



Pneumonia detection on chest x-ray images using residual convolutional neural network

İpek Atik*

Department of Electrical and Electronics Engineering, Faculty of Engineering and Natural Sciences, Gaziantep Islam Science and Technology University, 27000, Gaziantep, Türkiye

Highlights:

- An effective CNN model has been proposed for detecting pneumonia.
- It has been shown that pneumonia disease can be classified with high performance by deep learning method.
- The study will save time and the number of specialists in the detection of pneumonia

Keywords:

- Chest x-ray image
- Pneumonia,
- Classification
- CNN
- Residual block

Article Info:

Research Article
Received: 27.03.2023
Accepted: 29.08.2023

DOI:

10.17341/gazimmfd.1271385

Correspondence:

Author: İpek Atik
e-mail:
ipek.atik@gibtu.edu.tr
phone: +90 553 282 2826

Graphical/Tabular Abstract

Early diagnosis of the disease is very important in the fight against pneumonia, which causes serious deaths every year all over the world. Today, machine learning methods are used in many fields as well as in the field of health. In the study, an effective CNN model was developed for the detection of pneumonia from chest X-ray images. First, the 3D chest X-ray images in the dataset were dimensioned by preprocessing. Then the CNN model was developed and the hyperparameters of the model were determined. The network was trained with the training data, the performance of the model was measured with validation, and the test data images that the model never saw were classified as normal and pneumonia. The flow chart for the classification study is given in Figure A.




Figure A. Flow chart of the study

Purpose:

Thanks to the CNN model developed in this study, it is aimed to detect the disease without loss of time in cases where the number of specialist radiologists is not sufficient.

Theory and Methods:

The proposed model is designed using a transfer learning approach with pre-trained ResNet. With the residual block connections used in the model, the performance of the deep learning architecture has been increased.

Results:

According to the analyzes performed, the accuracy, specificity, sensitivity, precision and F-1 score values of the proposed method were 98.42%, respectively; 97.52%; 99.35%; It was obtained as 97.47% and 98.90%.

Conclusion:

When the results obtained from the analyzes are examined, it is revealed that the proposed method is successful in detecting pneumonia from chest X-ray images.



Mühendislik Mimarlık Fakültesi Dergisi

Journal of The Faculty of Engineering
and Architecture of Gazi University

Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Artık evrişimli sinir ağı kullanılarak göğüs röntgeni görüntülerinde pnömoni tespiti

İpek Atik*^{ID}

Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 27000, Gaziantep, Türkiye

Ö N E Ç İ K A N L A R

- Pnömoni tespitinde efektif bir ESA modeli önerilmiştir
- Pnömoni hastalığının derin öğrenme yöntemi ile yüksek başarımla sınıflandırılabilceği gösterilmiştir
- Çalışma pnömoni tespitinde nitelikli iş gücüne destek olacak bir yöntem önerilmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 27.03.2023

Kabul: 29.08.2023

DOI:

10.17341/gazimmfd.1271385

Anahtar Kelimeler:

Göğüs röntgen görüntü,
pnömoni,
sınıflandırma,
ESA,
artık blok

ÖZ

Pnömoni hastalığı akciğer dokusunun iltihaplanması neticesinde ortaya çıkan bir göğüs hastalığıdır. Pnömoni her yaşta görülebilmekle birlikte iki yaş altı ve altmış beş yaş üstü kişilerde oldukça tehlikelidir. Dünya Sağlık Örgütü verilerine göre dünyadaki tüm ölümlerin yaklaşık yüzde %7'si kadarının pnömoni nedeniyle olduğu belirtilmektedir. Hastalıktan kaynaklı ölüm oranlarının azaltılmasında hastalığın erken teşhisi ve tedavisi önemli bir etkidir. Çalışmada üç boyutlu (3D) göğüs röntgen görüntülerinden pnömoni tespiti için etkin bir evrişimli sinir ağı (ESA) modeli önerilmiştir. Önerilen model, ön eğitilmiş ResNet ile transfer öğrenme yaklaşımı kullanılarak tasarlanmıştır. Modelde artık blok bağlantıları ile derin öğrenme mimarisindeki bazı katmanlar atlanarak performansı artırılmıştır. Analizlerde 5617 X-Ray görüntüsünden oluşan, pnömoni ve normal etiketli, açık erişim veri seti kullanılmıştır. Önerilen yöntemin performansı, üç farklı modelle karşılaştırılmıştır. İlk model, basit bir ESA modelidir. İkinci model, önerilen modelden bazı blokların çıkarıldığı bir ESA modelidir. Üçüncü model ise ResNet-18 olarak bilinen yaygın olarak kullanılan bir ön eğitilmiş ağı temsil etmektedir. Yapılan analizlere göre önerilen yöntemin doğruluk, özgüllük, hassasiyet, kesinlik ve F-1 skoru değerleri sırasıyla %98,42; %97,52; %99,35; %97,47 ve %98,90 olarak elde edilmiştir. Analizlerden elde edilen sonuçlar incelendiğinde, önerilen yöntemin göğüs röntgen görüntülerinden pnömoni tespitinde başarılı olduğunu ortaya koymaktadır.

Pneumonia detection on chest x-ray images using residual convolutional neural network

H I G H L I G H T S

- An effective CNN model has been proposed for detecting pneumonia
- It has been shown that pneumonia disease can be classified with high performance by deep learning method
- The study will save time and the number of specialists in the detection of pneumonia

Article Info

Research Article

Received: 27.03.2023

Accepted: 29.08.2023

DOI:

10.17341/gazimmfd.1271385

Keywords:

Chest x-ray image,
pneumonia,
classification,
CNN,
residual block

ABSTRACT

Pneumonia is a chest disease that occurs as a result of inflammation of the lung tissue. Although pneumonia can occur at any age, it is quite dangerous in people under the age of two and over the age of sixty-five. According to World Health Organization data, approximately 7% of all deaths in the world are due to pneumonia. Early diagnosis and treatment of the disease is an important factor in reducing mortality rates due to the disease. In the study, an effective convolutional neural network (ESA) model was proposed for pneumonia detection from three-dimensional (3D) chest x-ray images. The proposed model is designed using transfer learning approach with pre-trained ResNet. The performance of the model has now been increased by skipping block connections and some layers in the deep learning architecture. An open access dataset consisting of 5617 X-Ray images, labeled pneumonia and normal, was used in the analysis. The performance of the proposed method is compared with three different models. The first model is a simple ESA model. The second model is an ESA model in which some blocks are removed from the proposed model. The third model represents a widely used pre-trained network known as ResNet-18. According to the analysis, the accuracy, specificity, sensitivity, precision and F-1 score values of the proposed method are 98.42%, respectively; 97.52%; 99.35%; It was obtained as 97.47% and 98.90%. When the results obtained from the analyzes are examined, it is revealed that the proposed method is successful in detecting pneumonia from chest X-ray images.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *ipek.atik@gibtu.edu.tr / Tel: +90 553 282 2826

1. Giriş (Introduction)

Halk arasında zatürre olarak bilinen pnömoni hastalığı akciğerdeki hava keseciklerinin iltihaplı bir sıvı ile dolmasıdır. Oldukça bulaşıcı bir hastalık olan pnömoni, virüsler, bakteriler ve nadir olarak mantar enfeksiyonlarının akciğerlere ulaşmasıyla meydana gelir [1]. Dünyada her yıl yaklaşık 4 milyon insanın ölümüne sebep olmaktadır. Havalarda soğudukça hastalığın görülme sıklığı da artar [2]. Hastalığın belirtileri, çok hızlı nefes alma, hırıltılı seslerle nefes almak, ateş, öksürük ve göğüs ağrısıdır. Hastalığın tedavisinde geç kalındığı zaman ölümle sonuçlanabilir. Hastalığın erken teşhis edilip tedaviye başlanması hastalıkla mücadelede önemli unsurdur [3].

Günümüzde pnömoni teşhisinde en sık kullanılan yöntem göğüs radyografi görüntüleridir. Göğüs radyografisi, hastalık tespitinde kullanılan diğer yöntemlere göre daha az radyasyon sağlaması ve maliyetinin düşük olması sebebi ile tercih sebebidir [4]. Hastalık durumunu hızlı şekilde gösterebilen düşük maliyetli bir testtir. Ayrıca diğer yöntemler olan bilgisayarlı tomografi ve manyetik rezonans görüntülemeye oranla daha düşük radyasyon vermesi yönüyle tercih sebebidir [5]. Pnömoni görüntüleri yorumlayacak uzman sayısının az olması ve pnömoni görüntülerinin çok net olmaması neticesinde uzman teşhislerinde hatalar meydana gelebilir. Bu nedenle hızlı ve güvenilir şekilde pnömoni teşhisi için bilgisayar destekli tanı sistemlerine ihtiyaç vardır. Gelişen derin öğrenme yöntemleri bu alanda uzmanlara oldukça yardımcı olmaktadır [6].

Çalışmanın Önemi

Göğüs hastalıklarının erken teşhisi, hastalığın başarılı tedavisi için çok önemlidir. Son yıllardaki teknolojik gelişmeler ile hastalıkların teşhisinde makine öğrenmesi ve görüntü işleme yöntemleri yaygın olarak kullanılmaktadır [7, 13]. Bu çalışmada artık blok bağlantılı ESA modeli geliştirilmiştir. Artık blok bağlantılar, ağıın bir katmanından diğerine direkt geçişi sağlar ve temelde ağıın çıktısını doğrudan girişe ekleyerek bir tür "artıklık" oluşturur. Modelde kullanılan artık blok bağlantıların avantajları aşağıdaki şekilde sıralanabilir;

- Gradyanın daha etkili akışı: Derin sinir ağları, eğitim sırasında gradyanın geri yayılmasıyla öğrenir. Ancak, bu gradyan geriye doğru aktarım sırasında azalabilir ve bazı durumlarda "gradyan kaybolması" olarak adlandırılan bir soruna yol açabilir. Artık blok bağlantılar, ağıın daha derin katmanlarına doğrudan geçiş sağladığından, gradyanın daha etkili bir şekilde akmasını sağlayarak bu sorunu hafifletebilir.
- Ağıın daha derin olabilmeli: Geleneksel sinir ağlarında, ağıın derinliği arttıkça eğitim zorlaşabilir ve performans düşebilir. Artık blok bağlantılar, ağıın daha derin olabilmeliğini sağlar çünkü gradyanlar daha iyi akar ve ağıın daha derin kısımlarında daha iyi öğrenme gerçekleşebilir. Bu, daha karmaşık görevleri çözebilen daha derin ağı yapılarının oluşturulabilmesini sağlar.
- Ağıın daha iyi genelleme yapabilmesi: Artık blok bağlantılar, ağıın daha iyi genelleme yapabilmesine yardımcı olabilir. Genellikle, bir ağıın daha fazla parametreye sahip olması, eğitim verilerine aşırı uyum sağlama (overfitting) riskini artırır. Ancak artık blok bağlantılar, ağıın daha derin olmasına izin vererek daha genel özelliklerin öğrenilmesine katkıda bulunabilir ve ağıın daha iyi genelleme yapabilmesini sağlayabilir.

Çalışmada geliştirilen model ile artık blokların avantajlarından faydalanılarak modelin performansını arttırmak amaçlanmıştır. Çalışmada önerilen modeldeki artık blok bağlantıları çıkarılmış ve o şekilde de analizler yapılmıştır. Böylece artık blok bağlantıların avantajlarının performans üzerindeki etkisi numerik değerlerle de görülmüştür.

Bu çalışmanın ilerleyen bölümleri şu şekildedir. Bölüm 2'de literatür taraması yapılmıştır. Bölüm 3'te deneysel metod kısmında kullanılan veri seti, önerilen yöntem hakkında açıklamalar vardır. Bölüm 4'te sonuçlar ve tartışmalar geniş şekilde verilmiştir. Bölüm 5'te ise çalışmadan elde edilen sonuçlar özetlenmiştir. Çalışmanın son kısmında ise gelecek çalışmalardan bahsedilmiştir.

2. Literatür Taraması (Literature Review)

Son yıllarda bilim insanları geliştirilen yapay zekâ ve derin öğrenme yöntemlerini sağlık alanındaki çalışmalara entegre etmeye çalışmaktadır. Araştırmacılar cilt bozuklukları, beyin ve meme kanseri, diyabet hastalıkları gibi birçok hastalıkta segmentasyon ve sınıflandırma çalışmalarında ESA yapılarında faydalanmaktadır. Radyologlar ve bilgisayar bilimcileri bilgisayar destekli tanı kullanarak tüberküloz, sıtma ve zatürre gibi mikrobiyal hastalıkları tespit etmek için birlikte çalışmaktadır [8, 9]. Literatürde pnömoni hastalık tespiti için yapılan bilgisayar destekli çalışmalar aşağıda özetlenmiştir.

Wang vd. [10], araştırmasında önce bir yöntem olarak evrişimli sinir ağlarını (ESA) kullanmış, ardından başarıyı artırmak için ResNet-50 modeli ile çalışmıştır. NIH Klinik Merkezi'ndeki göğüs radyografisi verilerini kullanmış ve ResNet-50 modeli ile AUC değerini 0.633 olarak elde etmiştir. Yao vd. [11], RNN (Recurrent Neural Network) yöntemi ile göğüs röntgeni-14 veri setini kullanarak AUC değerini 0.713 olarak bulmuştur. Rajpurkar vd. [12], yoğun bir evrişim ağı (DenseNet) kullanarak oluşturduğu, CheXNet olarak adlandırdığı modelinde ChestX-ray14 veri setini kullanmıştır. Modelde aktivasyon fonksiyonu olarak bir sigmoid aktivasyon fonksiyonu kullanılmıştır. Ağırlıklar için ImageNet'in önceden tanımlanmış model ağırlıklarını bir başlangıç noktası olarak kullanmıştır.

Rubin [14], MIMIC-CXR veri setini kullanarak göğüs hastalıklarının tespiti için iki ESA modeli sunmuştur. Çalışmada AUC değerini 0,72 olarak elde edilmiştir. Gülgün and Erol [15], yaptıkları çalışmada akciğer röntgen görüntülerinden pnömoni tespiti için farklı derin öğrenme modellerini karşılaştırmıştır. Çalışmada veri olarak 5840 göğüs röntgen görüntüsü kullanılmıştır. Bu verileri sınıflandırmak için ESA, veri çoğaltmalı ESA ve transfer öğrenimi modelleri kullanmıştır. Karşılaştırma sonucunda en iyi başarı oranı %93,4 olan veri büyütme tekniği ile uygulanan evrişimli sinir ağı modeli ile ulaşılmıştır. Uçar [16], Gaussian Laplace (LoG) filtresi ile derin öğrenme kullanarak konvolüsyon yoluyla akciğer nodüllerini X-ray görüntülerinden tanımlama çalışmıştır. Çalışmada Japonya Radyoloji Teknolojileri Derneği'ne ait kamuya açık göğüs röntgeni görüntüleri kullanılmıştır. Gauss Laplace filtre modelini kullanan evrişimli sinir ağı modeli ile %83 başarı oranı elde edilmiştir.

Varshni vd. [17], öznetelik çıkarıcı olarak önceden eğitilmiş ESA modellerini kullanmışlardır. En uygun ESA modelini belirlemek için anormal ve normal göğüs röntgeni görüntüleri farklı makine öğrenme algoritmaları kullanılarak sınıflandırılmıştır. Sirazitdinov [18], akciğer radyografisinde pnömoninin otomatik tespiti ve lokalizasyonu için ESA modeli geliştirmiştir. Veri seti olarak Kaggle'dan 26684 görüntüden oluşan açık erişim veri seti kullanılmış ve %79 duyarlılık değeri elde edilmiştir. Rahman vd. [19], dijital radyografi kullanarak bakteriyel ve viral pnömoniyi otomatik olarak tespit etmeyi amaçlamıştır. Önceden eğitilmiş AlexNet, ResNet-18, DenseNet-201 ve SqueezeNet modelleri kullanılmış ve veriler transfer öğrenme sürecine girmeden önce ön işleme tabi tutulmuştur. Model başarısı %98 olarak elde edilmiştir. Jain vd. [20], çalışmalarında radyograflardan pnömoniyi tespit etmek için ESA modellerini kullanmıştır. Farklı hiper parametreleri ve evrişim katmanlarının sayısını değiştirerek ESA modellerini eğitmişlerdir. Altı farklı

modelle yapılan bir çalışmada en iyi değer olarak %92 doğruluk oranı elde edilmiştir. Bahsedilen literatür çalışmaları aşağıda Tablo 1’de özetlenmiştir.

Yapılan çalışmalardan görüldüğü üzere pnömoni tespitinde bilgisayar destekli çalışmalar giderek artmaktadır. Geliştirilen modeller, farklı veri setleri kullanımı, görüntü işleme yöntemleri gibi tekniklerle sınıflandırma başarısının artırılması amaçlanmıştır.

3. Deneysel Metot (Experimental Method)


Görüntü sınıflandırma çalışmalarında yüksek performans göstermesi sebebi ile tercih edilen ESA modelleri evrişim, havuzlama, tam bağlantı katmanları ve aktivasyon fonksiyonu gibi yapıları içerir [21-24]. Bu yapılar ağırlık niteliklerini artırarak öğrenme yeteneğini artırır [25-27]. Bu çalışmada ilk olarak veri setindeki 3D göğüs röntgen görüntüleri için ön işleme ile boyutlandırma yapılmıştır [32]. Daha sonra ESA modeli geliştirilmiş ve modelin hiper parametreleri belirlenmiştir. Eğitim verileri ile ağ eğitilmiş, doğrulama ile modelin performansı ölçülmüş ve modelin hiç görmediği test verileri görüntüler normal ve pnömoni olarak sınıflandırılmıştır. Şekil 1’de sınıflandırma çalışması için akış şeması verilmiştir.

3.1. Veri Seti (Dataset)


Çalışmada veri seti olarak 5617 X-Ray görüntüsünden oluşan, pnömoni ve normal olarak iki sınıflı, açık erişim veri seti kullanılmıştır [33]. Röntgen görüntüleri Guangzhou Kadın ve Çocuk Tıp Merkezi’ne ait bir ila beş yaşındaki pediatrik hastaların retrospektif kohortlarından seçilmiştir. Veri setinde bulunan görüntülerin doğruluğu uzmanlar tarafından kontrol edilmiştir. Veri setinde normal sınıfında 2107, pnömoni sınıfında 3510 görüntü bulunmaktadır. Dengesiz veri kümesi, bir sınıftaki örneklerin diğer sınıflara göre daha fazla veya daha az temsil edildiği durumları içerebilir. Bu, modelin sınıflar arasında dengesiz bir öğrenme yapmasına neden olabilir. Az temsil edilen sınıfların örneklerini yanlış sınıflandırabilir veya önemli özellikleri tanıyamayabilir. Bu durumda, modelin performansı düşebilir ve hatalı sonuçlar elde edilebilir. Bu sebeple çalışmada dengeli veri seti olması adına normal etiketli sınıftan tüm görüntüler alınırken, pnömoni sınıfındaki görüntüler 2107 adet görüntü rastgele seçilmiştir. Böylelikle veri setinden daha iyi sonuç alınması amaçlanmıştır. Veri setinde bulunan görüntüler %70 eğitim, %15 doğrulama ve %15 test verisi olarak ayrılmıştır. Veri setinin örnek sınıf görüntüleri Şekil 2’de verilmiştir.

Tablo 1. Literatür araştırması (Literatür review)

Referans	Model	Veri Seti	Performans Ölçüt Parametresi
[10]	ResNet-50	ChestX-ray8	AUC=0,633
[11]	RNN (Recurrent Neural Network)	ChestX-ray14	AUC=0,713
[12]	CheXNet	ChestX-ray14	F1 Skoru (95% CI) = 0,435
[14]	DualNet	MIMIC-CXR	AUC= 0,72
[15]	ESA-transfer öğrenme	Kaggle açık erişim veri seti Chest X-Ray Images (Pneumonia)	Doğruluk= 0,93
[16]	Gauss Laplace filtre modelini kullanan ESA	Japonya Radyoloji Teknolojileri Derneği’ne ait kamuya açık göğüs röntgeni görüntüleri	Doğruluk= 0,83
[17]	ESA	ChestX-ray14	AUC=0,8002
[18]	ESA	Kaggle’den açık erişim veri seti	Duyarlılık= 0,79
[19]	DenseNet-201	Kaggle’den açık erişim veri seti Chest X-Ray Images (Pneumonia)	Doğruluk= 0,98
[20]	VGG19	Kaggle açık erişim veri seti Chest X-Ray Images (Pneumonia)	Doğruluk= 0,92




Şekil 1. Sınıflandırma çalışmasının akış diyagramı (Flow chart of the classification study)



Şekil 2. Her bir sınıf için örnek görüntü (Sample images for each class)

3.2. Artık Blok (Residual Blok)

Artık bloklar derin olan ağlarda eğitimi kolaylaştırmak, aşırı uyum (overfitting) oluşmasını engellemek için geliştirilen yapılardır. Ağın performansını arttırmaya yarayan artık bloklar, Şekil 3'te görüldüğü gibi, x katman girdisini aradaki bir veya daha fazla katmanı atlayarak toplama işlemine taşıyan kısayol bağlantıdır. Bu sayede girdiler daha hızlı şekilde yayılabilir. Artık bağlantıdan önce x girdisi katmanın ağırlık değerleri ile çarpılır ve bir ön yargı terimi eklenir. Sonrasında elde edilen terim $f(x)$ aktivasyon fonksiyonundan geçer ve Eş. 1'de verildiği gibi $H(x)$ çıkışı elde edilir [34, 35].



Şekil 3. Artık blok (Residual blok)

$$H(x) = f(wx + b), H(x) = f(x) \quad (1)$$

Kısayol bağlantısı ile elde edilen $h(x)$ çıkışı Eş. 2'de verildiği gibi elde edilir.

$$H(x) = f(x) + x \quad (2)$$

Burada x girdi değerini, w katman ağırlık değerini, b ön yargı terimini, $f(x)$ aktivasyon fonksiyonunu ve $H(x)$ çıkışı ifade eder.

3.3. Önerilen ESA Modeli (Proposed CNN Model)

Önerilen ESA modeli ön eğitilmiş ResNet modellerinden esinlenerek geliştirilmiştir. Modelde kullanılan artık blok yapısında konvolüsyon, normalizasyon, ReLU tekrar konvolüsyon ve normalizasyon katmanları bulunmaktadır. Modelde bu yapı 3 defa kullanılmıştır. Birinci artık blok bağlantısının girişi havuzlama3d-1 katmanına, çıkışı addition bağlantısıyla ReLU-3 katmanına bağlanmıştır. İkinci blokun girişi yine havuzlama3d-2 girişine çıkışı addition katmanı ile ReLU-5 katmanına bağlanmıştır. Benzer şekilde artık blok 3 bağlantısı da havuzlama3d-3 girişine ve addition bağlantısı ile ReLU-7 katmanına

bağlanmıştır. Modelde toplamda 8 evrişim katmanı, 4 havuzlama katmanı, 8 batchnorm katmanı, 10 ReLU katmanı, 3 addition katmanı, 2 dropout katmanı, softmax ve sınıflandırma katmanları bulunmaktadır. Önerilen ESA modeline ait katmanlar ve bağlantıları Şekil 4'te verilmiştir. Ayrıca katmanlara ait aktivasyon değerleri Tablo 2'de görülmektedir.

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu bölümde, önerilen ESA modeli ve karşılaştırma yapmak için kullanılan modellere ait analiz sonuçları yer almaktadır. Analizler Intel (R) i7-10750H CPU @2.60 GHz, NVIDIA Quadro P620 GPU ve 16 GB RAM belleğe sahip bir iş istasyonunda MATLAB R2021b ortamında yapılmıştır. Deneylerde, mini-yığın boyutu ve maksimum döngü sayısı sırasıyla 16 ve 100, eğitim boyunca başlangıç öğrenme oranı $1e^{-4}$, optimizasyon yöntemi Momentumlu Stokastik Gradyan İnişi olarak ayarlanmıştır.

4.1. Performans Değerlendirme Ölçütleri (Performance Evaluation Metrics)

Çalışmada performans değerlendirmesinde Doğruluk, Kesinlik, Duyarlılık, Özgüllük ve F1-skör gibi ölçütler seçilmiştir. Performans parametreleri Tablo 3'de verilen hata matrisi ile yapılmaktadır. Ölçütlerin hesaplanmasına ait ifadeler Eş. 3-7'de verilmiştir [36, 37].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (5)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (6)$$


$$\text{F1 - Skör} = \frac{2 \cdot \text{Duyarlılık} \cdot \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$

Burada, DP doğru sınıflandırılmış pozitif örnekleri, YP yanlış sınıflandırılmış negatif örnekleri, YN yanlış sınıflandırılmış pozitif örnekleri, DN doğru sınıflandırılmış negatif örnekleri ifade etmektedir.

4.2. Deneysel Çalışmalar (Experimental Studies)

Çalışmada önerilen ESA modeli ile sınıflandırma yapılmasının yanı sıra aynı veri seti ile farklı ESA modelleri de kullanılarak sınıflandırma çalışması yapılmıştır. Bu modeller Model 1, Model 2, Model 3 ve önerilen ESA modeli Model 4 olarak adlandırılmıştır. Model 1, basit yapılı bir ESA modelidir. Model 2, önerilen modeldeki artık blokların çıkarılarak elde edildiği ESA modelidir. Model 3, ön eğitilmiş ve sık kullanılan modellerden olan ResNet3d_18 ESA modelidir. Model 4, önerilen artık blok bağlantılı ESA modelidir. Bu modellerin detaylı yapısı Şekil 5'te görülmektedir.

Çalışmada kullanılan modellerle yapılan analizlerden elde edilen hata matrisleri Şekil 6'da verilmiştir. Burada, önerilen yöntem olan Model 4, normal etiketindeki 316 görüntünün 308'ini doğru sınıflandırırken 8 görüntüyü yanlış tahmin etmiştir. Aynı model pnömoni etiketindeki 316 görüntünün ise 314 tanesini doğru, 2 tanesini yanlış tahmin etmiştir. Analizleri yapılan modeller içinde en zayıf performansı gösteren Model 1 ise, normal etiketindeki 316 görüntüden 285 tanesini, pnömoni etiketindeki 316 görüntünün ise 275 tanesini doğru tahmin etmiştir. Model 2, ise normal etiketindeki 304, pnömoni etiketindeki 298 görüntüyü doğru tahmin etmiştir.




Şekil 4. Önerilen ESA modeli (Proposed CNN model)

Tablo 2. Önerilen model katmanları ve aktivasyon değerleri (Proposed model layers and activation values)

Katman	Aktivasyon	Katman	Aktivasyon
Giriş Katmanı	$60 \times 60 \times 1 \times 1$	Havuzlama _3	$60 \times 60 \times 1 \times 32$
Konvolüsyon 3d _1	$60 \times 60 \times 1 \times 32$	Konvolüsyon 3d _6	$60 \times 60 \times 1 \times 32$
Batch Normalizasyon _1	$60 \times 60 \times 1 \times 32$	Batch Normalizasyon _6	$60 \times 60 \times 1 \times 32$
ReLU _1	$60 \times 60 \times 1 \times 32$	ReLU _6	$60 \times 60 \times 1 \times 32$
Havuzlama _1	$60 \times 60 \times 1 \times 32$	Konvolüsyon 3d _7	$60 \times 60 \times 1 \times 32$
Konvolüsyon 3d _2	$60 \times 60 \times 1 \times 32$	Batch Normalizasyon _7	$60 \times 60 \times 1 \times 32$
Batch Normalizasyon _2	$60 \times 60 \times 1 \times 32$	Addition _3	$60 \times 60 \times 1 \times 32$
ReLU _2	$60 \times 60 \times 1 \times 32$	ReLU _7	$60 \times 60 \times 1 \times 32$
Konvolüsyon 3d _3	$60 \times 60 \times 1 \times 32$	Havuzlama _4	$60 \times 60 \times 1 \times 32$
Batch Normalizasyon _3	$60 \times 60 \times 1 \times 32$	Dropout	$60 \times 60 \times 1 \times 32$
Addition _1	$60 \times 60 \times 1 \times 32$	Convolution 3d _8	$60 \times 60 \times 1 \times 32$
ReLU _3	$60 \times 60 \times 1 \times 32$	Batch Normalizasyon _8	$60 \times 60 \times 1 \times 32$
Havuzlama _2	$60 \times 60 \times 1 \times 32$	ReLU _8	$60 \times 60 \times 1 \times 32$
Konvolüsyon 3d _4	$60 \times 60 \times 1 \times 32$	Dropout	$60 \times 60 \times 1 \times 32$
Batch Normalizasyon _4	$60 \times 60 \times 1 \times 32$	Tam bağlantı _1	$1 \times 1 \times 1 \times 400$
ReLU _4	$60 \times 60 \times 1 \times 32$	ReLU _9	$1 \times 1 \times 1 \times 400$
Konvolüsyon 3d _5	$60 \times 60 \times 1 \times 32$	Tam bağlantı _2	$1 \times 1 \times 1 \times 500$
Batch Normalizasyon _5	$60 \times 60 \times 1 \times 32$	ReLU _10	$1 \times 1 \times 1 \times 500$
Addition _2	$60 \times 60 \times 1 \times 32$	Softmax	$1 \times 1 \times 1 \times 2$
ReLU _5	$60 \times 60 \times 1 \times 32$	Çıkış	$1 \times 1 \times 1 \times 2$

Tablo 3. Hata Matrisi (Confusion matrix)

Hata Matrisi		Tahmin Edilen Sınıf	
		Pozitif (Pnömoni)	Negatif (Normal)
Gerçekteki Sınıf	Pozitif (Pnömoni)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif (Normal)	Yanlış Pozitif (YP)	Doğru Negatif (DN)



Şekil 5. Model mimarileri (a) Model 1, (b) Model 2, (c) Model 3 (Model architectures (a) Model 1, (b) Model 2, (c) Model 3)

Ön eğitilmiş ağırlardan Model 3 ise normal etiketindeki 295 tane görüntüyü doğru tahmin ederken 21 tanesini yanlış tahmin etmiştir.

Yine aynı yöntem pnömoni etiketindeki 283 görüntüyü doğru tahmin ederken 33 tanesini yanlış tahmin etmiştir.

Model 1		
	Normal	Pnömoni
Normal	87.42% 285	12.57% 31
Pnömoni	15.64% 41	84.35% 275

Model 3		
	Normal	Pnömoni
Normal	90.49% 295	9.50% 21
Pnömoni	13.19% 33	86.80% 283

Model 2		
	Normal	Pnömoni
Normal	93.25% 304	6.75% 12
Pnömoni	8.59% 18	91.41% 298

Model 4		
	Normal	Pnömoni
Normal	97.46% 308	2.53% 8
Pnömoni	0.64% 2	99.36% 314

Şekil 6. Hata matrisleri (Confusion matrices)

Tablo 4. Analiz yapılan modellere ait performans ölçüt değerleri (Performance metric values of the analyzed models)

Model No	Doğruluk	Özgüllük	Duyarlılık	Kesinlik	F1-Skor
Model 1	88,61	87,03	90,19	87,42	88,79
Model 2	95,25	94,30	96,20	94,41	95,30
Model 3	91,46	89,56	93,35	89,94	91,61
Model 4 (Önerilen Model)	98,42	97,52	99,35	97,47	98,40

Model 1, Model 2, Model 3 ve Model 4 için elde edilen hata matrisinden performans ölçüt değerleri Doğruluk, Özgüllük, Duyarlılık, Kesinlik ve F1-Skor değeri hesaplanmış ve Tablo 4'te verilmiştir. Ayrıca her bir model için bu ölçüt değerlerinin karşılaştırılması Şekil 7'de görülmektedir. Analiz sonuçları doğruluk değeri açısından incelendiğinde önerilen yöntemin doğruluk değeri %98,42 iken en iyi ikinci yüksek performansı gösteren Model 2'de ise %95,25 olarak elde edilmiştir. Ön eğitilmiş model olan Model 3'te ve basit ESA yapısı olan Model 1 ile yapılan analizlerde ise bu değer sırasıyla %91,46 ve %88,61 olarak hesaplanmıştır. Bu sonuçlardan en kötü değeri basit 3D ESA modelinin verdiği görülmektedir.

Diğer performans ölçütü kesinlik değerlerine bakıldığında, önerilen yöntemin kesinlik değeri %97,47 olarak elde edilirken Model 2'de bu değer %94,41 olarak hesaplanmıştır. Bu ölçüt değeri Model 1 ve Model 3 için sırasıyla %87,42 ve %89,94 olarak bulunmuştur. Bu sonuçlardan önerilen yöntemin en iyi kesinlik değerini sağladığı görülmektedir. Model performansları duyarlılık değerleri bakımından karşılaştırıldığında en iyi sonucu %99,35 ile önerilen model sağlamıştır. İkinci en iyi sonucu ise %96,20 değeri ile Model 2

göstermiştir. Model 1 ve Model 3 için duyarlılık değerleri sırasıyla %90,19 ve %93,35 olarak hesaplanmıştır. Modellerin performansı diğer bir ölçüt olan özgüllük değeri açısından karşılaştırıldığında en iyi sonucu %97,52 ile önerilen model sağlarken en kötü sonucu %87,03'lük değeri ile Model 1 göstermiştir. Model 2 ise %94,30 değeri ile en iyi ikinci sonucu sağlamıştır. Model 3'ten elde edilen özgüllük değeri ise %89,56 olarak hesaplanmıştır. Son olarak F1-skor açısından karşılaştırma yapıldığında en iyi sonuç %98,40 ile önerilen yöntem ile elde edilirken en kötü sonucu ise %88,79 ile Model 1 göstermiştir. Model 3 ve Model 2'nin F1-skorundaki değerleri sırasıyla %91,61 ve %95,30 olarak elde edilmiştir. Bu sonuçlara göre önerilen yöntemin pnömoni sınıflandırmasında en iyi performans sağlayan model olduğu söylenebilir.


Önerilen modelin diğer modellere kıyasla iyileştirme yüzdeleri de hesaplanmıştır. İyileştirme oranı, bir başlangıç değeri ile son değer arasındaki değişimi yüzde olarak ifade eden bir orandır. Matematiksel olarak Eş. 8'deki gibi ifade edilebilir;

$$\text{İyileştirme Oranı} = \frac{(\text{Son Değer} - \text{Başlangıç Değeri})}{(\text{Başlangıç Değeri})} * 100 \quad (8)$$


Burada son deęer önerilen modelden elde edilen performans deęerlerini ifade ederken, bařlangıç deęeri dięer modellerin performans deęerlerini temsil etmektedir. Buna göre önerilen yöntem Model 1, Model 2 ve Model 3'ün doęruluk deęerlerini sırasıyla %11,7 %3,32 ve %7,60; duyarlılık deęerlerini sırasıyla %10,15; %3,27 ve %6,42; F1-skor deęerlerini ise sırasıyla %10,82; %3,25 ve %7,41 oranında iyileřtirmiřtir. Her bir modele ait Alıcı İřletim Karakteristik

(Receiver Operating Characteristic-ROC) eęrileri performans ölçütleri duyarlılık ve özgülük deęerlerine göre çizilmektedir. Analiz sonuçlarına göre elde edilen ROC eęrileri řekil 8'de verilmiřtir.

Önerilen yöntemle ait olan ROC eęrisi incelendięinde ilgili eęri altında kalan alanların her iki sınıf için de 1 deęerine yakın olduęu görölmektedir. Bu durum sınıflandırmadaki görüntülerin doęru olarak



řekil 7. Performans ölçüt karşılařtırması (Performance metrics comparison)




řekil 8. ROC eęrileri (ROC curves)

tahmin edildiğini kanıtlamaktadır [38]. Önerilen yöntemin katmanlarındaki pnömoni ve normal etiketli görüntülere ait öznetelik çıkarımları da incelendiğinde Havuzlama-1, Konv3d-1, Konv3d-5, Havuzlama3d-4, FC-2 ve softmax katmanlarındaki kümelenmeler Şekil 9'da görülmektedir.

Şekil 9'da incelenen öznetelik dağılımları, bir derin öğrenme modelinin farklı katmanlarından elde edilen öznetelikleri temsil etmektedir. Bu durumda, Havuzlama-1 katmanından elde edilen öznetelikler normal ve pnömoni sınıflara ait olarak dağıtılmış ve birbirinden ayrılmamış görünmektedir. Bu da Havuzlama-1 katmanında elde edilen özneteliklerin sınıf ayrımı yapmak için yeterli olmadığını göstermektedir. Ancak, Konv3d-1, Konv3d-5 ve Havuzlama 3d-4 katmanlarının öznetelikleri incelendiğinde, her bir

etiketteki görüntülerin gruplandırılmadığı görülmektedir. Bu, bu katmanlardaki özneteliklerin sınıf ayrımını yapmak için yeterli olmadığını göstermektedir. Özneteliklerin dağınık olması, bu katmanlardaki bilginin yeterince odaklanmadığını veya ayrıntılı bir sınıflandırma yapmaktan ziyade daha genel öznetelikleri temsil ettiğini gösterebilir. Ancak, Fc-2 ve softmax katmanlarında gözlemlenen öznetelik dağılımları, sınıflar arasındaki ayrımı yapmak için daha belirgin bir şekilde gruplandığını göstermektedir. Bu da modelin daha son katmanlarda sınıf ayrımı için daha güçlü öznetelikler öğrendiğini ve bu özneteliklerin daha iyi bir sınıflandırma performansı sağladığını gösterir. Sonuç olarak, incelenen öznetelik dağılımlarının analizi, modelin daha derin katmanlarda daha iyi sınıf ayrımı yapabilen öznetelikleri öğrendiğini ve bu özneteliklerin son katmanlarda daha belirgin hale geldiğini göstermektedir. Şekil 10'de



Şekil 9. Önerilen yöntemin katmanlarından çıkarılan öznetelikler (Features extracted from the layers of the proposed method)

ise eğitim ve doğrulama sürecindeki doğruluk ve kayıplara ilişkin değişim verilmiştir. Buradan önerilen yöntemin süreç içindeki değişimi gözlemlenebilmektedir. Şekil 10'dan elde edilen verilere dayanarak yapılan analize göre, eğitim sürecinde hem eğitim hem de doğrulama verileri için doğruluk oranının hızlı bir şekilde arttığı gözlemlenmektedir. Bu durum, modelin eğitim verilerini daha iyi öğrenerek, daha doğru tahminler yapabilmesinin bir göstergesidir. Aynı şekilde, kayıp değerlerindeki değişim incelendiğinde, başlangıç yinlemelerinden itibaren kayıp değerlerinin hızla azaldığı tespit edilmektedir. Bu, modelin eğitim sürecinin ilerledikçe daha az hata yaptığını ve daha iyi bir performans sergilediğini göstermektedir. Kayıp değerlerinin azalması, modelin tahminlerinin gerçek değerlere daha yakın olduğunu ifade etmektedir. Bu da, modelin eğitim sürecinin başarılı olduğunu ve modelin verileri daha iyi öğrendiğini, doğruluk oranının arttığını ve kayıp değerlerinin azaldığını göstermektedir. Bu durum genellikle, bir modelin istenen hedeflere ulaşma ve iyi bir performans gösterme yolunda ilerlediğini gösteren olumlu bir göstergedir.


4.3 Tartışmalar (Discussions)

Literatürde bu çalışma ile aynı veri setini kullanan ve farklı derin öğrenme yöntemleriyle sınıflandırma analizleri yapılan çalışmalar Tablo 5'te verilmiştir.

Çalışma 4'te, aynı veri seti üzerinde eğitilen 15 farklı CNN mimarisinin performansını karşılaştırarak, göğüs X ışınlarına (CXR)

dayalı daha basit bir zatiirre tespiti yöntemi aranmıştır. Çalışmadaki asıl hedef eğitimi kolay (daha az hesaplama gerektiren ve daha hızlı), anlaşılabilir ve en iyi performans metriklerine sahip olan en ideal modeli seçmektir. Seçilen mimarinin metrikleri, CXR üzerinde eğitilmiş bazı ileri mimarilerle karşılaştırıldığında, CNN mimarilerinin basitleştirilmesinin doğruluk ve performans kalitesini tehlikeye atmadan anlaşılabilirlik için önemli olduğunu kanıtlamaktadır. Detaylı deneylerden sonra seçilen en basit mimarinin %90,8 doğruluk oranı elde edilmiştir.

Çalışma 8'de zatiirreyi CXR görüntülerinde tespit etmek ve bakteri ve virüs alt tiplerini ayırt etmek için farklı eğitim stratejileriyle bir evrişimli sinir ağı (ESA) mimarisi önerilmiştir. Ayrıca, sınıflandırmayı iyileştirmek için farklı görüntü ön işleme yöntemlerini değerlendirilmiştir. Değerlendirilen ön işleme yöntemleri görüntü kırma ve histogram eşitlemedir. Görüntüleri sınıflandırmak için VGG16 ESA kullanılmış ve tam bağlantılı katmanları özelleştirilmiş birçok katmanlı algılayıcı ile değiştirilmiştir. Bu mimariyle, dört farklı eğitim stratejisi önerilmiş ve en yüksek performansı sağlayan model ile sınıflandırmada %97,4 doğruluk değeri elde edilmiştir. Çalışma 19'da, transfer öğrenmeye dayalı sınıflandırma görevi için dört farklı önceden eğitilmiş derin Evrişimli Sinir Ağı (ESA) kullanılmıştır: AlexNet, ResNet18, DenseNet201 ve SqueezeNet. Bakteriyel, viral ve normal göğüs X-ray görüntülerinden oluşan veri seti ön işlemeye tabi tutulmuş ve transfer öğrenmeye dayalı sınıflandırma görevi için eğitilmiştir. Bu çalışmada, yazarlar normal-pnömoni sınıflandırmasında %98,0 doğruluk oranı elde etmiştir.



Şekil 10. Önerilen yöntem için eğitim ve doğrulama sürecindeki doğruluk ve kayıp değişimi
(Accuracy and loss variation in the training and validation process for the proposed method)

Tablo 5. Literatür sonuçları ile karşılaştırma (Comparison with literature results)

Ref.	Dataset	Eğitim Verisi	Test Verisi	Model	Hiper parametre	Yıl	Doğruluk (%)
[4]	Chest X-Ray images	5216	640	ESA model	Mini yığın boyutu=- Öğrenme Oranı=- Momentum=- Optimizasyon =-	2021	90,8
[8]	Chest X-Ray images	5232	624	ESA model	Mini yığın boyutu=16 Öğrenme Oranı=0.0001 Momentum=- Optimizasyon = Stokastik Gradyan İnişi/RMSprop Optimizer	2020	97,4
[19]	Chest X-Ray images (augmented)	9000	419	ESA model	Mini yığın boyutu=16 Öğrenme Oranı=0.0003 Momentum=0.9 Optimizasyon = Stokastik Gradyan İnişi	2020	98,0
Bu çalışma	Chest X-Ray images	5211	652	ESA model	Mini yığın boyutu=16 Öğrenme Oranı=0.0001 Momentum=0.9 Optimizasyon = Stokastik Gradyan İnişi	2023	98,42

4.4. Modelin Farklı Veri Seti İle Test Edilmesi (Testing the model with different data set)

Bu çalışmada, önerilen modelin performansı farklı bir veri seti üzerinde de değerlendirilmiştir. Söz konusu veri seti çalışma için özel olarak oluşturulmuştur. Görüntüler internetten açık kaynaktan alınmıştır [39]. Veri setinde toplamda 3002 adet göğüs röntgen göğüs görüntüsü bulunmaktadır. Sınıf sayısı diğer analizlerdeki gibi iki olarak belirlenmiştir: normal ve pnömoni. Veri seti dengeli bir veri setidir, yani her iki sınıf için de aynı sayıda örnek içermektedir. Veri setine ön işlem olarak boyutlandırma yapılmıştır, herhangi bir augmented yöntemi uygulanmamıştır. Veri seti %70 eğitim, %15 doğrulama ve %15 test verisi olarak ayrılmıştır. Eğitim aşamasında hiper parametreler çalışmadaki ilk analizdeki hiper parametrelerle aynı (mini yığın boyutu=16; öğrenme oranı=0.0001; momentum=0.9; optimizasyon = stokastik gradyan inişi) seçilmiştir. Elde edilen sonuçları değerlendirmek amacıyla karmaşıklık matrisi kullanılmış ve Şekil 11'de sunulmuştur.

	Model 4	
	Normal	Pnömoni
Normal	96.88% 218	3.12% 7
Pnömoni	2.22% 5	97.78% 220

Şekil 11. Önerilen modelin farklı bir veri seti ile elde edilen karmaşıklık matrisi
(Complexity matrix of the proposed model obtained with a different data set)

Analizler sonucunda, doğruluk, özgüllük, duyarlılık, kesinlik ve F1-skor ölçütleri sırasıyla %97,33, %96,92, %97,76, %96,89 ve %97,32 olarak elde edilmiştir. Çalışmanın farklı veri seti ile denemesi sonucunda yüksek bir performans sergilediği gözlenmiştir. Bu durum, önerilen modelin genelleme yeteneğinin ve farklı veri setleri üzerindeki uygulanabilirliğinin olduğunu göstermektedir. Bu bulgular, çalışmanın önemini vurgulamaktadır ve göğüs röntgen görüntüleri üzerinde yapılan otomatik sınıflandırma işleminde önerilen modelin etkili bir araç olabileceğini göstermektedir.

5. Sonuçlar (Conclusions)

Bu çalışmada, 3 boyutlu pnömoni ve normal göğüs görüntülerini sınıflandırmak için derin öğrenme yöntemi ile bir evrişimli sinir ağı (ESA) modeli geliştirilmiştir. Önerilen yöntemin performansı, üç farklı modelle karşılaştırılarak değerlendirilmiştir. Önerilen modelde artık blok bağlantıların kullanılması ile modelin performansını artırma yoluna gidilmiştir. Artık blok bağlantılar ile ağı daha derin olması sağlanmıştır. Ayrıca artık bloklar ağı daha genel özellikleri öğrenmesine yardımcı olmuş ve aşırı uyum riskini azaltarak daha iyi genelleme yapmasını sağlamıştır. Bu sayede doğruluk oranında artış sağlanmıştır. Analiz sonuçlarına göre, önerilen model en yüksek

doğruluk sonucu olan %98.42'lik bir değer elde etmiştir. Ayrıca model farklı veri seti için de denenmiş %97.33'lük doğruluk oranı elde edilmiştir. Bu da modelin genel uygulanabilirliğini göstermektedir.

Gelecek Çalışmalar (Future Studies)

Farklı göğüs hastalıklarının tespiti ve sınıflandırılması için farklı ESA modellerinin geliştirilebileceği belirtilmektedir. Ayrıca, önerilen model yapısının iyileştirilebilmesi için farklı optimizasyon yöntemlerinin kullanılabileceği ve bu alanda daha fazla araştırma yapılması gerektiği vurgulanmaktadır.

Geliştirme Ortamı (Development Environment)

Analizler Intel (R) i7-10750H CPU @2.60 GHz, NVIDIA Quadro P620 GPU ve 16 GB RAM belleğe sahip bir iş istasyonunda MATLAB R2021b ortamında yapılmıştır.

Kaynaklar (References)

1. Gereje R. S., and Laufer P. M., Pneumonia, *Pediatr Rev.*, 34 (10), 438–456, 2013.
2. Prayle A., Atkinson M. and Smyth A., Pneumonia in the developed world, *Paediatric Respiratory Reviews.*, 12 (1), 60–69, 2011.
3. Ruuskanen O., Lahti E., Jennings L. C. and Murdoch D. R., Viral pneumonia, *The Lancet*, 377 (9773), 1264–1275, 2011.
4. GM H., Gourisaria M. K., Rautaray S. S. and Pandey M., Pneumonia detection using CNN through chest X-ray, *Journal of Engineering Science and Technology*, 16 (1), 861–876, 2021.
5. Khoiriyah S. A., Basofi A. and Fariza A., Convolutional Neural Network for Automatic Pneumonia Detection in Chest Radiography, *The 2020 International Electronics Symposium (IES)*, Surabaya, Indonesia, 476–480, 29-30 Eylül, 2020.
6. Asnaoui K., Chawki Y. and Idri A., Automated methods for detection and classification pneumonia based on x-ray images using deep learning, *Artificial intelligence and blockchain for future cybersecurity applications*, Springer, 257–284, 2021.
7. Baltruschat, I. M., Nickisch, H., Grass M., Knopp T. and Saalbach A., Comparison of deep learning approaches for multi-label chest X-ray classification, *Scientific Reports*, 9 (1), 1–10, 2019.
8. Ferreira J. R., Cardenas D., Moreno R. A., Sá Rebelo M., Krieger J. E. and Gutierrez M. A., Multi-view ensemble convolutional neural network to improve classification of pneumonia in low contrast chest x-ray images. *42nd annual international conference of the IEEE engineering in Medicine & Biology Society*, Sydney, 1238–1241, 20-24 Temmuz, 2020.
9. Demir F., DeepCoroNet: A deep LSTM approach for automated detection of COVID-19 cases from chest X-ray images, *Applied Soft Computing*, 103, 107160, 2021.
10. Wang X., Peng Y., Lu L., Lu Z., Bagheri M. and Summers R., ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases, *IEEE CVPR 2017*, Honolulu, USA, 2097-2106, 21-26 Temmuz, 2017.
11. Yao L., Poblens E., Dagunts D., Covington B., Bernard D. and Lyman K., Learning to diagnose from scratch by exploiting dependencies among labels, *arXiv preprint arXiv:1710.10501*, 2017.
12. Rajpurkar P., Irvin J., Zhu K., Yang B., Mehta H., Duan T., Ding D., Bagul A., Langlotz C. and Shpanskaya K., Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning, *arXiv preprint arXiv:1711.05225*, 2017.
13. Kaymak S., Almezghwi K. and Shelag A., Classification of diseases on chest X-rays using deep learning, *The International Conference on Theory and Applications of Fuzzy Systems and Soft Computing*, Warsaw, Poland, 516–523, 26-27 Ağustos, 2018.
14. Rubin J., Sanghavi D., Zhao C., Lee K., Qadir A. and Xu-Wilson M., Large scale automated reading of frontal and lateral chest x-rays using dual convolutional neural networks[J]. *arXiv preprint arXiv:1804.07839*, 2018.
15. Gülgün O. D., Hamza E., Classification performance comparisons of deep learning models in pneumonia diagnosis using chest x-ray images, *Turkish Journal of Engineering*, 4 (3), 129–141, 2020.

16. Ucar F., Korkmaz D., COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images, *Medical Hypotheses*, 140, 109761–109761, 2020.
17. Varshni D., Thakral K., Agarwal L., Nijhawan R. and Mittal A., Pneumonia detection using CNN based feature extraction, 2019 IEEE international conference on electrical, computer and communication technologies, Tamil Nadu, India, 1–7, 20–22 Şubat, 2019.
18. Sirazitdinov I., Kholiavchenko M., Mustafaev T., Yixuan Y., Kuleev R. and Ibragimov B., Deep neural network ensemble for pneumonia localization from a large-scale chest x-ray database, *Computers & Electrical Engineering*, 78, 388–399, 2019.
19. Rahman T., Chowdhury M. E., Khandakar A., Islam K. R., Islam K. F., Mahbub Z. B., Kadir M. A. and Kashem S., Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest X-ray, *Applied Sciences*, 10 (9), 3233, 2020.
20. Jain R., Nagrath P., Kataria G., Kaushik V. S. and Hemanth D. J., Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning, *Measurement*, 165, 108046, 2020.
21. Račić L., Popović T. and Šandi S., Pneumonia detection using deep learning based on convolutional neural network, 25th International Conference on Information Technology (IT), Žabljak, 1–4, 28–29 September, 2021.
22. Atik I., COVID-19 Case Forecast with Deep Learning BiLSTM Approach: The Turkey Case, *Int. J. Mech. Eng.*, 7 (1), 6307–6314, 2022.
23. Atik I., Performance comparison of regression learning methods: COVID-19 case prediction for Turkey, *Int. J. Mech. Eng.*, 7 (1), 6297–6306, 2022.
24. [Atik I., A New CNN-Based Method for Short-Term Forecasting of Electrical Energy Consumption in the Covid-19 Period: The Case of Turkey, *IEEE Access*, 10, 22586–22598, 2022.
25. Atik I., Performance Comparison of Pre-Trained Convolutional Neural Networks in Flower Image Classification, *Eur. J. Sci. Technol.*, 35, 315–321, 2022.
26. Atik I., A Hybrid Prediction Approach Based on ANN and NAR Neural Networks for Annual Electric Energy Demand in Turkey, *UPB Sci Bull Ser. C*, 83 (4), 311–330, 2021.
27. Acikgoz H., Korkmaz D. and Dandil B., Classification of Hotspots in Photovoltaic Modules with Deep Learning Methods, *Turkish Journal of Science & Technology*, 17 (2), 211–221, 2022.
28. Gökdemir A., Calhan A., Deep learning and machine learning based anomaly detection in internet of things environments, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (4), 1945–1956, 2022.
29. Karasulu B., Yücalar F., Borandag E., A hybrid approach based on deep learning for gender recognition using human ear images, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (3), 1579–1594, 2022.
30. Şafak E., Barıscı N., Real-time fire and smoke detection for mobile devices using deep learning, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (4), 2179–2190, 2023.
31. Çubukçu E. A., Demir V., Sevimli M. F., Akım Verilerinin Makine Öğrenmesi Teknikleriyle Tahmin Edilmesi, *Gazi Mühendis. Bilim. Derg.*, 8 (2), 257–272, 2022.
32. Atik I., Analysis of Biodegradable and Non-Biodegradable Materials Using Selected Deep Learning Algorithms, *International Journal of Computer*, 43 (1), 48–59, 2022.
33. Kaggle data set, <https://www.kaggle.com/datasets>. Erişim tarihi: 06 Aralık 2021.
34. Bi Q., Qin K., Zhang H., Li Z. and Xu K., RADC-Net: A residual attention-based convolution network for aerial scene classification, *Neurocomputing*, 377, 345–359, 2020.
35. He K., Zhang X., Ren S. and Sun J., Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, Nevada, 770–778, 26 Haziran- 1 Temmuz, 2016.
36. Atik I., Classification of Electronic Components Based on Convolutional Neural Network Architecture, *Energies*, 15 (7), 2347, 2022.
37. Szegedy C., Ioffe S., Vanhoucke V. and Alemi A., Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning, *Proceedings of the AAAI Conference on Artificial Intelligence*, California USA, 31 (1), 4278–4284, 7–8 Haziran, 2017.
38. Rasekh M., Karami H., Wilson A. D. and Gancarz M., Classification, and identification of essential oils from herbs and fruits based on a MOS electronic-nose technology, *Chemosensors*, 9 (6), 142, 2021.
39. Kaggle data set, <https://www.kaggle.com/datasets/jtiptj/chest-xray-pneumoniacovid19tuberculosis>, Erişim tarihi: 02 Haziran 2023.

