



Derin Evrişimli Sinir Ağları Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti

Ferhat BOZKURT¹, Mete YAĞANOĞLU^{1*}

¹Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Erzurum

Özet

COVID-19 salgını, dünya çapında büyük bir güvenlik ve sağlık tehdidi haline gelmiştir. Tipik akciğer X-ray görüntüleri şüpheli vakaların erken taranmasına yardımcı olmaktadır. Ancak, çeşitli viral pnömoni (zatürre) görüntüleri COVID-19 görüntülerine benzerdir ve benzer ortak özellikler içermektedir. Bundan dolayı radyologların benzer diğer akciğer hastalıklarını COVID-19'dan ayırt etmesi zorlaşmaktadır. Bu çalışmada akciğer X-ray görüntülerinden COVID-19'un derin evrişimli sinir ağları (ESA) kullanılarak tespiti yapılmıştır. Çalışmada bir derin ESA modeli sunulmuş olup, açık erişimli veri kümesi üzerinde deneysel çalışmalar gerçekleştirilmiştir. Bu veri kümesinde, COVID-19, Normal ve Viral Pnömoni olmak üzere üç sınıfa ait toplam 3886 görüntü bulunmaktadır. Bu veri kümesini kullanarak, önerilen ESA modelinin doğruluğu üzerine performans değerlendirmeleri yapılmış olup ayrıca sonuçlar VGG19, Inception V3 ve ResNet50 gibi derin ESA tabanlı diğer popüler modeller ile karşılaştırılmıştır. Deneysel çalışmalarda, önerilen derin ESA modeli ile doğruluk değeri ortalama %96 bulunmuştur.

Anahtar Kelimeler: Derin öğrenme, ESA, X-Ray, COVID-19

COVID-19 Detection from Chest X-Ray Images Using Deep Convolutional Neural Networks

Abstract

The COVID-19 pandemic has become a major safety and health threat worldwide. Typical chest X-ray images aid early diagnosis of suspected cases. However, various images of viral pneumonia are similar to COVID-19 and include similar features. Therefore, it is difficult for radiologists to distinguish other similar lung diseases from COVID-19. In this study, COVID-19 is detected from chest X-ray images using deep Convolutional Neural Networks (CNN). In this study, a deep CNN model has built and experimental studies have been conducted on an open-access dataset. This dataset contains a total of 3886 images belonging to three classes as COVID-19, Normal and Viral Pneumonia. The performance evaluations were performed about the accuracy of the proposed CNN model by using this dataset. In addition, the results were compared with other popular deep CNN based models such as VGG19, Inception V3, and ResNet50. In experimental studies, the average accuracy is obtained to be 96% with the proposed deep CNN model.

Keywords: Deep learning; CNN; X-Ray; COVID-19

Makale Bilgisi

Başvuru:

09/05/2021

Kabul:

30/07/2021

* İletişim e-posta: yaganoglu@atauni.edu.tr

1 Giriş

Koronavirüs hastalığı (COVID-19), günümüzde milyonlarca can kaybına neden olan ve dünya çapında milyonlarca insana bulaşmış bir salgın hastalıktır. 11 Haziran 2020'ye kadar 200'den fazla ülkede 7,5 milyondan fazla enfekte vaka bulundu, bunların arasında 421 bin ölüm, 3,8 milyon iyileşme, 3,2 milyon hafif vaka ve 54 bin kritik vaka rapor edildi [1, 2]. COVID-19 salgınının yayılmasını engellemenin en önemli adımlarından biri, virüsün popülasyonda daha fazla yayılmasını önlemek için enfekte olduğundan şüphelenilen kişilerin etkili bir şekilde taranmasıdır. Yeni koroner pnömoni için en doğru tarama yöntemi nükleik asit tespittir. Bir diğer ifade ile ters transkriptasepolimeraz zincir reaksiyonu (RT PCR) tespiti, nazofaringeal sürüntülerden, balgamdan ve diğer alt solunum yolu sekresyonlarından, kan ve dışkı örneklerinden alınır. RT-PCR testi, COVID-19 taraması için altın standart olmasına rağmen, RT-PCR testi çok karmaşık, zaman alıcı ve yoğun emek gerektiren bir süreçtir. Tüm bölgelerdeki sağlık kurumları bu tür test koşullarına sahip değildir. Salgının başlangıcından beri, RT-PCR saptama reaktiflerinin sayısı çok sınırlı ve maliyeti yüksektir. Küresel salgın süresince, bazı ülkeler ve bölgeler hala yeterli sayıda RT-PCR test kitine sahip değildir. Birçok ülke, yalnızca test kitlerinin olmaması nedeniyle değil, aynı zamanda test sonuçlarındaki gecikme nedeniyle de yanlış COVID-19 pozitif vakası sayısıyla karşı karşıyadır [3]. Gecikmiş test sonuçlarına sahip pahalı bir tarama aracı, hastalığın yayılmasına yol açarak senaryoyu daha da kötü hale getirmektedir [4].

COVID-19 enfeksiyonunun hızlı bir şekilde ve yüksek doğrulukta taranmasını sağlayan herhangi bir teknolojik araç, sağlıkçılar için faydalı olmaktadır. Bu bağlamda, X-ray tomografik görüntüleme COVID-19 teşhisinde kolay erişilebilir alternatif bir araçtır. Tipik akciğer X-ray görüntüleri şüpheli vakaların erken taranmasına yardımcı olur. Ancak çeşitli viral pnömoni (zatürre) görüntüleri COVID-19 görüntülerine benzerdir ve benzer ortak özellikler içermektedir. Bu nedenle radyologların diğer bulaşıcı ve enflamatuar akciğer hastalıkları ile COVID-19'u ayırt etmesi zorlaşır. COVID-19 semptomlarının viral pnömoniyeye benzer olması, yanlış tanıya yol açmaktadır [4].

Göğüs röntgenleri üzerine derin öğrenme teknikleri giderek popülerlik kazanmaktadır. Derin ESA teknikleri ile göğüs röntgenleri üzerine etkili sonuçlar veren çalışmalar literatürde mevcuttur.

Mangla ve ark. [5], önceden hazırlanmış derin evrişimli sinir ağlarını kullanarak COVID-19 vaka tanımlamasını yaptı. Bu çalışmada, tamamen ilişkili bir katman tarafından takip edilen 121 katmanlı yoğun evrişimli ağ (DenseNet) ile önceden hazırlanmış CheXNet modeli kurdular. Dört sınıflı sınıflandırmada, %87.2 doğruluk elde ettiler. El Asnaou ve Chawki [6], derin öğrenme yöntemlerini kullanarak görüntü tabanlı COVID-19 vaka tanıma çalıştılar. X-Ray ve tomografi tarama görüntülerine VGG16, VGG19, Resnet50, MobileNet V2, Inception ResNet V2, DenseNet201 ve Inception V3 gibi birkaç derin öğrenme mimarisini uyguladılar. Inception ResNet V2, %92.18 doğrulukla diğer mimarilerden daha iyi performans göstermiştir. Apostolopoulos ve Mpesiana [7] çalışmalarında önceden hazırlanmış derin öğrenme modellerini kullandılar. Zatürre (pnömoni), COVID-19 ve normal görüntüler olmak üzere 1427 adet X-Ray görüntüsü kullandılar. Çalışmalarında, MobileNet V2, Inception, VGG19, Xception ve Inception ResNet V2 mimarilerini kullandılar. VGG19 ile iki sınıflı sınıflandırmada %98,75 doğruluk oranıyla en iyi sonucu elde ettiler. Abbas ve ark. [8], COVID-19 vakalarını daha etkili bir şekilde ayırt etmek için X-ray görüntülerinde etkili olan değiştirilmiş bir derin sinir ağı kurdular. DeTraC adını verdikleri model, üç iç katman içermektedir. Bu modeli arka uçta ResNet18 kullanarak oluşturdu ve X-Ray veri setinde %95.12 doğruluk elde ettiler. Rahimzadeh ve Attar [9], COVID-19 vakalarını ayırt etmek için Xception V2 ve ResNet50 modellerinin birleşimini gerçekleştirdiler. Sınıflandırma probleminde en iyi sonucu elde etmek için çeşitli derin öğrenme modellerini denediler. Xception V2 ve ResNet50'in bir kombinasyonu olan model ile %91,40 doğruluk elde ettiler. Naurin ve ark. [10], COVID-19 vakalarının X-Ray görüntülerinden tespitini ESA'nın, Inception V3, Inception ResNetV3 ve ResNet50 modelleri ile gerçekleştirdiler. Önceden eğitilmiş ResNet50 modeli ile yaklaşık olarak %98 doğruluk elde ettiler. Majeed ve ark. [11] topluluk tabanlı yeni bir CNN-X modeli önerdiler. Deneylerinde. %93,15 hassasiyet (sensitivity) %97,86 belirginlik (specificity) elde ettiler [12]. Hemdan ve ark. [13], X-Ray görüntülerinden COVID-19 teşhisi için COVIDXNET adlı bir derin öğrenme sınıflandırıcı altyapısını önerdiler, çalışmalarında ayrıca VGG19 ve Densenet201 gibi yedi farklı DCNN modelini doğruladılar. VGG19 ve DenseNet sınıflandırmasının daha iyi performans gösterdiğini buldular. Wang ve ark. [14], COVID-19 vakalarını göğüs röntgeni görüntülerinden tespit

etmek için COVID-Net adlı derin bir evrişimli sinir ağını sundular. Bozkurt [15], 11 farklı derin öğrenme tekniğini kullanarak akciğer X-Ray görüntülerinden COVID-19 tespitinde farklı yöntemlerin doğruluk performanslarına yönelik değerlendirmeler yapmıştır.



Şekil 1. Veri kümesindeki normal, COVID-19, Viral Pnömoni ile enfekte hastaların örnek akciğer X-Ray görüntüleri [4, 16].


Bu çalışmada, akciğer X-ray görüntülerini COVID-19, normal ve viral pnömoni (zatürre) hastalar olarak sınıflandırabilen bir derin ESA modeli uygulanmıştır. Önerilen ESA modelin performansını değerlendirmek için X-ray görüntülerini içeren açık erişimli bir veri seti kullanılır ve sonuçlar, VGG19, Inception V3 ve ResNet50 gibi son teknoloji derin öğrenme tabanlı yaklaşımlarla karşılaştırılır. Çalışmanın diğer kısımları aşağıdaki gibi organize edilmiştir. Bölüm 2’de materyal ve metoda değinilmiş olup, bu aşamada deneysel çalışmada kullanılan veri setinden ve uygulaması yapılan derin ESA modelinden bahsedilmiştir. Bölüm 3’de deneysel çalışmalar, Bölüm 4’de ise çalışmanın tartışma ve sonuçlar kısmına yer verilmiştir.

2 Materyal ve metot


2.1 Materyal

Farklı makine öğrenimi modellerini eğitmek için açık erişimli veriler literatürde mevcuttur. Bu çalışmada, akciğer X-ray görüntülerini içeren Kaggle popüler veritabanı kullanılmıştır [4, 16]. Şekil 1’de bu veri kümesindeki normal, COVID-19, Viral Pnömoni hastalarına ait örnek akciğer X-Ray görüntüleri gösterilmiştir. Bu veri içerisinde üç sınıfa ait, 1200 adet COVID-19, 1341 adet Normal ve 1345 adet Viral Pnömoni olmak üzere toplam 3886 görüntü bulunmaktadır. Derin ESA modeli oluşturulmadan önce veriler; birinci deneysel çalışmada veriler %85 eğitim, %10 doğrulama ve %5 test için ayrılmıştır (Şekil 2), ikinci deneysel çalışmada veriler %70 eğitim, %10 doğrulama ve %20 test için ayrılmıştır (Şekil3). Bu deneysel çalışmalara ait veri kümesinin kategorik dağılımları

ve eğitim, test, doğrulama veri sayıları Şekil 2 ve Şekil 3’de gösterilmiştir.



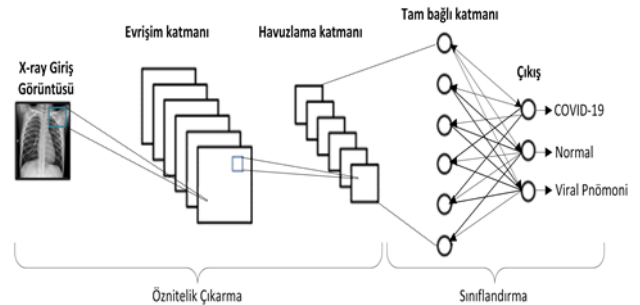
Şekil 2. Birinci deneysel çalışmaya ait veri kümesinin kategorik dağılımı.



Şekil 3. İkinci deneysel çalışmaya ait veri kümesinin kategorik dağılımı.

2.2 Metot

Derin öğrenme teknikleri, orijinal görüntülerden görünmeyen görüntü özneliklerini ortaya çıkarabilir [17]. Derin evrişimli sinir ağı, derin öğrenmede sezgisel ve güçlü bir ağ mimarisidir. Örüntü tanıma ve görüntü sınıflandırma işlemlerinde yaygın olarak kullanılır. Evrişimli Sinir Ağı (ESA), özellik çıkarma ve öğrenmede son derece yararlı olduğu kanıtlanmış ve çoğu çalışmada kullanılmıştır [18]. Son yıllarda, derin öğrenme teknolojisinin daha da gelişmesiyle birlikte, VGG, ResNet, DenseNet, EfficientNet gibi daha verimli derin ESA (DCNN) modelleri yakın zamanda önerildi. Bu derin ESA’lar, görüntü sınıflandırma görevlerinde iyi performans göstererek bilgisayarların görsel sınıflandırmada insanlardan daha iyi performans göstermesini mümkün kılar.



Şekil 4. Evrişimli sinir ağının temel mimarisi.

Bu çalışmada, akciğer X-ray görüntülerini COVID-19, normal ve viral pnömoni (zatürre) hastalar olarak sınıflandırabilen bir derin ESA modeli uygulanmıştır. Şekil 4'de ESA'nın temel mimarisinde de gösterildiği gibi, X-Ray giriş görüntülerinden ESA'da ard arda evrişim ve havuzlama katmanları ile öznetelik çıkarılmış ve sınıflandırma ile görüntülerin tanınması yapılabilmektedir. Bu aşamada kurulan modelden ve ESA'dan bahsedilmiştir.

Evrişim katmanı: Evrişimsel sinir sinir ağlarının temelini oluşturan, evrişim süreci ile girdiyeye bir filtre matrisinin uygulanması ve sonuçların bir sonraki katman için kullanılması amaçlanmaktadır. Bu katmanda, tüm görüntüye 2x2, 3x3 ve 5x5 gibi küçük boyutlu filtrelerin uygulanması yapılmaktadır. Böylelikle görüntüdeki daha ayırt edici özellikler çıkartılarak yeni bir görüntü elde edilir. Evrişim işlemi için kullanılan filtre matrisinin ağırlıkları, evrişimli sinir ağının öğrenme aşamasında belirlenir. Filtre matrisi belirtilen adımla kaydırılır ve evrişim işlemi uygulanır. Burada elde edilen sonuç, son katman değilse bir sonraki katman için girdi olarak verilir. Eğer bu son katman ise çıktı görüntüsünü temsil eder. Denklem (1) 'de görüldüğü gibi, filtre katsayıları (f), görüntüdeki eşit büyüklükteki pencerelerle (w) çarpılır ve toplamları alınarak hesaplanır. Sonuç olarak, ayırt edici üst düzey özelliklere dayalı yeni bir görüntü elde edilir [19, 20].

$$w(x, y) * f(x, y) = \sum_{i=-a}^a \sum_{j=-b}^b w(i, j) f(x+i, y+j) \quad (1)$$

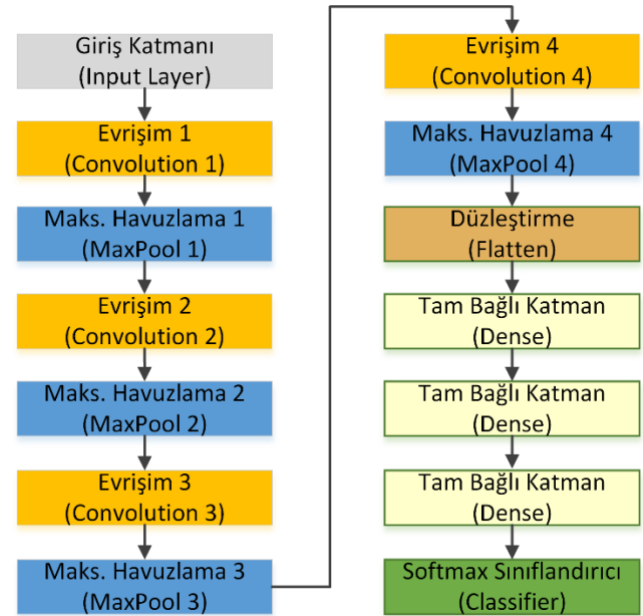
Havuzlama katmanı: Bu katmanı, ağ içindeki parametreleri azaltır, hesaplama yükünü azaltmak için kullanılır. Maksimum havuzlamada, filtre penceresinde kalan piksel değerlerinin en yüksek olanı ve ortalama havuzlama işleminde, filtre penceresindeki tüm piksel değerlerinin ortalaması çıktı pikselinde tek bir değer olarak tutulur. Havuzlama işleminin sonunda görüntünün en boy oranı azaltılır. Bu süreçte piksel değerlerinde kayıplar olur, ancak bu kayıplar sonraki katmanlar için daha az hesaplama yükü oluşturur.

Düzleştirme katmanı: Yukarıda bahsi geçen katmanlar evrişim ve havuzlama art arda birden fazla kez uygulanabilir. Bu işlemlerden sonra elde edilen matrisin tam bağlı katmanda kullanılması için düzleştirilmesi gerekmektedir.

Tam bağlı katman: Tam bağlantılı katman, genellikle ESA'nın sonunda bulunur ve sınıflandırma işlemlerinde kullanılır. Bu katman sınıf skorlarını optimize etmek için kullanılır. Ayrıca, burada gizli katman sayısı derin öğrenmeye dayalı mimarilerde farklılık gösterebilir. Belli eşik değer altındaki düğümlerin bırakılması ya da seyreltilmesinin (dropout) öğrenmede başarıyı arttırmaktadır. Bir başka ifade ile zayıf bilgilerin unutulması öğrenimi arttırmaktadır [19, 20].

$$\text{soft max}(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}; j = 1, \dots, K \quad (2)$$

Sınıflandırma: Sınıflandırma katmanı, sınıflandırma işleminin gerçekleştirildiği ESA modelinin son katmanıdır. Bu katmanın çıktı değerleri tanınacak nesnelere sayısına göre değişir ve sınıfların sayısına eşittir. Aktivasyon fonksiyonları, ağ değişkenleri arasındaki herhangi bir sürekli ve karmaşık ilişkiyi öğrenmek için kullanılır. Ayrıca, ağdaki doğrusallığı önlemek için ReLU aktivasyon fonksiyonu kullanılır. ESA mimarisinde tam bağlantılı katmanda çok sınıflı sınıflandırmaya ihtiyaç duyulduğundan, denklem (2) 'de verildiği gibi bir softmax fonksiyonu kullanılmaktadır. Bu fonksiyon ile kurulan Softmax sınıflandırıcısı, ESA mimarilerine sıkça kullanılır. Bu sınıflandırıcı, her sınıf için 0-1 arasında olasılıklı değerler üretir. Sonuç olarak, en yüksek olasılık değeri, model tarafından tahmin edilen sınıfı verir [19, 20].



Şekil 5. Bu çalışmada önerilen Derin Evrişimli Sinir Ağı (Derin ESA) mimarisi.

Bir ESA mimarisinin Şekil 5'te gösterildiği gibi iki ana bölümü vardır: (1) Öznitelik çıkarma adı verilen işlemde, görüntünün çeşitli özniteliklerini ayıran ve tanımlayan bir evrişim kümesi (evrişim-havuzlama) yapılır. (2) Sınıflandırma, evrişim sürecinden elde edilen çıktıyı kullanan ve önceki aşamalarda çıkarılan özniteliklere göre görüntünün sınıfını tahmin eden tam bağlı katman kurulur. Evrişimli katmanlar, havuz katmanları ve tam bağlı katmanlar bir ESA'yı oluşturur [17]. Bu katmanlar art arda getirildiğinde bir ESA mimarisi oluşur. Bu üç katmana ek olarak, bırakma (dropout) katmanı ve aktivasyon fonksiyonu olmak üzere iki önemli parametre daha bulunmaktadır [21].

Bu çalışmada önerilen model, Şekil 5'te görüldüğü gibi dört küme evrişim havuzlama ağı, bir düzleştirilmiş katmanı, üç tam bağlı katman ve bir sınıflandırıcıdan oluşur. Şekil 5'te gösterildiği gibi önerilen ESA mimarisinde, 1 giriş katmanı, 4 evrişim (konvolüsyon) katmanı, 4 havuzlama katmanı, üç tam bağlantılı katmanı ve 1 çıkış katmanından oluşur. Birinci konvolüsyon katmanında 3×3 boyutunda 64 adet konvolüsyon filtresi, ikinci konvolüsyon katmanında 3×3 boyutunda 256 adet konvolüsyon filtresi, üçüncü konvolüsyon katmanında 3×3 boyutunda 512 adet konvolüsyon filtresi, dördüncü konvolüsyon katmanında ise 3×3 boyutunda 512 adet konvolüsyon filtresi mevcuttur. Tüm evrişim katmanlarından sonra ReLU aktivasyon fonksiyonu uygulanmıştır. Ayrıca her konvolüsyon ve ReLU işleminden sonra adım kaydırma sayısı (stride=2) alınarak 3×3 filtre boyutlu maksimum havuzlama yapılmıştır. Bu aşamadan sonra çok boyutlu öznitelik kümesinin düzleştirilmesi (flattening) yapılarak, tek boyutlu bir dizin şekline dönüştürülerek bir sonraki tam bağlı katmanlara girdi olarak iletimi yapılır. Tam bağlı ilk iki katmanın her birinde toplam 4096 nöron bulunmaktadır. Son tam bağlı katmanda ise verideki sınıf sayısına bağlı olarak üç tane nöron bulunmaktadır. Eğitim deneylerinde, eğitim iterasyon (epoch) sayısı 50, yığın boyutu (batch size) 128 olarak ayarlanmıştır. Derin öğrenmede hatayı en aza indirmek için kullanılan optimizasyon algoritmalarından en popüler olanlardan biri olan, gradyan iniş tabanlı Adam optimizasyon algoritması tercih edilmiştir. Bu aşamada, tasarımı yapılan derin ESA mimarisi toplam 374,905,859 parametreye sahiptir.

Ağ değişkenleri arasındaki her türlü sürekli ve karmaşık ilişkiyi öğrenmek ve tahmin etmek için aktivasyon fonksiyonları kullanılır. Tanh, Sigmoid,


ReLU ve Softmax literatürde yaygın olarak kullanılan aktivasyon fonksiyonlarıdır. Sinir ağlarında ağın genelleme performansı aktivasyon fonksiyonuna göre değişkenlik gösterebilir. Bu bağlamda, ReLU aktivasyon fonksiyonu derin sinir ağlarında sıklıkla tercih edilir ve ağın hızlı öğrenmesi ayrıca yüksek sınıflandırma başarısı vermesini sağlar [22]. Bu çalışmada; Sigmoid, ReLU, Sigmoid+ReLU, Relu+Sigmoid ve ReLU+Softmax gibi farklı aktivasyon fonksiyonları yüksek sınıflandırma başarısı elde etmek için test edilmiştir. Bu çalışmada, ağda doğrusalığın önüne geçmek için ReLU aktivasyon fonksiyonu kullanılmıştır. ESA mimarisinde, tam bağlı katmanda çok sınıflı sınıflandırmaya ihtiyaç duyulduğundan softmax fonksiyon kullanılmıştır. Yapılan deneysel çalışmalarda, evrişim katmanlarında ReLU ve çıkış katmanında Softmax kullanılması ile en yüksek doğruluk oranına (%96.23) ulaşılmıştır. Genellikle, tüm öznitelikler tam bağlı katmanına bağlandığında, eğitim veri kümesinde aşırı öğrenme (overfitting) durumu olabilir. Aşırı öğrenme, belirli bir model eğitim verileri üzerinde çok iyi çalıştığında ortaya çıkar ve yeni bir veri üzerinde kullanıldığında modelin performansında olumsuz bir etkiye neden olur. Bunun önüne geçmek için bu çalışmada, dropout değeri 0,3 (%30) olarak belirlenmiştir.

3 Deneysel Çalışmalar

Bu çalışmada önerilen Derin ESA modeli, ilgili kütüphaneler ile birlikte Python 3.7 kullanılarak gerçekleştirildi. Deneysel çalışmanın yapıldığı masaüstü bilgisayarı, Intel (R) Core (TM) i7 8700U CPU @ 3.20 GHz işlemcili, 4 GB NVIDIA GeForce GTX 1050 Ti ekran kartlı ve 16GB birincil belleğe sahiptir. Test işlemi yapılmadan önce tüm görüntüler modele aktarılmadan önce 256×256 boyutunda tek tip olarak yeniden boyutlandırıldı. Bu aşamada veriler farklı büyüklükte bölünerek iki tür deney yapıldı. Birinci deneysel çalışmada veriler (Deney1); %85 eğitim, %10 doğrulama ve %5 test için ayrılmıştır. İkinci deneysel çalışmada veriler (Deney2); %70 eğitim, %10 doğrulama ve %20 test için ayrılmıştır. Bu bölümde her iki deneye yönelik performans değerlendirmelerine yer verilmiştir.

Bu aşamada önerilen derin ESA modelinin performansı farklı değerlendirme ölçütleri ile yapıldı. Farklı ağların performansı, kesinlik (precision), duyarlılık (recall), F1-skoru, doğruluk (accuracy) gibi dört performans ölçütü kullanılarak değerlendirildi. Bu değerler, her bir sınıf için hata matrisleri üzerinden hesaplanır. Hata matrisi ile

sınıflandırma algoritmalarının performansı değerlendirilir [23, 24]. Şekil 6'da her bir deney (Deney1, Deney2) için örnek bir hata matrisleri verilmiştir. Tablo 1'de görüldüğü gibi her iki deney verisi için Şekil 6'daki hata matrislerinden elde edilen örnek bir performans değerlendirmesi yapılmıştır. Örneğin, her iki deneysel çalışmada da önerilen ESA modeli ile elde edilen doğruluk değeri yaklaşık olarak %96'dır.



Şekil 6. Model ile iki farklı deneyden elde edilen örnek hata (confusion) matrisleri.

Tablo 1. Derin ESA modeli ile Şekil 5'deki hata matrislerinden elde edilen örnek bir performans değerlendirmesi

| | Kesinlik | Duyarlılık | F1-Skoru | Doğruluk |
|---------------|----------|------------|----------|--------------|
| Deney1 | 96.13 | 96.01 | 96.06 | 95.92 |
| Deney2 | 96.12 | 96.02 | 96.07 | 96.02 |

Şekil 7 ve Şekil 8'de bu çalışmada önerilen Derin ESA modeli ile sırasıyla Deney1 ve Deney2'den elde edilen (50 iterasyon için) eğitim/test doğruluk ve eğitim/test kayıp grafikleri verilmiştir. Hem test hem de eğitim doğruluk eğrileri, iterasyon sayısı arttıkça yükselen bir eğim gösterir. Kayıp eğrisi, Şekil 6 ve Şekil 7'de gösterildiği gibi hata oranındaki düşüşü göstermektedir. Eğitim sürecinin ve ağıın öğrenilmesinin iyi bir öğrenme oranında olduğunu göstermektedir. Şekil 7 ve Şekil 8'de görüldüğü gibi her iterasyonda kayıp değeri azalırken verilen eğitim seti ile doğruluk oranı artar ve öğrenme gerçekleşir.

Bu aşamada, önerilen derin ESA modelinin performansını kıyaslamak için diğer evrişimli sinir ağıları tabanlı modeller (VGG19, Inception V3 ve ResNet50) ile karşılaştırması yapılmıştır. Deneysel çalışmalarda, modellerin performanslarının geçerliliğini artırmak için 10-kat çapraz geçirme (cross validation) kullanılmıştır. Deney1 ve Deney2 için ayrı ayrı yöntemlerin doğrulukları on kat çapraz doğrulama kullanılarak test edilmiştir. Her bir model için on katlı çapraz geçirme sonucunda

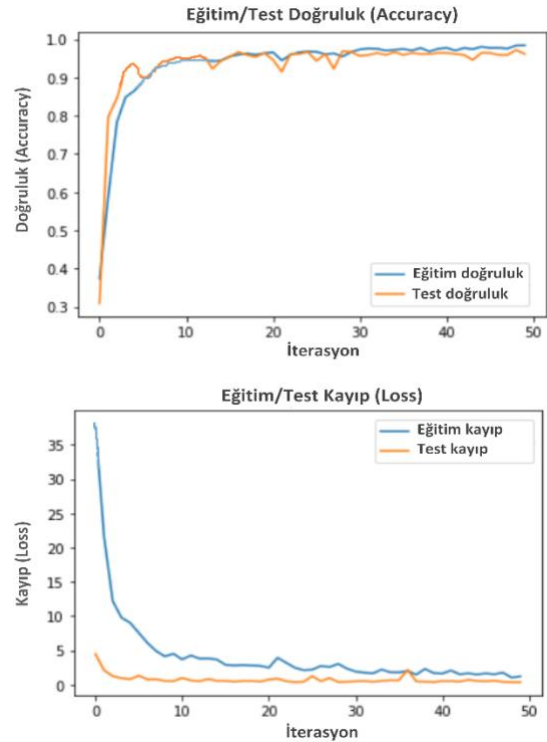
ortalama doğruluk oranları çıkarılmıştır. Tablo 2'de Deney1 için ve Tablo 3'de Deney2 için evrişimli sinir ağıları tabanlı VGG19, Inception V3 ve ResNet50 gibi farklı modeller ile önerilen ESA modelin ortalama doğruluk oranları her bir ölçüt için verilmiştir. Her iki deneysel çalışmada da önerilen ESA modeli ile elde edilen doğruluk değeri yaklaşık olarak %96'dır. Bu çalışmada önerilen derin ESA modelinin diğer ESA tabanlı modellerden daha iyi performans gösterdiği gözlemlenmiştir.

Tablo 2. Deney1 için derin ESA modelinin diğer ESA tabanlı modeller ile karşılaştırılması

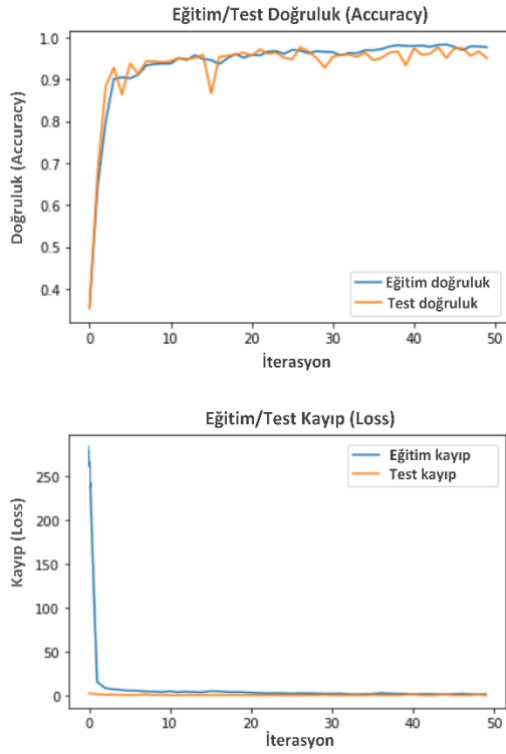
| | Kesinlik | Duyarlılık | F1-Skoru | Doğruluk |
|---------------------|----------|------------|----------|--------------|
| Derin ESA | 96.03 | 95.91 | 95.94 | 95.90 |
| VGG19 | 94.75 | 94.30 | 94.44 | 94.29 |
| Inception V3 | 91.96 | 91.73 | 91.80 | 91.75 |
| ResNet50 | 90.65 | 89.64 | 89.96 | 89.69 |

Tablo 3. Deney2 için derin ESA modelinin diğer ESA tabanlı modeller ile karşılaştırılması

| | Kesinlik | Duyarlılık | F1-Skoru | Doğruluk |
|---------------------|----------|------------|----------|--------------|
| Derin ESA | 96.22 | 96.09 | 96.15 | 96.10 |
| VGG19 | 94.86 | 94.41 | 94.54 | 94.39 |
| Inception V3 | 92.03 | 91.83 | 91.91 | 91.84 |
| ResNet50 | 90.75 | 89.74 | 90.05 | 89.80 |



Şekil 7. Deney1'den elde edilen eğitim/test doğruluk ve eğitim/test kayıp grafikleri.



Şekil 8. Deney2'den elde edilen eğitim/test doğruluk ve eğitim/test kayıp grafikleri.

4 Tartışma ve Sonuç

Akciğer X-ray görüntüleri, zatürre ve COVID-19 vakalarının erken tanınmasına yardımcı olmaktadır. Ancak, çeşitli viral pnömoni (zatürre) görüntüleri COVID-19 görüntülerine benzerdir ve benzer ortak özellikler içermektedir. Bundan dolayı radyologların benzer diğer akciğer hastalıklarını COVID-19'dan ayırt etmesi zorlaşmaktadır. COVID-19 semptomlarının viral pnömoniye benzer olması bu bağlamda yanlış tanıya yol açabilmektedir. Bu çalışmada, derin evrişimli bir sinir ağı modeli sunulmuş olup, açık erişimli akciğer X-ray görüntüleri üzerinde deneysel çalışmalar gerçekleştirilmiştir. Bu veri kümesinde, COVID-19, Normal ve Viral Pnömoni olmak üzere üç sınıfa ait toplam 3886 görüntü bulunmaktadır. Bu amaçla, bu çalışmada akciğer X-ray görüntülerini COVID-19, normal ve viral pnömoni (zatürre) hastalar olarak sınıflandırabilen bir derin ESA modeli uygulanmıştır. Bu çalışmada verinin farklı miktarlarda eğitim, doğrulama ve test için ayrılması ile iki farklı türde deneysel çalışmalar gerçekleştirilmiştir. Önerilen ESA modelinin doğruluğu üzerine performans değerlendirmeleri yapılmış olup ayrıca sonuçlar VGG19, Inception V3 ve ResNet50 gibi son teknoloji derin öğrenme

tabanlı yaklaşımlarla karşılaştırılmıştır. Yapılan deneysel çalışmalarda, evrişim katmanlarında ReLU ve çıkış katmanında Softmax kullanılması ile en yüksek doğruluk oranına ulaşılmıştır. Deneysel çalışmalarda, önerilen derin ESA modeli ile doğruluk değeri ortalama %96 olmuştur. İleri çalışmalarda daha fazla derin öğrenme tabanlı diğer modeller ve daha fazla veri üzerinde çalışmalar gerçekleştirilecek ve karşılaştırmalar yapılacaktır.

Kaynaklar

- [1] Organization W. H., "Global COVID-19 report," March 25, 2020.
- [2] Medicine J. H. U., Coronavirus COVID-19 Global Cases by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University (JHU), accessed on Jan. 2021. [Online]. Available: <https://coronavirus.jhu.edu/map.html>
- [3] News A. J., India's poor testing rate may have masked coronavirus cases. accessed on Mar. 2020. [Online]. Available: <https://www.aljazeera.com/news/2020/3/18/india-s-poor-testing-rate-may-have-masked-coronavirus-cases>
- [4] Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., ... & Islam, M. T., "Can AI help in screening viral and COVID-19 pneumonia?", IEEE Access, 8, 132665-132676, 2020.
- [5] Mangal, A., Kalia, S., Rajgopal, H., Rangarajan, K., Namboodiri, V., Banerjee, S., & Arora, C., "CovidAID: COVID-19 detection using chest X-ray", arXiv preprint arXiv:2004.09803, 2020.
- [6] El Asnaoui, K., & Chawki, Y., "Using X-ray images and deep learning for automated detection of coronavirus disease", Journal of Biomolecular Structure and Dynamics, 1-12, 2020.
- [7] Apostolopoulos, I. D., & Mpesiana, T. A., "Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks", Physical and Engineering Sciences in Medicine, 43(2), 635-640, 2020.
- [8] Abbas, A., Abdelsamea, M. M., & Gaber, M. M., "Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network", Applied Intelligence, 51(2), 854-864, 2021.
- [9] Rahimzadeh, M., & Attar, A., "A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2", Informatics in Medicine Unlocked, 19, 100360, 2020.
- [10] Narin, A., Kaya, C., & Pamuk, Z., "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks", arXiv preprint arXiv:2003.10849, 2020.

- [11] Majeed, T., Rashid, R., Ali, D., & Asaad, A., "Covid-19 detection using cnn transfer learning from x-ray images", medRxiv, 2020.
- [12] Rafi, T. H., "An ensemble deep transfer-learning approach to identify COVID-19 cases from chest X-ray images", In 2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB) (pp. 1-5). IEEE, 2020.
- [13] Hemdan, E. E. D., Shouman, M. A., & Karar, M. E., "Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images", arXiv preprint arXiv:2003.11055, 2020.
- [14] Wang, L., Lin, Z. Q., & Wong, A., "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images", Scientific Reports, 10(1), 1-12, 2020.
- [15] Bozkurt, F., "Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti", Avrupa Bilim ve Teknoloji Dergisi, (24), 149-156, 2021.
- [16] T. R. Muhammad E. H. Chowdhury, Amith Khandakar, Rashid Mazhar, Muhammad Abdul Kadir, Zaid Bin Mahbub, Khandakar R. Islam, Muhammad Salman Khan, Atif Iqbal, Nasser Al-Emadi, Mamun Bin Ibne Reaz. (2020), Covid-19 Chest X-Ray Database, Available: <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
- [17] Oğuz Ç. & Yağanoğlu, M., "Determination of Covid-19 Possible Cases by Using Deep Learning Techniques", Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 7-17, 2021.
- [18] Krizhevsky, A., Sutskever, I., & Hinton, G. E., "Imagenet classification with deep convolutional neural networks", Advances in neural information processing systems, 25, 1097-1105, 2012.
- [19] Meunier, L. C. V., & Chandy, D. A., "Design of convolution neural network for facial emotion recognition", In 2019 2nd International Conference on Signal Processing and Communication (ICSPC), pp. 376-379, IEEE, 2019.
- [20] Umer, M., Ashraf, I., Ullah, S., Mehmood, A., & Choi, G. S., "COVINet: a convolutional neural network approach for predicting COVID-19 from chest X-ray images", Journal of Ambient Intelligence and Humanized Computing, 1-13, 2021.
- [21] Uçkun F. A., Özer H., Nurbaş E., and Onat E., "Direction Finding Using Convolutional Neural Networks and Convolutional Recurrent Neural Networks", 2020 28th Signal Processing and Communications Applications Conference (SIU), Gaziantep, Turkey, pp. 1-4, 2020.
- [22] Yıldız, O., "Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study", Journal of the Faculty of Engineering and Architecture of Gazi University, 34(4), 2241-2260, 2019.
- [23] Candan, H., Durmuş, A., & Harman, G., "Genetik Algoritma Ve Sınıflandırıcı Yöntemler İle Kanser Tahmini", Veri Bilimi, 2(1), 30-34, 2019.
- [24] Bozkurt, F., Çoban, Ö., Baturalp Günay, F., & Yücel Altay, Ş., "High Performance Twitter Sentiment Analysis Using CUDA Based Distance Kernel on GPUs", Tehnički vjesnik, 26(5), 1218-1227, 2019.