-2: Akciğer bilgisayarlı tomografi görüntüleri

SARS-COV-2 Ct-Scan Dataset, 1252 COVID, 1230 normal olmak üzere toplam 2.482 BT görüntüsünden oluşan halka açık bir COVID-19 tarama veri setidir. Bu veriler Brezilya, Sao Paulo'daki hastanelerdeki gerçek hastalardan toplanmıştır. Bu veri kümesinin amacı, bir kişinin BT taramalarının analizi yoluyla COVID-19 ile enfekte olup olmadığını belirleyebilen yapay zeka yöntemlerinin araştırılmasını ve geliştirilmesini teşvik etmektir.

COVID-19 Radiography Database veri kümesinde 10.192 normal, 6012 COVID ve 1345 Viral Pnömoniden oluşan 17.549 X-Ray görüntüsü mevcuttur. Çeşitli ülkelerden araştırmacıların birlikte oluşturduğu geniş bir veri kümesidir. Çalışmanın uygulama ortamı Google Colab'da veri kümesinin büyük olması sorunlara neden olduğu için çalışmada bu veri kümesindeki her sınıftan rastgele 1000 adet olmak üzere toplam 3.000 X-Ray görüntüsü alınmıştır. Çalışmada kullanılan, X-Ray ve BT görüntü sayıları Çizelge 1'de verilmiştir. Deneylerde toplam 5.482 adet görüntü kullanılmıştır.

3.2 Derin Öğrenme

Derin öğrenme; çok katmanlı yapay sinir ağları ile insan beynini taklit eden çalışma prensibine sahiptir. Derin

Çizelge-1: Veri setleri görüntü sayıları


	X-RAY GÖRÜNTÜLER	BT GÖRÜNTÜLER
Normal	1.000	1.230
COVID	1.000	1.252
Viral Pnömoni	1.000	-
Toplam	3.000	2.482

öğrenme; makinelerin konuşulanları algılama, tercüme etme, nesnelere tanımlama ve karar verme yeteneği kazandırma gibi insan denetimi olmadan öğrenmesini sağlar. Sağlık hizmetleri, finansal hizmetler, havacılık ve savunma, sürücüsüz araçlar, sanal yardımcıları gibi bilgisayarla görme, ses tanıma ve doğal dil işleme alanlarında kullanılmaktadır.

Yapay sinir ağlarındaki katman sayılarının artırılmasıyla kurulan Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağı (SRN), Uzun Kısa Vadeli Memory (RNN), Kısıtlanmış Boltzmann Makineleri (RBM), Derin İnanç Ağları (DBN) ve Derin Oto-kodlayıcılar (DAE) gibi çok farklı türde derin öğrenme mimarileri bulunmaktadır. CNN, bir girdi verisini alarak, bu verideki farklı birçok özelliği birbirinden ayırabilen bir derin öğrenme algoritmasıdır. AlexNet, ResNet, GoogleNet/InceptionNet, MobileNetV1, VGG-16,VGG19, Inception v2, Inception v3,V4 , Inception-ResNet, DenseNet, Xception, Channel Boosted CNN, Residual Attention CNN Attention Based CNNs, Feautre-Map based CNNs ve Squeeze and Excitation Networks gibi birçok farklı mimarileri vardır. Mevcut çalışmada, üç farklı yapıya ve yüksek başarıma sahip VGG-16, InceptionResNetV2 ve DenseNet121 derin mimariler kullanılmıştır.

3.2.1 VGG-16 Mimarisi


VGG-16 modeli 13 konvolüsyon, 3 tam bağlaşımlı katman olmak üzere 16 katmandan oluşur (Şekil 3). Modele 224x224x3 boyutlarında veri girişi yapılır. Bu ağ oldukça büyük bir ağıdır, ReLU aktivasyon fonksiyonu kullanılmıştır ve yaklaşık 138 milyon parametreye sahiptir [15].



Şekil-3: VGG-16 yapısı [15]

3.2.2 Inception ResNet V2 Mimarisi


Inception-ResNet modeli, Inception mimarisinde yer alan Inception modülleri ile ResNet mimarisinin başarımından esinlenilerek oluşturulan melez bir modeldir [16]. Inception V3 modelinden daha derin bir mimariye sahiptir (Şekil 4).



Şekil-4: Inception ResNet V2 mimari yapısı [16]

3.2.3 DenseNet121 Mimarisi

Yapay sinir ağları eğitilirken, evrişim ve alt örnekleme süreçleri nedeniyle öznetelik haritaları azalır. Aynı zamanda katmanlar arası geçişlerde görüntü özelliğinde kayıplar olmaktadır. Görüntü bilgilerini daha etkin kullanmak için Huang ve arkadaşları DenseNet sistemini geliştirmiştir. Sistemde her katman diğer katmanlara ileri doğru beslenir. Bu sayede herhangi bir katman, kendisinden önceki tüm katmanların özellik bilgilerine erişebilir (Şekil 5). [17]



Şekil-5: DenseNet Mimarisi [17]

3.3 Sınıflandırma

3.3.1. k-En Yakın Komşu Algoritması


kNN algoritması, tüm makine öğrenme algoritmaları arasında en basit ve kullanışlı denetimli sınıflandırma algoritmasıdır. Yüz tanıma, el yazısı ve resim tanıma, videodaki nesnelerin algılanmasında sıkça kullanılmakta olup görüntüleme teknikleri ve tahlillerden hastalıkların teşhisine olanak sağlamaktadır. Bu algoritmada, sınıf özelliği daha önceden belirlenmiş verilerden faydalanılır. kNN algoritması ile sınıflandırma yapabilmek için, öznetelik vektörlerinin önceden oluşturulmuş olması gereklidir.

kNN sınıflandırma yöntemi, uygulanmasının basit, gürültülü verilere karşı etkili olması ve büyük eğitim setlerinde uygulanabilmesi avantajlarına sahiptir. Her yeni örnek eklendiğinde tüm uzaklık hesaplamalarının yinelenmesi açısından hesaplama maliyeti oldukça yüksektir. k parametresine ihtiyaç duyması, yüksek miktarda bellek alanlarına ihtiyaç duyması, hesaplamada birçok farklı fonksiyon kullanılabilmesi ve hangisinin kullanılması gerektiği karmaşası içermesi dezavantajlarına sahiptir.

3.3.2. Destek Vektör Makineleri

SVM farklı sınıflara ait verileri karar sınır çizgisi ile birbirinden en uygun şekilde ayırmak için kullanılan denetimli sınıflandırma algoritmasıdır. Günümüzde yüz algılama, protein çaprazlama, el yazısı tanıma, görüntü ve sınıflandırma, biyoinformatik, çevre bilimleri ve tahmine dayalı kontrol gibi birçok alanda kullanılmaktadır.

Ayırım için gerekli karar sınırı, sınıflar arasındaki en iyi boşluğu bularak düzlem üzerine yerleştirilmiş noktaları ayırmak için bir doğru (hiper düzlem sınır çizgisi) çeker (Şekil 6). En iyi yerden geçebilecek çizginin belirlenmesini kolaylaştıran ve karar sınırına en yakın noktalara veya değerlere "destek" denir. Bu değer veya noktalar değiştiğinde karar sınırları da değişir. Destek vektör ismini buradan almaktadır.



Şekil-6: SVM küme ayrışımı

4. Deneyler ve Bulgular

Bu çalışma, Python programlama diline dayalı bir bulut hizmeti olan Google Colab kullanılarak gerçekleştirilmiştir. Çalışmada OpenCV, pandas, keras, tensorflow, numpy, matplotlib, random, Python kütüphaneleri kullanılmıştır. Deneysel çalışmanın yapıldığı bilgisayar, Intel(R) Core(TM) i7-2630QM CPU @ 2.00GHz 2.00 GHz işlemcili, NVIDIA GeForce GT 550 ekran kartlı ve 4GB birincil belleğe sahiptir. Deneysel çalışmada, veriler %80 eğitim, %20 test olarak ayrılmıştır. 2.482 BT verilerinin 1.986'sı eğitim, 496'sı test için kullanılmıştır. 3.000 X-Ray verilerinin 2.400'ü eğitim, 600'ü test için kullanılmıştır.

Denetimli öğrenme tekniklerinin kullanıldığı sınıflandırma problemlerinde, model başarımını değerlendirebilmek için en çok kullanılan yöntemlerden biri, hedef niteliğin sınıflarına ait gerçek ve tahmin değerlerinin bir arada gösterdikleri karmaşıklık tablosundan hareketle hesaplanan değerlerdir. Şekil 7'de bu tablo gösterilmiştir.

DURUM	GERÇEK			TOPLAM
	POZİTİF	POZİTİF	NEGATİF	
TAHMİNİ	POZİTİF	Doğru Pozitif (dp)	Yanlış Pozitif (yp)	tPoz
	NEGATİF	Yanlış Negatif (yn)	Doğru Negatif (dn)	tNeg
	TOPLAM	poz	neg	m

Şekil-7: Karmaşıklık tablosu

Yapılan çalışmada modellerin başarımlarını değerlendirmek için karmaşıklık tablosundan hareketle hesaplanan başarı ölçütleri doğruluk, tutturma, bulma ve F1 ölçüsüdür. Bu ölçütler aşağıdaki denklemlerle hesaplanmaktadır.

$$\text{Doğruluk (Accuracy)} = \frac{N_{TN} + N_{TP}}{N_{TN} + N_{FN} + N_{TP} + N_{FP}} \quad (1)$$

$$\text{Tutturma (Precision)} = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (2)$$

$$\text{Bulma (Recall)} = \frac{N_{TP}}{N_{TN} + N_{FP}} \quad (3)$$

$$\text{F1 Ölçüsü} = \frac{2 * N_{TP}}{2 * N_{TP} + N_{FP} + N_{FN}} \quad (4)$$

Çizelge-2: VGG16, InceptionResNetV2 ve DenseNet121 ağlarının COVID-19 tespiti başarımları

Veri kümesi	BT (COVID 19, Normal)				X-RAY (COVID 19, Normal, Pnömoni)			
	Doğruluk	F1	Bulma	Tutturma	Doğruluk	F1	Bulma	Tutturma
VGG-16	%87,5	%87,6	%79	%98,2	%79,1	%72	%84,4	%80,6
InceptionResNetV2	%94,5	%94,2	%89,5	%99,5	%92,1	%92,2	%92,2	%92,3
DenseNet121	%98,1	%97,9	%98,1	%97,7	%97	%97	%97	%96,9

4.1. VGG16, InceptionResNetV2 ve DenseNet121 ağları ile COVID-19 Teşhisi Sonuçları

Her iki veri kümesi 1000 sınıf ve yaklaşık 15 milyon görüntüye sahip ImageNet te önceden eğitilmiş derin öğrenme mimarileri olan VGG-16, InceptionResNetV2 ve DenseNet121'de ayrı ayrı eğitilip başarımlar hesaplanmış ve kıyaslanmıştır. 3 derin öğrenme modeli için BT verilerinin eğitimi 9 dk 50 s, X-Ray verilerin eğitimi 8 dk 29 s sürede tamamlanmıştır. Eğitimler Epok=25, batch=32 değerleri ile gerçekleştirilmiştir. Elde edilen sonuçlar Çizelge 2'de verilmiştir. Çizelgeden görüldüğü gibi BT verileriyle VGG-16 eğitimi çalışmasında; eğitim aşamasında 16.813.206, sınamada 512 olmak üzere toplamda 16.813.718 parametre kullanılmıştır. Yapılan başarımlar ölçümleri sonucu %87,5 doğruluk, %87,6 F1, %79 özgülük ve %98,2 tutturma değerleri elde edilmiştir. X-Ray verileriyle VGG-16 eğitimi çalışmasında, eğitim aşamasında 15,895,959, sınamada 512 olmak üzere toplamda 15.896.471 parametre kullanılmıştır. Yapılan başarımlar ölçümleri sonucu %79,1 doğruluk, 76,1 F1, %62,1 Bulma ve %98,3 tutturma değerleri elde edilmiştir.

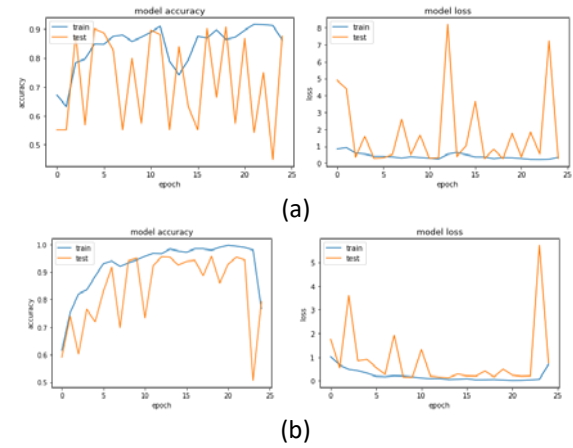
BT verileriyle InceptionResNetV2 eğitimi çalışmasında, eğitim aşamasında 54.673.846, sınamada 64.128 olmak üzere toplamda 54.737.974 parametre kullanılmıştır. Yapılan başarımlar ölçümleri sonucu %94,5 doğruluk, %94,2 F1, %89,5 bulma ve %99,5 tutturma değerleri elde edilmiştir. X-Ray verileriyle InceptionResNetV2 eğitimi çalışmasında, eğitim aşamasında 54.674.103, sınamada 64.128 olmak üzere toplamda 54.738.231 parametre kullanılmıştır. Yapılan başarımlar ölçümleri sonucu %92,1 doğruluk, %92,2 F1, %92,2 bulma ve %92,3 tutturma değerleri elde edilmiştir.

BT verileriyle DenseNet121 eğitimi çalışmasında, eğitim aşamasında 7.219.414, sınamada 86.208 olmak üzere toplamda 57.305.622 parametre kullanılmıştır. Yapılan başarımlar ölçümleri sonucu %98,1 doğruluk, %97,9 F1, %98,1 bulma ve %97,7 tutturma değerleri elde edilmiştir. X-Ray verileriyle DenseNet121 eğitimi çalışmasında, eğitim aşamasında 7.219.671, testte 86.208 olmak üzere toplamda 7.305.879 parametre kullanılmıştır. Yapılan başarımlar ölçümleri sonucu %97 doğruluk, %97 F1, %97 bulma ve %96,9 tutturma değerleri elde edilmiştir.


VGG-16, InceptionResNetV2 ve DenseNet121 ağlarının BT ve X-Ray görüntüleri üzerindeki başarımlar grafikleri sırasıyla Şekil 8, 9 ve 10 da verilmiştir.

BT verilerle yapılan deneylerde DenseNet121 mimarisi doğruluk, F1 ve bulma ölçütlerinde, InceptionResNetV2


mimarisi tutturma ölçütünde en yüksek başarımlar değerlerini sağlamıştır. X-Ray görüntülerde ise DenseNet121 mimarisi tüm ölçütlerde en yüksek başarımlara sahiptir.



Şekil-8: VGG-16 Modelinin (a) BT ve (b) X-Ray verileriyle başarımlar grafiği



Şekil-9: InceptionResNetV2 Modelinin (a) BT ve (b) X-Ray verileriyle başarımlar grafiği



Şekil -10: DenseNet121 (a) BT ve (b) X-Ray verileriyle başarımlar grafiği

4.2. Derin Özniteliklerin kNN ve SVM ile Sınıflandırılması ile COVID-19 Tanısı Sonuçları

Çalışmanın ikinci aşamasında, VGG16, InceptionResnetV2 ve Densenet121 ağlarının sırasıyla "fc6", "predictions", ve "fc1000" olmak üzere tam bağlı katmanları kullanılarak derin özellikler çıkarılmıştır. Daha sonra, bu derin özellikler, kNN ve SVM sınıflandırıcı yöntemlerinin girişine verilmiştir. BT verilerinin eğitimi 16 dk 22 s, X-Ray verilerin eğitimi 11 dk 57 s sürede tamamlanmıştır. Elde edilen sonuçlar Çizelge 3'te verilmiştir. BT verileriyle yapılan çalışmada başarımlar ölçümlerinde; doğruluk sonuçlarında %97,9, F1 sonuçlarında %97,7 ve bulma sonuçlarında %99 ile DenseNet121'den elde edilen özniteliklerin kNN ile sınıflandırılması en yüksek başarımlar elde edilmiştir. Tutturma sonucunda ise %96,8 ile

VGG-16'den elde edilen özniteliklerin kNN ile sınıflandırılması en yüksek başarımlara sahiptir. X-Ray verileriyle yapılan çalışmada ise, doğruluk sonuçlarında %90,5, F1 sonuçlarında %90,4, bulma sonuçlarında %90,7 ve tutturma sonucunda %90 ile InceptionResNetV2 ağından elde edilen özniteliklerin SVM ile sınıflandırılması en yüksek başarımları vermiştir. Her iki veri kümesinin sonuçlarından, BT verileriyle elde edilen sonuçların X-Ray sonuçlarından yüksek olduğu belirlenmiştir.

4.3. Birleştirilmiş Derin Özniteliklerin kNN ve SVM ile Sınıflandırılması ile COVID-19 Teşhisi Sonuçları

Çalışmanın bu aşamasında her iki veri kümesinde ayrı ayrı VGG16, InceptionResnetV2 ve DenseNet121 ağlarında üretilen öznitelikler birleştirilmiş ve birleşik öznitelik vektörleri kNN ve SVM ile sınıflandırılmıştır. VGG-16'dan 4.096, InceptionResNetV2'den 1.000 ve DenseNet121'den 1.000 olmak üzere birleştirilmiş öznitelik vektörünün boyutu 6.096'dır. Deneysel çalışmanın bu aşamasında sınıma verilerinden sınıflandırma başarımlarının değerlendirilmesinde Karmaşıklık Matrisi'nden yararlanılmıştır. Önerilen VGG-16, InceptionResNetV2 ve DenseNet121 ağlarından elde edilen özniteliklerin kNN ve SVM ile sınıflandırılması sonucu oluşan karmaşıklık matrisleri Şekil 11 ve 12'de verilmiştir. Çizelge 4'te ise birleştirilmiş özniteliklerle elde edilen sonuçlar görülmektedir. Elde edilen tüm sonuçlara göre (Çizelge 5) BT görüntüleri için en yüksek değerler %98,9 doğruluk, %98,8 F1, %99 bulma %98,6 tutturma ile birleştirilmiş özniteliklerin kNN ile sınıflandırılmasında elde edilmiştir. X-Ray görüntülerinde ise DenseNet121 ağı bütün ölçütlerde tek başına daha iyi bir başarımlar göstermektedir.

Çizelge -3 : Derin Özniteliklerin kNN ve SVM ile Sınıflandırılması ile COVID-19 Teşhisi Sonuçları

	BT (COVID 19, Normal)				X-RAY (COVID 19, Normal, Pnömoni)			
	Doğruluk	F1	Bulma	Tutturma	Doğruluk	F1	Bulma	Tutturma
VGG-16+kNN	%97,7	%97,5	%98,1	%96,8	%89,8	%89,8	%90,1	%89,8
VGG-16+SVM	%81,2	%80,7	%75,0	%87,4	%82,8	%82,7	%83,1	%82,8
InceptionResNetV2 +kNN	%95,9	%95,4	%96,3	%94,6	%83,5	%83,5	%83,8	%83,5
Inception ResNet V2 +SVM	%91,3	%90,7	%86,8	%95,0	%90,5	%90,4	%90,7	%90,0
DenseNet121+kNN	%97,9	%97,7	%99,0	%96,4	%87,8	%87,7	%87,0	%87,8
DenseNet121+SVM	%92,3	%91,7	%88,7	%95,0	%89,0	%88,9	%89,1	%89,0

Gerçek Sınıf	KNN	
	COVID19	Normal
	COVID19	272
Normal	3	220
		Tahmini Sınıf

Gerçek Sınıf	SVM	
	COVID19	Normal
	COVID19	240
Normal	13	210
		Tahmini Sınıf

Şekil-11: BT veri kümesi için karmaşıklık matrisleri

Gerçek Sınıf	KNN			Gerçek Sınıf	SVM		
	COVID19	Normal	Pnömoni		COVID 19	Normal	Pnömoni
COVID19	169	6	10	COVID19	151	21	13
Normal	2	194	10	Normal	1	193	2
Pnömoni	35	3	181	Pnömoni	38	0	181
	Tahmini Sınıf				Tahmini Sınıf		

Şekil-12: X-Ray veri kümesinde karmaşıklık matrisleri

Çizelge-4: Öznitelik birleştirilmesi sonucu sınıflandırma başarımları

	BT (COVID 19, Normal)				X-RAY (COVID 19, Normal, Pnömoni)			
	Doğruluk	F1	Bulma	Tutturma	Doğruluk	F1	Bulma	Tutturma
Birleştirilmiş Derin Öznitelikler +kNN	%98,9	%98,8	%99,0	%98,6	%90,6	%90,6	%91,1	%90,6
Birleştirilmiş Derin Öznitelikler +SVM	%90,5	%89,9	%86,0	%94,1	%87,5	%87,4	%87,6	%87,5

Çizelge-5: Çalışmada elde edilen sonuçlar

Veri kümesi	BT (COVID 19, Normal)				X-RAY (COVID 19, Normal, Pnömoni)			
	Doğruluk	F1	Bulma	Tutturma	Doğruluk	F1	Bulma	Tutturma
Ağ Mimarisi								
DenseNet121	%98,1	%97,9	%98,1	%97,7	<u>%97</u>	<u>%97</u>	<u>%97</u>	<u>%96,9</u>
DenseNet121+kNN	%97,9	%97,7	%99,0	%96,4	%87,8	%87,7	%87,0	%87,8
Birleştirilmiş Derin Öznitelikler +kNN	<u>%98,9</u>	<u>%98,8</u>	<u>%99,0</u>	<u>%98,6</u>	%90,6	%90,6	%91,1	%90,6

5. Sonuçlar

Bu çalışmada, COVID-19 vakalarını sınıflandırmak için BT ve X-Ray olmak üzere 2 ayrı veri kümesi ile ayrı ayrı çalışılmış, BT'de 2 ve X-Ray'de 3 sınıflı etiketleme yapılmış, 3 derin öğrenme mimarisi ve 2 makine öğrenmesi sınıflandırıcısı kullanılarak başarımlar karşılaştırılmıştır. BT görüntülerden elde edilen başarımların X-Ray görüntülerde daha yüksek olduğu gözlenmiştir. Bununla birlikte, derin öğrenme mimarileri arasından Densenet121 mimarisi ve makine öğrenmesi sınıflandırıcısından kNN algoritması daha başarılı olmuştur. Son olarak, genel olarak farklı yapıya sahip derin mimarilerden elde edilen derin özelliklerin birleştirilmesi, sınıflandırma başarımlarını artırdığını açıkça göstermiştir.

Kaynakça

- [1] Bozkurt, F. "Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti", Avrupa Bilim ve Teknoloji Dergisi, no. 24, Apri 2021, pp. 149-156, <https://doi:10.31590/ejosat.898385>
- [2] Erdaş, Ç. B., Detection and differentiation of COVID-19 using deep learning approach fed by x-rays, International Journal of Applied Mathematics, 8(3), 2020, pp. 097-101. <https://dergipark.org.tr/en/download/article-file/1308359>
- [3] Özbay, E., Özbay, F. A., COVID-19 Detection from CT images with Deep Learning and Classification Approaches, DÜMF Mühendislik Dergisi 12(2), 2021, pp. 211-219. <https://dergipark.org.tr/tr/download/article-file/1352635>
- [4] Kutlu, Y., Camgözlü, Y., Detection of coronavirus disease (COVID-19) from X-ray images using deep convolutional neural Networks, Natural and Engineering Sciences, 6(1), 2021, pp. 60-74. <https://doi.org/10.28978/nesciences.868087>
- [5] Güraksin, G. E., COVID-19 Diagnosis Using Deep Learning, Düzce University Journal of Science & Technology, 9, 2021, pp. 8-23. <https://doi.org/10.29130/dubited.866124>
- [6] Hemdan, E. E., A. Shouman, M., Karar, M.E., COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images, Cornell University Electrical Engineering and Systems Science -Image and Video Processing, <https://doi.org/10.48550/arXiv.2003.11055>
- [7] Jia, G., Lam, H. K., Classification of COVID-19 chest X-Ray and CT images using a type of dynamic CNN modification method, Computers in Biology and Medicine, 134, 2921, pp. 104425. <https://doi.org/10.1016/j.compbiomed.2021.104425>
- [8] Şahinbaş, K., Çatak, F. Ö., Transfer learning-based convolutional neural network for COVID-19 detection with X-ray images, Data Science for COVID-19, 2021, pp. 451-466. <https://doi.org/10.1016/B978-0-12-824536-1.00003-4>

- [9] Sethy, P.K., Behera, S.K., Detection of Coronavirus Disease (COVID-19) Based on Deep Features, Preprints, 2020, 2020030300, <https://doi.org/10.20944/preprints202003.0300.v1>
- [10] Asnaoui, K., Chawki, Y., Using X-ray images and deep learning for automated detection of coronavirus disease, Journal of Biomolecular Structure and Dynamics, 39(10), 2021, pp. 3615-3626. <https://doi.org/10.1080/07391102.2020.1767212>
- [11] Ardakani, A.A., Kanafi, A. R., Acharya,U. R. , Khadem,N. ,Mohammadi, A., Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural Networks, Computers in Biology and Medicine, 121, 20220, pp. 103795. <https://doi.org/10.1016/j.combiomed.2020.103795>
- [12] Kart, Ö., Başçiftçi, F., Makine Öğrenmesi Algoritmalarıyla Akciğer Tomografi Görüntülerinden COVID-19 Tespiti, Avrupa Bilim ve Teknoloji Dergisi Özel Sayı, 28, 2021, pp. 630-637. <https://doi.org/10.31590/ejosat.1009611>
- [13] <https://www.kaggle.com/datasets/tawsifurrahman/COVID19-radiography-database>
- [14] <https://www.kaggle.com/datasets/plameneduardo/sarscov2-ctscan-dataset>
- [15] K. Simonyan, A. Zisserman, Very Deep Convolutional Networks for Large-Scale Image Recognition, ArXiv Prepr., 2014, pp. 1409e1556
- [16] https://www.researchgate.net/figure/Schematic-diagram-of-InceptionResNetV2-model-compressed-view_fig9_326421398
- [17] Huang, G. Liu, Z. Maaten L. Van Der, Weinberger, K.Q. Densely connected convolutional networks,in: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017, pp. 4700e4708