



## A comparison of deep learning models for pneumonia detection from chest x-ray images

Zehra Kadiroğlu<sup>1\*</sup>, Erkan Deniz<sup>1</sup>, Abdurrahman Şenyiğit<sup>2</sup>

<sup>1</sup>Department of Electrical and Electronics Engineering, Faculty of Technology, Fırat University, 23119, Elazığ, Türkiye

<sup>2</sup>Department of Chest Diseases and Tuberculosis, Faculty of Medicine, Dicle University, 21280, Diyarbakır, Türkiye

### Highlights:

- Classification chest x ray images
- Comparing the deep learning methods
- A new pneumonia dataset was created

### Keywords:

- Pneumonia detection
- Convolutional Neural Networks
- Deep Feature Extraction
- Transfer learning
- Chest X-Ray Images

### Article Info:

Research Article

Received: 14.11.2022

Accepted: 12.04.2023

### DOI:

10.17341/gazimmfd.1204092

### Correspondence:

Author: Zehra Kadiroğlu

e-mail:

zehrakad@gmail.com

phone: +90 535 571 4614

### Graphical/Tabular Abstract

In this study, pneumonia detection is performed on 2000 chest X-ray images using deep learning based approaches. Out of 2000 chest X-ray images, 1000 images belong to the pneumonia class and 1000 images belong to the healthy class. The deep learning approaches used in this study are deep feature extraction, transfer learning and end-to-end learning (Figure A).

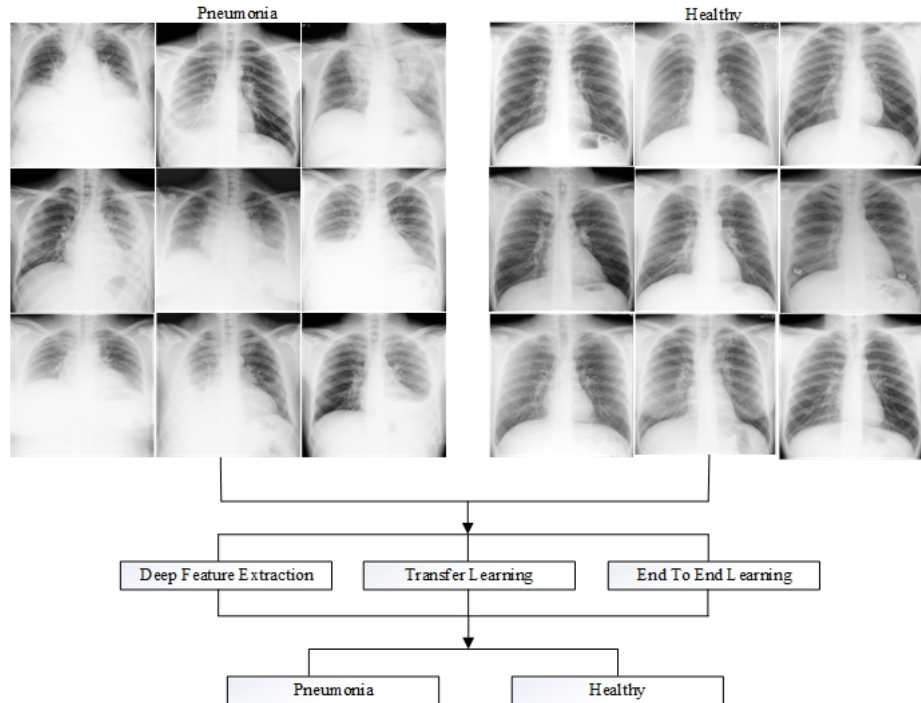


Figure A. Flowchart of the proposed method for pneumonia detection

**Purpose:** The aim of this study is to develop an automatic pneumonia detection system for disease detection by effectively extracting disease-related features from chest X-ray images.

**Theory and Methods:** Three different deep learning approaches are proposed for automatic detection of pneumonia. These approaches are deep feature extraction, transfer learning, and end-to-end learning. In experimental studies, 10 different pre-trained convolutional neural network models (AlexNet, VGG16, VGG19, ResNet50, DenseNet201, DarkNet53, ShuffleNet, SqueezeNet, MobileNetV2 and NasNetMobile) were used and a new network was trained from scratch. The extracted features are classified with the support vector machine, k nearest neighbor and random forest classifiers.

**Results:** The success of the fine-tuned AlexNet model produced an accuracy score of a 98.50%, which was the highest of all results achieved. In the deep feature extraction method, the ShuffleNet model showed the highest success rate of 98.00% among all models. The end-to-end training of the developed CNN model yielded 96.75% results.

**Conclusions:** As a result, in this paper, a new chest X-ray pneumonia dataset is introduced. Various deep learning approaches are employed for pneumonia detection on this new dataset.



## Göğüs röntgen görüntülerinde pnömoni tespiti için derin öğrenme modellerinin karşılaştırılması

Zehra Kadiroğlu<sup>1\*</sup>, Erkan Deniz<sup>1</sup>, Abdurrahman Şenyiğit<sup>2</sup>

<sup>1</sup>Firat Üniversitesi, Teknoloji Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 23119, Elazığ, Türkiye

<sup>2</sup>Dicle Üniversitesi, Tıp Fakültesi, Göğüs Hastalıkları ve Tüberküloz AD, 21280, Diyarbakır, Türkiye

### ÖNEÇIKANLAR

- Göğüs röntgen görüntülerinin sınıflandırılması
- Derin öğrenme metodlarının karşılaştırılması
- Yeni bir Pnömoni veri seti oluşturulmuştur

### Makale Bilgileri

Araştırma Makalesi

Geliş: 14.11.2022

Kabul: 12.04.2023

DOI:

10.17341/gazimmfd.1204092

### Anahtar Kelimeler:

Pnömoni tespiti,  
evrimsel sinir ağları,  
derin öznitelik çıkarımı,  
transfer öğrenme,  
göğüs röntgen görüntüleri

### ÖZ

Pnömoni, akciğer dokusunda ciddi iltihaplanmalara sebep olabilen akut alt solunum yolu hastalıklarından biridir. Pnömoni tanısı için en yaygın klinik yöntem göğüs röntgeni (CXR) olmakla beraber, CXR görüntülerinden pnömoni teşhisi, uzman radyologlar için bile zor bir iştir. Derin öğrenme tabanlı görüntü işlemenin, pnömoni'nin otomatik teşhisinde etkili olduğu literatürdeki çalışmalarda gösterilmiştir. Bu çalışmada pnömoni ve sağlıklı CXR görüntülerini sınıflandırmak için derin öğrenmeye dayalı yaklaşımlar kullanılmıştır. Bu yaklaşımlar, derin öznitelik çıkarımı, önceden eğitilmiş evrimsel sinir ağlarının (ESA) ince ayarı ve geliştirilmiş bir ESA modelinin uçtan uca eğitimidir. Derin öznitelik çıkarımı ve transfer öğrenme için 10 farklı önceden eğitilmiş ESA modelleri (AlexNet, ResNet50, DenseNet201, VGG16, VGG19, DarkNet53, ShuffleNet, SqueezeNet, NASNetMobile ve MobileNetV2) kullanılmıştır. Derin özniteliklerin sınıflandırılması için Destek Vektör Makineleri (DVM), k-En Yakın Komşu (kNN) ve Rastgele Orman (RO) sınıflandırıcıları kullanılmıştır. İnce ayarlı AlexNet modelinin başarısı, elde edilen tüm sonuçlar arasında en yüksek olan %98,50 doğruluk puanı üretmiştir. Geliştirilen 21 katmanlı ESA modelinin uçtan uca eğitimi %96,75 sonuç vermiştir. Bu çalışmada kullanılan veri seti, Dicle Üniversitesi Tıp Fakültesi Göğüs Hastalıkları ve Tüberküloz kliniği ile yoğun bakım ünitesinden ve göğüs polikliniğinden elde edilen pnömonili ve sağlıklı CXR görüntülerinden oluşmaktadır.

## A comparison of deep learning models for pneumonia detection from chest x-ray images

### HIGHLIGHTS

- Classification chest x ray images
- Comparing the deep learning methods
- A new pneumonia dataset was created

### Article Info

Research Article

Received: 14.11.2022

Accepted: 12.04.2023

DOI:

10.17341/gazimmfd.1204092

### Keywords:

Pneumonia detection,  
convolutional neural  
networks,  
deep feature extraction,  
transfer learning,  
chest x-ray images

### ABSTRACT

Pneumonia is one of the acute lower respiratory tract diseases that can cause severe inflammation of the lung tissue. Although chest X-ray (CXR) is the most common clinical method for diagnosing pneumonia due to its low cost and ease of access, diagnosing pneumonia from CXR images is a difficult task even for specialist radiologists. It has been shown in the literature that deep learning-based image processing is effective in the automatic diagnosis of pneumonia. In conclusion, deep learning-based approaches were used in this study to classify pneumonia and healthy CXR images. These approaches are deep feature extraction, fine-tuning of pre-trained Convolutional Neural Networks (CNN), and end-to-end training of an enhanced ESA model. For deep feature extraction and transfer learning, 10 different pre-trained deep CNN models (AlexNet, ResNet50, DenseNet201, VGG16, VGG19, DarkNet53, ShuffleNet, SqueezeNet, NASNetMobile and MobileNetV2) were used. Support Vector Machines (SVM), k Nearest Neighbor (kNN), Random Forest (RF) classifiers are used to classify deep features. The success of the fine-tuned AlexNet model produced an accuracy score of 98.50%, the highest of all results achieved. The end-to-end training of the developed ESA model yielded 96.75% results. The data set used in this study consists of Pneumonia and healthy CXR images obtained from Dicle University Medical Faculty Pulmonary Diseases and Tuberculosis clinic, intensive care unit and pulmonary outpatients' clinic.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : \*zehrakad@gmail.com, edeniz@firat.edu.tr, drasenyigit@gmail.com /  
Tel: +90 535 571 4614

## 1. Giriş (Introduction)

Pnömoni, akciğerde bakteri, virüs veya mantarların neden olduğu akut solunum yolu enfeksiyonudur. Enfeksiyon, alveol adı verilen akciğerlerin küçük hava keseciklerinin iltihaplanmasına ve sıvı ile dolmasına neden olur. Enfeksiyonun neden olduğu semptomlar arasında öksürük, göğüs ağrısı, solunum güçlüğü, ateş yaygın olarak görülmektedir [1]. Pnömoni, Dünya Sağlık Örgütü'ne (DSÖ) göre her yaşta insanda hafif ile şiddetli hastalığa neden olabilir, ancak dünya çapında en çok beş yaşın altındaki çocuklarda bulaşıcılığı ve ölüm oranları yüksektir [2]. Pnömoni, bebekler ve küçük çocuklar, 65 yaş ve üstü yetişkinler ve zayıf bir bağışıklık sistemi olanlar, KOAH, astım veya kistik fibroz gibi kronik akciğer hastalığı olanlar, diyabet veya kalp hastalığı gibi diğer kronik sağlık sorunları olan kişiler için hayati tehlike arz eder. Artan kirlilik ve yetersiz beslenme gibi faktörler hastalığa yakalanma riskini artırır [3].

Bilgisayar destekli tanı (BDT), tıbbi görüntülerdeki farklı anormallik türlerini tespit etmeyi sağlayan çok popüler bir teknikler dizisidir [4]. Göğüs röntgen (CXR) görüntüleri, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) akciğer hastalıklarının teşhisine yardımcı olan BDT şemalarının yaygın örnekleridir. CXR görüntüleri, BT ve MRG kadar doğru olmasa da radyolojik incelemeler arasında en ucuz olanıdır ve dar gelirli kişilerin bu tür incelemelere erişmesine olanak tanır. CXR pnömoniyi teşhis etmek için en yaygın olarak kullanılan yöntemdir [5]. Göğüs radyografileri hastanın durumu hakkında önemli miktarda bilgi sağlar, ancak bu görüntüler akciğer kanseri ve aşırı sıvı gibi diğer çeşitli akciğer anormallikleri ile benzer opasitelere (akciğer nodülü) sahip olduğundan, son derece deneyimli radyologlar için bile CXR'lerden pnömoniyi saptamak zordur. Bu nedenle CXR görüntülerinden pnömoniyi teşhis etmede radyologlara yardımcı olacak bilgisayarlı destek sistemlerine ihtiyaç vardır [6]. Son yıllarda, yapay zekâ (AI) ve makine öğrenimi (ML) teknikleri, dikkatli ve hızlı tanı sağlamak için BDT sistemleri ile birleştirilmiştir [7]. Makine öğreniminin alt dalı olan ve evrimsel sinir ağları (ESA) da dâhil olmak üzere birçok algoritmaya sahip olan derin öğrenme teknikleri, radyologların CXR görüntülerinden pnömoniyi dikkatli ve hızlı bir şekilde tespit etmesine yardımcı olduğu için yaygın olarak kullanılmakta ve yüksek performans elde edilmektedir [8]. Literatürde yer alan çalışmalar sınıflandırma performansına, sınıf sayısına, kullanılan veri setine, ön işleme aşamasına ve ESA'nın yapısına göre gözden geçirilmiştir. Yaseliani vd. [9], CXR görüntülerinde pnömoniyi tespit etmek için yeni bir hibrit VGG tabanlı ESA modeli önermiştir. Bu çalışmada, üç sınıflandırma yaklaşımı kullanılmıştır. İlk sınıflandırma yaklaşımında, CXR görüntülerinin sınıflandırılması için Tam Bağlantılı (FC) katmanlar kullanılmıştır. İkinci sınıflandırma yaklaşımında, CXR görüntü özelliklerini çıkarmak için optimize edilmiş ağırlıklar kullanılmış ve görüntüleri sınıflandırmak için ML sınıflandırıcıları kullanılmıştır. Üçüncü sınıflandırma yaklaşımında, CXR görüntülerini sınıflandırmak için önerilen sınıflandırıcıların bir topluluğu oluşturulmuştur. Deneysel çalışmalar Kaggle veri tabanında yer alan 5863 CXR görüntüsü [10] üzerinde gerçekleştirilmiştir. Sonuçlar, Radyal Temel Fonksiyonlu (RTF) Destek Vektör Makinesi (DVM) ve Lojistik Regresyon (LR) sınıflandırıcılarını kullanan topluluk sınıflandırıcısının %98,55 doğrulukla en iyi performansla sahip olduğunu göstermektedir. Mujahid vd. [11] röntgen görüntüleri kullanarak pnömoni tespiti için önceden eğitilmiş VGG16, Inceptionv3 ve ResNet50 dahil olmak üzere farklı ESA varyantları kullanmıştır. CXR veri seti [10], transfer öğrenme görevleri için uygun hale getirmek için önceden işlenmiştir. InceptionV3, VGG16 ve ResNet50 modelleri topluluk öğrenme yöntemi ile birleştirilmiştir. Ortak değerlendirme metriklerinin yanı sıra, önceden eğitilmiş ve topluluk derin öğrenme modellerinin performansı, cohen kappa

katsayısının yanı sıra eğri altındaki alan (AUC) ile ölçülmüştür. Deneysel sonuçlar, ESA'lı InceptionV3'ün sırasıyla %99,29 ve %99,73 ile en yüksek doğruluk ve duyarlılık puanına ulaştığını göstermektedir. Szepesi vd. [12] CXR görüntülerine dayalı pnömoni tespiti için verimli ve doğru bir çözüm sağlamak amacıyla sıfırdan bir ESA modeli önermişlerdir. Önerilen modeldeki ana yenilik, ağır evrişim katmanları arasına bir bırakma katmanının yerleştirilmesinden oluşmaktadır. Önerilen yöntem, CXR veri seti [10] üzerinde eğitilmiş ve test edilmiştir. Deneysel, önerilen modelin doğruluk ve verimlilik açısından daha iyi performans gösterdiğini ve %97'nin çok üzerinde duyarlılık ve kesinlik sağladığını göstermiştir. Qaimkhani vd. [13] pnömoni teşhisi için yapay sinir ağları (YSA), ESA ve VGG19 kullanmıştır. Araştırmada CXR veri seti [10] kullanılmış ve doğruluk oranları sırasıyla %94,44, %96,68 ve %98,27 olarak elde edilmiştir. VGG19 modelinden transfer öğrenme yaklaşımı ile daha yüksek doğruluk elde edilmiştir. Al-Dulaimi vd. [14] CXR görüntülerini kullanarak pnömoniyi tespit etmek için bir ESA modeli geliştirmiştir. Önerilen çerçeve iki ana aşamadan oluşmaktadır. Bu aşamalar görüntü ön işleme aşaması, öznelik çıkarma aşaması ve görüntü sınıflandırma aşamasıdır. Önerilen ESA modeli, sırasıyla %98, %98, %97 ve %99,82 oranında yüksek kesinlik, duyarlılık, F1 puanı ve doğruluk sonuçları sağlamıştır. Alshehri vd. [15] pnömoniyi teşhis etmek için ESA tabanlı bir model uygulamıştır. ReLU aktivasyon fonksiyonu, bırakma işlemi ve maksimum havuzlama katmanlarını birleştiren ve yedi katman içeren ESA mimarilerini orijinal görüntülerden öznelikleri çıkarmak için kullanmışlardır. CXR görüntüleri [10] üzerinde gerçekleştirilen deneysel çalışmalarda %93'lük doğruluk oranı ve %95,7'lik kesinlik oranı elde edilmiştir. Kaur vd. [16] pnömoniyi otomatik olarak tespit etmek için üç farklı derin ESA kullanmıştır. Kullanılan ESA modelleri InceptionResNetV2, VGG16 ve VGG19'den oluşmaktadır. Önerilen modeli test etmek için CXR veri seti [10] ve CXR-14 [17] veri seti kullanılmıştır. VGG16 modelinde %95,07, VGG19 modelinde %94,88, InceptionResNetV2 modelinde ise %94,07 doğruluk elde edilmiştir. Ayan vd. [18] çocuklarda görülen pnömoninin otomatik tanısı için ESA topluluk modeli önermiştir. Bu kapsamda, ImageNet veri seti üzerinde önceden eğitilmiş yedi ESA modeli (VGG16, VGG19, ResNet50, InceptionV3, Xception, MobileNet ve SqueezeNet) transfer öğrenmesi ile eğitilmiştir. Yedi farklı model arasından en başarılı üçü topluluk yöntemi için seçilmiştir. Test sırasında ESA modellerinin tahminleri topluluk yöntemiyle birleştirilerek nihai sonuçlar elde edilmiştir. Ayrıca bir ESA modeli sıfırdan eğitilmiş ve bu modelin sonuçları önerilen topluluk yöntemi ile karşılaştırılmıştır. Önerilen topluluk yöntemi, test verileri üzerinde %95,21 AUC ve %97,76 kesinlik ile dikkate değer sonuçlar elde etmiştir. Ayrıca önerilen topluluk yöntemi, CXR görüntülerinde normal, viral pnömoni ve bakteriyel pnömoni olarak %90,71 sınıflandırma doğruluğu elde etmiştir. Sourab vd. [19] teşhis karmaşıklığını azaltmak ve radyologlara yardım etmek için 22 katmanlı bir ESA mimarisi oluşturmuş ve ESA modelinden özellikleri çıkarmak ve sınıflandırmak için üç farklı ML tekniği kullanmıştır. Kullanılan ML yöntemleri sırasıyla RF, KNN ve DVM'dir. Mevcut veri setine çeşitlilik katmak için belirli veri büyütme teknikleri kullanmışlardır. İlk yoğun katmanda bir düzenleyici kullanılarak fazla sığdırma önlenmiş ve ayrıca veri büyütme kullanılmıştır. Kullanılan veri seti 5856 CXR görüntüsüne sahip Mendeley Data v2 [10] dir. ESA modellerinden öznelikler çıkartıldıktan ve RF, KNN ve DVM algoritmaları ile sınıflandırıldıktan sonra elde edilen doğruluk değerleri sırasıyla %99,52, %96,55 ve %97,32 olarak bulunmuştur. Saha vd. [20] çalışmalarında CXR görüntülerini eğitmek, pnömoni varlığını tahmin etmek ve özellikler çıkarmak için ESA modelini benimseyen değiştirilmiş bir derin öğrenme yaklaşımı önermiştir. Gerekli görüntü veri seti, Kaggle platformundan seçilmiştir. Önerilen model, deney sırasında daha iyi performans göstermiş ve mevcut derin

öğrenme tabanlı klinik görüntü sınıflandırma algoritmalarından nispeten daha iyi olan %89 doğruluğa ulaşmıştır.

Bu çalışmanın amacı, Dicle Üniversitesi Tıp Fakültesi Göğüs Hastalıkları ve Tüberküloz kliniği ile yoğun bakım ünitesinden elde edilen pnömoni ve sağlıklı CXR görüntüleri kullanılarak hastalığın hızlı ve kolay teşhisine yardımcı olacak derin öğrenme çerçevesi geliştirmektir. Kullanılan derin öğrenme yöntemleri derin öznitelik çıkarımı, transfer öğrenme ve uçtan uca öğrenmedir. Sınıflandırma aşaması DVM, RF ve KNN algoritmaları ile tamamlanmıştır. Yapılan çalışmada önceden eğitilmiş AlexNet, VGG16, VGG19, ResNet50, DenseNet201, DarkNet53, ShuffleNet, SqueezeNet, MobileNetV2 ve NasNetMobile modelleri ile deneysel çalışmalar gerçekleştirilmiştir. Uçtan uca öğrenme için ise 21 katmanlı yeni bir model oluşturularak sıfırdan eğitilmiştir. Kullanılan ESA modellerinin ve önerilen yöntemin teorik açıklaması sırasıyla verilmiştir. İnce ayarlı AlexNet modeli %98,50 doğruluk puanı ile tüm deneylerde en yüksek başarıma ulaşırken; 21 katmanlı yeni ESA modelinin başarıma %96,75'dir. Bu bölümde pnömoni ile ilgili tıbbi bilgiler ayrıntılı olarak verilmiştir. Derin öğrenme algoritmaları kullanılarak pnömoni tespiti ile ilgili literatür çalışmalarından bahsedilmiş olup bu çalışmanın amacı da açıklanmıştır. Bölüm 2'de bu çalışmada kullanılan veri seti ve pnömoni tespiti için önerilen derin öğrenme algoritmaları, derin öğrenme yöntemleri hakkında ayrıntılı bilgi verilmiştir. Bölüm 3'de deneysel çalışmalarda izlenen adımlar ve deneysel çalışmaların sonuçlarından bahsedilmiştir. Bölüm 4'de çalışmada elde edilen sonuçlar değerlendirilmiştir.

Makalenin ana katkıları:

- 1000'i pnömoni 1000'i sağlıklı bireylere ait olmak üzere toplam 2000 yeni CXR görüntüsü toplanmıştır ve yeni bir veri seti oluşturulmuştur.
- 21 katmanlı yeni bir ESA modeli önerilmiştir.
- Veri seti hem k kat çapraz doğrulama hem de hold-out yöntemiyle ayrılarak önerilen yöntemlerin geçerliliği test edilmiştir.

## 2. Materyal ve Metotlar (Material and Methods)


Hazırlanan Pnömoni veri seti için derin öğrenme tabanlı üç farklı yöntem denenmiş olup ilgili sonuçlar verilmiştir. Bu yöntemler sırası ile derin öznitelik çıkarımı, yeni bir ESA modelinin sıfırdan eğitimi ve transfer öğrenmedir.

### 2.1. Veri Seti (Dataset)

Bu çalışma, Dicle Üniversitesi Tıp Fakültesi Göğüs Hastalıkları ve Tüberküloz kliniği ile yoğun bakım ünitesine 2001 Ocak- 2021 Ocak ayları arasında pnömoni tanısıyla yatırılan hastalar üzerinde gerçekleştirilmiştir. Kontrol grubunu ise herhangi bir solunum şikâyetiyle göğüs hastalıkları polikliniğine başvurup Posteror anterior (PA) akciğer grafisi çekilen ve normal olan hastalar oluşturmuştur. Çalışmada PA akciğer grafisinde pnömoni tanısı alan 1000 kişi 1. grup ve PA akciğer grafisi normal olan 1000 kişide 2. grup olmak üzere toplam 2000 kişi ile gerçekleştirilmiştir. Şekil 1'de deneysel çalışmalar için oluşturduğumuz veri setinin pnömoni ve sağlıklı CXR görüntü sınıflarına ait örnekler gösterilmiştir.

### 2.2. Evrimsel Sinir Ağları / ESA (Convolutional Neural Network / CNN)

Evrimsel Sinir Ağları (ESA), görsel görüntüleri analiz eden ve nesne sınıflandırma, algılama ve segmentasyon gibi görevleri gerçekleştiren bir derin sinir ağıdır. Genel olarak, bir ESA modeli beş katmandan oluşur; bunlar giriş katmanı, evrişim katmanları, havuzlama katmanları, tam bağlantı katmanları ve çıkış katmanıdır [21]. ESA'da, giriş katmanının bilgileri bir görüntüdür, gizli katmanlar özellik çıkarımını yapar ve çıkış katmanı sisteme çıkışı verir. Ayrıca öznitelik çıkarımına ve seçimine, son olarak sınıflandırmaya veya tahmine olanak sağlamak için ESA modelinin uçtan uca eğitilebileceği bilinmektedir [22]. AlexNet, 5 evrişim katmanı ve 3 tam bağlantı katmanından oluşur, bunlardan maksimum havuzlama işlemi üç evrişim katmanından sonra gerçekleştirilir. 227×227 görüntü giriş boyutuna sahip olan toplamda 25 katmandan oluşmaktadır [23]. VGG modelleri sırasıyla 41 ve 47 katman içeren VGG16 ve VGG19'dur. VGG16 ve VGG19 arasındaki fark, VGG19'un üç evrişim bloğunun her birinde bir katmana daha sahip olmasıdır. 224×224 giriş boyutuna sahiptirler [24]. ResNet50, bir milyondan fazla görüntü üzerinde eğitilmiştir, nesnelere 1000 sınıfa ayırmak için veri kümesi ImageNet üzerinde eğitilmiş 50 katman derinliğinde ESA'dır. Ağ, 224×224 görüntü giriş boyutuna sahiptir. ResNet modelinin diğer modellere göre avantajı, mimari derinleşse bile performansının düşmemesidir [25]. DenseNet201, 201 katman derinliğinde bir ESA'dır. Ağ, nesnelere 1000 nesne sınıfı arasında kategorize etmek için veri kümesi ImageNet üzerinde eğitilmiştir. Sonuç olarak ağ, çeşitli görüntü türleri



Şekil 1. a) Pnömoni b) Sağlıklı CXR görüntüleri (a) Pneumonia b) Healthy CXR images)

için kapsamlı özellik temsillerini öğrenmiştir. Ağın görüntü giriş boyutu  $224 \times 224$ 'tür [26]. MobileNetV2, MobileNet'in ters çevrilmiş artık ile doğrusal darboğaz modülleri (inverted residual with linear bottleneck modules) eklenerek geliştirilmiş bir versiyonudur ve 54 katmandan oluşur ve  $224 \times 224$  görüntü giriş boyutuna sahiptir [27]. ShuffleNet, 2018'de Zhang vd. , tarafından önerilen, hesaplama açısından son derece verimli bir ESA modelidir. ShuffleNet mimarisi, nesnelere 1000 nesne sınıfı arasında sınıflandırmak için veri kümesi ImageNet üzerinde eğitilmiş 173 katmanlı bir ESA'dır. Bu ağ için görüntünün giriş boyutu  $224 \times 224$ 'tür. [28]. SqueezeNet, 18 katman derinliğinde bir evrimsel sinir ağıdır. Ağ,  $227 \times 227$  görüntü giriş boyutuna sahiptir. [29]. NASNetMobile mimarisi, nesnelere 1000 nesne sınıfı arasında kategorize etmek için veri kümesi ImageNet üzerinde eğitilmiş toplam 914 katman içerir. Bu ağ için görüntünün giriş boyutu  $224 \times 224$ 'tür [30]. Eğitim görüntülerinin özelliklerini çıkarmak için kullanılan hedef tespit ağı YOLOv3'ün temel özellik çıkarma ağı olan DarkNet53, Joseph vd. , tarafından önerilmiştir. 53 katman derinliğine sahip derin evrimsel bir sinir ağıdır. Ağ,  $256 \times 256$  görüntü giriş boyutuna sahiptir [31].

### 2.3. Derin Öznitelik Çıkarımı (Deep Feature Extraction)

ESA ile görüntüler sınıflandırılırken görüntü matrisleri aracılığıyla görüntünün sınıfını etkileyen özellik haritası çıkarılır. Bu sayede görüntülerdeki ayırt edici kısımların tespit edilmesi ve sınıflandırmaya etki eden özelliklerin bulunması sağlanmaktadır [32]. ESA mimarileri CXR görüntülerinden pnömöni tanısı koymak için öznitelik çıkarma ve sınıflandırma yöntemi olarak kullanılmaktadır. Bu modeller, önceden eğitilmiş başlangıç ağırlıklarına dayalı olarak girdiyi eğitebilir. Bu yaklaşım, eğitimi süresini azaltır ve sınıflandırma performansının iyileştirilmesine katkı sağlar. Bu çalışmada kullanılan önceden eğitilmiş ESA modelleri AlexNet, VGG16, VGG19, ResNet50, DenseNet201, DarkNet53, ShuffleNet, SqueezeNet, MobileNetV2 ve NasNetMobile'dir. AlexNet'in fc6; VGG16 ve VGG19'un fc7; ResNet50 ve DenseNet201'in fc1000; DarkNet53'ün conv53; NasNetMobile'in predictions; MobileNetV2'nin Logits; ShuffleNet'in node\_202 ve SqueezeNet'in pool10 katmanlarından öznitelikler çıkarılıp sınıflandırıcıya verilmektedir.

### 2.4. Transfer Öğrenme / TÖ (Transfer Learning / TL)

Transfer öğrenimi (TÖ), bir alandan (kaynak alan) çıkarılan bilginin başka bir (hedef) alana aktararak öğrenmenin gerçekleştiği bir öğrenme yaklaşımıdır. CXR görüntülerinin analizinde en yaygın olarak kullanılan transfer öğrenme yaklaşımlarından biri, önceden eğitilmiştir. Önceden eğitim yaklaşımıyla, ağ mimarisi önce mevcut bir etiketli veri tabanındaki bir görev için eğitilir ve daha sonra eğitilen ağırlıklar, ince ayar için farklı ancak ilgili bir görev için bir başlatma olarak kullanılır [33]. Bir veri kümesi üzerinde eğitilen ve başka bir veri kümesi için kullanılan modele önceden eğitilmiş model denir. Biyomedikal görüntü analizi için uygulanan önceden eğitilmiş modeller, 14 milyon görüntü ve 1000 sınıf etiketli geniş bir veri kümesi olan ImageNet veri kümesi üzerinde eğitilir.

### 2.5. Uçtan Uca Öğrenme (End to End Learning)

Uçtan uca öğrenme, sisteme bir bütün olarak gradyan tabanlı öğrenme uygulayarak karmaşık bir öğrenme sisteminin eğitilmesi anlamına gelir. Uçtan uca öğrenme yönteminin çalışma ilkesi, bir öğrenme sisteminin tüm modüllerinin tüm ayarlanabilir parametrelere (ağırlıklara) göre türevlenebilir olmasını ve sistemin bir bütün olarak eğitilmesini sağlamaktır. Modelin ilk girdi aşaması ile nihai çıktı sonucu arasındaki tüm adımları öğrendiği bir tekniktir. Bu, tüm farklı parçaların sıralı olarak değil aynı anda eğitildiği bir derin öğrenme sürecidir. Geleneksel ardışık tasarımda bulunan ara katmanları atlayarak, tüm hedef sistemi temsil eden tek bir modelle karmaşık bir öğrenme sisteminin eğitimini ifade eder [34].

### 2.6. Destek Vektör Makineleri/DVM (Support Vector Machines/SVM)

Destek Vektör Makinesi (DVM), doğrusal ve doğrusal olarak ayrılamayan veri kümelerinin sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan bir denetimli makine öğrenimi yöntemidir. Algoritmanın çalışma prensibi, sınıflar arasındaki mesafeyi maksimize eden bir hiper düzlem oluşturarak sınıflandırma işlemini gerçekleştirmesidir. Çizilen hiper düzlem, eğitimde kullanılan çekirdeğe göre tanımlanır. Doğrusal, polinom ve Radyal Temel İşlev (RBF) gibi çekirdek fonksiyonları vardır. Polinom ve RBF çekirdekleri, DVM'de doğrusal olarak ayrılamayan sınıflar için en çok kullanılan çekirdek fonksiyonlarından ikisidir [35]. DVM'de çekirdek kullanımı girdi verilerinin yüksek boyutlu uzaya dönüştürülmesine yardımcı olur ve bu da doğrusal olarak ayrılamayan sınıflandırma problemlerinin çözülmesini sağlar. Bu açıdan DVM, doğrusal olarak ayrılan ve ayrılamayan sınıflara kolayca uygulanabilir bir yöntemdir. Ayrıca otomatik olarak düzenli hale getirilmeleri ve düzenli hale getirmenin aşırı öğrenmeyi önlemesi sayesinde yüksek boyut problemini çözmek için kullanılan uygun yöntemlerden biridir [36, 37].

### 2.7. K En Yakın Komşu (K-Nearest Neighbour/ KNN)

KNN algoritması, sınıflandırma işlemlerinde sıklıkla kullanılan denetimli öğrenme yöntemlerindedir. Girdi uzayındaki nesnelere en yakın örneklerle göre sınıflandıran parametrik olmayan ve temel bir tekniktir [38]. Komşu sayısı k ile gösterilirken sınıflandırılacak veriye yakınlığı önemli olduğu için k-en yakın komşu algoritması olarak adlandırılır [39]. Algoritma yapısı gereği 5 temel adımdan oluşmaktadır. İlk önce kullanılacak olan k değeri belirlenmektedir. Var olan nesnelere yeni gelen veriye olan uzaklıklar öklid, manhattan ve minkowski uzaklık ölçümlerinden biriyle hesaplanır. Elde edilen uzaklık sonuçları sıralanıp minimum uzaklık temel alınarak en yakın komşular belirlenir. Daha sonra en yakın komşu kümeleri toplanıp en uygun küme seçilir [40].

### 2.8. Rastgele Orman (Random Forest/ RF)

Karar ağaçları, rastgele orman algoritmasının temel yapı taşıdır. Algoritma, topluluk olarak çalışan çok sayıda bireysel karar ağacından oluşmaktadır. Rastgele ormanlardaki sınıflandırma, sonuca ulaşmak için bir topluluk öğrenme metodolojisi kullanır. Eğitim verileri, çeşitli karar ağaçlarını eğitmek için beslenir. Bu veri seti, düğümlerin bölünmesi sırasında rastgele seçilecek olan gözlemlerden ve özelliklerden oluşur. Bir rastgele orman sistemi, çeşitli karar ağaçlarına dayanır. Her karar ağacı karar düğümlerinden, yaprak düğümlerinden ve bir kök düğümünden oluşur. Her ağacın yaprak düğümü, söz konusu karar ağacı tarafından üretilen nihai çıktıdır. Nihai çıktının seçimi çoğunluk oylama sistemini takip eder. Bu durumda, karar ağaçlarının çoğunluğu tarafından seçilen çıktı, rastgele orman sisteminin nihai çıktısı olur. Rastgele orman, sınıflandırma ve regresyon problemlerinde kullanılan denetimli öğrenme algoritmasıdır [41, 42].

### 2.9. Performans Metrikleri (Performance Metrics)

Çalışmada önerilen yöntemlerin sınıflandırma performanslarını değerlendirmek için doğruluk, duyarlılık, kesinlik ve F1 skor başarımlarını değerlendirme metrikleri kullanılmıştır. Doğruluk, etiketlemeye uygun olarak sınıflandırılmış örneklerin toplamının toplam örnek sayısına bölünerek önerilen yöntemin genel performansını değerlendirmenin sezgisel bir yoludur. Bir modelin bir etiketi kaç kez doğru tahmin ettiğini ölçer. Kesinlik, pozitif olarak tahmin edilen değerlerin kaçının gerçekten pozitif olduğunu gösterir. Duyarlılık, modelin pozitif olarak tahmin etmesi gereken örneklerden kaçının

pozitif olarak tahmin edildiğini ifade eder. F1 skor, kesinlik ve duyarlılığın harmonik ortalaması olarak alınır. Doğruluk, duyarlılık, kesinlik ve F1 skor formülleri Eş. 1-Eş. 4’de yer almaktadır [43].

$$\text{Doğruluk} = (\text{DP} + \text{DN}) / (\text{DP} + \text{DN} + \text{YP} + \text{YN}) \quad (1)$$

$$\text{Duyarlılık} = (\text{DP}) / (\text{DP} + \text{YN}) \quad (2)$$

$$\text{Kesinlik} = (\text{DP}) / (\text{DP} + \text{YP}) \quad (3)$$

$$\text{F1 skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (4)$$

**Tablo 1.** Karmaşıklık matrisi (Confusion Matrix)

	Gerçek Durum		
	(+)	(-)	
Test Sonucu	(+)	DP	YP
	(-)	YN	DN

Tablo 1’de karmaşıklık matrisi yer almaktadır. Doğru Pozitif (DP), pnömoni görüntüsünün model tarafından pnömoni olarak sınıflandırılması, yani pozitif sınıfın doğru sınıflandırılmasıdır. Doğru Negatif (DN), negatif sınıfın doğru sınıflandırılmasıdır, pnömoni olmayan görüntünün yani sağlıklı görüntüsünün sınıflandırma sonrası

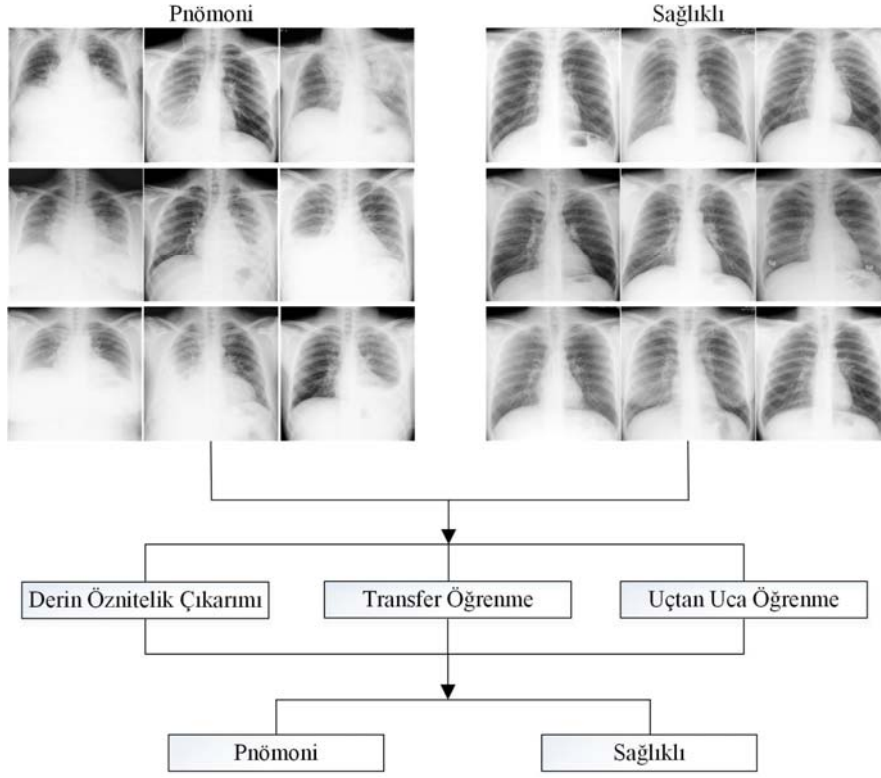
model tarafından sağlıklı olarak etiketlenmesidir. Yanlış Pozitif (YP), pozitiflerin yanlış tahmin edilmesidir, pnömoni görüntüsünün model tarafından sağlıklı olarak sınıflandırılmasıdır. Yanlış Negatif (YN), negatiflerin yanlış tahminidir, sağlıklı görüntünün model tarafından pnömoni görüntüsü olarak etiketlenmesidir [44]. Tablo 2’de incelenen literatür çalışmalarının kapsamlı tablosu yer almaktadır.

### 3. Deneysel Sonuçlar ve Tartışma (Experimental Results and Discussion)

Bu bölümde önerilen pnömoni tespit yöntemlerinin deneysel değerlendirmeleri sunulmaktadır. Bu çalışmada, pnömoni ve sağlıklı CXR görüntüleri kullanılarak derin öğrenme yöntemleriyle sınıflandırma işlemi yapılmıştır. Kullanılan derin öğrenme yöntemleri derin öznetelik çıkarımı, transfer öğrenme ve uçtan uca öğrenmedir. Sınıflandırma aşaması DVM, KNN ve RF algoritmaları ile tamamlanmıştır. Deneysel çalışmalarda kullanılan DVM hiperparametreleri; çekirdek fonksiyonu ‘linear’ olarak belirlenmiştir. KNN hiperparametrelerinde komşu sayısı ‘10’ olarak belirlenmiştir. Uzaklık ölçü birimi ‘minkowski’ olarak seçilmiştir. RF hiperparametrelerinde eğitim metodu ‘bag’, toplulukta kullanılacak ağaç sayısı 50 seçilmiştir. Yapılan çalışmada önceden eğitilmiş AlexNet, VGG16, VGG19, ResNet50, DenseNet201, DarkNet53, ShuffleNet, SqueezeNet, MobileNetV2 ve NasNetMobile modelleri

**Tablo 2.** Güncel çalışmaların kapsamlı incelenmesi (Comprehensive review of current studies)

Yazarlar	Önerilen yöntem	Karşılaştırılan teknikler	Veri seti	Performans metrikleri (%)
Yaseliani vd. [9]	Hibrit Derin ESA	VGG16 VGG19	[10]	Kesinlik: 98,72 Duyarlılık: 99,30 F1 skor: 99,01 Doğruluk: 98,55
Mujahid vd. [11]	Topluluk Öğrenme	VGG16 Inceptionv3 ResNet50	[10]	Doğruluk: 99,29 Duyarlılık: 99,73
Szepesi vd. [12]	ESA + değiştirilmiş dropout	ESA, ESA+drop out	[10]	Doğruluk: 97,2 Duyarlılık: 97,3 Kesinlik: 97,4
Qaimkhani vd. [13]	Derin öğrenme algoritmaları	YSA ESA VGG19	[10]	YSA Doğruluk: 94,44 ESA Doğruluk: 96,68 VGG19 Doğruluk: 98,27
Dulaimi vd. [14]	Derin öğrenme algoritmaları	Önerilen ESA Resnet50 VGG16	[10]	Kesinlik: 98 Duyarlılık: 98 F1-skor: 97 Doğruluk: 99,82
Alshehri vd. [15]	Ardışık Model	VGG	[10]	Doğruluk: 93 Kesinlik: 95,7 Duyarlılık: 76,49 F1 skor: 85,02
Kaur vd. [16]	Derin öğrenme tabanlı yapı	VGG-16 VGG-19 InceptionResNetV2	[10] [17]	Doğruluk: 95,07
Ayan vd. [18]	Derin ESA Topluluğu	VGG-16 VGG-19 ResNet-50 Inception-V3 Xception MobileNet SqueezeNet	[10]	Hassasiyet: 97,76 Doğruluk: 90,71
Sourab vd. [19]	Hibrit derin öğrenme modeli	ESA-RF ESA-KNN ESA-DVM	[10]	Doğruluk: 99,52
Saha vd. [20]	Yeni derin öğrenme modeli	14 katmanlı yeni ESA	[10]	Doğruluk: 89,0



Şekil 2. Pnömoni tespiti için önerilen yöntemin akış diyagramı (Flowchart of the proposed method for pneumonia detection)

Tablo 3. Deneysel çalışmanın gerçekleştirildiği bilgisayarın yazılım ve donanım parametreleri (Software and hardware parameters of the computer on which the experimental study was carried out)

Yazılım/ Donanım	Parametreler
İşletim sistemi	Windows
CPU	Intel(R) Xeon(R) E5-1650
GPU	NVIDIA Quadro M4000
GHz hızı	3.60 GHz
Bellek özellikleri	64 GB bellek
Program dili	MATLAB

Tablo 4. Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin DVM başarıları (SVM achievements of pre-trained ESA models in the Pneumonia/Healthy classification)

Derin Öznitelikler + DVM (%80 Eğitim - %20 Test)	Doğruluk	Kesinlik	Duyarlılık	F1 skor
AlexNet (fc6)	97,00	95,50	98,45	96,95
SqueezeNet(pool10)	97,25	96,00	98,46	97,22
ResNet50(fc1000)	96,50	96,00	96,97	96,48
ShuffleNet(node202)	96,75	96,00	97,46	96,73
NasNetMobile(predictions)	95,75	93,00	98,41	95,63
MobileNetV2(Logits)	96,00	95,50	96,46	95,98
VGG16 (fc7)	96,50	95,50	97,45	96,46
VGG19 (fc7)	96,00	95,00	96,94	95,96
DenseNet201(fc1000)	95,00	94,00	95,92	94,95
DarkNet53(conv53)	93,50	95,50	97,45	96,46

ile deneysel çalışmalar gerçekleştirilmiştir. Uçtan uca öğrenme için ise 21 katmanlı model oluşturularak sıfırdan eğitilmiştir. Çalışmanın ön işleme aşaması olarak; kullanılan farklı algoritmaların görüntü girişleri farklı olduğu için CXR görüntüleri yeniden boyutlandırılmıştır. Önceden eğitilmiş ESA modellerini eşit şartlar altında karşılaştırmak için tüm modeller minimum girdi boyutlarını karşılayacak ortak boyut olan 256×256 yeniden boyutlandırılmıştır. Deneysel çalışmalarda veri seti hem belirli oranlarda eğitim ve test veri setlerine ayrılmıştır, hem de k-katlı çapraz geçerlilik testi uygulanmıştır. Böylece veri seti %80 eğitim ve %20 test olarak

ayrılmıştır. Ayrıca k-katlı çapraz geçerlilik testi için k değeri 5 seçilmiştir. Literatür incelendiğinde k değeri genellikle 5 veya 10 seçilmektedir. Bu çalışmada, veri işleme yükü ve zaman tasarrufu açısından k değeri 5 olarak belirlenmiştir. Şekil 2’de pnömoni tespiti için önerilen yöntemin akış diyagramı yer almaktadır. Tablo 3’de deneysel çalışmaların yürütüldüğü bilgisayarın yazılım ve donanım parametreleri yer almaktadır. Tablo 4, Tablo 5 ve Tablo 6’da önceden eğitilmiş 10 adet ESA modelinin ilk derin öznitelik çıkarımı sınıflandırma başarımları gösterilmiştir. Tablo 4’den, SqueezeNet modelinin %97,25 ortalama doğruluk puanı ile en yüksek ortalama

doğruluk puanını ürettiği, AlexNet, ShuffleNet, VGG16, ResNet50, MobileNetV2 ve VGG19 modellerinin ise sırasıyla %97,00, %96,75, %96,50, %96,50, %96,00 ve %96,00 ortalama doğruluk puanı ürettiği görülebilir. DenseNet201 modeli %95,00 ortalama doğruluk puanı üretirken, DarkNet53 modeli %93,50 ile en düşük doğruluk puanları üretmiştir. SqueezeNet, ResNet50 ve ShuffleNet %96,00 ile aynı kesinlik puanını elde ederken NasNetMobile %93,00 ile en düşük kesinlik başarımlarını göstermiştir. SqueezeNet, AlexNet ve NasNetMobile sırasıyla %98,46, %98,45 ve %98,41 ile en yüksek duyarlılık puanları elde ederken, DenseNet201 %95,92 ile en düşük duyarlılık başarımlarını göstermiştir. SqueezeNet, AlexNet, ShuffleNet ve ResNet50 sırasıyla %97,22, %96,95, %96,73, %96,48 F1 skor puanı üretirken, DenseNet201 %94,95 ile en düşük F1 skor puanı elde etmiştir. Önceden eğitilmiş ESA modellerinden çıkarılan derin özniteliklerin KNN sınıflandırma performansları Tablo 5’de yer almaktadır. AlexNet’in fc6 katmanından çıkarılan özniteliklerin sınıflandırmada %96,00 doğruluk puanı ile en yüksek ortalama doğruluk puanını ürettiği, ResNet fc1000 katmanı kullanılarak çıkarılan özniteliklerin sınıflandırmada ikinci en iyi puan olarak %94,00 doğruluk puanı ürettiği görülebilir. ShuffleNet modeli %93,75 ortalama doğruluk puanı üretirken, SqueezeNet modeli %89,50 ile en düşük doğruluk oranına sahiptir. DarkNet53 %95,00 ile en yüksek kesinlik puanı elde ederken; ResNet50 %94,00, AlexNet %92,50 ve VGG16 %91,00 kesinlik puanı elde etmiştir. SqueezeNet %82,50 ve NasNetMobile %84,00 ile en düşük kesinlik başarımlarını göstermiştir. AlexNet %99,46 ile en yüksek duyarlılık elde ederken; MobileNetV2 %98,31 ile en yüksek ikinci duyarlılık değeri elde etmiştir. %89,89 ile NasNetMobile en düşük duyarlılık puanı üretmiştir. AlexNet ve ResNet50 sırasıyla %95,85 ve %94,00 ile en yüksek F1 skor puanları elde ederken; NasNetMobile %87,11 ile en düşük F1 skor puanı elde etmiştir.

Önceden eğitilmiş ESA modellerinden çıkarılan derin özniteliklerin RF sınıflandırma performansları Tablo 6’da yer almaktadır. AlexNet’in fc6 katmanından çıkarılan özniteliklerin sınıflandırmada %95,75 doğruluk puanı ile en yüksek ortalama doğruluk puanını ürettiği, ShuffleNet’in node202 katmanı kullanılarak çıkarılan

özniteliklerin sınıflandırmada ikinci en iyi puan olarak %95,25 doğruluk puanı ürettiği görülebilir. MobileNetV2 modeli %94,00 ortalama doğruluk puanı üretirken, SqueezeNet modeli %91,50 ile en düşük doğruluk oranına sahiptir. AlexNet %96,00 ile en yüksek kesinlik puanı elde ederken; MobileNetV2 %95,00, ShuffleNet %94,50 ve DenseNet201 %93,50 kesinlik puanı elde etmiştir. VGG modelleri %92,00 ve SqueezeNet %90,50 ile en düşük kesinlik başarımlarını göstermiştir. ShuffleNet %95,94 ile en yüksek duyarlılık elde ederken; AlexNet %95,52 ile en yüksek ikinci duyarlılık değeri elde etmiştir. %91,37 ile NasNetMobile en düşük duyarlılık puanı üretmiştir. AlexNet ve ShuffleNet sırasıyla %95,76 ve %95,21 ile en yüksek F1 skor puanları elde ederken; NasNetMobile %90,68 ile en düşük F1 skor puanı elde etmiştir.

İkinci derin öznitelik çıkarma deneylerinde veri seti 5 kat çapraz doğrulama kullanılarak ayrılmıştır. Tablo 7’de önceden eğitilmiş ESA modellerinin DVM sınıflandırma başarımları yer almaktadır. ShuffleNet %98,00 doğruluk puanı ile en yüksek doğruluğa ulaşırken; AlexNet %97,75, SqueezeNet %97,50, DenseNet201 %97,25 doğruluk elde etmiştir. VGG16 ve DarkNet53 %96,00 ile en düşük doğruluk puanı üretmiştir. SqueezeNet %98,50 ile en yüksek kesinlik puanı elde ederken; DarkNet53 ve NasNetMobile %95,00 ile diğer modellere göre daha düşük kesinlik puanı elde etmiştir. ShuffleNet %98,98 ve AlexNet %98,48 ile en yüksek duyarlılık puanlarını üretirken; VGG16 %96,00 ile en düşük duyarlılık başarımlarını göstermiştir. ShuffleNet, AlexNet ve SqueezeNet sırasıyla %97,98, %97,73, %97,52 ile ortalama en yüksek F1 skor puanı elde etmiştir. DarkNet53 en düşük F1 skor puanını %95,98 ile göstermiştir.

Tablo 8’de önceden eğitilmiş ESA modellerinin KNN sınıflandırma başarımları yer almaktadır. AlexNet %96,25 doğruluk puanı ile en yüksek doğruluğa ulaşırken; ShuffleNet %95,75, VGG16 %93,50, DenseNet201 ve ResNet50 %93,25 doğruluk elde etmiştir. NasNetMobile %90,00 ile en düşük doğruluk puanı üretmiştir. ResNet50 %95,00 ile en yüksek kesinlik puanı elde ederken; SqueezeNet ve NasNetMobile %88,00 ile diğer modellere göre daha düşük kesinlik puanı elde etmiştir. AlexNet %97,93 ve DenseNet201

**Tablo 5.** Pnömoni/ Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin KNN başarımları  
(KNN achievements of pre-trained ESA models in the Pneumonia/ Healthy classification)

Derin Öznitelikler + KNN (%80 Eğitim - %20 Test)	Doğruluk	Kesinlik	Duyarlılık	F1 skor
AlexNet	96,00	92,50	99,46	95,85
SqueezeNet	89,50	82,50	95,93	88,71
ResNet50	94,00	94,00	94,00	94,00
ShuffleNet	93,75	89,50	97,81	93,47
NasNetMobile	87,50	84,50	89,89	87,11
MobileNetV2	93,00	87,50	98,31	92,59
VGG16	91,50	91,00	91,92	91,46
VGG19	92,00	89,50	94,21	91,79
DenseNet201	93,25	89,00	97,27	92,95
DarkNet53	92,75	95,00	90,91	92,91

**Tablo 6.** Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin RF başarımları  
(RF achievements of pre-trained ESA models in the Pneumonia/ Healthy classification)

Derin Öznitelikler + RF (%80 Eğitim - %20 Test)	Doğruluk	Kesinlik	Duyarlılık	F1 skor
AlexNet	95,75	96,00	95,52	95,76
SqueezeNet	91,50	90,50	92,35	91,41
ResNet50	93,50	93,00	93,94	93,47
ShuffleNet	95,25	94,50	95,94	95,21
NasNetMobile	90,75	90,00	91,37	90,68
MobileNetV2	94,00	95,00	93,14	94,06
VGG16	92,50	92,00	92,93	92,46
VGG19	92,25	92,00	92,46	92,23
DenseNet201	92,75	93,50	92,12	92,80
DarkNet53	93,25	93,00	93,47	93,23



%97,27 ile en yüksek duyarlılık puanlarını üretirken; DarkNet53 %89,95 ile en düşük duyarlılık başarımı göstermiştir. AlexNet ve ShuffleNet sırasıyla %96,18, %95,70 ile ortalama en yüksek F1 skor puanı elde etmiştir. NasNetMobile en düşük F1 skor puanını %89,80 ile göstermiştir.

Veri setinin 5 kat çapraz doğrulamayla ayrıldığı son derin öznitelik çıkarımı deneysel çalışması Tablo 9'da sunulmuştur. Önceden eğitilmiş ESA modellerinden çıkarılan özniteliklerin RF sınıflandırma performansları açısından ShuffleNet %97,00 ile en yüksek doğruluğu elde etmiştir. AlexNet %96,75, DenseNet201 %95,25 ve ResNet50 %95,00 ortalama doğruluk puanları üretmiştir. DarkNet53 %90,50 ile en düşük doğruluk puanına sahiptir. Kesinlik başarımları açısından AlexNet %97,50 ile en yüksek; ShuffleNet %97,00 ile en yüksek ikinci puanı üretmiştir. DarkNet53 %90,00 ve NasNetMobile %91,00 ile en düşük kesinlik puanı elde etmiştir. Duyarlılık açısından DarkNet53 %90,91 ile en düşük; ShuffleNet %97,00 ile en yüksek puanları elde etmiştir. F1 skor açısından da DarkNet53 %90,45 ile en düşük; ShuffleNet %97,00 ile en yüksek puanları üretmiştir.

İki derin öznitelik çıkarımı deneylerinin sonuçları karşılaştırıldığında; 5 katlı çapraz doğrulama kullanılarak ayrılan veri seti ile yapılan test

sonuçlarının daha yüksek doğruluk puanlarına ulaştığı görülmektedir. K-katlı çapraz doğrulama kullanılırken, verilerin tüm bölümleri test verilerinin bir parçası olarak kullanılabilir. Bu şekilde, veri kümesindeki tüm veriler hem eğitim hem de test için kullanılabilir ve modelin performansının daha iyi değerlendirilmesini sağlar [45].

Tablo 10'da önceden eğitilmiş modellerin ince ayarının doğruluk sonuçları gösterilmiştir. Veri seti %80 eğitim ve %20 test olarak ayrılmıştır. En yüksek doğruluk puanı %98,50 ile AlexNet modeli tarafından üretilirken; ikinci en iyi doğruluk puanı %98,00 ile NasNetMobile modelinden elde edilmiştir. MobileNetV2, VGG16 ve ResNet50 modelleri sırasıyla %97,75, %97,50 ve %97,25 doğruluk puanları elde edilmiştir. DenseNet201 %94,75 ile en düşük doğruluk puanı elde etmiştir. Kesinlik puanları açısından karşılaştırıldığında sonuçlar %89,50 ile %99,50 arasında değişmektedir. VGG19 %99,50 ile en yüksek; DenseNet201 %89,50 ile en düşük kesinlik puanlarını üretmiştir. ResNet50 ve DarkNet53 %94,50 ile ortalama kesinlik değeri elde etmiştir. AlexNet, ResNet50 ve DenseNet201 %100,00 duyarlılık değeri üretmiştir. %99,48 ile en yüksek ikinci duyarlılık değerinin MobileNetV2 üretmiştir. VGG19 %92,56; ShuffleNet %95,63 ile diğer modellere göre daha düşük duyarlılık elde etmiştir. F1 skor değerleri %94,46 ile %98,48 arasında değişmektedir. VGG16,

**Tablo 7.** Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin DVM başarımları  
(SVM achievements of pre-trained ESA models in the Pneumonia/ Healthy classification)

Derin Öznitelikler + DVM (5 kat çapraz doğrulama)	Doğruluk	Kesinlik	Duyarlılık	F1 skor
AlexNet	97,75	97,00	98,48	97,73
SqueezeNet	97,50	98,50	96,57	97,52
ResNet50	96,75	96,50	96,98	96,74
ShuffleNet	98,00	97,00	98,98	97,98
NasNetMobile	96,25	95,00	97,44	96,20
MobileNetV2	96,75	96,50	96,98	96,74
VGG16	96,00	96,00	96,00	96,00
VGG19	97,00	97,50	96,53	97,01
DenseNet201	97,25	96,50	97,97	97,23
DarkNet53	96,00	95,00	96,46	95,98

**Tablo 8.** Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin KNN başarımları  
(KNN achievements of pre-trained ESA models in the Pneumonia/Healthy classification)

Derin Öznitelikler + KNN (5 kat çapraz doğrulama)	Doğruluk	Kesinlik	Duyarlılık	F1 skor
AlexNet	96,25	94,50	97,93	96,18
SqueezeNet	91,50	88,00	94,62	91,19
ResNet50	93,25	95,00	91,79	93,37
ShuffleNet	95,75	94,50	96,92	95,70
NasNetMobile	90,00	88,00	91,67	89,80
MobileNetV2	92,50	89,50	95,21	92,27
VGG16	93,50	93,00	93,94	93,47
VGG19	92,50	91,00	93,81	92,39
DenseNet201	93,25	89,00	97,27	92,95
DarkNet53	91,75	94,00	89,95	91,93

**Tablo 9.** Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin RF başarımları  
(RF achievements of pre-trained ESA models in the Pneumonia/ Healthy classification)

Derin Öznitelikler + RF (5 kat çapraz doğrulama)	Doğruluk	Kesinlik	Duyarlılık	F1 skor
AlexNet	96,75	97,50	96,06	96,77
SqueezeNet	93,00	94,00	92,16	93,07
ResNet50	95,00	94,00	95,92	94,95
ShuffleNet	97,00	97,00	97,00	97,00
NasNetMobile	91,25	91,00	91,46	91,23
MobileNetV2	93,00	93,00	93,00	93,00
VGG16	93,50	93,00	93,94	93,47
VGG19	93,25	93,50	93,03	93,27
DenseNet201	95,25	95,00	95,48	95,24
DarkNet53	90,50	90,00	90,91	90,45

NasNetMobile, MobileNetV2 modelleri sırasıyla %98,00, %97,71, %97,52 elde etmiştir. DenseNet201'in ürettiği %94,46 ve SqueezeNet'in ürettiği %94,82 düşük F1 skor değerlerindedir.

Tablo 11'de önerilen ESA modellerinin 5 katlı çapraz doğrulama test sonuçları yer almaktadır. Modeller doğruluk değerleri açısından karşılaştırıldığında; VGG16 %98,25 ile en yüksek puana ulaşırken, DenseNet201 %98,10, Resnet50 ve DarkNet53 %98,00 başarımlarını göstermiştir. ShuffleNet %97,75, MobileNetV2 %97,15, NasNetMobile %97,00 doğruluk değeri üretmiştir. VGG19 ve NasNetMobile %99,50 ile en yüksek kesinlik değeri elde etmiştir. DarkNet53 %98,10, ResNet50 %98,00 ile en yüksek duyarlılık değerlerini üretmiştir. NasNetMobile %94,94 ile en düşük duyarlılık performansı göstermiştir. VGG16'nin F1 skor değeri %98,26'dır, %91,80 ile en düşük F1 skor performansı SqueezeNet'e aittir.

Mevcut çalışmanın son deneylerinde, yeni bir ESA modeli oluşturulmuş ve pnömoni sınıflandırması amacıyla uçtan uca

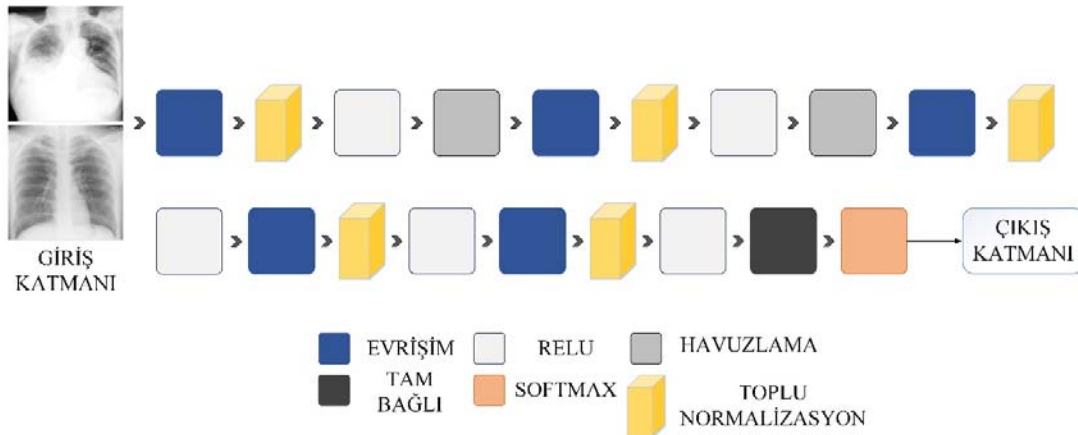
eğitilmiştir. Geliştirilen ESA modelleri Şekil 3'de gösterildiği gibi 21 katmandan oluşmaktadır. Yeni ESA mimarisi, bir giriş katmanı ile başlayıp, ardından her bir evrişim katmanını izleyen toplu normalleştirme ve ReLU katmanı ile devam etmektedir. Havuzlama katmanlarında 'max' operatör fonksiyonu kullanılmıştır. 21 katmanlı ESA mimarisinin evrişim\_1, evrişim\_2, evrişim\_3, evrişim\_4 ve evrişim\_5 olmak üzere beş evrişim katmanı bulunmaktadır. Ayrıca sırasıyla ReLu\_1 ve ReLu\_2 katmanlarından sonra gelen havuzlama\_1 ve havuzlama\_2 olmak üzere iki havuz katmanı vardır. Sınıflandırma amacıyla tam bağlantılı katman, softmax katmanı ve sınıflandırma katmanı da kullanılmıştır. Evrişim\_1, evrişim\_2 ve evrişim\_3 katmanları,  $3 \times 3$  piksel boyutunda 64, 32, 16, 8 ve 4 filtre içermektedir. Katmanların, aktivasyonların ve öğrenilebilir ağırlıkların açıklamalarını kapsayan yeni ESA mimarisinin detayları Şekil 3'de ve deney sonuçları Tablo 12 ve Tablo 13'de sunulmuştur. 21 katmanlı yeni ESA hiperparametreleri; 'trainingOptions', 'InitialLearnRate', 'MaxEpochs' ve 'MiniBatchSize' sırasıyla 'sgdm', 0.0001, 8 ve  $10^4$ 'dur.

**Tablo 10.** Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin ince ayarının başarıları (Achievements of fine tuning pre-trained ESA models in Pneumonia/ Healthy classification)

Transfer Learning (%80 Eğitim- %20 Test)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
AlexNet	98,50	97,00	100,00	98,48
SqueezeNet	95,00	91,50	98,39	94,82
ResNet50	97,25	94,50	100,00	97,17
ShuffleNet	97,00	98,50	95,63	97,04
NasNetMobile	98,00	98,00	98,00	98,00
MobileNetV2	97,75	96,00	99,48	97,71
VGG16	97,50	98,50	96,57	97,52
VGG19	95,75	99,50	92,56	95,90
DenseNet201	94,75	89,50	100,00	94,46
DarkNet53	96,50	94,50	98,44	96,43

**Tablo 11.** Pnömoni/Sağlıklı sınıflandırmasında önceden eğitilmiş ESA modellerinin ince ayarının başarıları (Achievements of fine tuning pre-trained ESA models in Pneumonia/Healthy classification)

Transfer Learning (5 kat çapraz doğrulama)	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 skor (%)
AlexNet	94,00	90,60	97,21	93,79
SqueezeNet	92,00	89,00	94,78	91,80
ResNet50	98,00	98,00	98,00	98,00
ShuffleNet	97,75	97,80	97,70	97,75
NasNetMobile	97,10	99,50	94,94	97,17
MobileNetV2	97,15	98,50	95,91	97,19
VGG16	98,25	99,00	97,54	98,26
VGG19	97,00	99,50	94,76	97,08
DenseNet201	98,10	98,50	97,72	98,11
DarkNet53	98,00	97,80	98,10	97,95



**Şekil 3.** Pnömoni tespitinde önerilen yeni 21 katmanlı ESA modeli (New 21 layer CNN model proposed for pneumonia detection)

**Tablo 12.** Uçtan uca eğitilmiş ESA modelinin başarıları (Achievements of end-to-end trained ESA model)

Uçtan uca eğitilmiş ESA (%80eğitim- %20test) 21 katman	Doğruluk	Kesinlik	Duyarlılık	F1 skor
	96,75	96,50	97,00	96,75

**Tablo 13.** Uçtan uca eğitilmiş ESA modelinin başarıları (Achievements of end-to-end trained ESA model)

Uçtan uca eğitilmiş ESA (5 kat çapraz doğrulama) 21 katman	Doğruluk	Kesinlik	Duyarlılık	F1 skor
	95,75	93,50	97,91	95,65

**Tablo 14.** Önerilen modelin Kaggle Pnömoni X-ray görüntü veri setindeki performans metrikleri  
(Performance metrics of the proposed model in the Kaggle Pneumonia X-ray image dataset)

Uçtan uca eğitilmiş ESA (5 kat çapraz doğrulama) 21 katman	Doğruluk	Kesinlik	Duyarlılık	F1 skor
	94,50	90,50	98,37	94,27

Çalışmanın son aşamasında Kaggle Pnömoni adlı halka açık bir veri seti de kullanılmıştır [10]. Veri seti, Pnömoni ve Normal sınıflarına ait 5863 X-ışını Göğüs görüntüsü içerir. Sınıf dengesizliği problemlerini önlemek için her iki sınıftan eşit sayıda rastgele seçilmiş ve kullanılmıştır. Bu çalışmada 1750 adedi normal sınıftan ve diğer 1750 örneği pnömoni sınıfından olmak üzere 3500 görüntü kullanılmıştır. Bu çalışma için önerilen 21 katmanlı yeni modelin Kaggle Pnömoni CXR veri setindeki performans değerlendirmeleri Tablo 14’de yer almaktadır.

Tablo 12 ve Tablo 13’de önerilen yeni ESA modelinin çapraz doğrulama ve hold out doğrulama yöntemleriyle geçerliliği test edilmiştir. Tablo 12’de 21 katmanlı ESA %96,75 doğruluk değeri elde etmiştir. 21 katmanlı yeni ESA modelinin Kaggle CXR veri setindeki doğruluk performansı %94,50’dir. Uygulanan yöntemlerin performans karşılaştırılması Tablo 15’de gösterilmiştir. Yapılan tüm deneysel çalışmalar karşılaştırıldığında, derin öznitelik çıkarma ve derin transfer öğrenme yaklaşımı, önerilen ESA modellerinin uçtan uca eğitiminden daha iyi doğruluk puanları üretmiştir. Bu sonuç hem derin öznitelik çıkarma hem de derin transfer öğrenme için önceden eğitilmiş derin ESA modelleri kullanıldığından makul kabul edilmiştir.

**Tablo 15.** Uygulanan yöntemlerin performans karşılaştırması  
(Performance comparison of applied methods)

Yöntem	Doğruluk
ShuffleNet+ DVM (k fold)	%98,00
İnce ayarlı AlexNet (hold out)	%98,50
Uçtan uca eğitilmiş ESA (hold out)	%96,75

#### 4. Sonuçlar (Conclusions)

Mevcut çalışmada, CXR görüntülerine dayalı olarak pnömoni tespiti için üç ESA yaklaşımı uygulanmıştır. Daha spesifik olarak, iki transfer öğrenme yaklaşımı, yani derin öznitelik çıkarma ve ince ayar ve ayrıca uçtan uca eğitilmiş yeni bir ESA modeli önerilmiştir. Bu kapsamda on farklı ESA modeli VGG16, VGG19, ResNet50, AlexNet, ShuffleNet, MobileNetV2, NasNetMobile, DarkNet53, DenseNet201 ve SqueezeNet ve önerilen ESA modeli, transfer öğrenme yaklaşımları ve uçtan uca öğrenme için aynı veri seti üzerinde eğitilmiştir. Çıkarılan derin öznitelikler DVM, KNN ve RF algoritmaları ile sınıflandırılmışlardır. Şekil 1’de bu çalışma için oluşturulmuş CXR görüntü veri seti yer alırken, Tablo 4, Tablo 5 ve Tablo 6’da önceden eğitilmiş ESA modellerinin derin öznitelik çıkarımı sonuçlarının doğruluk oranları karşılaştırılmıştır. Tablo 7, Tablo 8 ve Tablo 9’da önceden eğitilmiş ESA modellerinin derin öznitelik çıkarımı çapraz doğrulama sonuçlarının doğruluk oranları karşılaştırılmıştır. Tablo 10 ve Tablo 11’de transfer öğrenme yönteminin doğruluk oranları mukayese edilmiştir. Tablo 12 ve Tablo

13’de uçtan uca öğrenme ile eğitilmiş yeni ESA modelinin sınıflandırma performansları karşılaştırılmıştır. Tablo 14’de önerilen yeni ESA modelinin Kaggle CXR veri setindeki performans sonuçları yer almaktadır. Tablo 15’de yapılan çalışmanın metodları ve performans sonuçları kıyaslanmıştır. Önceden eğitilmiş AlexNet ağının ince ayarının %98,50 ile deneysel çalışmalar arasında en yüksek doğruluk puanına ulaştığı görülmektedir. Gelecekteki çalışmalarda, derin ağların eğitimini iyileştirmek için CXR görüntü veri setini büyütmeyi amaçlıyoruz. Bunun için ek pnömoni göğüs röntgeni görüntüleri toplanacak ve pnömoni tespiti için daha derin ESA modelleri araştırılacaktır.

#### Teşekkür (Acknowledgement)

Bu makalede sunulan çalışmalar, Zehra Kadiroğlu’nun “Sayısal Veri ve Göğüs Röntgen Görüntülerinden Derin Öğrenme Yaklaşımları ile Pnömoni Tespiti” isimli doktora tez çalışması kapsamında yürütülmüştür. Doktora tez çalışmasında birinci danışman Doç. Dr. Erkan Deniz ve ikinci danışman Prof. Dr. Abdurrahman Şenyiğit’tir. Dicle Üniversitesi Tıp Fakültesi Göğüs Hastalıkları ve Tüberküloz Ana Bilim Dalı’na çalışmaya veri katkılarından dolayı teşekkür ederim.

#### Etik Onay (Ethics approval)

Bu çalışma Helsinki Deklarasyonu ilkelerine uygun olarak yapılmıştır. Dicle Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu’ndan onay alındı. Tarih: 13.10.2021, Sayı: 421

#### Kaynaklar (References)

- Luján-García J. E., Yáñez-Márquez C., Villuendas-Rey Y., Camacho-Nieto O., A transfer learning method for pneumonia classification and visualization, Applied Sciences, 10 (8), 2908, 2020.
- Mahomed N., Van Ginneken, B., Philipsen R. H., Melendez J., Moore D. P., Moodley H., Sewchuran T., Mathew D., Madhi S. A., Computer-aided diagnosis for World Health Organization-defined chest radiograph primary-endpoint pneumonia in children, Pediatric Radiology, 50 (4), 482-491, 2020.
- Kumar S., Singh P., Ranjan M., A review on deep learning-based pneumonia detection systems, International Conference on Artificial Intelligence and Smart Systems (ICAIS), India, 289-296, 2021.
- Doi K., Computer-aided diagnosis in medical imaging: historical review, current status and future potential, Computerized medical imaging and graphics, 31 (4-5), 198-211, 2007.
- WHO. Standardization of Interpretation of Chest Radiographs for the Diagnosis of Pneumonia in Children; World Health Organization: Geneva, Switzerland, 2001.
- Ayan E., Ünver H. M., Diagnosis of pneumonia from chest X-ray images using deep learning. In 2019 Scientific Meeting on Electrical-

- Electronics & Biomedical Engineering and Computer Science (EBBT),1-5,2019.
7. El Zein O. M., Soliman M. M., Elkholy A. K., Ghali N. I., Transfer Learning Based Model for Pneumonia Detection in Chest X-ray Images, *International Journal of Intelligent Engineering and Systems*, 14 (5), 56-66, 2021.
  8. Rahman T., Chowdhury M. E., Khandakar A., Islam K. R., Islam K. F., Mahub Z. B., Kashem S., Transfer learning with deep convolutional neural network for pneumonia detection using chest X-ray, *Applied Sciences*, 10 (9), 3233, 2020.
  9. Yaseliani M., Hamadani A. Z., Maghsoodi A. I., Mosavi A., Pneumonia Detection Proposing a Hybrid Deep Convolutional Neural Network Based on Two Parallel Visual Geometry Group Architectures and Machine Learning Classifiers, *IEEE Access*, 10, 62110-62128, 2022.
  10. Kermany D. S., Goldbaum M., Cai W., Valentim C. C., Liang H., Baxter S. L., ... & Zhang, K., Identifying medical diagnoses and treatable diseases by image-based deep learning, *Cell*, 172 (5), 1122-1131, 2018.
  11. Mujahid M., Rustam F., Álvarez R., Luis Vidal Mazón J., Diez I. D. L. T., Ashraf I., Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network, *Diagnostics*, 12 (5), 1280, 2022.
  12. Szepeşi P., Szilágyi L., Detection of pneumonia using convolutional neural networks and deep learning, *Bioinformatics and Biomedical Engineering*, 42 (3), 1012-1022, 2022.
  13. Qaimkhani F. M., Hussain M., Shiren Y., Xingfang J., Pneumonia Detection Using Deep Learning Methods, *International Journal of Scientific Advances (IJSCIA)*, 3 (3), 489-493, 2022.
  14. Al-Dulaimi D. S., Mahmoud A. G., Hassan N. M., Alkhayyat A., Majeed S. A., Development of Pneumonia Disease Detection Model Based on Deep Learning Algorithm, *Wireless Communications and Mobile Computing*, 2022.
  15. Alshehri A., Alharbi B., Alharbi A., Pneumonia Detection from Chest X-ray Images Based on Sequential Model, *International Journal of Computer Science & Network Security*, 22 (4), 53-58, 2022.
  16. Kaur R. P., Sharma A., Singh I., Malhotra R., Deep Learning-Based Pneumonia Recognition from Chest X-Ray Images, *International Journal of Performability Engineering*, 18 (5), 380-386, 2022.
  17. Wang X., Peng Y., Lu L., Lu Z., Bagheri M., Summers R. M., Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, USA, 2097-2106, 2017.
  18. Ayan E., Karabulut B., Ünver H. M., Diagnosis of pediatric pneumonia with ensemble of deep convolutional neural networks in chest x-ray images, *Arabian Journal for Science and Engineering*, 47(2), 2123-2139, 2022.
  19. Sourab S. Y., Kabir M. A., A comparison of hybrid deep learning models for pneumonia diagnosis from chest radiograms, *Sensors International*, 3, 100-167, 2022.
  20. Saha A. K., Rahman M., An Efficient Deep Learning Approach for Detecting Pneumonia Using the Convolutional Neural Network, In *Sentimental Analysis and Deep Learning*, Springer, 59-68, 2022.
  21. İnik Ö., Ülker E., Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104, 2017.
  22. Mohamed O., Khalid E. A., Mohammed O., Brahim, A., Content-based image retrieval using convolutional neural networks, In *First International Conference on Real Time Intelligent Systems*, Springer, 463-476, 2017.
  23. Krizhevsky A., Sutskever I., Hinton G. E., ImageNet classification with deep convolutional neural networks, In *NIPS*, 1106-1114, 2012.
  24. Simonyan K., Zisserman A., Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.
  25. He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, USA, 770-778, 2016.
  26. Huang G., Liu Z., Van Der Maaten L., Weinberger K. Q., Densely connected convolutional networks, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, USA, 4700-4708, 2017.
  27. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L. C., Mobilenetv2: Inverted residuals and linear bottlenecks, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, USA, 4510-4520, 2018.
  28. Zhang X., Zhou X., Lin M., Sun J., Shufflenet: An extremely efficient convolutional neural network for mobile devices, In *Conference on Computer Vision and Pattern Recognition*, 6848-6856, 2018.
  29. Iandola F. N., Han S., Moskewicz M. W., Ashraf K., Dally W. J., Keutzer K., SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size, *arXiv preprint arXiv:1602.07360*, 2016.
  30. Zoph B., Vasudevan V., Shlens J., Le Q. V., Learning transferable architectures for scalable image recognition, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, USA, 8697-8710, 2018.
  31. Redmon J., Farhadi A., Yolov3: An incremental improvement, *arXiv preprint arXiv:1804.02767*, 2018.
  32. 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.
  33. Çallı E., Sogancıoğlu E., Van Ginneken B., Van Leeuwen K. G., Murphy K., SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size, *Medical Image Analysis*, 72, 102-125, 2021.
  34. Glasmachers T., Limits of end-to-end learning, In *Asian Conference on Machine Learning*, Seoul-Kore, 17-32, 2017.
  35. Cortes C., Vapnik V., Support-vector networks, *Machine learning*, 20(3), 273-297, 1995.
  36. Karcioğlu A. A., Aydın T., Sentiment analysis of Turkish and english twitter feeds using Word2Vec model, In *2019 27th Signal Processing and Communications Applications Conference (SIU)*, Sivas-Türkiye, 1-4, 2019.
  37. Karcioğlu A. A., Bulut H., Performance Evaluation of Classification Algorithms Using Hyperparameter Optimization, In *2021 6th International Conference on Computer Science and Engineering (UBMK)*, Ankara-Türkiye, 354-358, 2021.
  38. Nahzat S., Yağanoğlu M., Classification of Epileptic Seizure Dataset Using Different Machine Learning Algorithms and PCA Feature Reduction Technique, *Journal of Investigations on Engineering and Technology*, 4 (2), 47-60, 2021.
  39. Taşçı E., Onan A., K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi, *Akademik Bilişim*, 1 (1), 4-18, 2016.
  40. Cover T., Hart P., Nearest neighbor pattern classification, *IEEE transactions on information theory*, 13 (1), 21-27, 1967.
  41. Breiman L., Random forests. *Machine learning*, 45 (1), 5-32, 2001.
  42. Altay Y., Delialioğlu R. A., Diagnosing lameness with the Random Forest classification algorithm using thermal cameras and digital colour parameters, *Mediterranean Agricultural Sciences*, 35 (1), 47-54, 2022.
  43. Türkoğlu M., Hanbay K., Sivrikaya, I. S., Hanbay, D., Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9 (1), 334-345, 2021.
  44. Visuña L., Yang D., Garcia-Blas J., Carretero J., Computer-aided diagnostic for classifying chest X-ray images using deep ensemble learning, *BMC Medical Imaging*, 22 (1), 1-16, 2022.
  45. Yadav S., Shukla, S., Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification, In *2016 IEEE 6th International Conference on Advanced Computing (IACC)*, Bhimavaram-Hindistan, 78-83, 2016.