

Received: 13.10.2022

Accepted: 04.12.2022

Birbirine Benzeyen Üç Farklı Hastalığın Tespitinde Derin Öğrenme Modellerinin Performansı

Yunus Emre KARACA^{1*}, Serpil ASLAN²

^{1,2}Malatya Turgut Özal Üniversitesi, Lisansüstü Eğitim Enstitüsü, Enformatik Bölümü, 44210, Malatya, Turkey

Özet

Bir hastalığın doğru teşhis edilmesi ve doğru tedavi yöntemlerinin kullanılması hastalıklı bireye kısa sürede şifayı sağlamada önemli iki kriterdir. Kısacası sorun bilinirse çözümü de kolaylaşacaktır. Gelişen tıp teknolojisini destekleyici mahiyette olan çalışmada, bir birine benzeyen üç hastalık tipi olan viral, bakteriyel ve COVID-19 pnömosine sahip hasta radyolojik görüntülerinin konvansiyonel sinir ağ(CNN) mimarileriyle hastalıkların tespit performansları karşılaştırıldı. Bu karşılaştırmada başarı oranının artması, doğru hastalık tanısı konulmasını da arttırmış olacaktır. Bu şekilde başarılı yöntemlerin ortaya çıkması hem teşhisi koyan hekimin işini kolaylaştırmasının yanı sıra tüm insanlık için en değerli kavram olan vakitten de tasarruf edilmiş olacaktır. 1281 COVID-19, 3270 Normal, 1656 viral-pnömoni ve 3001 bakteriyel-pnömoni toplamda 9208 göğüs röntgen görüntüsünü kullanılıp, en başarılı performansı %88,05 ile Resnet50 mimarisi elde etmiştir.

Anahtar Kelimeler: CNN, Derin Öğrenme, COVID-19, Pnömoni, Hastalık Tespiti, Viral, Bakteriyel

Performance of Deep Learning Models in Detection of Three Similar Diseases

Yunus Emre KARACA^{1*}, Serpil ASLAN²

Abstract

The correct diagnosis of a disease and the use of the right treatment methods are two important criteria in providing the diseased individual with healing in a short time. In short, if the problem is known, the solution will be easier. In the study, which supports the developing medical technology, the detection performances of the diseases with the conventional neural network (CNN) architectures of the patient radiological images with three similar disease types, viral, bacterial and COVID-19 pneumonia, were compared. The increase in the success rate in this comparison will also increase the correct diagnosis of the disease. In this way, the emergence of successful methods will not only facilitate the work of the physician who makes the diagnosis, but also save time, which is the most valuable concept for all humanity. A total of 9208 chest X-ray images with 1281 COVID-19, 3270 Normal, 1656 viral-pneumonia and 3001 bacterial-pneumonia were used, and the Resnet50 architecture achieved the most successful performance with 88.05%.

Keywords: CNN, Deep Learning, COVID-19, Pneumonia, Disease Detection, Viral, Bacterial

1. Giriş

Halk arasında zatürre adıyla bilinen pnömoni, akciğerlerin alveollerini ve distal bronş ağacını etkileyen yaygın bir akut solunum yolu enfeksiyonudur [1]. Pnömoni, gelişmekte olan ülkelerdeki küçük çocukların ve gelişmiş ülkelerdeki yaşlıların başlıca katili olmaya devam eden yaygın bir hastalıktır [2]. Vos ve ark. [3] 2019 yılında yaptığı çalışmada elde edilen veriler, pnömoni ve bronşiyolit dahil olmak üzere alt solunum yolu enfeksiyonlarının dünya çapında 489 milyon insanı etkilediğini ve 5 yaşından küçük çocuklar ile 70 yaşından büyük yetişkinler pnömoniden en çok etkilenen popülasyonlardı. Pnömoni genel olarak toplum kökenli pnömoni veya hastane kökenli pnömoni olarak ikiye ayrılır. Bakteriler, solunum virüsleri ve mantarlar dahil olmak üzere çok çeşitli mikroorganizmalar pnömoniyeye neden olabilir. Pnömoni, 5 yaşından küçük çocuklar, kronik rahatsızlıkları olan ve yaşça büyük yetişkinler dahil olmak üzere duyarlı bireylerde daha sık görülür. Hastalığın gelişimi büyük ölçüde konakçının bağışıklık tepkisine bağlıdır ve patojen özellikleri daha az belirgin bir role sahiptir. Pnömonili bireyler sıklıkla solunum ve sistemik semptomlarla başvururlar ve tanı hem klinik sunuma hem de radyolojik bulgulara dayanmaktadır [1].

Amerikan Toraks Derneği, pnömoni tanısının göğüs radyografisi temelinde yapılması gerektiği yönündedir [4]. Göğüs radyografilerindeki doku arasında bulunan sızıntıların genellikle pnömoninin viral bir nedenini ve alveolar sızıntıların bakteriyel bir nedeni gösterdiği düşünülür. Bununla birlikte, bakteri ve virüsler tek başlarına veya birlikte çok çeşitli göğüs radyografik değişiklikleri indükleyebilir ve değişiklikler sadece belirli vakalarda pnömoninin mikrobiyal bir nedenini doğrulamak için yardımcı olur [5]. Yetişkinlerde, virüsler, özellikle influenza virüsleri, rinovirüsler ve koronavirüsler olmak üzere toplum kökenli pnömoni vakalarının üçte birinde varsayılan nedensel ajanlardır. Bakteriler, pnömonili erişkinlerde baskın bir role sahip olmaya devam etmektedir. Toplumda viral salgınların varlığı, hastanın yaşı, hastalığın başlangıç hızı, semptomlar, biyobelirteçler, radyografik değişiklikler ve tedaviye yanıt, viral pnömoniyi bakteriyel pnömoniden ayırmaya yardımcı olabilir [2].

Viral pnömoniyi bakteriyel pnömoniden ayırt etme yeteneğinin önemli yönetim etkileri olabilir. Gelişmelere rağmen, teşhis testleri, etkilenen birçok kişide neden olan ajanları belirlemede hala başarısız oluyor [6]. Bu durumda gecikmiş ve yetersiz antimikrobiyal tedaviyle kötü sonuçlara yol açabileceğinden, neden olan patojenleri belirlemek çok önemlidir. Patojenleri ve antibiyotik direncini tespit edebilen hızlı ve doğru tanı testlerine ek olarak yeni antibiyotik ve antibiyotik dışı tedaviler, pnömoni yönetimini iyileştirecektir [1].

Gelişen teknolojiyle birlikte yapay zeka araştırmacıları, insanlığa faydalı olmak adına çoğu hastalığın teşhisi için farklı yöntemler sunmanın yanı sıra geçtiğimiz yılların korkulu rüyası COVID-19 salgınıyla mücadele etmek için de çeşitli son teknolojileri tanıtır ve geliştiriyorlar. Bu alanda yapılan çalışmalar, göğüs röntgeni ve bilgisayarlı tomografi(BT) görüntülerini kullanarak COVID-19 ve pnömoni hastalarını teşhis etmek için çeşitli teknikler önermektedir. Bu teknolojilerin tıbbi sisteme entegre edilebilir ve COVID-19 ve pnömoni hastalarının teşhisinde olağanüstü performans gösterir. Bu alanda umut vadeden çeşitli çalışmalardan bahsetmek gerekir ise:

Oh ve ark. [7], yaptığı çalışmada FC-DenceNet103 kullanılarak göğüs röntgeni görüntülerinde segmentasyon gerçekleştirilir ve sınıflandırma aşında ResNet-18 kullanılır. Sınıflandırıcı dört sınıfa ayrılır: Normal, tüberküloz, bakteriyel pnömoni ve COVID-19 vakalarını içerir. Veri kümesi sırasıyla; 191, 57, 54 ve 200 göğüs röntgeni görüntüsünü içerir. Sınıflandırma için hem global hem de yerel yaklaşım uygulanmış, %70.7 ve %59 doğruluk gösterdi. Zargari Khuzani

ve ark. [8], 140'ı COVID-19 pozitif hastalara, 140'ı pnömoni hastalarına ve 140'ı Normal insanlara ait olmak üzere 420 adet (512×512) göğüs röntgeni görüntüsünü içeren bir veri ile kullanarak; optimal özellikler ve genel özellikler çıkarmak için boyut küçültme yöntemiyle, görüntüleri analiz ederek COVID-19 pozitif hastaları bulabilen iki gizli katmana sahip etkili bir makine öğrenimi sınıflandırıcısı oluşturulması üzerine çalışırlar. Model nispeten küçük bir veri kümesi kullanılarak geliştirildiğinden, COVID-19 sınıfı için %96 kesinlik, %100 hassasiyet ve 0.98 F-skoru ile çok iyi performans gösterdi. Asif ve ark [9]. Derin CNN(DCNN) tabanlı Inception V3 mimarisini kullanarak transfer öğrenme yaklaşımını uyguladılar. Etiketli, 864 COVID-19, 1345 viral pnömoni ve 1341 normal göğüs röntgeni görüntüsü içeren bir veri kümesi kullandılar. Önerilen model, %96 doğruluk göstermiştir. Rahman ve ark. [10], 576'sı COVID-19'dan etkilenen hastalardan, 4273'ü pnömoniden etkilenen hastalardan ve 1583'ü normal hastalardan olmak üzere toplam 6432 göğüs röntgeni görüntüsünde görüntülerindeki spesifik anormalliği bulabilen sınıflar halinde etkin bir şekilde sınıflandırabilen, yönlendirilmiş gradyanlar ve DCNN model histogramı önerdi. Sistemin genel doğruluğu %96,74 olarak bulunmuştur. Önerilen sistem, göğüs röntgeni görüntülerinden COVID-19 ile ilgili pnömoniyi tespit etmede çok iyi bir performansla sahip olsa da, bazı durumlarda bazı görüntüler hala yanlış sınıflandırılmaktadır. Bu yanlış durumlardan da çalışmada ayrıntılı bahsedilmiştir. Rehman ve ark. [11], transfer öğrenmeyi kullandıkları ve CNN mimarileri arasında sağlıklı vakalar, bakteriyel pnömoni, viral pnömoni arasında COVID-19'u tespit etmeye yönelik bir sistem geliştirdi. Bu çalışmada veri kümesi olarak, COVID-19'dan etkilenen kişilerin 200 görüntüsünü, viral pnömoninin 200 görüntüsünü, bakteriyel pnömoninin 200 görüntüsünü ve normal kişilerin 200 akciğer grafisi ve BT görüntüsünü içerir. Önerilen modelin performansını değerlendirmek için on kat çapraz doğrulama kullanılan çalışmada; MobileNet mimarisi, %80,95 doğruluk göstererek en başarılı mimari oldu.

Spesifik olarak sadece COVID-19 üzerine yapılan bazı çalışmalara da örnek verilirse; Sing ve ark. [12], göğüs BT tarama görüntülerinde COVID-19 sınıflandırması için bir topluluk derin öğrenme modeli önerilmiştir. Önerilen topluluk modeli, DCCN'ler, ResNet152V2 ve VGG16 olmak üzere iyi bilinen üç modeli kullanmıştır. Önerilen model, göğüs BT veri kümesinde test edildi ve on beş rakip modelle karşılaştırıldı. Shah ve ark. [13], BT tarama görüntülerini analiz ederek COVID-19 teşhisi için dört konvolüsyonel blok içeren CTnet-10 adlı derin bir CNN tabanlı model oluşturdu. Bu çalışmada kullanılan veri kümesi, COVID-19'dan etkilenen insanların 349 görüntüsünü ve normal insanların 738 görüntüsünün; %80, %10 ve %10'u sırasıyla eğitim, doğrulama ve test olarak bölünmüştür. Önerilen yöntem, DenceNer-169, VGG-19, InceptiopnV3, VGG16 ve ResNet50 gibi bazı CNN mimarileriyle karşılaştırılmıştır. Önerilen model %82,1 doğruluk elde etmiş ve VGG19 %94.52 ile en yüksek doğruluğu göstermiştir.

Bu bilgiler ışığında çalışmamızda da koronavirüs, viral ve bakteriyel pnömonili hastalar ve normal bireylerin radyolojik görüntüler içeren veri kümemiz 4 derin öğrenme mimari ile eğitime tabi tutulup başarı performansları karşılaştırılmıştır. Çalışmamızın ikinci bölümünde materyal ve yöntem kısmında veri kümesi ve metodolojiden bahsedilip üçüncü bölümde ise bulgular ile deneysel sonuçlar paylaşılmış, beşinci bölüm olan tartışma kısmında ise önceki çalışmalar ile karşılaştırmalar yapılmıştır, son bölümde ise sonuç ile çalışmamız tamamlanmıştır.

2. Materyal Ve Yöntem


Bu bölümde, çalışmamızda kullanılan veri kümesi ve metodoloji iki farklı başlık olarak ayrıntılı bahsedilmiştir.

2.1. Veri Kümesi

Çalışmamızda veri bilimcilerin çok yönlü kullandığı, veri kümelerinin paylaşım yapılıp indirilebildiği açık erişim sitesi Kaggle'dan indirilen veri kümesi kullanılmıştır [14]. İndirilen veri kümesi halka açık 15 veri kümesinin harmanlanmasıyla ve kaynakçaları belirtilerek elde edilen edilmiştir. Mevcut veri kümesi 1281 COVID-19, 3270 Normal, 1656 viral-pnömoni ve 3001 bakteriyel-pnömoni göğüs röntgen görüntüsünü içerir. Toplanan veri kümeleri entegre bir havuz oluşturmak için birleştirilir. Bu entegre depo ilk aşamada 4558 COVID-19, 5403 Normal, 4497 Viral pnömoni ve 5768 bakteriyel pnömoni göğüs röntgen görüntüsü içerirken; bunlardan 1379'u COVID-19, 1476'sı normal, 2690 viral pnömoni ve 2588 bakteriyel pnömoni göğüs röntgen görüntüsü görüntü benzerliklerine dayalı olarak kopya olarak bulunduğu kaldırılır. Görüntü yerleştirmelerini elde etmek için Inception V3 mimarisi kullanılır, bunu kosinüs benzerlik mesafelerine dayalı denetimsiz öğrenme algoritmalarının kullanımı takip eder. Bu mesafeler kümelenebilir ve daha sonra; gürültü, pikselleştirilmiş, sıkıştırılmış, medikal implantlar, yıkanmış görüntü, yan görünüm, dilimlenmiş görüntü, en-boy oranı bozulması / kırılmış / yakınlaştırılmış, döndürülmüş görüntüler, açıklamalı görüntüler gibi farklı görüntü kusurları kategorilerini bulmak için görselleştirilir. Bu kusurlu görüntü kümeleri, iyileştirme işlemi sırasında kaldırılır ve indirilebilecek rafine bir veri kümesi elde edilir. Tablo 1'de bu durum ayrıntılı bir şekilde verilirken, şekil 1'de ise veri kümesine ait örnek görüntüler içermektedir.

Tablo 1. Veri Kümesinin Belli Aşamalarla Rafine Hale Gelmesi

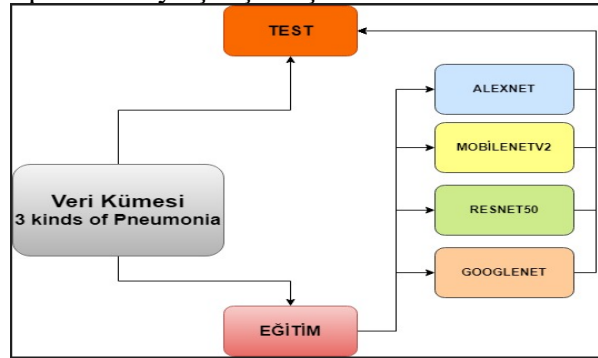
	COVID-19	Normal	Bakteriyel Pnömoni	Viral Pnömoni
TOPLAM GÖRÜNTÜ	4558	5403	5768	4497
KOPYA	1379	1476	2588	2690
KUSURLU	1898	657	179	151
KALAN RAFİNE VERİ KÜMESİ	1281	3270	3001	1656



Şekil 1. “3 kinds of Pneumonia” Veri Kümesinden Örnekler (A.COVID-19- B.Normal- C.Bakteriyel Pnomoni- D.Viral Pnomoni)

2.2. Metodoloji

Deneyler, CNN mimarilerinde eğitim için çok modelli sayısal hesaplama araç ve yazılımı olan MATLAB platformunda gerçekleştirilmiştir. Tüm deneyler Intel Core i7 Windows 10 işletim sistemli 8 GB RAM bilgisayarda test edilmiştir. Kaggle’da yer alan “3 kinds of Pneumonia” yaklaşık 4 GB alana sahip içinde COVID-19, Normal, bakteriyel pnömoni ve viral pnömoni 4 farklı sınıfın olduğu 9208 adet görüntü içeren veri seti kullanılmıştır. Veri kümesinin %80’i eğitim için kullanılırken, test için kalan %20 görüntü kullanılmıştır. Alexnet, MobilenetV2, Resnet50 ve Googlenet olmak üzere 4 farklı CNN mimarisinin çalıştırıldığı çalışmamızda tüm mimariler 5 dönem çalıştırılmıştır. İş akış diyagramının Şekil 2’de gösterildiği çalışmamızda en başarılı metodoloji tespit edilmeye çalışılmıştır.



Şekil 2. İş Akış Diyagramı

Çalışmanın sonunda elde edilen karmaşıklık parametleri ise belli formülasyonlar kullanılarak performans değerlendirilmesi yapılır. Karmaşıklık matrisinin çözümünde kullanılan modelin doğru tahmin ettiği olasılıklar (True Positive(TP), True Negative (TN)) ve yanlış tahminde bulunduğu olasılıklar False Positive (FP), False Negative (FN) en başarılı mimaride her sınıflandırma için ayrı ayrı hesaplandı. Performans metrikleri olarak; hassaslık (sensitivity), özgüllük (specificity), pozitif ve negatif prediktif değerler (PPV ve NPV), yanlış pozitif oran, yanlış keşif oran, yanlış negatif oran, doğruluk (Accuracy), F1 Score ve Matthews Korelasyon Katsayısı ile hesaplanır. Tablo 2’de metriklerin hesaplama yöntemleri formülleri ile verilmiştir.

Tablo 2. Ölçüm Metrikleri Ve Formülasyon

ÖLÇÜM METRİKLERİ VE FORMULASYON	
Ölçüm	Formül

Sensitivity	$TPR = TP / (TP + FN)$
Specificity	$SPC = TN / (FP + TN)$
Precision	$PPV = TP / (TP + FP)$
Negative Predictive Value	$NPV = TN / (TN + FN)$
False Positive Rate	$FPR = FP / (FP + TN)$
False Discovery Rate	$FDR = FP / (FP + TP)$
False Negative Rate	$FNR = FN / (FN + TP)$
Accuracy	$ACC = (TP + TN) / (P + N)$
F1 Score	$F1 = 2TP / (2TP + FP + FN)$
Matthews Correlation Coefficient	$TP*TN - FP*FN / \sqrt{((TP+FP)*(TP+FN)*(TN+FP)*(TN+FN))}$

2.3. Kullanılan CNN Mimarileri

ALEXNET

Alexnet ilk olarak Alex Krizhevsky ve arkadaşları [15] tarafından, LeNet'e kıyasla daha derin ve daha geniş bir CNN modeli olarak önerdikleri mimari 2012'de ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) olarak adlandırılan görsel nesne tanıma yarışması ImageNet'i kazandılar. AlexNet, tüm geleneksel makine öğrenimi ve bilgisayarla görme yaklaşımlarına karşı son teknoloji tanıma doğruluğu elde etti. Görsel tanıma ve sınıflandırma görevleri için makine öğrenimi ve bilgisayar görüşü alanında önemli bir atılımdı ve tarihte derin öğrenmeye ilginin hızla arttığı noktadır.

MOBILENETV2

MobileNet V2 Mimarisini Sandler ve arkadaşları [16], mobil modellerin performansını birden fazla görev ve kıyaslamada ve ayrıca farklı model boyutlarından oluşan bir yelpazede iyileştirdiğini açıklamaktadır. MobileNet V2'de her blok, 1 x 1 genişleme katmanına ek olarak, derinlemesine ve noktasal evrişim katmanlarını içerir. MobileNet V1'den farklı olarak, V2'nin projeksiyon katmanı olarak bilinen noktasal evrişimli katmanı, çok sayıda kanala sahip verileri çok daha az sayıda kanala sahip bir tensöre yansıtır. MobileNet V2'nin yapı taşındaki ikinci yeni şey artık bağlantıdır. Artık bağlantı, ağ üzerinden gradyanların akışına yardımcı olmak için mevcuttur. MobileNet V2'nin her katmanı, toplu normalleştirmeye ve aktivasyon işlevi olarak ReLU6'ya sahiptir. Ancak, projeksiyon katmanının çıktısının bir aktivasyon fonksiyonu yoktur. MobileNet V2 mimarisi, düzenli bir 1x1 konvolüsyon, bir global ortalama havuzlama katmanı ve bir sınıflandırma katmanının takip ettiği sıralı 17 darboğaz artık bloğundan oluşur.

RESNET50

ILSVRC 2015'in kazananı artık ağ mimarisi olarak bilinen ResNet, önceki mimarilerin sahip olduğu yok olan gradyan problemini yaşamayan ultra derin ağlar tasarlamak amacıyla Kaiming He tarafından geliştirilmiştir [17]. ResNet, birçok farklı sayıda katmanla geliştirilmiştir; 34, 50,101, 152 ve hatta 1202. En Popüleri olan ResNet50, ağın sonunda 49 evrişim katmanı ve 1 tam bağlı katman içeriyordu.

GOOGLENET

ILSVRC 2014'ün galibi GoogLeNet, geleneksel CNN'e kıyasla hesaplama karmaşıklığını azaltmak amacıyla Google'dan Christian Szegedy tarafından önerildi [18]. Önerilen yöntem, farklı çekirdek boyutları tarafından oluşturulan değişken alıcı alanlara sahip "Başlangıç Katmanlarını" dahil etmekte. Bu alıcı alanlar, yeni özellik haritası yığınındaki seyrek korelasyon modellerini yakalayan operasyonlar yarattı. Başlangıç katmanları yığını kullanarak en gelişmiş tanıma doğruluğunu geliştirdi.

3. Bulgular ve Tartışma

3.1. Bulgular

Çalışmamızda çok paradigmatlı sayısal hesaplama aracı diye bilenen MATLAB kullanılmıştır. Kullandığımız veri kümesi ise bünyesinde veri kümelerini de barındıran açık erişim sitesi Kaggle'dan alınan 4 farklı sınıfa sahip COVID-19, Normal, bakteriyel pnömoni ve viral pnömonili göğüs röntgeni verilerinden oluşturmaktadır.

Tablo 3. Veri Kümesinin Çalıştırıldığı 4 Mimari Ve Doğruluk Oranları

DERİN ÖĞRENME SİNİR AĞI	DOĞRULUK
ALEXNET	85,77%
MOBİLENETV2	86,53%
RESNET50	88,05%
GOOGLINET	85,82%


Alexnet, MobilenetV2, Resnet50 ve Googlenet mimarileri veri setimiz üzerinde çalıştırılmıştır. İlgili mimarilerin deneysel sonuçları Tablo 3'te gösterildiği gibidir.

Eğitim kısmı her dönemi 430 iterasyondan oluşan 5 dönemden toplamda 2300 iterasyondan meydana gelmektedir. Eğitimin iterasyonlar şeklinde 5 dönem ilerlemesi Şekil 3'te verilmiştir. Şekilde de görüleceği üzere en hızlı sürede eğitimi tamamlayan Alexnet olmasına karşın 4 mimari arasında en düşük doğruluğu yakalayan mimari olmuştur. Zaman olarak bakıldığında en hızlı ikinci mimari olan Googlenet doğrulukta sondan bir önceki mimari olmuştur. Eğitimi yaklaşık 230 dakika gibi bir sürede bitiren MobilenetV2 çalışmanın en iyi doğruluk veren 2. mimarisi olmuştur. Eğitimi en uzun sürede eğitimi tamamlayan Resnet50 ise %88,05'lik doğruluk oranı ile COVID-19, normal, bakteriyel pnömoni ve viral pnömonili göğüs röntgen görüntüleri tespitinde en başarılı mimari olmuştur.

A. Alexnet Training Progress




B. MobilenetV2 Training Progress



Results
Validation accuracy: 86.53%
Training finished: Reached final iteration
Training Time
Elapsed time: 230 min 39 sec
Training Cycle
Epoch: 5 of 5
Iteration: 2300 of 2300
iterations per epoch: 460
Maximum iterations: 2300

Accuracy
— Training (smoothed)
— Training
— Validation
Loss
— Training (smoothed)
— Training
— Validation


C. Resnet50 Training Progress



Results
Validation accuracy: 88.05%
Training finished: Reached final iteration
Training Time
Elapsed time: 410 min 10 sec
Training Cycle
Epoch: 5 of 5
Iteration: 2300 of 2300
iterations per epoch: 460
Maximum iterations: 2300

Accuracy
— Training (smoothed)
— Training
— Validation
Loss
— Training (smoothed)
— Training
— Validation

D. Googlenet Training Progress



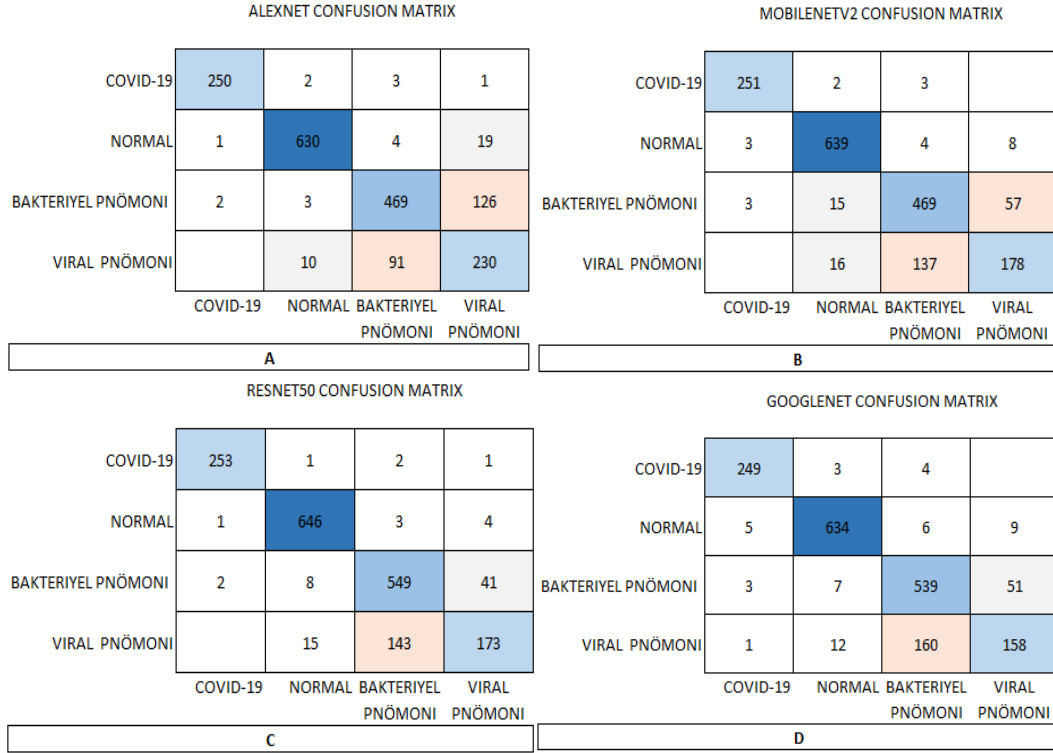
Results
Validation accuracy: 85.82%
Training finished: Reached final iteration
Training Time
Elapsed time: 191 min 8 sec
Training Cycle
Epoch: 5 of 5
Iteration: 2300 of 2300
iterations per epoch: 460
Maximum iterations: 2300

Accuracy
— Training (smoothed)
— Training
— Validation
Loss
— Training (smoothed)
— Training
— Validation

Şekil 3. Eğitim İlerlemesi (A. Alexnet - B. MobilenetV2- C. Resnet50 - D. Googlenet)

Elde ettiğimiz karmaşıklık matrisleri Şekil 4'te tüm mimariler için ayrı ayrı verilmiştir. Tablo 2'de verdiğimiz formülasyonlar kullanılarak karmaşıklık matrisleri üzerinde performans değerlendirilmesi yapılır. Çalışmamızda ise en başarılı mimari olan Resnet50'ye bu formülasyonlar uygulanmış ve Tablo 4'te ayrıntılı bir şekilde sonuçları tüm sınıflar için paylaşılmıştır. Çalışmamızda Sensitivity ve specificity, PPV ve NPV değerleri datasetin 4 eğitim sınıfı için bakıldığında COVID-19 ve normal görüntüleri için çıkan yüksek sonuç, istatistiğin doğruluğunu gösterirken; FPR, PNR, FDR değerleri ise yine bu sınıflar için sıfıra yakın değerler çıkarmakta buda çalışmanın performansın bu iki sınıf için başarılı olduğunu göstermektedir. Sınıflandırma modelimiz doğruluk, kesinlik ve F1 Score parametrelerine COVID-19 ve normal görüntü sınıflarında bakıldığında 1'e yakın sonuçlar ile başarılı bir tahmin yürüttüğünü söyleyebiliriz. Matthews Korelasyon Katsayısı bu iki sınıf için minimum

0,96 değerini görmüştür. Bu değerler 1'e yakın, bu da modelin tahmin etme konusunda iyi bir iş çıkardığını gösteriyor.



Şekil 4. Karışıklık Matrisi (A. Alexnet - B. MobileNetV2- C. Resnet50 - D. GoogLeNet)

Karışıklık matrisi analizinde görülüyor ki bakteriyel pnömoli ve viral pnömonoli görüntüler tüm metotlar için bakıldığında düşük performans sergilenmiş diğer iki sınıfa nazaran daha az başarıya sahip olmuştur.

Tablo 4. Görüntülerinin Analiz Sonuçları (A.COVID-19- B.Normal- C.Bakteriyel Pnomoni- D.Viral Pnomoni)

A. COVID19	
Ölçüm	Değer
Sensitivity	0.9844
Specificity	0.9981
Precision	0.9883
Negative Predictive Value	0.9975
False Positive Rate	0.0019
False Discovery Rate	0.0117
False Negative Rate	0.0156
Accuracy	0.9962
F1 Score	0.9864
Matthews Correlation Coefficient	0.9841

B. NORMAL	
Ölçüm	Değer
Sensitivity	0.9878
Specificity	0.9798
Precision	0.9642
Negative Predictive Value	0.9932
False Positive Rate	0.0202
False Discovery Rate	0.0358
False Negative Rate	0.0122
Accuracy	0.9826
F1 Score	0.9758
Matthews Correlation Coefficient	0.9624

C. BAKTERİYEL PNOMONI	
Ölçüm	Değer
Sensitivity	0.9150
Specificity	0.8808
Precision	0.7877
Negative Predictive Value	0.9555
False Positive Rate	0.1192
False Discovery Rate	0.2123
False Negative Rate	0.0850
Accuracy	0.8920
F1 Score	0.8466
Matthews Correlation Coefficient	0.7690

D. VIRAL PNOMONI	
Ölçüm	Değer
Sensitivity	0.5227
Specificity	0.9696
Precision	0.7900
Negative Predictive Value	0.9026
False Positive Rate	0.0304
False Discovery Rate	0.2100
False Negative Rate	0.4773
Accuracy	0.8893
F1 Score	0.6291
Matthews Correlation Coefficient	0.5839

3.2. Tartışma

Veri kümemizde 1281 COVID-19, 3270 Normal, 1656 viral-pnömoni ve 3001 bakteriyel-pnömonili toplamda 9208 göğüs röntgen görüntüsü bulunmakta ve CNN mimarileri bu görüntüler üzerinde eğitim ve test aşamalarını tamamladıktan sonra en başarılı performansı %88,05 ile Resnet50 mimarisi elde etmiştir.

Tablo 4. İlgili çalışmaların karşılaştırılması

Çalışma	Metot	Doğruluk	Veri Kümesi/ Toplam Görüntü Sayısı(Adet)
Oh ve ark. [7]	ResNet-18	70,70%	502
Asif ve ark. [9]	Inception V3	96%	3550
Rahman ve ark. [10]	HOG + CNN Net	96,74%	6432
Rehman ve ark. [11]	MobileNet	80,95%	600
Shah ve ark. [13]	CTnet-10	82,10%	1088

Tablo 4’te bazı benzer çalışmaların karşılaştırılması yapılmıştır. Çalışmamız, verilen tablodaki çalışmalarla kıyaslanınca veri kümesi olarak en kapsamlı çalışma, bize ait olduğu gözükmemektedir. Doğruluk olarak bakıldığında 3 çalışmadan daha başarılı sonuç alınmış fakat 2 çalışmanın gerisinde kalmıştır. Daha başarılı makaleler incelendiğinde ise veri kümesinin bizim çalışmamıza nazaran azlığı ve tespit edilen sınıfların 3 sınıfta kalması gözükmemektedir. Şöyle ki; Asif ve ark. [9] ve Rahman ve ark. [10] çalışmalarında COVID-19, pnömonili ve normal görüntüler üzerinde çalışmalar yürütürken, çalışmamızda 4 ayrı kategoriden görüntüler üzerine eğitim ve test yapılmıştır. Ayrıca çalışmamızda tüm mimarilerin karmaşıklık matrisi ve analiz sonuçlarına bakıldığında ise hata oranının bariz artmasına sebep olan bakteriyel ve viral pnömonili hasta görüntü kategorileri oluşturmaktadır. Bu görüntüler üzerinde hassas çalışma metotları ve geliştirilen hibrit modellerle bu hata oranı azaltıp doğruluk oranı artırılabilir.

Tüm hastalıklar için bilinen bir gerçek var ki erken teşhis tedaviye yanıt oranını arttırmaktadır. Yine benzer bir şekilde teşhis yöntemlerinin doğruluğu da bu kapsamda önem arz etmektedir. Çalışmamızda ise son iki yılda dünya gündeminin önemli konularından olan COVID-19’lu hastaların yanı sıra yine bu rahatsızlıkla ayırt edilmesi zor olan bakteriyel ve viral pnömonili hasta görüntüleri üzerine çalışılmıştır. Birbirine benzeyen bu hastalıkların tespiti sübjektif sonuçlar doğurabilmenin yanı sıra zaman kaybına da yol açmaktadır. Hem hekimin iş gücünü azaltmada hem de objektif sonuçlar elde etmek için yapay sinir ağları bu alanda yeniliklere açık bir alan oluşturmaktadır.

Yapay zeka yöntemleri, veri kümesinin analizini geliştirmede, anlamlı özellikleri çıkarmada, kümeleme ve sınıflandırmada hayati bir rol oynamaktadır. Yapılan bu çalışmada göğüs röntgen görüntüleri Alexnet, MobilenetV2, Resnet50 ve Googlenet olmak üzere 4 farklı CNN mimarisi ile eğitilmiştir. Bu mimariler arasında Resnet50, %88,05’lik doğruluk ile en başarılı performans sergileyen yöntem olmuştur. Çalışmamızın bir sonraki aşaması olarak başarılı mimariler arasında hibrit model geliştirilerek sonuç üzerinde pozitif ilerleme kat edilebilir. Daha özgün ve geniş veri kümeleri ile daha başarılı sonuçlar elde edilebilir.

4. Sonuç

Tüm hastalıklar için bilinen bir gerçek var ki erken teşhis tedaviye yanıt oranını arttırmaktadır. Yine benzer bir şekilde teşhis yöntemlerinin doğruluğu da bu kapsamda önem arz etmektedir. Çalışmamızda ise son iki yılda dünya gündeminin önemli konularından olan COVID-19’lu

hastaların yanı sıra yine bu rahatsızlıkla ayırt edilmesi zor olan bakteriyel ve viral pnömoli hasta görüntüleri üzerine çalışılmıştır. Birbirine benzeyen bu hastalıkların tespiti sübjektif sonuçlar doğurabilmenin yanı sıra zaman kaybına da yol açmaktadır. Hem hekimin iş gücünü azaltmada hem de objektif sonuçlar elde etmek için yapay sinir ağları bu alanda yeniliklere açık bir alan oluşturmaktadır.

Yapay zeka yöntemleri, veri kümesinin analizini geliştirmede, anlamlı özellikleri çıkarmada, kümelemede ve sınıflandırmada hayati bir rol oynamaktadır. Yapılan bu çalışmada göğüs röntgen görüntüleri Alexnet, MobilenetV2, Resnet50 ve Googlenet olmak üzere 4 farklı CNN mimarisi ile eğitilmiştir. Bu mimariler arasında Resnet50, %88,05'lik doğruluk ile en başarılı performans sergileyen yöntem olmuştur. Çalışmamızın bir sonraki aşaması olarak başarılı mimariler arasında hibrit model geliştirilerek sonuç üzerinde pozitif ilerleme kat edilebilir. Daha özgün ve geniş veri kümeleri ile daha başarılı sonuçlar elde edilebilir.

5. Kaynakça

- [1] A. Torres, C. Cilloniz, M. S. Niederman, R. Menendez ve T. van der Poll, «Pneumonia,» *Nature Reviews Disease Primers*, no. 7(1), pp. 1-28, 2021.
- [2] R. O., E. Lahti, L. C. Jennings ve D. R. Murdoch, «Viral pneumonia,» *The Lancet*, no. 377(9773), pp. 1264-1275, 2011.
- [3] T. H. E. O. Vos, S. S. Lim, C. Abbafati, K. M. Abbas, M. Abbasi, M. Abbasifard, ... & ve A. Abdelalim, «GBD 2019 Diseases and Injuries Collaborators. Global burden of 369 diseases and injuries in 204 countries and territories, 1990-2019: a systematic analysis for the Global Burden of Disease Study 2019,» *Lancet*, no. 396(10258), pp. 1204-1222, 2020.
- [4] L. A. Mandell, R. G. Wunderink, A. Anzueto, J. G. Bartlett, G. D. Campbell, N. C. Dean, ... & ve A. Torres, «Infectious Diseases Society of America/American Thoracic Society consensus guidelines on the management of community-acquired pneumonia in adults,» *Clin Infect Dis*, no. 44(Suppl 2), pp. S27-S72, 2007.
- [5] R. Virkki, T. Juven, H. Rikalainen, E. Svedström, J. Mertsola ve O. Ruuskanen, «Differentiation of bacterial and viral pneumonia in children,» *Thorax*, no. 57(5), pp. 438-441, 2002.
- [6] D. R. Murdoch, L. C. Jennings, N. Bhat ve T. P. Anderson, «Emerging advances in rapid diagnostics of respiratory infections,» *Infectious Disease Clinics*, no. 24(3), pp. 791-807, 2010.
- [7] Y. Oh, S. Park ve J. C. Ye, «Deep learning COVID-19 features on CXR using limited training data sets,» *IEEE transactions on medical imaging*, no. 39(8), pp. 2688-2700, 2020.
- [8] A. Zargari Khuzani, M. Heidari ve S. A. Shariati, «COVID-Classifer: An automated machine learning model to assist in the diagnosis of COVID-19 infection in chest x-ray images,» *Scientific Reports*, no. 11(1), pp. 1-6, 2021.
- [9] S. Asif, Y. Wenhui, H. Jin ve S. Jinhai, «Classification of COVID-19 from chest X-ray images using deep convolutional neural network,» %1 içinde *In 2020 IEEE 6th international conference on computer and communications (ICCC)*, 2020.
- [10] M. M. Rahman, S. Nooruddin, K. M. Hasan ve N. K. Dey, «HOG+ CNN Net: Diagnosing COVID-19 and pneumonia by deep neural network from chest X-Ray images,» *SN computer science*, no. 2(5), pp. 1-15, 2021.
- [11] A. Rehman, S. Naz, A. Khan, A. Zaib ve I. Razzak, «Improving coronavirus (COVID-19) diagnosis using deep transfer learning,» %1 içinde *In Proceedings of International Conference on Information Technology and Applications*, Singapore., 2022.
- [12] D. Singh, V. Kumar ve M. Kaur, «Densely connected convolutional networks-based COVID-19 screening model,» *Applied Intelligence*, no. 51(5), pp. 3044-3051, 2021.

- [13] V. Shah, R. Keniya, A. Shridharani, M. Punjabi, J. Shah ve N. Mehendale, «Diagnosis of COVID-19 using CT scan images and deep learning techniques,» *Emergency radiology*, no. 28(3), pp. 497-505.
- [14] U. Sait, G. L. KV, S. P. Prajapati, R. Bhaumik, T. Kumar, S. Shivakumar ve K. Bhalla, «3 kinds of Pneumonia,» 31 Mayıs 2022. [Çevrimiçi]. Available: <https://www.kaggle.com/datasets/artiomkolas/3-kinds-of-pneumonia?resource=download>. [Erişildi: 25 Eylül 2022].
- [15] A. Kirzhevsky, I. Sutskever ve G. E. Hinton, «Imagenet classification with deep convolutional neural networks,» *Advances in neural information processing systems*, no. 25, pp. 1097-1105, 2012.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov ve L. C. Chen, «Mobilenetv2: Inverted residuals and linear bottlenecks,» %1 içinde *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018.
- [17] K. He, X. Zhang, S. Ren ve J. Sun, «Deep residual learning for image recognition,» %1 içinde *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
- [18] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov ve A. Rabinovich, «Going deeper with convolutions,» %1 içinde *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9, 2015.