

Stokastik Komşuluk Gömülme ile Özellik Çıkarımı ve Derin Transfer Öğrenmesi Kullanılarak Göğüs Röntgeni Görüntülerinden Etkili Pnömoni Tespiti

Effective Pneumonia Detection from Chest x-ray Images Using Feature Extraction and Deep Transfer Learning with Stochastic Neighborhood Embedding

Enver Elitok 

Arş. Gör., Kütahya Dumlupınar Üniversitesi, Simav Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kütahya, Türkiye.

Ömer Kasım 

Doç. Dr., Kütahya Dumlupınar Üniversitesi, Simav Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kütahya, Türkiye

Hamdi Melih Saraoğlu 

Prof. Dr., Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kütahya, Türkiye

* Corresponding author: enver.elitok@dpu.edu.tr

Geliş Tarihi / Received: 05.06.2024
Kabul Tarihi / Accepted: 04.08.2024

Araştırma Makalesi/Research Article
DOI: 10.5281/zenodo.13231261

ÖZET

Pnömoni, akciğerlerde ortaya çıkan bir enfeksiyondur. Bu enfeksiyon dünya çapında ciddi sağlık sorunlarına sebep olmaktadır. Özellikle hastanın hasta hizmetlerini kullanmasında oldukça meşakkatli bir tedavi süreci gerektirmektedir. Yapay zekâ teknolojilerinin sağlık alanına uygulaması ile bu problem çözülebilir. Radyoloji alanındaki uzmanlara destek olacak bir yapay zekâ modeli ile hastalığın erken teşhisinde gözden kaçabilecek önemli bilgiler uzmanlara bildirildiğinde yorgunluk gibi etmenler minimize edilebilecektir. Bu sistemler, teşhiste uzmanlık gerektirmeyen ve hızlı sonuçlar üretebilen otomatik bir yaklaşım sunmaktadır. Bu çalışmada akciğer X-ray görüntülerinin sınıflandırılmasında farklı iki yaklaşım önerilmektedir. Veri seti, Hindistan Bilim Enstitüsü, PES Üniversitesi, MS Ramaiah Teknoloji Enstitüsü, Concordia Üniversitesi tarafından sağlanan X-ray görüntüleri kullanılmıştır (doi: 10.17632/9xkhgts2s6.3). Bu veri seti, her biri değişken boyutlarda 3270 normal ve 4657 pnömoni olmak üzere toplam 7927 görüntüden oluşmaktadır. İlk yaklaşımda, görüntülerden MobileNetV2 kullanılarak öznetelik çıkarılmış ve Destek Vektör Makinesi (DVM) ve Uzun-Kısa Süreli Bellek (UKSB) ile ayrı ayrı sınıflandırılmıştır. DVM, %97,22 doğruluk ve 8,2 milisaniye tahmin süresiyle, UKSB ise %90,35 doğruluk ve 9,78 saniye tahmin süresiyle sonuçlanmıştır. İkinci yaklaşımda, öznetelikler t-SNE ile boyutu azaltılarak DVM ve UKSB ile sınıflandırılmıştır. DVM, %94,64 doğruluk ve 3,2 milisaniye tahmin süresiyle, UKSB ise %94,83 doğruluk ve 8,62 saniye tahmin süresiyle sınıflandırma yapmıştır. t-SNE, DVM'nin doğruluğunu azaltırken, UKSB'nin doğruluğunu artırmış ve her iki sınıflandırıcının da tahmin süresini kısaltmıştır. Bu çalışmada, pnömoni tanısında akciğer X-ray görüntülerinin sınıflandırılmasında derin öğrenme ve makine öğrenme modellerinin ve t-SNE gibi veri boyutu azaltma algoritmalarının performansı değerlendirilmiştir. Bu bulgular, pnömoni tanısında bilgisayar destekli yöntemlerin, özellikle derin öğrenme ve veri boyutu azaltma algoritmalarının etkili bir şekilde kullanılmasının, tanı sürecini

hızlandırabileceğini ve doğruluğunu artırabileceğini göstermektedir. Bu sonuçlar, gelecekteki pnömoni tanı yöntemlerinin geliştirilmesinde önemli bir yol gösterici olabilir.

Anahtar Kelimeler: Pnömoni, Görüntü İşleme, Transfer Öğrenme ile Özellik Çıkarma, Stokastik Komşu Gömülme ile Özellik Optimizasyonu, Destek Vektör Makinesi ile Sınıflandırma, Uzun-Kısa Süreli Bellek ile Sınıflandırma.

ABSTRACT

Pneumonia is an infection that occurs in the lungs, posing significant global health challenges. It requires a particularly demanding treatment process for patients utilizing healthcare services. The application of artificial intelligence (AI) technologies in healthcare could address this issue. AI models supporting radiology experts can minimize factors like fatigue by reporting crucial details that might be overlooked in early diagnosis. These systems provide an automatic approach that does not require specialized expertise and produces rapid results. In this study, two different approaches are proposed for classifying lung X-ray images. The dataset used consists of X-ray images provided by the Indian Institute of Science, PES University, MS Ramaiah Institute of Technology, and Concordia University (DOI: 10.17632/9xkhgts2s6.3). This dataset comprises a total of 7927 images, with 3270 normal and 4657 pneumonia images, each of varying dimensions. In the first approach, features were extracted from the images using MobileNetV2, a pre-trained deep learning model. These features were then classified separately using Support Vector Machine (SVM) and Long Short-Term Memory (LSTM). SVM achieved an accuracy of 97.22% with an average prediction time of 8.2 milliseconds, while LSTM achieved an accuracy of 90.35% with an average prediction time of 9.78 seconds. In the second approach, features were extracted using MobileNetV2, and their dimensionality was reduced using t-Distributed Stochastic Neighbor Embedding (t-SNE) before being classified separately by SVM and LSTM. SVM achieved an accuracy of 94.64% with an average prediction time of 3.2 milliseconds, while LSTM achieved an accuracy of 94.83% with an average prediction time of 8.62 seconds. The t-SNE reduced the classification accuracy of SVM but increased the accuracy of LSTM, and it also shortened the prediction times for both classifiers. This study evaluates the performance of deep learning and machine learning models, as well as dimensionality reduction algorithms like t-SNE, in classifying lung X-ray images for pneumonia diagnosis. The findings suggest that computer-aided methods, particularly deep learning and dimensionality reduction algorithms, can effectively speed up and improve the accuracy of the diagnostic process for pneumonia. These results can serve as a significant guide for developing future pneumonia diagnosis methods.

Keywords: Pneumonia, Image Processing, Feature Extraction with Transfer Learning, Feature Optimization with t-Distributed Stochastic Neighbor Embedding, Classification with Support Vector Machine, Classification with Long Short-Term Memory.

1. GİRİŞ

Pnömoni, dünya genelinde ciddi hastalık ve ölüm oranlarına yol açan yaygın bir solunum yolu enfeksiyonudur. Özellikle çocuklar, yaşlılar ve bağışıklık sistemi zayıf olan bireyler için büyük bir sağlık tehdidi oluşturmaktadır. Bu enfeksiyon, akciğer dokusunda iltihaplanmaya neden olarak solunum fonksiyonlarını olumsuz etkiler. Erken ve doğru teşhis, tedavi sürecinde kritik bir öneme sahiptir. Tedavi edilmediğinde veya geç kalındığında, pnömoni ciddi komplikasyonlara ve hatta ölüme yol açabilir (Cyriac vd., 2022; Souid vd., 2021). Pnömoni virüs, bakteri ve mantar kaynaklı olabilmektedir (Chouhan vd., 2020).

Tıbbi görüntüleme, modern sağlık sisteminde önemli bir rol oynamaktadır. Bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG) ve X-ışını görüntüleme gibi teknolojilerin ilerlemeleri,

hastalık tanısında kritik öneme sahip olmuştur. Bu cihazların gelişimi, doğru ve hızlı tanı konulabilmesi için vazgeçilmez hale gelmiştir (Chakraborty vd., 2022).

Bilgisayar destekli tanı (BDT) sistemleri, tıbbi görüntülerde çeşitli anormallikleri tespit etmek amacıyla kullanılan araçlardır (Luján-García vd., 2020). Bu sistemler, doğru teşhis performansını artırmak ve tıbbi uygulamalarda olası hataları önlemek için geliştirilmiştir. BDT, pnömoni vakalarının erken tespiti ve müdahalesiyle halk sağlığını olumsuz etkileyebilecek durumların önlenmesinde önemli bir rol oynamaktadır (Parveen & Khan, 2020).

Yapay zekanın (YZ) kullanımı BDT sistemlerinin etkinliğini daha da artırmaktadır (Güntürkün & Tosun, 2020). YZ, büyük veri setlerini analiz edebilme ve görüntülerdeki örüntüleri tanıma özelliği sayesinde, tıbbi görüntüleme daha yüksek doğruluk ve duyarlılık sağlamaktadır. Özellikle derin öğrenme (DL) algoritmaları, farklı hastalıkların erken teşhisi ve sınıflandırılmasında önemli bir rol oynamaktadır. YZ tabanlı BDT sistemleri, sürekli öğrenme kapasitesi ile yeni verilerle kendini güncelleyebilir ve bu sayede teşhis süreçlerinde sürekli bir iyileşme sağlayabilir. Bu özellikler, YZ'yi modern tıbbi uygulamalarda önemli bir araç haline getirmektedir (Jawahar vd., 2021; El Gannour vd., 2020). Bu çalışmada BDT mimarisini içeren pnömoni hastalığını röntgen görüntülerinden derin öğrenme mimarisi ile teşhis etmek amaçlanmıştır. Bu amaç doğrultusunda derin öğrenme modeli içeren yapay zekâ yazılımı geliştirme, özellik optimizasyonu ile daha hızlı ve dayanıklı sistem tasarımının yapılması ve geçerliliği kanıtlanan bir veri seti ile sonuçların doğrulanması hedeflenmiştir.

Transfer öğrenimi (TL), makine öğrenimi (ML) ve DL alanlarında önemli bir araştırma konusu haline gelmiştir. TL, Pnömoni ve COVID-19 gibi akciğer hastalıklarının teşhisinde oldukça etkili bir yöntemdir. Akciğer röntgen görüntülerinin sınıflandırılmasında yüksek performans elde etmek için TL yaygın olarak kullanılmaktadır (Rahman vd., 2020). EfficientNetB0 (Shaikh vd., 2020), EfficientNetB2 (Hariri & Avşar, 2023), InceptionV3 (Mujahid vd., 2022), InceptionResNetV2 (Sharma vd., 2022), MobileNetV2 (Kolonne vd., 2021), NASNet-Mobile (Mishra, 2021), VGG16 (Sunyoto vd., 2022) ve VGG19 (Jain vd., 2022) gibi modeller, ImageNet (Hashmi vd., 2020) üzerinde önceden eğitilmiş modellerden bazılarıdır. Bu modellerden olan MobileNetV2 mimarisi mobil ve gömülü cihazlarda derin öğrenme modellerinin verimli bir şekilde çalışmasını sağlamak amacıyla tasarlanmış bir konvolüsyonel sinir ağıdır (Kolonne vd., 2021). Bu mimari, özellikle kaynak kısıtlı ortamlar için optimize edildiğinden bu çalışmada transfer öğrenmesini kullanmaya bizi motive etti.

Bu çalışmada, akciğer X-ray görüntülerinin sınıflandırılması için iki farklı yaklaşım önerilmektedir. Kullanılan veri seti, Hindistan Bilim Enstitüsü, PES Üniversitesi, MS Ramaiah Teknoloji Enstitüsü ve Concordia Üniversitesi tarafından sağlanan X-ray görüntülerini içermektedir (doi: 10.17632/9xkhgts2s6.3). Bu veri seti, değişken boyutlarda toplam 7927 görüntüden oluşmakta olup, 4657 pnömoni ve 3270 normal görüntü içermektedir. İlk önerilen yaklaşımda, görüntülerden önceden eğitilmiş derin öğrenme modeli MobileNetV2 kullanılarak öznetelikler çıkarılmıştır. Bu öznetelikler, makine öğrenmesi algoritması Destek Vektör Makinesi (DVM) ve derin öğrenme algoritması Uzun-Kısa Süreli Bellek (UKSB) kullanılarak ayrı ayrı sınıflandırılmıştır. İkinci önerilen yaklaşımda ise, görüntülerden MobileNetV2 ile öznetelik çıkarılmış ve bu özneteliklerin boyutu, Stokastik Komşuluk Gömülmesi (t-SNE) algoritması kullanılarak azaltılmıştır. Ardından, boyutu azaltılmış öznetelikler SVM ve UKSB kullanılarak ayrı ayrı sınıflandırılmıştır. Bu çalışmada, pnömoni tanısında akciğer X-ray görüntülerinin sınıflandırılmasında derin öğrenme ve makine öğrenme modellerinin yanı sıra t-SNE gibi veri boyutu azaltma algoritmalarının performansı incelenmiştir. Elde edilen bulgular, pnömoni tanısında bilgisayar destekli yöntemlerin, özellikle derin öğrenme ve veri boyutu azaltma algoritmalarının etkin kullanımının, tanı sürecini hızlandırabileceğini ve doğruluğunu artırabileceğini ortaya koymaktadır. Bu sonuçlar, gelecekteki pnömoni tanı yöntemlerinin geliştirilmesi açısından önemli bir rehber niteliği taşımaktadır.

Literatür Çalışmaları

Göğüs röntgeni görüntülerini kullanarak pnömoni ve Covid-19 gibi solunum yolu hastalıklarının tespiti ve sınıflandırılması üzerine çok sayıda çalışma yapılmıştır. Çeşitli kaynaklardan alınan veri setlerindeki görüntüler kullanılarak, önceden eğitilmiş derin öğrenme modelleri görüntülerin sınıflandırılması için kullanılmıştır. Çalışmalar, doğruluk, hassasiyet, geri çağırma ve F1 skoru gibi metriklerle değerlendirilmiş ve yüksek performans elde edilmiştir. Derin öğrenme yöntemlerinin pnömoni teşhisinde etkili olduğu ve klinik uygulamalarda kullanılabilirliği vurgulanmıştır. Bu çalışmalardan bazıları aşağıda verilmiştir.

Jha vd. (2022) çalışmalarında, Kaggle ve Mendeley Data'dan aldıkları veri setleri kullanılarak 3616 COVID-19, 4657 pnömoni ve 10192 normal göğüs röntgen görüntülerini sınıflandırmışlardır. Veri setindeki sınıf dengesizliğini gidermek için veri artırma teknikleri kullanmışlardır. Inception-ResNet-v2 modeli kullanarak, iki etiketli sınıflandırmada %97.46, üç etiketli sınıflandırmada %97.44, dört etiketli sınıflandırmada %94.56 ve beş etiketli sınıflandırmada %90.85 doğruluk elde etmişlerdir. Tasarladıkları modellerin küçük veri setlerinde bile etkili olduğunu savunmuşlardır. Gelecekteki çalışmalarda, COVID-19 ve pnömoninin şiddet seviyelerini sınıflandırmayı hedeflemişlerdir.

Kassem ve Albaker (2022) çalışmalarında, üç veri seti kullanılarak pnömoni tespiti yapmışlardır. 224x224 piksel boyutlarına getirdikleri 4618 pnömoni ve 4618 normal göğüs röntgen görüntülerini %70 eğitim, %15 doğrulama ve %15 test için kullanmışlardır. EfficientNetV2 modeli ile yaptıkları normal ve pnömoni görüntülerini %99.2 doğruluk ile sınıflandırmışlardır. Modellerinin doğruluk, hassasiyet ve özgüllük açısından üstün performans sergilediğini ve klinik uygulamalarda kullanılabilirliğini göstermişlerdir.

Srivastava vd. (2022), 15 veri setini birleştirerek oluşturdukları 1281 COVID-19, 3270 normal ve 1656 viral pnömoni göğüs röntgen görüntülerini InceptionV3, InceptionResNetV2, ResNet50V2, DenseNet121 ve DenseNet201 ağlarını kullanarak öznitelik çıkarımı yapmışlardır. Öznitelik vektörlerini 1024 nöronlu tam bağlantılı bir katmanla sınıflandırmışlardır. Aşırı uydurmayı önlemek için dropout katmanı eklenmişlerdir. Alan Genişletilmiş Transfer Öğrenimi (DETL) ve Condorcet'in Jüri Teoremi (CJT) iki adet yöntem geliştirmişlerdir. DETL tabanlı model ile %97.26 doğruluk ve %98.37 hassasiyet, CJT tabanlı model ile %98.22 doğruluk ve %98.37 hassasiyet elde etmişlerdir. Çalışmalarının, derin öğrenme modelleriyle COVID-19 ve pnömoni taraması için etkili bir yöntem sunduğunu ve klinik uygulamalarda erken teşhis ve kontrol için önemli katkılar sağlayabileceğini belirtmişlerdir.

Sunyoto vd. (2022), 28 veri setinden aldıkları toplamda 38,181 göğüs röntgen görüntüsünü normal, pnömoni, viral pnömoni ve COVID-19 sınıflarına ayırmışlardır. VGG16 modelini kullanarak, veri setlerinin boyutu ve sınıf sayısına bağlı olarak %80.10 ile %97.99 arasında doğruluk oranları elde etmişlerdir. Dört sınıf içeren veri setlerinde daha düşük doğruluk değerleri almışlardır. Gelecek çalışmalarında, veri artırma teknikleri kullanılarak modellerinin performansını artırmayı hedeflemişlerdir.

Cyriac vd. (2022), Kaggle RSNA CXR veri setinden 1281 COVID-19, 3270 Normal ve 1656 pnömoni olmak üzere toplam 6207 akciğer röntgen görüntülerini sınıflandırma için kullanmışlardır. Görüntüleri 299x299x3 boyutuna yeniden boyutlandırmış ve veri artırma teknikleri ile görüntü sayılarını artırmışlardır. VGG16, InceptionV3 ve MobileNetV2 modellerini sınıflandırma için kullanmışlardır. Performans değerlendirmesi için doğruluk, geri çağırma, F1 skoru, AUC ve kesinlik metriklerine bakmışlardır. InceptionV3 %96.32 test doğruluğu, VGG16 %98.92 AUC puanı elde etmişlerdir. Tüm modelleri birleştirerek yaptıkları sınıflandırmada %98.63 doğruluk, %99.78 geri çağırma, %97.61 F1 skoru, %98.22 AUC ve %95.54 kesinlik almışlardır. Tasarladıkları modellerin, doktorların pnömoni teşhisinde yardımcı olabileceğini belirtmişlerdir.

Kalgutkar vd. (2021), Mendeley veri setinden aldıkları 5,863 etiketli normal ve pnömoni göğüs röntgeni görüntülerini sınıflandırma için kullanmışlardır. 300x300x3 boyutundaki görüntüleri veri

artırma yöntemleriyle çoğaltmışlardır. VGG16, ResNet-50 ve InceptionV3 modellerini kullandıklarında sırasıyla %94, %93.9 ve %93.5 test doğruluklarına ulaşmışlardır. VGG16 modelinin en yüksek test doğruluğu ve en düşük test kaybına, ResNet-50 modelinin ise en yüksek geri çağırma oranına sahip olduğunu elde etmişlerdir. Veri artırmanın ve özelleştirdikleri model katmanlarının performansı artırdığını göstermişlerdir. Çalışmalarının, pnömoninin hızlı ve doğru teşhisi için derin öğrenmenin etkinliğini gösterdiğini belirtmişlerdir.

Sakib vd. (2021), Radiological Society of North America (RSNA) veri setindeki normal ve pnömoni akciğer röntgen görüntülerini sınıflandırma için kullanmışlardır. Veri seti, 1274 erkek, 876 kadın ve 2152 karma görüntü içeren cinsiyet gruplarına ayrılmıştır. DenseNet121, MobileNet, ResNet101, VGG16, Xception, InceptionV3 modellerini bu gruplar üzerinde test etmişlerdir. Veri setini, %70 eğitim, %15 doğrulama ve %15 test olarak bölmüşlerdir. Görüntüleri 1024x1024 boyutundan 224x224 boyutuna yeniden boyutlandırmışlar ve çeşitli veri artırma teknikleri uygulanmışlardır. InceptionV3 modelinin, kadın veri setinde %96 doğruluk ile en iyi performansı gösterdiğini elde etmişlerdir. DenseNet121 modelinin, kadın ve karma gruplarda %95 doğruluk ile yüksek performans sergilediğini bulmuşlardır. ResNet101 modelinin ise tüm gruplarda en düşük performansı gösterdiğini belirtmişlerdir. Çalışmalarında, cinsiyete özgü modellerin önemli farklılıklar gösterdiğini ve doğru model seçiminin teşhis doğruluğunu artırabileceğini vurgulamışlardır. Gelecekte, bakteriyel ve viral pnömoni sınıflandırması ve klinik kullanım için etkileşimli uygulamaların geliştirilmesini hedeflemişlerdir.

Alharbi ve Hosni Mahmoud (2022), dört veri setinden (PND, BelPnem, NIAPn Pneumonia ve RPNA) elde ettikleri 4300 sağlıklı ve 6767 pnömoni x-ray görüntülerini sınıflandırma için kullanmışlardır. İlk olarak BoxENet modeli ile görüntülere segmentasyon uygulamışlardır. Daha sonra BoxENet, Geliştirilmiş BoxENet, InceptV5, DSNet3 ve DSNet5 modellerini kullanarak sınıflandırma yapmışlardır. Segmentli ve segmentsiz görüntüleri beş modelle ayrı ayrı sınıflandırmışlardır. Geliştirilmiş BoxENet modeliyle, segmentli görüntülerde %98.60 doğruluk, %98.66 duyarlılık ve %98.46 özgüllük elde etmişlerdir. Segmentasyon sürecinin, sınıflandırma doğruluğunu artırdığını bulmuşlardır. BoxENet ve DSNet3 modellerinin en yüksek doğruluk oranlarını gösterdiğini belirtmişlerdir. Sonuçların, x-ray görüntülerine sınıflandırılmadan önce segmentasyon uygulanmasının sınıflandırma doğruluğunu artırabileceğini savunmuşlardır.

Khaled vd. (2022), sağlıklı ve pnömoni göğüs röntgen görüntülerinden oluşan iki farklı veri setini sınıflandırma için kullanmışlardır. Kermany veri setinde toplam 5840 sağlıklı ve pnömoni olmak üzere iki etiketli ve Curated X-ray veri setinde sağlıklı, viral pnömoni, bakteriyel pnömoni ve Covid-19 olmak üzere dört etiketli toplam 18417 görüntü içermektedir. Görüntüleri %90 eğitim ve %10 test için ayırmışlardır. AlexNet, VGG-16, ResNet-50, DenseNet-121 ve InceptionV3 modellerini iki veri setindeki görüntüleri sınıflandırmak için kullanmışlardır. Veri setlerinin küçük olmasından dolayı veri artırma teknikleri uygulamışlardır. Daha sonra bu beş modeli birleştirerek AVRDIS isimli yeni bir model geliştirmişlerdir. Modellerinin performansını doğruluk, hassasiyet, geri çağırma ve F1 skoru gibi metrikler kullanılarak değerlendirmişlerdir. Veri artırma tekniklerinin ve doğru transfer öğrenme yaklaşımlarının model performansını önemli ölçüde artırdığını belirtmişlerdir. AVRDIS modelinin %96.15 doğruluk ve %97.44 F1 skoru ile en yüksek performansı verdiğini göstermişlerdir. Derin öğrenme ve transfer öğrenme yöntemlerinin pnömoni teşhisinde etkili olduğunu vurgulamışlardır.

Venu (2020), Chest X-ray veri setinde normal ve pnömoni olarak etiketlenmiş toplam 5856 göğüs röntgen görüntüsünü sınıflandırma için kullanmışlardır. Tüm görüntüleri, derin öğrenme modellerinin gereksinimlerine uygun olarak 224x224 piksel boyutunda yeniden boyutlandırmış ve veri artırma teknikleri ile eğitim verilerinin boyutu artırmışlardır. Xception, MobileNetV2, InceptionResNet, DenseNet201 ve ResNet152V2 gibi önceden eğitilmiş beş modeli, ImageNet veri setinden transfer öğrenme yöntemiyle alarak, pnömoni sınıflandırması için optimize etmişlerdir. Eğitim sürecinde, her modelin çıktılarını ağırlıklı ortalama yöntemiyle birleştirmiş ve softmax

katmanı ile nihai tahminler yapmışlardır. Ağırlıklı ortalama topluluk modeli adını verdikleri bu yöntemle, toplamda 162 milyon eğitim parametresi ile %98.46 doğruluk, %98.38 hassasiyet, %99.53 geri çağırma ve %98.96 f1 skoru elde etmişlerdir. Elde ettikleri sonuçların, pnömoni sınıflandırmasında önemli bir başarı gösterdiğini savunmuşlardır.

Gu ve Lee (2024), Kaggle platformundaki Chest X-ray Images veri setindeki görüntüleri sınıflandırmak için kullanmışlardır. Bu veri seti, çocukların akciğer röntgenlerini içermekte olup, 1341 normal ve 3875 pnömoni olmak üzere toplam 5863 röntgen görüntüsü içermektedir. Çalışmalarında genellikle tek renk kanallı olan görüntüleri, üç renk kanalına (RGB) dönüştürmüşlerdir. ResNet, DenseNet, ShuffleNet ve MobileNet gibi popüler CNN mimarileri ile görüntüleri sınıflandırmışlardır. Modellerinin performansını değerlendirmek için doğruluk, kesinlik, geri çağırma ve F1 skoru gibi metrikler kullanmışlardır. ResNet18, %93.1 doğruluk ve 0.947 F1 skoru; ResNet50, %89.4 doğruluk ve 0.922 F1 skoru; DenseNet161, %93.6 doğruluk ve 0.951 F1 skoru; ShuffleNet v2, %91.2 doğruluk ve 0.931 F1 skoru; MobileNet v2, %90.9 doğruluk ve 0.931 F1 skoru; ResNeXt50 (32x4d), %92.3 doğruluk ve 0.941 F1 skoru; Wide ResNet50-2, %89.7 doğruluk ve 0.924 F1 skoru elde etmişlerdir. Önceden eğitilmiş modellerin tıbbi görüntü analizinde başarıyla kullanılabilmesini ve derin öğrenmenin sağlık uygulamalarında önemli bir avantaj sağladığı sonucuna varmışlardır. Gelecekte, bu yöntemin farklı tıbbi görüntü veri setleri ve görevlerinde uygulanabilirliğini araştırarak, transfer öğrenme süreçlerinin daha sofistike hale getirilmesine odaklanabileceğini vurgulamışlardır.

El Asnaoui (2021), iki farklı veri seti kullanarak pnömoni sınıflandırması için bir derin öğrenme modeli tasarlamışlardır. Veri seti 1493 viral pnömoni, 2780 bakteriyel pnömoni, 1583 normal ve 231 Covid-19 olmak üzere toplam 6087 görüntüden oluşan dört etiketli görüntülerden oluşmaktadır. Görüntülere ön işleme ve veri artırma teknikleri uygulamışlardır. Tekil modellerden olan InceptionResNet_V2 ile %94.27 doğruluk ve %93.52 F1 skoru, ResNet50 ile %92.97 doğruluk ve %93.47 F1 skoru, MobileNet_V2 ile %94.53 doğruluk ve %91.62 F1 skoru elde etmişlerdir. Topluluk modellerinden olan MobileNet_V2 + InceptionResNet_V2 ile %92.52 F1 skoru, ResNet50 + InceptionResNet_V2 ile %92.43 F1 skoru, ResNet50 + MobileNet_V2 ile %93.79 F1 skoru, ResNet50 + MobileNet_V2 + InceptionResNet_V2 ile %94.84 F1 skoru elde etmişlerdir. Topluluk öğrenme modellerinin pnömoni sınıflandırmasında tekli modellerden daha yüksek performans sağladığını göstermişlerdir. Özellikle ResNet50, MobileNet_V2 ve InceptionResNet_V2 topluluğunun en iyi sonuçları verdiğini belirtmişlerdir. Bu bulguların, CAD sistemlerinin pnömoni teşhisindeki doğruluğunu artırmada önemli bir adım olarak değerlendirilebileceğini vurgulamışlardır.

Bakır vd. (2023), Kaggle platformundan temin ettikleri Chest X-Ray Images (Pneumonia) veri setindeki 1493 bakteriyel pnömoni, 1493 viral pnömoni ve 1493 normal olmak üzere toplam 4479 görüntüyü sınıflandırma için kullanmışlardır. Tüm görüntüleri 180x180 olarak boyutlandırmışlar ve 0-1 arasında normaliz etmişlerdir. %80 eğitim, %10 validasyon ve %10 test olarak ayırmışlardır. Görüntülerden ResNet, Inception ve MobileNet önceden eğitilmiş üç evrişimli sinir ağı (CNN) ile öz nitelik çıkarmışlar ve yapay sinir ağıyla (ANN) sınıflandırmışlardır. Modellerinin performansını doğruluk, hassasiyet, hatırlama ve F1 skorları ile değerlendirmişlerdir. Veri setinin homojen dağılımının, modelin farklı sınıflar arasındaki performansını objektif bir şekilde değerlendirmeyi sağladığını belirtmişlerdir. ANN modelinin ikili sınıflandırmada %95.67 doğruluk, üç etiketli sınıflandırmada ise %81.67 doğruluk elde etmişlerdir. Derin öğrenme tekniklerinin akciğer X-Ray görüntülerinden pnömoni tespiti ve sınıflandırılmasında güvenilir bir şekilde kullanılabilmesini vurgulamışlardır.

Gummedi vd. (2021), sınıflandırma için 4273'ü pnömoni, 1583'ü ise sağlıklı olmak üzere toplam 5856 göğüs röntgen görüntüsü kullanmışlardır. Veri setini, eğitim için 4685 ve test için 1171 görüntüye ayırmışlardır. Görüntüleri, derin öğrenme modelleri tarafından işlenebilmesi için VGG-16 ve VGG-19 için 224x224x3, Inception ResNet V2 için ise 229x229x3 boyutlarına dönüştürmüşler ve veri artırma teknikleri ile görüntüleri artırmışlardır. VGG-19 modelinin, diğer iki modele göre en yüksek

doğruluk ve hassasiyet değerlerine ulaştığını göstermişlerdir. Doğruluk, hassasiyet, özgüllük, kesinlik ve F1 skorunun VGG-19 modeli için en yüksek değerlere ulaştığını bulmuşlardır. Modellerinin, %95.82 doğruluk, %98.55 kesinlik, %95.67 duyarlılık ve %96.20 özgüllük ile diğer çalışmalardan daha iyi sonuçlar elde ettiğini göstermişlerdir. Gelecekteki çalışmalar için modelin daha büyük veri setleri ile test edilmesi ve diğer hastalıkların tespiti için uyarlanmasını önermişlerdir.

Prusty vd. (2022), Kaggle'dan aldıkları 1341 normal ve 3875 pnömoni vakasını içeren toplam 5216 göğüs röntgeni görüntüsünü ResNet50V2 modeli ile sınıflandırmışlardır. 234 normal ve 390 pnömoni görüntüsünü test için kullanmışlar %99.69 doğruluk elde etmişlerdir. Eğitim ve doğrulama kayıplarının %10'un altında olduğunu belirtmişlerdir. ResNet50V2 modelinin pnömoni tespitinde üstün performans gösterdiğini ve diğer transfer öğrenme modellerine kıyasla daha yüksek doğruluk ve düşük hata oranına sahip olduğunu savunmuşlardır. Bu sonuçların, derin öğrenme tabanlı bilgisayar destekli teşhis sistemlerinin tıbbi görüntülerde hastalık tespitinde etkin bir şekilde kullanılabilceğini belirtmişlerdir.

Ayan (2022), Guangzhou Kadın ve Çocuk Sağlığı Merkezi'nden toplanan ve 5 yaş altı çocukların göğüs röntgenlerini içeren 5856 RGB görüntüden oluşan veri seti kullanmışlardır. Görüntüler normal, bakteriyel pnömoni ve viral pnömoni olmak üzere üç etiketlidir. Veri setini eğitim (5232) ve test (624) olarak ayırmışlar ve Xception CNN modeline uygun şekilde yeniden boyutlandırıp normalize etmişlerdir. Eğitim ve doğrulama veri setlerini, görüntü işleme yöntemlerini kullanarak artırmışlardır. Xception modelinin %89.74 doğruluk elde ettiğini göstermişlerdir. Xception modelini öznelik çıkarıcı olarak kullandıklarında, SVM sınıflandırıcısının %89.58 doğruluk ile en başarılı makine öğrenme algoritması olduğunu elde etmişlerdir. CNN modelinin, viral pnömoni vakalarını tespit etmede daha başarılı olduğunu belirtmişlerdir. Gelecekteki çalışmalarda, birden fazla CNN modelinin özellik çıkarıcı olarak kullanılması ve bu özelliklerin birleştirilerek bir topluluk makine öğrenme sınıflandırıcısı ile eğitilmesini planlamışlardır.

de Lima Mendes vd. (2021), Çok Katmanlı Transfer Öğrenme Genetik Algoritması (MLTLGA) adını verdikleri yeni bir genetik algoritma önermişlerdir. MLTLGA'nın, InceptionV3 CNN mimarisindeki eğitilebilir katmanları seçerek göğüs röntgeni (CXR) görüntülerinden pnömoni tespiti yaptığını ve diğer genetik algoritmalara ve geleneksel transfer öğrenme yöntemlerine kıyasla en az %2 daha yüksek doğruluk sağladığını belirtmişlerdir. Kullandıkları veri seti, Guangzhou Kadın ve Çocuk Sağlığı Merkezi'nden toplanan beş yaş altı çocukların röntgen görüntülerinden oluşmakta olup, eğitim setinde 3875 pnömoni ve 1341 normal görüntü bulunmaktadır. Eğitim setinden rastgele seçilen 467 görüntü (239 pnömoni ve 228 normal), doğrulama setinde 149 görüntü (75 pnömoni ve 74 normal) ve test setinde 624 görüntü (390 pnömoni ve 234 normal) kullanmışlardır. Tüm görüntüleri, InceptionV3 modelinin giriş boyutuna uygun olarak yeniden boyutlandırmış ve normalize etmişlerdir. MLTLGA algoritması ile, doğrulama setinde %97, test setinde ise ortalama %84 doğruluk elde etmişlerdir, Sonuç olarak, MLTLGA'nın küçük veri setleri için transfer öğrenme uygulamalarında etkili olduğunu belirtmişlerdir.

Mohamed vd. (2024), pediatrik göğüs röntgenlerinde pnömoni tespiti için Koşullu Üretici Karşıt Ağlar (CGAN) ile artırılmış veri setleri ve hafif derin transfer öğrenme (DTL) modelleri kullanmışlardır. Veri seti, Guangzhou Kadın ve Çocuk Sağlığı Merkezi'nden toplanan 5858 göğüs röntgeni görüntüsünü içermektedir. Bu görüntülerin 1584'ü normal, 4274'ü pnömoni etiketlidir. Veri setini 5217 eğitim, 16 doğrulama ve 625 test olarak ayırmışlardır. CGAN ile veri artırımı yaptıklarından sonra eğitim seti 5982, doğrulama seti 1709 ve test seti 855 görüntüye ulaşmıştır. Önerdikleri model, CGAN ile veri artırımı ve MobileNet, MobileNetV2, Xception, EfficientNetB0 olmak üzere dört hafif DTL modellerinin kullanımını içermektedir. Hafif DTL modellerini, CGAN ile artırılmış veri seti ile eğittiklerinde Xception %99.26, MobileNetV2 %98.23, MobileNet %97.06 ve EfficientNetB0 %94.55 doğruluk vermiştir. CGAN ile artırılan veri setinin, modellerinin performansını önemli ölçüde artırdığını ve sınıflandırma doğruluğunu iyileştirdiğini göstermişlerdir. Bu yöntemin, sınırlı ve dengesiz veri setleri ile çalışırken bile yüksek performans sağladığını

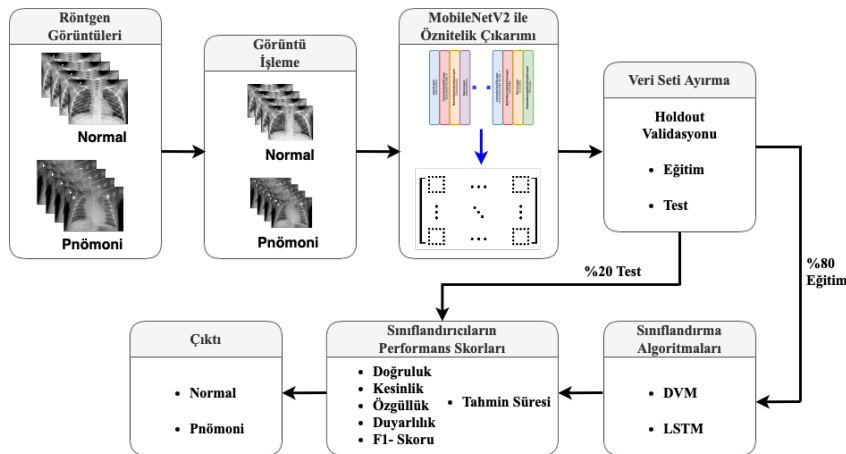
savunmuşlardır. Çalışmalarında, pediatrik göğüs röntgenlerinde pnömoni tespitini iyileştirmek için CGAN ve hafif DTL modellerinin kullanımını önermektedirler ve yüksek doğruluk oranlarına ulaşarak pnömoni teşhisinde önemli bir ilerleme sağladığını ifade etmişlerdir.

Hashmi vd. (2020), Guangzhou Kadın ve Çocuk Sağlık Merkezi'nden aldıkları toplam 5836 akciğer röntgen görüntüsü kullanarak derin transfer öğrenimi ile pnömoni tespiti için bir model önermişlerdir. Veri setindeki görüntülerin 5136'sını eğitim, 700'ü test için ayırmışlardır. Pnömoni vakalarını viral ve bakteriyel olarak ayırmamış ve pnömoni olarak etiketlemişlerdir. ResNet18, DenseNet121, InceptionV3, Xception ve MobileNetV2 olmak üzere beş önceden eğitilmiş derin öğrenme modeli kullanmışlardır. Veri artırma teknikleri kullanılarak eğitim veri setini dengeli bir şekilde artırmışlardır. Modellerini doğruluk, hatırlama, kesinlik, F1 skoru ve AUC skoru gibi çeşitli performans metrikleri ile değerlendirmişlerdir. Tüm modellerden optimize şekilde ağırlık kullandıklarında sınıflandırıcının, %98.43 doğruluk ve %99.76 AUC skoru elde ederek tüm bireysel modelleri geride bıraktığını göstermişlerdir. Önerdikleri modelin, pnömoni teşhisinde yüksek doğruluk ve AUC skoru gösterdiğini ve modellerinin klinik karar destek sistemi olarak kullanılabileceğini savunmuşlardır.

2. MATERYAL VE YÖNTEM

Önerilen Yöntem

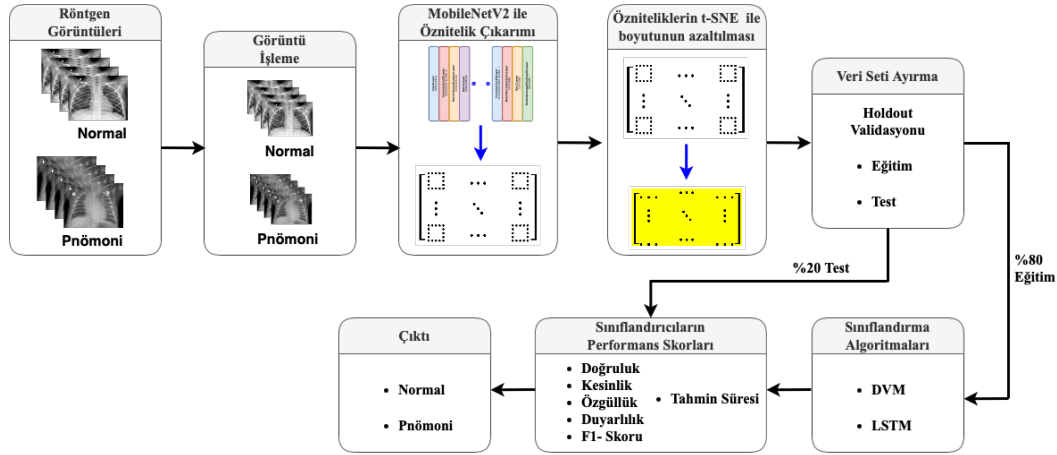
Pnömoni ve normal göğüs röntgen görüntülerinin tespiti için bu çalışmada iki farklı yaklaşım önerilmiştir. İlk yaklaşımda, göğüs röntgen görüntüleri 224x224x3 boyutunda renkli RGB formatına dönüştürülerek MobileNetV2 modeline uygulanmıştır. Bu model, her bir görüntüden 1280 uzunluğunda öznitelik vektörleri çıkarmıştır. Elde edilen öznitelik vektörleri eğitim ve test setlerine ayrılarak, ayrı ayrı Destek Vektör Makineleri (DVM) ve Uzun Kısa Süreli Bellek Ağları (UKSB) ile sınıflandırılmıştır. Sınıflandırıcıların performans skorları detaylı olarak sunulmuştur. Bu yaklaşımın akış diyagramı Şekil 1'de gösterilmiştir.



Şekil 1. Birinci yaklaşım akış diyagramı.

Önerilen ikinci yaklaşımda ise, yine MobileNetV2 modeli kullanılarak her bir görüntüden 1280 uzunluğunda öznitelik vektörleri çıkarılmıştır. Ancak, bu aşamada t-SNE (Dağılımlı Stokastik Komşu Gömülme) algoritması kullanılarak öznitelik vektörleri optimize edilmiş ve boyutları 1280'den 3'e düşürülmüştür. Optimize edilmiş öznitelik vektörleri eğitim ve test setlerine ayrılarak, DVM ve

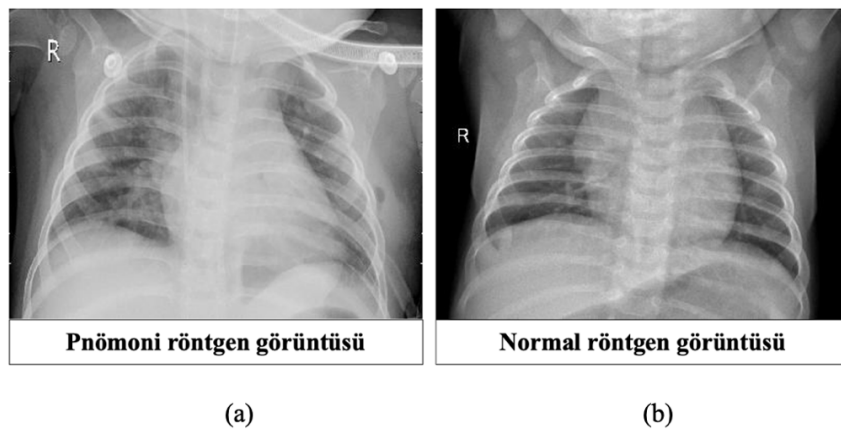
UKSB ile sınıflandırma yapılmıştır. Bu sınıflandırıcıların performans skorları detaylı olarak verilmiştir. İkinci yaklaşımın akış diyagramı ise Şekil 2’de sunulmuştur.



Şekil 2. İkinci yaklaşım akış diyagramı.

Veri Seti

Bu çalışmada, Hindistan Bilim Enstitüsü, PES Üniversitesi, MS Ramaiah Teknoloji Enstitüsü ve Concordia Üniversitesi tarafından sağlanan Curated Dataset for COVID-19 Posterior-Anterior Chest Radiography Images (X-Rays) adlı veri seti kullanılmıştır. Bu veri seti, COVID-19, normal, viral pnömoni ve bakteriyel pnömoni vakalarına ait toplam 9208 tek kanallı (gri tonlamalı) göğüs röntgen görüntüsünden oluşmaktadır. Özellikle, veri setinde 1281 COVID-19, 3270 normal, 1656 viral pnömoni ve 3001 bakteriyel pnömoni görüntüsü bulunmaktadır. Veri setinden örnek olarak alınan pnömoni ve normal röntgen görüntüleri Şekil 3’te gösterilmiştir. Bu veri seti, çeşitli kaynaklardan derlenmiş ve dikkatle filtrelenmiştir, bu da çalışmanın güvenilirliğini ve geçerliliğini artırmaktadır (Sait vd., 2020).



Şekil 3. Veri setinden örnek olarak alınan (a) pnömoni ve (b) normal röntgen görüntüsü.

Çalışmamızda normal, viral pnömoni ve bakteriyel pnömoni görüntüleri kullanılmıştır. Viral pnömoni ve bakteriyel pnömoni görüntüleri birleştirilerek pnömoni olarak etiketlenmiştir. 3270

Normal ve 4657 pnömoni olmak üzere iki etiketli toplam 7927 görüntü elde edilmiştir. Tablo 1’de, elde edilen veri seti ve her bir etikete karşılık gelen görüntü sayıları detaylı olarak gösterilmiştir.

Tablo 1: Çalışmada kullanılan veri seti.

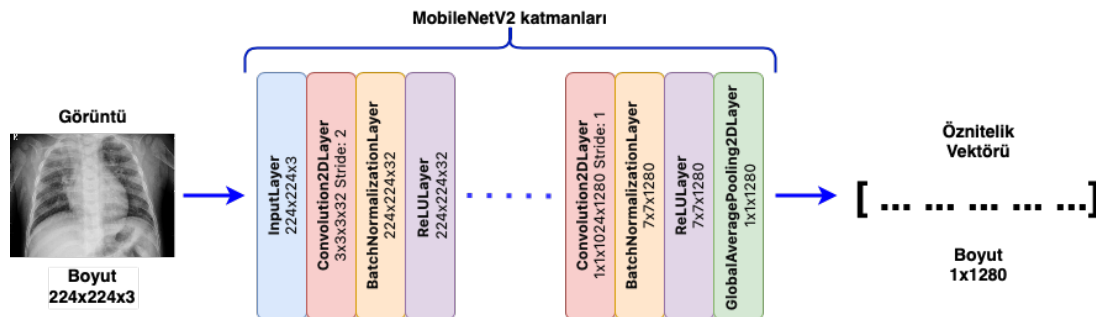
Sınıf	Görüntü sayısı	Görüntü formatı	Görüntü kanal sayısı	Görüntü boyutu
Normal	3270	JPEG	tek kanallı (gri)	değişken
Pnömoni (viral + bakteriyel pnömoni görüntüleri)	4657	JPEG	tek kanallı (gri)	değişken

Görüntü Önileme

Bu çalışmada, pnömoni teşhisi için kullanılan veri setindeki göğüs röntgen görüntüleri tek kanallı ve değişken boyutlardadır. MobileNetV2 modeline uygun hale getirmek için, bu görüntüler 224x224x3 piksel boyutlarına yeniden boyutlandırılmıştır. Bu, derin öğrenme modelinin giriş katmanına uyum sağlamak ve tutarlı bir veri yapısı oluşturmak için gerekli olmaktadır. JPEG formatında olan görüntüler PNG formatına dönüştürülmüştür. Yeniden boyutlandırma işlemi sırasında görüntülerin kalitesinin ve önemli özelliklerinin korumasına özen gösterilmiştir. Veri setinde herhangi bir veri artırma tekniği uygulanmamıştır. Bu nedenle modelin performansını artırmak için yalnızca mevcut görüntüler kullanılmıştır.

MobileNetV2 Mimarisiyle Özellik Çıkarımı

MobileNetV2, mobil ve gömülü cihazlar için optimize edilmiş, düşük hesaplama maliyeti ve yüksek performans sunan bir derin öğrenme modelidir. Sınıflandırma ve öznitelik çıkarma görevlerinde üstün başarı gösteren bu model, özellikle tıbbi görüntü analizi gibi alanlarda güçlü bir yöntem olarak öne çıkmaktadır. MobileNetV2'nin temel yenilikleri arasında "ters artıklık" (inverted residual) ve "doğrusal dar boğaz" (linear bottleneck) katmanları bulunmaktadır. Ters artıklık blokları, bilgiyi düşük boyutlu bir uzaydan yüksek boyutlu bir uzaya genişletip ardından tekrar düşük boyutlu bir uzaya projekte ederek bilgi kaybını minimize etmekte ve verimliliği artırmaktadır. Genişletme (expansion) katmanı, 1x1 evrişim (convolution) ve ReLU6 aktivasyon fonksiyonu kullanarak dar boğazdan yüksek boyutlu bir uzaya geçiş yaparken, Derinlik Ayırma Evrişimi (depthwise convolution) katmanı, her giriş kanalına ayrı 3x3 evrişim uygulamakta ve hesaplama maliyetini azaltmaktadır. Projeksiyon (projection) katmanı ise yüksek boyutlu uzaydan düşük boyutlu uzaya geçiş yaparak, 1x1 evrişim ve lineer aktivasyon fonksiyonunu kullanmaktadır. Bu yapılar, modelin verimli ve etkili bir şekilde öznitelik çıkarımını sağlamaktadır (Sandler vd., 2018).



Şekil 4. MobileNetV2 modeliyle bir görüntüden öznitelik vektörü çıkarımı.

Öznitelik çıkarımı için MobileNetV2 katmanları Şekil 4’te gösterilmiştir. Girdi olarak kullanılan göğüs röntgeni görüntüsü, 224x224x3 boyutlarında olup, modelin giriş katmanına verilmiştir. İlk katmanda, 3x3 filtre boyutunda ve adım (stride) 2 ile çalışan bir evrişimsel (convolutional) katman bulunmaktadır. Bu katmanı bir Küme Normalizasyonu (Batch Normalization) katmanı ve ardından bir ReLU aktivasyon katmanı izlemektedir. Modelin sonunda, 7x7 ortalama havuzlama (average pooling) katmanı, global ortalama havuzlama işlemi gerçekleştirmektedir. Bu işlemler sonucunda, modelin çıktısı 1x1280 boyutlarında bir öznitelik vektörü (feature vector) oluşturmaktadır (Sandler vd., 2018).

t-SNE (t-Dağılımlı Stokastik Komşu Gömülme) Algoritmasıyla Özellik Optimizasyonu

t-Dağılımlı Stokastik Komşu Gömülme (t-SNE), makine öğreniminde yüksek boyutlu veri setlerinin düşük boyutlu görselleştirilmesi için kullanılan popüler bir yöntemdir. Bu algoritma, 2008 yılında Laurens van der Maaten ve Geoffrey Hinton tarafından geliştirilmiştir ve yüksek boyutlu verilerdeki yerel yapıları koruyarak, bu verileri iki veya üç boyutlu bir düzleme indirgemektedir. t-SNE, özellikle karmaşık veri kümelerinin görselleştirilmesi ve kümelenme yapılarını anlamak için kullanılmaktadır (Van der Maaten & Hinton, 2008).

Yüksek boyutlu veri noktaları arasındaki benzerlikler, Eşitlik 1’de Gaussian dağılımları kullanılarak hesaplanmaktadır. İki veri noktası arasındaki benzerlik $p_{j|i}$ veri noktalarının yakınlıklarını ifade eder ve Eşitlik 1’de hesaplanmıştır (Van der Maaten & Hinton, 2008).

$$p_{j|i} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma_i^2)}{\sum_{k \neq i} \exp(-\|x_i - x_k\|^2 / 2\sigma_i^2)} \quad (1)$$

Eşitlik 1’de, x_i ve x_j yüksek boyutlu uzaydaki veri noktaları, σ_i ise veri noktası i için ölçek parametresidir. Daha sonra, simetrik olasılıklar elde etmek için Eşitlik 2 kullanılmaktadır. N veri noktalarının sayısıdır (Van der Maaten & Hinton, 2008).

$$p_{ij} = \frac{p_{j|i} + p_{i|j}}{2N} \quad (2)$$

Düşük boyutlu uzayda, veri noktaları arasındaki benzerlikler t-dağılımı kullanılarak hesaplanmaktadır. Bu şekilde yüksek boyutlu uzaydaki benzerliklerin korunmasını sağlanmaktadır. Düşük boyutlu uzaydaki benzerlik q_{ij} Eşitlik 3’te hesaplanmıştır. y_i ve y_j düşük boyutlu uzaydaki veri noktalarıdır (Van der Maaten & Hinton, 2008).

$$q_{ij} = \frac{(1 + \|y_i - y_j\|^2)^{-1}}{\sum_{k \neq i} (1 + \|y_k - y_i\|^2)^{-1}} \quad (3)$$

t-SNE, yüksek boyutlu uzaydaki ve düşük boyutlu uzaydaki olasılık dağılımları arasındaki farkı minimize etmek için Kullback-Leibler (KL) Divergansı'nı kullanmaktadır. Bu kayıp fonksiyonu Eşitlik 4’te ifade edilmiştir (Van der Maaten & Hinton, 2008).

$$C = KL(P \parallel Q) = \sum_i \sum_j p_{ij} \log \left(\frac{p_{ij}}{q_{ij}} \right) \quad (4)$$

Buradaki, $KL(P \parallel Q)$ ise yüksek ve düşük olasılıklar arasındaki fark ve C kayıp fonksiyonudur. Bu kayıp fonksiyonu, gradyan iniş yöntemi kullanılarak minimize edilmektedir (Van der Maaten & Hinton, 2008). t-SNE algoritmasının başarımı ve sonuçları, bazı önemli parametrelere bağlıdır. Bu önemli parametreler ve açıklamaları aşağıda maddeler halinde verilmiştir.

- Perplexity: Bu parametre, t-SNE'nin yerel ve global yapıları nasıl dengeleyeceğini belirlemektedir. Bu parametre, veri setindeki noktaların etkili komşu sayısını kontrol etmektedir.

- Öğrenme Hızı (Learning Rate): t-SNE algoritmasında, kayıp fonksiyonunu minimize ederken kullanılan adım boyutudur. Çok küçük bir öğrenme hızı yavaş yakınsamaya yol açarken, çok büyük bir öğrenme hızı da dengesiz sonuçlara neden olabilmektedir.
- İterasyonlar (Iterations): t-SNE algoritmasının kaç kez çalıştırılacağını belirlemektedir.
- Açık (Theta): Bu parametre, hızlandırılmış t-SNE algoritmasında (Barnes-Hut t-SNE) kullanılmakta ve hesaplama süresini düşürmek için bir hata toleransı sağlamaktadır. Düşük değerler daha doğru sonuçlar verirken, yüksek değerler daha hızlı sonuçlar sağlamaktadır.

DVM (Destek Vektör Makinesi) ile Sınıflandırma

DVM, 1990'ların başında Vladimir Vapnik ve meslektaşları tarafından geliştirilen bir denetimli öğrenme algoritmasıdır. DVM, özellikle sınıflandırma ve regresyon analizinde kullanılmakta ve iki sınıf arasında mümkün olan en geniş marjini sağlayan bir hiper düzlem bulmayı hedeflemektedir. Marjin, hiper düzlemi iki sınıf veri noktalarından ayıran en yakın veri noktalarına olan mesafe olarak tanımlanmaktadır. Hiper düzlem, doğrusal olarak ayırt edilebilen veriler için doğrusal bir sınır, doğrusal olarak ayırt edilemeyen veriler için ise çekirdek fonksiyonları kullanarak doğrusal olmayan bir sınır olabilmektedir (Cortes & Vapnik, 1995).

$$\mathbf{w} \cdot \mathbf{x} + b = 0 \quad (5)$$

Doğrusal bir hiper düzlem Eşitlik 5'te ifade edilmiştir. Bu ifadedeki, \mathbf{w} hiper düzlemin normal vektörü, \mathbf{x} veri noktaları ve b hiper düzlemin ofset terimidir. DVM'nin amacı marjini maksimum veya $\|\mathbf{w}\|$ normunu minimum yapmaktır. Eşitlik 6'da doğrusal DVM'nin optimizasyon problemi verilmiştir. Burada $y_i: \{+1, -1\}$ sınıf etiketleri ve \mathbf{x}_i veri noktalarını ifade eder (Cortes & Vapnik, 1995).

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (6)$$
$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, i = 1, \dots, n$$

Doğrusal olmayan durumlarda, veri noktalarını daha yüksek boyutlu bir uzaya haritalamak için çekirdek fonksiyonları kullanılmaktadır. Bu durumda, optimizasyon problemi Eşitlik 7'de verilmiştir (Cortes & Vapnik, 1995).

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (7)$$
$$y_i(\mathbf{w} \cdot \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, i = 1, \dots, n$$
$$\xi_i \geq 0, i = 1, \dots, n$$

Eşitlik 7'de verilen $\phi(\mathbf{x})$, veri noktalarını daha yüksek boyutlu bir uzaya haritalayan çekirdek fonksiyonu, C cezalandırma parametresi ve ξ_i hata terimleri veya slack değişkenleri olarak ifade edilmektedir. Eşitlik 8-11'de ise DVM'nin çekirdek fonksiyonları verilmiştir. κ ve θ sigmoid sigmoid çekirdek parametreleri ve σ ise gaussian çekirdek fonksiyonunun standart sapmasıdır (Cortes & Vapnik, 1995).

$$\text{Doğrusal: } K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i \cdot \mathbf{x}_j \quad (8)$$

$$\text{Polinom: } K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + 1)^d \quad (9)$$

$$\text{Gaussian (RBF): } K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \quad (10)$$

$$\text{Sigmoid: } K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\kappa \mathbf{x}_i \cdot \mathbf{x}_j + \theta) \quad (11)$$

UKSB (Uzun Kısa Süreli Bellek) ile Sınıflandırma

UKSB ağları, tekrarlayan sinir ağlarının (RNN) bir türüdür ve özellikle uzun vadeli bağımlılıkları öğrenmede etkin bir şekilde çalışmaktadırlar. 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından geliştirilmiştir. UKSB'ler, zaman serisi verileri, dil modelleme, metin oluşturma ve ses tanıma gibi sıralı veri gerektiren birçok uygulamada yaygın olarak kullanılmaktadır. UKSB'nin en önemli özelliği, hücre durumu (cell state) adı verilen ve ağın uzun vadeli bağımlılıkları hatırlamasını sağlayan özel bir yapıya sahip olmasıdır. UKSB hücreleri, bilgi akışını kontrol etmek için unutmama kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate) olmak üzere üç ana kapı (gate) mekanizmasına sahiptir (Gers vd., 2000; Mert, 2023).

Unutmama kapısı, hücre durumundan hangi bilgilerin atılacağını belirlemektedir ve Eşitlik 12'de verilmiştir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (12)$$

Eşitlik 12'de verilen f_t unutmama kapısı, σ sigmoid aktivasyon fonksiyonu, W_f unutmama kapısı için ağırlık matrisi, h_{t-1} bir önceki zaman adımındaki gizli durum (hidden state), x_t mevcut zaman adımındaki girdi ve b_f unutmama kapısı için bias terimidir (Göker, 2023; Tosun, 2021).

Giriş kapısı, hücre durumuna hangi yeni bilgilerin ekleneceğini belirler ve Eşitlik 13'te verilmiştir. Yeni hücre durumu adayları Eşitlik 14'te ifade edilmiştir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (13)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (14)$$

Eşitlik 13-14'te verilen i_t giriş kapısı vektörü, \tilde{C}_t yeni hücre durumu adayları, W_i giriş kapısı için ağırlık matrisi, W_C hücre durumu için ağırlık matrisi, b_i giriş için bias terimi ve b_C hücre durumu için bias terimidir (Göker, 2023).

Hücre durumu C_t güncellenmesi Eşitlik 15'teki gibi ifade edilir. C_t güncellenmiş hücre durumu, C_{t-1} bir önceki hücre durumu, * eleman bazında çarpma işlemini gösterir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (15)$$

Çıkış kapısı, hücre durumunun hangi kısmının çıkış olarak kullanılacağını belirlemektedir ve Eşitlik 16'da gösterilmiştir. Güncellenmiş hücre durumu ile çıkış kapısının kombinasyonu sonucu oluşturulan gizli durum Eşitlik 17'de verilmiştir (Tosun, 2021).

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (16)$$

$$h_t = o_t * \tanh(C_t) \quad (17)$$

Eşitlik 16-17'deki, o_t çıkış kapısı vektörü, W_o çıkış kapısı için ağırlık matrisi, b_o çıkış kapısı için bias terimi ve $h_t = o_t$ güncellenmiş gizli durumu ifade etmektedir (Tosun, 2021).

3. BULGU VE TARTIŞMALAR

Yaptığımız çalışmada, pnömoni teşhisi için göğüs röntgen görüntülerinin makine öğrenmesi ve derin öğrenme tabanlı yöntemler kullanılarak sınıflandırılması yapılmıştır. İki farklı yaklaşım önerilmiştir. İlk yaklaşımda, önceden işlenmiş göğüs röntgen görüntülerinden MobileNetV2 modeli kullanılarak öznetelik çıkarımı yapılmış ve bu öznetelikler doğrudan sınıflandırma algoritmalarına beslenmiştir. İkinci yaklaşımda ise, MobileNetV2 ile çıkarılan öznetelikler t-SNE kullanılarak boyutları azaltıldıktan sonra sınıflandırma algoritmalarına verilmiştir. Veri seti, %80 eğitim ve %20 test olacak şekilde holdout (ayırma) doğrulama yöntemiyle ayrılmıştır. Her iki yaklaşımda da öznetelik vektörleri, Destek Vektör Makineleri (DVM) ve Uzun Kısa Süreli Bellek Ağları (UKSB) kullanılarak sınıflandırılmıştır. Modellerin performansı doğruluk, kesinlik, özgüllük, duyarlılık ve F1 skoru gibi

metrikler kullanılarak değerlendirilmiş ve tahmin süreleri de dikkate alınmıştır. Ayrıca, elde edilen sonuçlar literatürdeki diğer çalışmalarla karşılaştırılarak çalışmamızın yenilikçi yönleri ve üstünlükleri tartışılmıştır.

Çalışmamızdaki veri seti, 4657 pnömoni ve 3270 normal olmak üzere değişken boyutlu ve tek kanallı (gri) toplam 7927 görüntüden oluşmaktadır. MobileNetV2 giriş katmanına uygun olması için ön işleme ile görüntüler 224x224x3 boyutuna getirilmiştir. Veri seti, %80 eğitim ve %20 test olacak şekilde holdout doğrulama yöntemiyle, eğitim ve test setlerine ayrılmıştır. Veri setindeki sınıfların görüntü sayıları, eğitim ve test için kullanılan görüntü sayıları Tablo 2’de gösterilmiştir. Veri artırma teknikleri kullanılmamıştır.

Tablo 2: Eğitim ve Test veri seti görüntü sayıları.

Veri Seti	Görüntü sayıları	Eğitim ve Test veri seti görüntü sayıları	
		%80 Eğitim	%20 Test
Pnömoni	4657	3726	931
Normal	3270	2616	654
Toplam	7927	6342	1585

Birinci ve ikinci yaklaşımda da Tablo 2’de gösterilen eğitim ve test veri setleri kullanılmıştır. Pnömoni etiketli 4657 görüntüden 3726 görüntü eğitim için, 931 görüntü ise test için ayrılmıştır. Normal etiketli 3270 görüntüden 2616 görüntü eğitim için, 654 görüntü test için ayrılmıştır. Eğitim seti toplam 6342 ve test seti toplam 1585 görüntü içermektedir. Daha sonra MobileNetV2 mimarisineyle global ortalama havuzlama (global average pooling) katmanından her bir görüntüden 1x1280 uzunluğunda öz nitelik vektörü çıkarılmıştır. Tablo 3’te çıkarılan öz niteliklerin boyutları gösterilmiştir.

Tablo 3: MobileNetV2 ile çıkarılan öz nitelik matrisleri.

Veri Seti	Görüntü sayıları	Öz nitelik matrislerinin boyutları	
		%80 Eğitim	%20 Test
Pnömoni	4657	3726x1280	931x1280
Normal	3270	2616x1280	654x1280
Toplam	7927	6342x1280	1585x1280

Tablo 3’te Pnömoni etiketli eğitim için 3726x1280 boyutunda, test için 931x1280 boyutunda öz nitelik matrisi elde edilmiştir. Normal etiketli eğitim için 2616x1280 boyutunda, test için ise 654x1280 boyutunda öz nitelik matrisi çıkarılmıştır. Eğitim için kullanılan 6342x1280 boyutunda ve test için kullanılan 1585x1280 boyutunda öz nitelik matrisi çıkarılmıştır. Önerilen birinci ve ikinci yaklaşımda Tablo 3’te elde edilen öz nitelikler kullanılmıştır. İkinci yaklaşımda t-SNE ile optimize edilerek boyutu düşürülen öz nitelik matrisleri Tablo 4’te yer almaktadır.

Tablo 4: İkinci yaklaşımda t-SNE ile optimize yapılarak öz nitelik matrislerinin boyutlarının azaltılması.


Veri Seti	Görüntü sayıları	Öznitelik matrislerinin boyutları	
		%80 Eğitim	%20 Test
Pnömoni	4657	3726x3	931x3
Normal	3270	2616x3	654x3
Toplam	7927	6342x3	1585x3

Bu çalışmada, veri boyutu düşürme için kullanılan t-SNE algoritmasının parametreleri Tablo 5'te gösterilmiştir. Burada 'MaxIter', iterasyon sayısıdır ve algoritmanın veri noktalarını yerleştirme işlemini kaç kez gerçekleştireceğini belirtir. 'Algorithm', t-SNE algoritmasının hangi varyantının kullanılacağını belirtir. Barnes-Hut yaklaşımı kullanılmıştır. Bu yaklaşım t-SNE algoritmasını büyük veri kümeleri için hızlandırmak amacıyla kullanılan bir optimizasyondur. Hesaplama karmaşıklığını azaltarak daha hızlı sonuç alınmasını sağlamaktadır. 'Distance', veri noktaları arasındaki mesafeyi hesaplamak için kullanılan mesafe metriğini belirtmektedir. 'minkowski' mesafesini kullanmaktadır. Öklid (Euclidean) mesafesiyle aynıdır. Minkowski mesafesi verilerin doğru ve anlamlı bir şekilde düşük boyutlu bir temsili oluşturmak için güçlü bir araçtır. Bu parametreler ampirik olarak belirlenmiştir.

Tablo 5: Çalışmada kullanılan t-SNE algoritmasının parametre ayarları.

t-SNE parametreleri	Parametre değeri
'MaxIter' (Maksimum iterasyon sayısı)	1000
'Algorithm' (Algoritma)	'barneshut'
'Distance' (Mesafe)	'minkowski'
'NumDimensions' (Boyut)	3

'NumDimensions', çıktı veri kümesinin boyut sayısını belirlemektedir. 3 olarak ayarlanması, t-SNE algoritmasının çıktı olarak 3 boyutlu bir veri kümesi üreteceğini belirtmektedir. Bu, sonuçların 3 boyutlu (3D) bir grafikte görselleştirilmesine olanak tanımaktadır. Şekil 5'te t-SNE uygulandıktan sonra öznitelik dağılımları gösterilmektedir.



Şekil 5. t-SNE algoritması uygulandıktan sonra öznitelik dağılımı.

Çalışmada birinci ve ikinci yaklaşımda kullanılan DVM sınıflandırma algoritması Eşitlik 8'de verilen doğrusal çekirdek fonksiyonunu kullanmaktadır. Dolayısıyla doğrusal DVM kullanılmıştır. Her iki yaklaşımda kullanılan UKSB sınıflandırma algoritmasının katmanları "sequenceInputLayer(1)",

“UKSBLayer(100)”, “dropoutLayer(0.1)”, “UKSBLayer(100)”, “dropoutLayer(0.1)”, “UKSBLayer(100)”, “fullyConnectedLayer(2)”, “softmaxLayer” ve “classificationLayer” olarak sıralanmıştır. “sequenceInputLayer(1)” giriş katmanıdır ve 1 boyutlu sekans beklemektedir. “UKSBLayer(100)”, 100 hücreli bir UKSB katmanıdır. “dropoutLayer(0.1)”, aşırı öğrenmeyi (overfitting) önlemek için rastgele olarak bazı nöronları sıfırlamaktadır. 0.1 değeri her adımda nöronların %10'unun sıfırlanacağını belirtmektedir. “fullyConnectedLayer(2)”, tam bağlantılı (fully connected) bir katmandır ve 2 nörona sahiptir. Bu, UKSB'nin çıktısını 2 sınıfa ayırmak için kullanılmaktadır. “softmaxLayer”, sınıflandırma için softmax aktivasyon fonksiyonunu kullanır. Her sınıf için bir olasılık dağılımı üretmektedir. “classificationLayer” ise sınıflandırma hatasını hesaplayan ve eğitime sürecinde hata sinyalinin geri yayarak ağı güncellemektedir. UKSB algoritmasının parametre ayarları Tablo 6’da verilmiştir. UKSB parametreleri ampirik olarak en başarılı olanlar seçilerek düzenlenmiştir.

Tablo 6: Çalışmada kullanılan UKSB algoritmasının parametre ayarları.

UKSB parametreleri	Parametre değeri
'MaxEpochs'	120
'MiniBatchSize'	64
'InitialLearnRate'	1e-3
'SequenceLength'	1000

Bu çalışmada, modellerin performansı doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru gibi metrikler kullanılarak değerlendirilmiştir. Performans metriklerinin yanı sıra DVM ve UKSB sınıflandırıcılarının tahmin süreleri de verilmiştir. Performans metrikleri Eşitlik 18-22’de verilmiştir. Bu metrikler karışıklık matrisi (confusion matrix) kullanılarak bulunabilir. Şekil 6’da karışıklık matrisi tablosu verilmiştir.

		Tahmin Edilen	
		Pozitif	Negatif
Gerçek	Pozitif	TP	FN
	Negatif	FP	TN

Şekil 6. Karışıklık matrisi tablosu.

Karışıklık matrisi tablosunda, Doğru Pozitifler (True Positives, TP), Doğru Negatifler (True Negatives, TN), Yanlış Pozitifler (False Positives, FP) ve Yanlış Negatifler (False Negatives, FN). Doğru Pozitifler (TP), modelin pozitif olarak doğru tahmin ettiği örnekleri ifade ederken; Doğru Negatifler (TN), modelin negatif olarak doğru tahmin ettiği örnekleri gösterir. Yanlış Pozitifler (FP), modelin negatif olan örnekleri yanlış bir şekilde pozitif olarak tahmin ettiği durumları belirtirken;

Yanlış Negatifler (FN), modelin pozitif olan örnekleri yanlış bir şekilde negatif olarak tahmin ettiği durumları ifade etmektedir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (18)$$


$$\text{Duyarlılık} = \frac{TP}{(TP+FN)} \quad (19)$$

$$\text{Özgüllük} = \frac{TN}{(TN+FP)} \quad (20)$$

$$\text{Kesinlik} = \frac{TP}{(TP+FP)} \quad (21)$$

$$F1 - \text{skor} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{(\text{Duyarlılık} + \text{Kesinlik})} \quad (22)$$

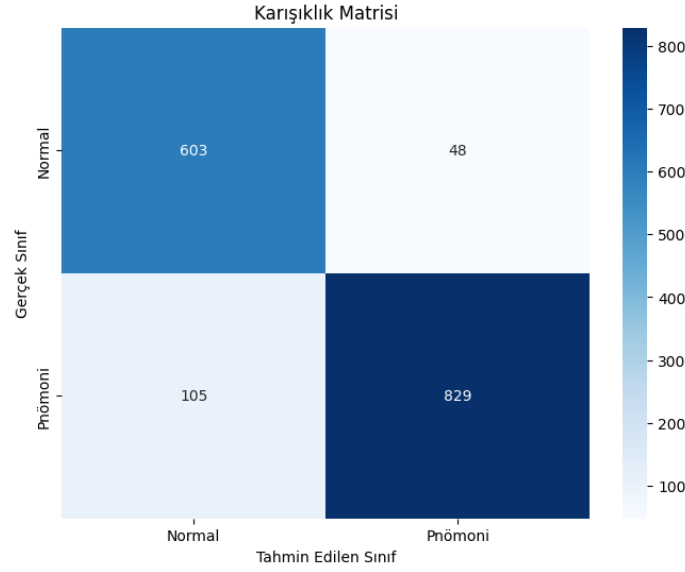
Birinci yaklaşımda DVM kullanılarak yapılan sınıflandırmada elde edilen karışıklık matrisi Şekil 7’de verilmiştir.



Şekil 7. Birinci yaklaşımda DVM sınıflandırıcısı ile elde edilen karışıklık matrisi.

Birinci yaklaşımda DVM ile yapılan sınıflandırmada TP değeri 626, FN değeri 27, FP değeri 17 ve TN değeri 915 bulunmuştur. %97,22 doğruluk, %95,90 duyarlılık, %98,20 özgüllük, %97,40 kesinlik ve %96,60 F1-skoru elde edilmiştir. DVM sınıflandırıcısı ortalama 8,22 milisaniye ile tahmin yapmıştır.


Birinci yaklaşımda UKSB kullanılarak yapılan sınıflandırmada elde edilen karışıklık matrisi Şekil 8’de verilmiştir.



Şekil 8. Birinci yaklaşımda UKSB sınıflandırıcısı ile elde edilen karışıklık matrisi.

Birinci yaklaşımda UKSB ile yapılan sınıflandırmada TP değeri 603, FN değeri 48, FP değeri 105 ve TN değeri 829 bulunmuştur. %90,35 doğruluk, %92,63 duyarlılık, %88,80 özgüllük, %85,20 kesinlik ve %88,74 F1-skoru elde edilmiştir. UKSB sınıflandırıcısı ortalama 9,7864 saniye ile tahmin yapmıştır.

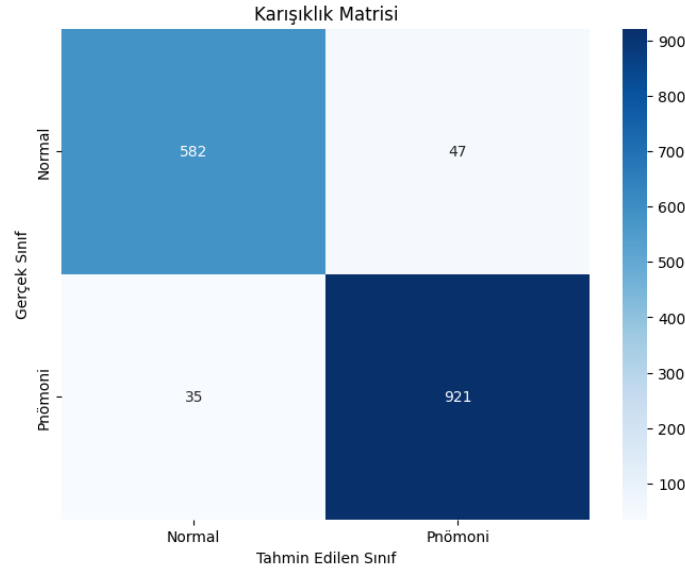
İkinci yaklaşımda DVM kullanılarak yapılan sınıflandırmada elde edilen karışıklık matrisi Şekil 9'de verilmiştir.



Şekil 9. İkinci yaklaşımda DVM sınıflandırıcısı ile elde edilen karışıklık matrisi.

İkinci yaklaşımda DVM ile yapılan sınıflandırmada TP değeri 586, FN değeri 42, FP değeri 43 ve TN değeri 914 bulunmuştur. %94,64 doğruluk, %93,31 duyarlılık, %95,51 özgüllük, %93,20 kesinlik ve %93,24 F1-skoru elde edilmiştir. DVM sınıflandırıcısı ortalama 3,2 milisaniye ile tahmin yapmıştır.

İkinci yaklaşımda UKSB kullanılarak yapılan sınıflandırmada elde edilen karışıklık matrisi Şekil 8’de verilmiştir.



Şekil 8. İkinci yaklaşımda UKSB sınıflandırıcısı ile elde edilen karışıklık matrisi.

İkinci yaklaşımda UKSB ile yapılan sınıflandırmada TP değeri 582, FN değeri 47, FP değeri 35 ve TN değeri 921 bulunmuştur. %94,83 doğruluk, %92,53 duyarlılık, %96,34 özgüllük, %94,33 kesinlik ve %93,42 F1-skoru elde edilmiştir. UKSB sınıflandırıcısı ortalama 8,6162 saniye ile tahmin yapmıştır. Tablo 7’de önerilen yöntemlerden elde edilen performans metrikleri ve sınıflandırıcıların tahmin süreleri verilmiştir.

Tablo 7. Önerilen yöntemlerden elde edilen performans metrikleri ve tahmin süreleri.

Önerilen Yöntemler	Sınıflandırıcı	Sınıflandırıcı Tahmin süresi	Performans Metrikleri				
			Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skoru
Birinci Yaklaşım	DVM	8,22 milisaniye	%97,22	%95,90	%98,20	%97,40	%96,60
	UKSB	9,79 saniye	%90,35	%92,63	%88,80	%85,20	%88,74
İkinci Yaklaşım	DVM	3,20 milisaniye	%94,64	%93,31	%95,51	%93,20	%93,24
	UKSB	8,62 saniye	%94,83	%92,53	%96,34	%94,33	%93,42

İlk yaklaşımda t-SNE kullanılmamış, doğrudan MobileNetV2 ile özellik çıkarımı sonrası DVM ve UKSB sınıflandırıcıları uygulanmıştır. Bu durumda, DVM ile %97,22 doğruluk ve ortalama 8,22 milisaniye tahmin süresi elde edilirken, UKSB ile %90,35 doğruluk ve ortalama 9,7864 saniye tahmin süresi elde edilmiştir. İkinci yaklaşımda ise t-SNE kullanılarak öznelik boyutları azaltılmış ve DVM ile %94,64 doğruluk ve ortalama 3,2 milisaniye tahmin süresi, UKSB ile %94,83 doğruluk ve ortalama 8,6162 saniye tahmin süresi elde edilmiştir. t-SNE kullanımı, özellikle DVM sınıflandırıcısının tahmin süresini belirgin şekilde azaltırken, doğruluk açısından hafif bir düşüş gözlenmiştir. UKSB sınıflandırıcısında ise t-SNE kullanımı hem doğruluk oranını artırmış hem de tahmin süresini kısaltmıştır. t-SNE kullanımı, DVM sınıflandırıcısının tahmin süresini %61,07

oranında azaltmıştır. UKSB sınıflandırıcısında ise t-SNE, tahmin süresini %11,96 oranında azaltmıştır. Bu sonuçlar, t-SNE'nin özellikle DVM için tahmin süresini önemli ölçüde iyileştirdiğini göstermektedir. Bu durum, t-SNE'nin yüksek boyutlu verilerde daha etkin bir özellik çıkarımı sağladığını ve sınıflandırıcıların performansını iyileştirdiğini göstermektedir.

Önerdiğimiz yöntemlerle, aynı veri setini kullanan literatürdeki benzer çalışmalar karşılaştırılmıştır. Karşılaştırmalı analiz Tablo 8'de verilmiştir.

Tablo 8. Aynı veri setini kullanan benzer çalışmalar.

Makalenin Adı	Görüntü Sayıları ve Etiketleri	Veri Seti Ayırma	Öznitelik Çıkarma Modelleri	En İyi Sınıflandırıcı	Doğruluk
Kassem & Albaker (2022)	4618 normal, 4618 pnömoni	Eğitim: %70, Doğrulama: %15, Test: %15	EfficientNetV2	EfficientNetV2	%99,20
Kalgutkar vd. (2021)	1466 normal, 4397 pnömoni	Eğitim: %70, Doğrulama: %15, Test: %15	VGG-16	VGG-16	%94,00
Gu & Lee (2024)	1341 normal, 3875 pnömoni	Eğitim: %90, Test: %10	DenseNet161	DenseNet161	%93,60
Khaled vd. (2022)	normal, pnömoni, toplam 18417	Eğitim: %91, Test: %9	AlexNet, VGG-16, ResNet, DenseNet121, InceptionV3	Birleştirilmiş model AVRDIS)	%96,15
Bakır vd. (2023)	1493 normal, 1493 viral pnömoni, 1493 bakteriyel pnömoni	Eğitim: %80, Doğrulama: %10, Test: %10	ResNet, InceptionNet, MobileNet	ANN	%95,67
Gummadi vd. (2021)	1583 normal, 4273 pnömoni	Eğitim: %80, Test: %20	VGG-19	VGG-19	%95,82
Prusty vd. (2022)	1341 normal, 3875 pnömoni	Eğitim: %90, Test: %10	ResNet50V2	ResNet50V2	%99,69
Önerilen birinci yaklaşım	3270 normal, 4657 pnömoni	Eğitim: %80, Test: %20	MobileNetV2	DVM	%97,22
Önerilen ikinci yaklaşım	3270 normal, 4657 pnömoni	Eğitim: %80, Test: %20	MobileNetV2+t-SNE	UKSB	%94,83

Bu çalışmada, pnömoni ve normal göğüs röntgen görüntülerinin tespiti için iki farklı yaklaşım önerilmiştir. İlk yaklaşımda, göğüs röntgen görüntüleri 224x224x3 boyutunda renkli RGB formatına dönüştürülerek MobileNetV2 modeline uygulanmıştır. Bu model, her bir görüntüden 1280 uzunluğunda öznitelik vektörleri çıkarmıştır. Elde edilen öznitelik vektörleri eğitim ve test setlerine ayrılarak, ayrı ayrı Destek Vektör Makineleri (DVM) ve Uzun Kısa Süreli Bellek Ağları (UKSB) ile sınıflandırılmıştır. DVM ile %97,22 doğruluk ve ortalama 8,22 milisaniye tahmin süresi elde edilmiştir. UKSB ile yapılan sınıflandırmada ise %90,35 doğruluk ve ortalama 9,7864 saniye tahmin süresi elde edilmiştir.

Önerilen ikinci yaklaşımda ise, yine MobileNetV2 modeli kullanılarak her bir görüntüden 1280 uzunluğunda öznitelik vektörleri çıkarılmıştır. Bu aşamada t-SNE algoritması kullanılarak öznitelik vektörleri optimize edilmiş ve boyutları 1280'den 3'e düşürülmüştür. Optimize edilmiş öznitelik vektörleri eğitim ve test setlerine ayrılarak, DVM ve UKSB ile sınıflandırma yapılmıştır. DVM sınıflandırıcısı %94,64 doğruluk ve ortalama 3,2 milisaniye tahmin süresi, UKSB sınıflandırıcısı ise %94,83 doğruluk ve ortalama 8,6162 saniye tahmin süresi elde etmiştir.

Aynı veri setini kullanan literatürdeki benzer çalışmalarda, önerilen birinci yaklaşımda MobileNetV2 ile özellik çıkarımı sonrası DVM kullanılarak %97,22 doğruluk elde edilmiştir. İkinci yaklaşımda ise t-SNE ile özellikler boyutlandırılıp UKSB ile %94,83 doğruluk sağlanmıştır. Kassem & Albaker

(2022) EfficientNetV2 kullanarak %99,20 doğruluk ile en yüksek performansı elde ederken, diğer çalışmalar VGG-16, DenseNet161 ve ResNet50V2 gibi modellerle %93,60 ile %99,20 arasında değişen doğruluk oranlarına ulaşmıştır. Önerilen yöntemlerin üstünlüğü, özellikle DVM ile düşük tahmin süresi (3,2 milisaniye) ve yüksek doğruluk oranı (%97,22) ile belirginleşmektedir. Ayrıca, UKSB tabanlı yaklaşımın doğruluğu ve tahmin süresi açısından diğer çalışmalara göre dengeli bir performans sunması, önerilen yöntemlerin etkinliğini ortaya koymaktadır.

Çalışmamızda, performans metriklerinin yanı sıra, diğer çalışmalardan farklı olarak t-SNE algoritması ile veri boyutu azaltıldıktan sonra sınıflandırma doğruluğu ve tahmin sürelerine olan etkisi de sunulmuştur. Benzer çalışmalarda kullanılan görüntü sayılarının farklılıkları ve önerilen modellerin çeşitliliği göz önüne alındığında, çalışmamızın belirgin üstünlüğü, veri artırma teknikleri kullanılmadan, hafif bir model olan MobileNetV2 ile yüksek performans elde edilmesidir.

4. SONUÇ VE ÖNERİLER

Bu çalışmada, pnömoni ve normal göğüs röntgen görüntülerinin sınıflandırılmasında iki farklı yaklaşım önerilmiştir. İlk yaklaşımda, MobileNetV2 modeli kullanılarak özellik çıkarımı yapılmış ve bu özellikler Destek Vektör Makineleri (DVM) ve Uzun Kısa Süreli Bellek Ağları (UKSB) ile sınıflandırılmıştır. Bu yaklaşım, DVM ile %97,22 doğruluk ve ortalama 8,22 milisaniye tahmin süresi elde edilerek üstün performans göstermiştir. UKSB ile yapılan sınıflandırmada ise %90,35 doğruluk ve ortalama 9,7864 saniye tahmin süresi elde edilmiştir. İkinci yaklaşımda ise, yine MobileNetV2 ile çıkarılan özellik vektörleri t-SNE algoritması kullanılarak boyutları 1280'den 3'e düşürülmüş ve ardından DVM ve UKSB ile sınıflandırma yapılmıştır. t-SNE kullanımı, özellikle DVM'nin tahmin süresini %61,07 oranında azaltarak önemli bir performans iyileştirmesi sağlamış, ancak doğruluk açısından hafif bir düşüş (%94,64) gözlenmiştir. UKSB ile yapılan sınıflandırmada ise t-SNE, doğruluğu artırmış (%94,83) ve tahmin süresini %11,96 oranında azaltmıştır. Bu sonuçlar, t-SNE algoritmasının veri boyutu azaltmada etkili olduğunu ve özellikle DVM sınıflandırıcısının performansını belirgin şekilde iyileştirdiğini göstermektedir. Ayrıca, t-SNE'nin hem DVM hem de UKSB sınıflandırıcılarının tahmin sürelerini kısaltarak daha hızlı sonuçlar elde edilmesini sağladığı ortaya konmuştur. Çalışmamızın bulguları, t-SNE algoritması ile özellik boyutu azaltımının, derin öğrenme ve makine öğrenme modellerinin performansını artırabileceğini göstermektedir. Özellikle yüksek boyutlu verilerle çalışırken, t-SNE gibi boyut azaltma tekniklerinin kullanılması, modelin doğruluğunu ve tahmin süresini iyileştirebilir. Bu, pnömoni teşhisi gibi kritik sağlık uygulamalarında daha hızlı ve doğru sonuçlar elde edilmesine katkı sağlayabilir. Daha gelişmiş derin öğrenme modellerinin kullanılması veya modellerin birleştirilmesi ile doğruluk oranlarının ve tahmin sürelerinin daha da iyileştirilmesi mümkün olabilir. Aynı şekilde, veri artırma tekniklerinin kullanılması, modellerin ve t-SNE'nin parametrelerinde yapılacak optimizasyonlarla daha iyi sonuçlar elde edilebilir. Bu durum, çalışmamızın hem hesaplama maliyeti açısından verimli hem de performans açısından rekabetçi olduğunu göstermektedir ve literatüre önemli katkılar sağlayabilir.

KAYNAKÇA

- Alharbi, A. H., & Hosni Mahmoud, H. A. (2022, May). Pneumonia transfer learning deep learning model from segmented X-rays. In *Healthcare* (Vol. 10, No. 6, p. 987). MDPI.
- Chakraborty, S., Paul, S., & Hasan, K. A. (2022). A transfer learning-based approach with deep cnn for covid-19-and pneumonia-affected chest x-ray image classification. *SN computer science*, 3, 1-10.
- Chouhan, V., Singh, S. K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., ... & De Albuquerque, V. H. C. (2020). A novel transfer learning based approach for pneumonia detection in chest X-ray images. *Applied Sciences*, 10(2), 559.

- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20, 273-297.
- Cyriac, S., Raju, N., & Kim, Y. W. (2022, October). Pneumonia Detection using Ensemble Transfer Learning. In *2022 13th International Conference on Information and Communication Technology Convergence (ICTC)* (pp. 479-484). IEEE.
- Cyriac, S., Raju, N., & Kim, Y. W. (2022, October). Pneumonia Detection using Ensemble Transfer Learning. In *2022 13th International Conference on Information and Communication Technology Convergence (ICTC)* (pp. 479-484). IEEE.
- de Lima Mendes, R., da Silva Alves, A. H., de Souza Gomes, M., Bertarini, P. L. L., & do Amaral, L. R. (2021, June). Many layer transfer learning genetic algorithm (MLTLGA): a new evolutionary transfer learning approach applied to pneumonia classification. In *2021 IEEE Congress on Evolutionary Computation (CEC)* (pp. 2476-2482). IEEE.
- El Asnaoui, K. (2021). Design ensemble deep learning model for pneumonia disease classification. *International Journal of Multimedia Information Retrieval*, 10(1), 55-68.
- El Gannour, O., Hamida, S., Cherradi, B., Raihani, A., & Moujahid, H. (2020, December). Performance evaluation of transfer learning technique for automatic detection of patients with COVID-19 on X-Ray images. In *2020 IEEE 2nd international conference on electronics, control, optimization and computer science (ICECOCS)* (pp. 1-6). IEEE.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10), 2451-2471.
- Göker, H. (2023). Automatic detection of migraine disease from EEG signals using bidirectional long-short term memory deep learning model. *Signal, Image and Video Processing*, 17(4), 1255-1263.
- Gu, C., & Lee, M. (2024). Deep Transfer Learning Using Real-World Image Features for Medical Image Classification, with a Case Study on Pneumonia X-ray Images. *Bioengineering*, 11(4), 406.
- Gummadi, S. D., Vootla, Y., Ghosh, A., Kartheek, P. N., & Kandimalla, A. K. (2021, September). Transfer learning based detection of pneumonia from chest x-ray images. In *2021 13th International Conference on Computational Intelligence and Communication Networks (CICN)* (pp. 135-139). IEEE.
- GÜNTÜRKÜN, R., & TOSUN, M. (2020). Estimation of the Amount of Drug to be Applied to the Patient Using Elman Recurrent Artificial Neural Network. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2(2), 24-29.
- Hariri, M., & Avşar, E. (2023). COVID-19 and pneumonia diagnosis from chest X-ray images using convolutional neural networks. *Network Modeling Analysis in Health Informatics and Bioinformatics*, 12(1), 17.
- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D., & Geem, Z. W. (2020). Efficient pneumonia detection in chest xray images using deep transfer learning. *Diagnostics*, 10(6), 417.
- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D., & Geem, Z. W. (2020). Efficient pneumonia detection in chest xray images using deep transfer learning. *Diagnostics*, 10(6), 417.
- Jain, R., Nagrath, P., Kataria, G., Kaushik, V. S., & Hemanth, D. J. (2020). Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, 165, 108046.
- Jawahar, M., Anbarasi, L. J., Jayachandran, P., Ramachandran, M., & Al-Turjman, F. (2021). Utilization of transfer learning model in detecting COVID-19 cases from chest x-ray images. *International Journal of E-Health and Medical Communications (IJEHMC)*, 13(2), 1-11.

- Jha, A., John, E., & Banerjee, T. (2022, August). Transfer Learning for COVID-19 and Pneumonia Detection using Chest X-Rays. In 2022 IEEE 65th International Midwest Symposium on Circuits and Systems (MWSCAS) (pp. 1-4). IEEE.
- Kalgutkar, S., Jain, V., Nair, G., Venkatesh, K., Parab, K., Deshpande, A., & Ambawade, D. (2021, April). Pneumonia Detection from chest X-ray using Transfer Learning. In 2021 6th International Conference for Convergence in Technology (I2CT)(pp. 1-6). IEEE.
- Kassem, M., & Albaker, B. M. (2022). Efficient Classification Model of Pneumonia Infection Based on Deep Transfer Learning and Chest X-Ray Images. *Al-Iraqia Journal for Scientific Engineering Research*, 1(1), 58-67.
- Khaled, M., Gaceb, D., Touazi, F., Otsmane, A., & Boutoutaou, F. (2022). Progressive and Combined Deep Transfer Learning for pneumonia diagnosis in chest X-ray images. In *IDDM* (pp. 160-173).
- Kolonne, S., Fernando, C., Kumarasinghe, H., & Meedeniya, D. (2021, December). MobileNetV2 based chest x-rays classification. In 2021 International Conference on Decision Aid Sciences and Application (DASA) (pp. 57-61). IEEE.
- Luján-García, J. E., Yáñez-Márquez, C., Villuendas-Rey, Y., & Camacho-Nieto, O. (2020). A transfer learning method for pneumonia classification and visualization. *Applied Sciences*, 10(8), 2908.
- MERT, A. (2023). Lightweight deep neural network models for electromyography signal recognition for prosthetic control. *Turkish Journal of Electrical Engineering and Computer Sciences*, 31(4), 706-721.
- Mishra, S. (2021). Deep transfer learning-based framework for COVID-19 diagnosis using chest CT scans and clinical information. *SN Computer Science*, 2(5), 390.
- Mohamed, C., Mwangi, R. W., & Kihoro, J. M. (2024). Enhancing Pneumonia Detection in Pediatric Chest X-Rays Using CGAN-Augmented Datasets and Lightweight Deep Transfer Learning Models. *Journal of Data Analysis and Information Processing*, 12(01), 1-23.
- Mujahid, M., Rustam, F., Álvarez, R., Luis Vidal Mazón, J., Díez, I. D. L. T., & Ashraf, I. (2022). Pneumonia classification from X-ray images with inception-V3 and convolutional neural network. *Diagnostics*, 12(5), 1280.
- Parveen, S., & Khan, K. B. (2020, November). Detection and classification of pneumonia in chest X-ray images by supervised learning. In *2020 IEEE 23rd International Multitopic Conference (INMIC)* (pp. 1-5). IEEE.
- Prusty, S., Patnaik, S., & Dash, S. K. (2022, August). ResNet50V2: a transfer learning model to predict pneumonia with chest X-ray images. In 2022 International Conference on Machine Learning, Computer Systems and Security (MLCSS)(pp. 208-213). IEEE.
- Rahman, T., Chowdhury, M. E., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., ... & Kashem, S. (2020). Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest X-ray. *Applied Sciences*, 10(9), 3233.
- Sait, U., Lal, K. G., Prajapati, S., Bhaumik, R., Kumar, T., Sanjana, S., & Bhalla, K. (2020). Curated dataset for COVID-19 posterior-anterior chest radiography images (X-Rays). *Mendeley Data*, 1, 1.
- Sakib, S. N., Masud, R., Rubaiat, S. Y., Bepery, C., Sarker, M., & Hasan, M. K. (2021, September). Pneumonia detection using deep transfer learning in gender specific chest x-ray images. In 2021 International Conference on Electronics, Communications and Information Technology (ICECIT) (pp. 1-4). IEEE.

- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- Shaikh, M., Arain, Q. A., Siddiqui, I. F., & Shaikh, H. A. (2022, November). Automated classification of pneumonia from chest x-ray images using deep transfer learning efficientnet-b0 model. In *2022 14th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS)* (pp. 1-6). IEEE.
- Sharma, C. M., Goyal, L., Chariar, V. M., & Sharma, N. (2022). [Retracted] Lung Disease Classification in CXR Images Using Hybrid Inception-ResNet-v2 Model and Edge Computing. *Journal of Healthcare Engineering*, 2022(1), 9036457.
- Soud, A., Sakli, N., & Sakli, H. (2021). Classification and predictions of lung diseases from chest x-rays using mobilenet v2. *Applied Sciences*, 11(6), 2751.
- Srivastava, G., Pradhan, N., & Saini, Y. (2022). Ensemble of Deep Neural Networks based on Condorcet's Jury Theorem for screening Covid-19 and Pneumonia from radiograph images. *Computers in Biology and Medicine*, 149, 105979.
- Sunyoto, A., Prityanto, Y., Setyanto, A., Alarfaj, F., Almusallam, N., & Alreshoodi, M. (2022). The Performance Evaluation of Transfer Learning VGG16 Algorithm on Various Chest X-ray Imaging Datasets for COVID-19 Classification. *International Journal of Advanced Computer Science and Applications*, 13(9).
- Sunyoto, A., Prityanto, Y., Setyanto, A., Alarfaj, F., Almusallam, N., & Alreshoodi, M. (2022). The Performance Evaluation of Transfer Learning VGG16 Algorithm on Various Chest X-ray Imaging Datasets for COVID-19 Classification. *International Journal of Advanced Computer Science and Applications*, 13(9).
- Tosun, M. (2021). Effects of spectral features of EEG signals recorded with different channels and recording statuses on ADHD classification with deep learning. *Physical and Engineering Sciences in Medicine*, 44(3), 693-702.
- Van der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of machine learning research*, 9(11).
- Venu, S. K. (2020). An ensemble-based approach by fine-tuning the deep transfer learning models to classify pneumonia from chest X-ray images. arXiv preprint arXiv:2011.05543.