

## **Derin Transfer Öğrenmesi Kullanarak Gömülü Platformda Göğüs Röntgeni Görüntülerinden Etkili Pnömoni Tespiti<sup>1</sup>**

### **Effective Pneumonia Detection From Chest X-ray Images on an Embedded Platform Using Deep Transfer Learning**

**Enver ELİTOK**

Kütahya Dumlupınar Üniversitesi, Simav Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü  
enver.elitok@dpu.edu.tr, ORCID ID: <https://orcid.org/0000-0001-6111-0404>

**Ömer KASIM**

Kütahya Dumlupınar Üniversitesi, Simav Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü  
omer.kasim@dpu.edu.tr, ORCID ID: <https://orcid.org/0000-0003-4021-5412>

**Hamdi Melih SARAĞLU**

Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü  
hmelih.saraoglu@dpu.edu.tr, ORCID ID: <https://orcid.org/0000-0002-5075-9504>

#### **Özet**

Pnömoni, dünya genelinde özellikle çocuklar ve yaşlılar için ciddi tehditler oluşturan önemli bir sağlık sorunudur. Erken teşhis ve doğru tedavi, hastaların yaşam kalitesini ve hayatta kalma oranlarını artırmada kritik bir rol oynamaktadır. Tıbbi görüntüleme teknikleri, pnömoni teşhisinde vazgeçilmez araçlar olup, invaziv olmayan yöntemlerle hastaların iç organlarının görüntülenmesini sağlamaktadır. Son yıllarda, yapay zekâ ve özellikle derin öğrenme yöntemleri, tıbbi görüntü analizinde büyük ilerlemeler kaydetmiştir. Transfer öğrenme, büyük veri kümeleri ve güçlü işlemciler kullanarak tıbbi görüntülerden anlamlı özellikler

<sup>1</sup> 6. Uluslararası İstanbul Modern Bilimsel Araştırmalar Kongresi 6 Temmuz 2024 tarihinde bildiri olarak sunulmuştur.

çıkarmakta ve bu görüntüleri yüksek doğruluk oranlarıyla sınıflandırmaktadır. Bu çalışmada, transfer öğrenme yöntemi kullanılarak önceden eğitilmiş MobileNetV2 modeli ile pnömoni ve normal akciğer röntgen görüntüleri kişisel bilgisayarda sınıflandırılmıştır. Veri seti, Hindistan Bilim Enstitüsü, PES Üniversitesi, MS Ramaiah Teknoloji Enstitüsü ve Concordia Üniversitesi tarafından sağlanan röntgen görüntülerini içermektedir (doi: 10.17632/9xkhgts2s6.3). Modelin performansı doğruluk, hassasiyet, duyarlılık ve özgüllük gibi metriklerle değerlendirilmiş ve düşük hesaplama maliyetleriyle yüksek doğruluk sağladığı görülmüştür. Eğitilen model, düşük maliyetli, yüksek performanslı ve taşınabilir bir gömülü sistem olan Nvidia Jetson Nano üzerinde çalıştırılmış ve bu platformdaki performansı incelenmiştir. Kişisel bilgisayarda modelin tahmin süresi 36.57 milisaniye, doğruluk %98.1, duyarlılık %97.8, özgüllük %98.5, kesinlik %98.9 ve F1-skoru %98.4 olarak elde edilmiştir. Jetson Nano platformunda ise tahmin süresi 111.2 milisaniye, doğruluk %97.8, duyarlılık %96.8, özgüllük %99.4, kesinlik %99.6 ve F1-skoru %98.2 olarak kaydedilmiştir. Çalışmanın bulguları, MobileNetV2 modelinin Nvidia Jetson Nano gömülü platformunda etkin şekilde çalışabileceğini ve yüksek performans sağladığını göstermektedir. Bu çalışma, pnömoni teşhisinde derin öğrenme ve gömülü sistemlerin entegrasyonunu kullanarak yenilikçi ve etkili bir çözüm sunmaktadır. Gelecekteki araştırmalar, daha büyük veri kümeleri ve çeşitli derin öğrenme modelleri kullanarak sınıflandırma performansını daha da artırabilir ve sağlık hizmetlerinin kalitesini ve erişilebilirliğini önemli ölçüde iyileştirebilir.

**Anahtar Kelimeler:** Pnömoni, Transfer Öğrenme, Gömülü Sistemler, Görüntü İşleme.

### **Abstract**

Pneumonia is a significant health problem worldwide, posing serious threats particularly to children and the elderly. Early diagnosis and accurate treatment play a critical role in improving the quality of life and survival rates of patients. Medical imaging techniques are indispensable tools in diagnosing pneumonia, providing non-invasive methods for visualizing the internal organs of patients. In recent years, artificial intelligence and especially deep learning methods have made significant advancements in medical image analysis. Transfer learning extracts meaningful features from medical images using large datasets and powerful processors, classifying these images with high accuracy. In this study, the pre-trained MobileNetV2 model is used to classify pneumonia and

normal chest X-ray images on a personal computer using transfer learning. The dataset includes 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). The model's performance is evaluated with metrics such as accuracy, precision, sensitivity, and specificity, demonstrating high accuracy with low computational costs. The trained model is then deployed on a low-cost, high-performance, and portable embedded system, the Nvidia Jetson Nano, and its performance on this platform is examined. On the personal computer, the model's prediction time is 36.57 milliseconds, with accuracy at 98.1%, sensitivity at 97.8%, specificity at 98.5%, precision at 98.9%, and F1-score at 98.4%. On the Jetson Nano platform, the prediction time is 111.2 milliseconds, with accuracy at 97.8%, sensitivity at 96.8%, specificity at 99.4%, precision at 99.6%, and F1-score at 98.2%. The findings of the study indicate that the MobileNetV2 model can effectively operate on the Nvidia Jetson Nano embedded platform and provide high performance. This study offers an innovative and effective solution for pneumonia diagnosis by integrating deep learning and embedded systems. Future research may further enhance classification performance and significantly improve the quality and accessibility of healthcare services by using larger datasets and various deep learning models.

**Keywords:** Pneumonia, Transfer Learning, Embedded Systems, Image Processing.

## 1. GİRİŞ

Pnömoni, akciğer dokusunun enfeksiyon nedeniyle iltihaplanması sonucu ortaya çıkan bir hastalıktır. Bu hastalık, bakteriyel, viral veya mantar enfeksiyonları sonucu gelişebilmekte ve tedavi edilmediğinde ciddi komplikasyonlara yol açabilmektedir (Antin vd., 2017). X-ışını, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi tıbbi görüntüleme teknikleri, vücut içindeki yapıların görüntülenmesi ile pnömoni ve diğer hastalıkların teşhis edilmesi için kullanılmaktadır (Feng vd., 2021). Bilgisayarlı destekli tanı (BDT) sistemleri, tıbbi

görüntülerin otomatik analizi için kullanılan sistemlerdir. Bu sistemler, tanı sürecini hızlandırmakta ve doğruluğu artırmaktadır (Naralasetti vd., 2021).

Yapay zekâ (YZ), BDT sistemlerinde kullanılan, tıbbi görüntülerin işlenmesi, analizi ve hastalıkların tespiti gibi alanlarda önemli katkılar sağlamaktadır (Jha vd., 2022; Kassem & Albaker, 2022). YZ sistemlerinden biri olan transfer öğrenme (TL), önceden eğitilmiş YZ modellerinin yeni veri setleri veya görevler için yeniden eğitilmesine dayanan bir yöntemdir. Bu yöntem, tıbbi görüntüleme yüksek doğruluk ve performans sağlamaktadır (Avola vd., 2022). TL, tıbbi görüntülerinin sınıflandırılmasında yüksek performans elde etmek için yaygın olarak kullanılmaktadır (Rahman vd., 2020). MobileNetV2 (Cyriac vd., 2022), EfficientNetB0 (Mohamed vd., 2024), InceptionV3 (Hashmi vd., 2020) TL modellerinden bazılarıdır.

Tıbbi görüntülerin analizi için kullanılan YZ yöntemleri yüksek hızlı ve gelişmiş grafik işlem birimlerine (GİB) sahip bilgisayarlarda gerçekleştirilmektedir. Geliştirilen yeni GİB mimari çözümleri, YZ sistemlerinin gömülü ve mobil GİB'lere dağıtılmasını mümkün kılmaktadır. Nvidia Jetson gömülü platformları tıbbi görüntülerin YZ yöntemleri ile teşhisinde düşük maliyet, düşük enerji tüketimi, yüksek hesaplama gücü ve yüksek performans sunmaktadır (Romera vd., 2021; Srinivasan & Wang, 2021).

Bu çalışmada, akciğer normal ve pnömoni röntgen görüntülerinin sınıflandırılması için, önceden eğitilmiş TL modeli olan MobileNetV2 modeli kullanılmıştır. Görüntüler, Hindistan Bilim Enstitüsü, PES Üniversitesi, MS Ramaiah Teknoloji Enstitüsü ve Concordia Üniversitesi'nden elde edilmiştir (doi: 10.17632/9xkhgts2s6.3). Modelin eğitilmesi, kişisel bilgisayarda gerçekleştirilmiştir. Eğitilen model, Nvidia Jetson Nano gömülü platformuna dağıtılmış ve modelin sınıflandırma performansı test edilmiştir.

## **Literatür Çalışmaları**

Lou vd. (2023), COVID-19 teşhisi için derin öğrenme tabanlı bir yöntem geliştirmişler ve gömülü uç cihazlarda test etmişlerdir. VGG19 modeli kullanarak, 194,922 BT görüntüsünden (60083 normal, 40291 pnömoni, 94548 COVID-19) oluşan COVIDx CT-2A ve 16104 BT görüntüsünden (7593 COVID-19, 6893 normal, 2618 CAP) oluşan entegre BT tarama veri setlerindeki görüntüleri sınıflandırmışlardır. COVIDx CT-2A'da %98.80 doğruluk, %98.55 hassasiyet ve %98.70 F1-skoru, entegre BT veri setinde ise %97.84 doğruluk, %97.83 hassasiyet ve %97.83 F1-skoru elde etmişlerdir. Tasarladıkları modeli, Nvidia Jetson TX2 ve Nano cihazlarında test ettiklerinde %97 doğruluğa ulaşmışlardır. Jetson cihazlarında, kişisel bilgisayar platformuna yakın doğruluk ve maliyet etkinliği ile pratik uygulamalar için yeterli performansı sağladıklarını savunmuşlardır. Yöntemlerinin, tıbbi uç bilişim sistemleri için düşük maliyetli, pratik ve kullanışlı olduğunu vurgulamışlardır.

Satheeshkumar vd. (2024), ResNet-50 CNN modelini kullanarak göğüs röntgeni görüntülerini gerçek zamanlı olarak Nvidia Jetson Nano GIB kullanarak sınıflandırmışlardır. Kaggle, SIRM, RSNA ve Radiopaedia gibi veri tabanlarından 680 COVID-19, 1230 tüberküloz ve 1050 normal göğüs röntgeni görüntülerini %70 eğitim ve %30 doğrulama oranıyla tasarladıkları modeli 50 epok boyunca eğitmişlerdir. Modelleri; %98.79 doğruluk, %97.58 kesinlik ve %1.96 kayıp değeri elde etmiştir. Jetson Nano üzerinde eğitim süresi 803 saniye olup, diğer cihazlara göre üstün performans gösterdiğini belirtmişlerdir. Tasarladıkları sistemin, COVID-19 teşhisinde yüksek doğruluk ve performans sunduğunu ve sağlık sistemlerin iyileştirmede önemli bir araç olabileceğini vurgulamışlardır.

Lekshmy vd. (2024), Kaggle'dan aldıkları NIH ve RSNA göğüs röntgeni veri setiyle, akciğer hastalıklarını teşhis etmek için GIB tabanlı gelişmiş bir harmanlanmış öğrenme paradigması (IBLP) geliştirmişlerdir. Toplam 6425 görüntüyü, eğitim (%80) ve test (%20) olarak ayırmışlardır. IBLP VGG16 modellerinin, %91.99 doğruluk, %95.5 hassasiyet, %97.69 F1 skoru ve %100 geri çağırma oranıyla, VGG19 (%88.91 doğruluk) ve ResNet50 (%87.02 doğruluk) modellerinden daha iyi performans gösterdiğini belirtmişlerdir. Modellerini, 224x224 boyutlarında normalize edilmiş

görüntülerle eğitmişler ve Nvidia Jetson Nano üzerinde gerçek zamanlı pnömoni tespiti için başarıyla uygulamışlardır.

Abubeker & Baskar (2023), göğüs röntgeni görüntülerinde pnömoni sınıflandırması için B2-Net isimli bir model geliştirmişlerdir. Kaggle RSNA veri setindeki 6020 görüntü kullanmışlardır. Dokuz derin öğrenme modeli arasından en iyi performans gösteren üç modeli (DenseNet-160, ResNet-121, VGGNet-16) seçmişler ve B2-Net modeli oluşturmuşlardır. B2-Net ile %97,69 doğruluk, %100 duyarlılık ve 0,9977 AUROC skoru elde etmişlerdir. Tasarladıkları modeli Nvidia Jetson Nano GIB platformunda test etmişlerdir. Veri artırma ve transfer öğrenimi teknikleriyle destekledikleri B2-Net modellerinin pnömoni teşhisinde yüksek doğruluk ve performans sağladığını belirtmişlerdir.


Ulutas vd. (2023), COVID-19 teşhisi için BT görüntülerini kullanarak tamamen otomatik bir derin öğrenme yöntemi geliştirmişlerdir. Kullandıkları COVID-CT-MD veri setinde, 3064 COVID-19, 2949 normal ve 2992 pnömoni görüntüsü bulunmaktadır. Çalışmalarında, ResNet50, MobileNetv2 ve özel olarak tasarlanmış CovidxNet-CT modelleri tasarlamışlardır. CovidxNet-CT modellerinin %98.83 doğruluk ve 0.99 AUC değeri ile üstün performans gösterdiğini belirtmişlerdir. MobileNetv2'nin %88.86 doğruluk ve 0.92 AUC, ResNet50'nin ise %90.09 doğruluk ve 0.93 AUC değerleri elde etmiştir. Modellerini, Jetson Nano ve Jetson TX2 platformlarında test etmişlerdir. Jetson TX2'de test süresinin 69.92 saniye ve tahmin süresinin 0.038 saniye; Jetson Nano'da ise test süresinin 72.52 saniye ve tahmin süresinin 0.040 saniye olarak bulmuşlardır. Çalışmalarının, yüksek doğruluk ve taşınabilirlik sağlayarak, COVID-19 ve benzer hastalıkların tanısında etkili bir karar destek mekanizması sunduğunu vurgulamışlardır.

## 2. MATERYAL VE YÖNTEM

### Veri Seti

Bu çalışmada, Curated Dataset for COVID-19 Posterior-Anterior Chest Radiography Images (X-Rays) adlı veri seti kullanılmıştır (Sait vd., 2020). Veri seti, COVID-19, normal, viral pnömoni ve bakteriyel pnömoni vakalarına ait 9208 tek kanallı göğüs röntgen görüntüsünden oluşmaktadır.

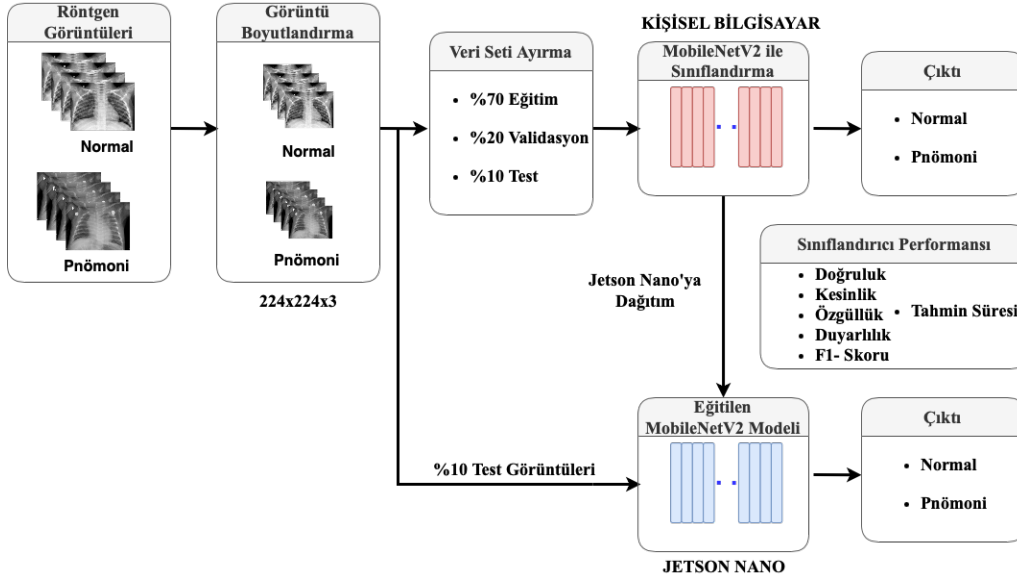
Çalışmada, 3270 normal ve 4657 pnömoni (viral ve bakteriyel pnömoni birleştirilerek) olmak üzere iki etiketli 7927 görüntü elde edilmiştir. Veri setindeki örnek normal ve pnömoni röntgen görüntüsü Şekil 1’de gösterilmiştir.



Şekil 1. (a) normal röntgen görüntüsü ve (b) pnömoni röntgen görüntüsü.

### Önerilen Yöntem

Pnömoni ve normal göğüs röntgen görüntülerinin sınıflandırılması için önerilen yöntemin akış diyagramı Şekil 2’de verilmiştir. Çalışmada kullanılan veri setindeki göğüs röntgen görüntüleri tek kanallı ve değişken boyutlardadır. MobilenetV2 modelinin giriş katmanına uygun hale getirmek için, bu görüntüler 224x224x3 olarak boyutlandırılmıştır.



Şekil 2. Önerilen yöntemin akış diyagramı.

Veri setinde herhangi bir veri artırma tekniği uygulanmamıştır. Veri seti %70 eğitim, %20 doğrulama ve %10 test olarak ayrılmıştır. Tablo 1’de eğitim, doğrulama ve test için kullanılan görüntü sayıları verilmiştir. Ayrılan eğitim ve doğrulama görüntüleri kullanılarak MobileNetV2 modeli eğitilmiş ve sınıflandırma yapılmıştır.

Tablo 1. Eğitim, doğrulama ve test için kullanılan görüntü sayıları.

Sınıf	Görüntü sayısı	%70 Eğitim	%20 Doğrulama	%10 Test
Normal	3270	2289	653	328
Pnömoni	4657	3260	932	465
Toplam	7927	5549	1585	793

Eğitilen model gömülü bir platform olan Nvidia Jetson Nano platformuna dağıtılmıştır. Sınıflandırma performansının analiz edilmesi için her iki platformda da Tablo 1’deki test görüntüleri kullanılmıştır. Böylece hem kişisel bilgisayarda hem de Jetson Nano platformundaki



performansı karşılaştırılabilir olmuştur. Kullanılan Jetson Nano platformu; 128 çekirdekli Maxwell GİB ve 472 GFLOPs (FP16) işlem gücü, 1.43 GHz hızında çalışan 4 çekirdekli ARM A57 merkezi işlem birimi (CPU), 4 GB 64 bit LPDDR4 25.6 GB/s bellek ve 16 GB eMMC depolama alanına sahiptir.

### MobileNetV2 Mimarisi

MobileNetV2, mobil ve gömülü cihazlar için optimize edilmiş, düşük hesaplama maliyetli ve yüksek performanslı bir derin öğrenme modelidir. Sınıflandırma ve öznetelik çıkarma görevlerinde başarılı olan bu model, tıbbi görüntü analizi gibi alanlarda etkili bir yöntemdir (Sandler vd., 2018).

Bu çalışmada kullanılan MobileNetV2 modeli, aşırı uyumu en aza indirmek için iki düşürme ‘dropout’ katmanı, 128 nörona sahip düzeltici doğrusal birim (ReLU) fonksiyonunu kullanan yoğun ‘dense’ katmanı ve ikili sınıflandırma yapmak için ise 1 nöronlu sigmoid fonksiyonunu kullanan yoğun katmandan ‘dense’ oluşmaktadır. Bu modelin sınıflandırma için kullanılan katmanları Tablo 2’de verilmiştir.

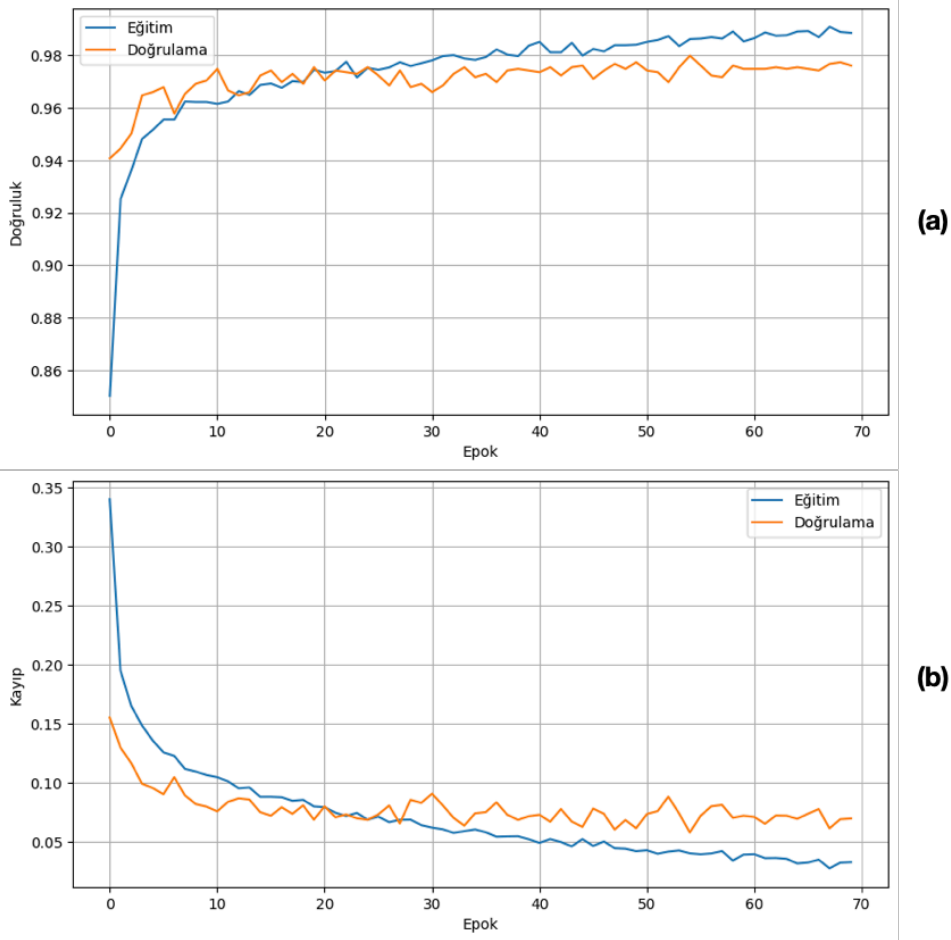
**Tablo 2.** Tasarlanan MobileNetV2 sınıflandırıcısının katmanları.

Katman Adı	Katman Açıklaması
GlobalAveragePooling2D	Özellik vektörü oluşturur
Dropout (%10)	%10 oranında nöronları düşürür
Dense	128 nörona sahip, ReLU aktivasyon fonksiyonu kullanır
Dropout (%30)	%30 oranında nöronları düşürür
Dense	Tek nörona sahip, sigmoid aktivasyon fonksiyonu kullanır

Tasarlanan model, ‘Adam’ optimizasyon algoritması, 32 yığın boyutu ‘batch size’, 0.0001 öğrenme oranı ‘learning rate’ kullanarak ikili çapraz entropi ‘binary\_crossentropy’ kayıp fonksiyonu ve doğruluk metriği ile derlenmiştir. Modelin eğitim epok sayısı 200 olmasına rağmen erken aşırı uyumu azaltmak için erken durdurma yapılarak 69 epok boyunca eğitilmiştir.

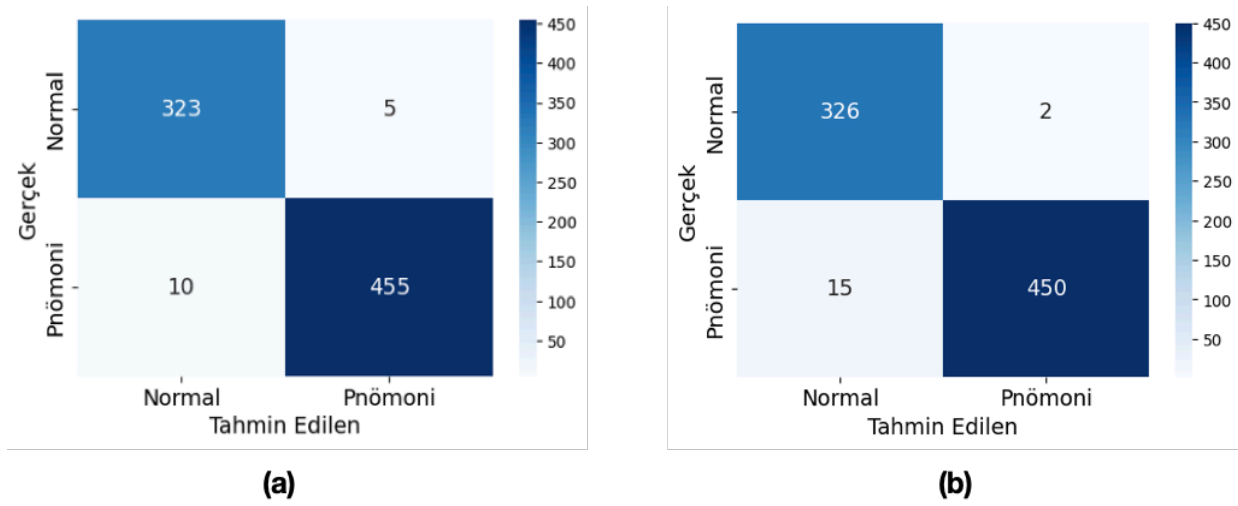
### 3. BULGU VE TARTIŞMALAR

Bu çalışmada kullanılan modelin performans analizi doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru metriklerle yapılmıştır. Ayrıca her iki platformda her bir görüntünün ortalama tahmin süreleri de verilmiştir. Şekil 3'te (a)'da modelin eğitim grafiği ve (b)'de kayıp grafiği verilmiştir. Bu grafikler değerlendirildiğinde tasarlanan model, eğitim ve doğrulama verileri üzerinde yüksek doğruluk ve düşük kayıp seviyeleriyle iyi performans vermiştir. Doğrulama kaybındaki küçük dalgalanmalar ve doğrulama doğruluğundaki sabitlik, aşırı öğrenme yapmadığını ve iyi bir genelleme yeteneğine sahip olduğunu göstermektedir.



Şekil 3. Modelin eğitim (a) ve kayıp grafiği (b).

Modelin sınıflandırma performansı Tablo 1’de verilen test görüntüleriyle test edilmiştir. Her iki platformda da aynı test görüntüleri kullanılmıştır. Şekil 4 (a)’da model test edildiğinde elde edilen karışıklık matrisi, (b)’de ise Jetson Nano platformunda eğitilmiş modelin test edilmesiyle elde edilen karışıklık matrisi verilmiştir. Eşitlik 1-5’te skorların hesaplanması için gereken eşitlikler verilmiştir.



Şekil 4. Kişisel bilgisayarda modelin karışıklık matrisi (a) ve Jetson Nano platformuna dağıtılan modelin karışıklık matrisi (b).

Tablo 3’te karışıklık matrislerine göre elde edilen skorları ve her bir görüntünün tahmin süreleri verilmiştir. Şekil 4’te (a)’da TP değeri 455, FN değeri 10, FP değeri 5 ve TN değeri 323 bulunmuştur. %98.1 doğruluk, %97.8 duyarlılık, %98.5 özgüllük, %98.9 kesinlik ve %98.4 F1-skoru elde edilmiştir. (b)’de TP değeri 450, FN değeri 15, FP değeri 2 ve TN değeri 326 bulunmuştur. %97.8 doğruluk, %96.8 duyarlılık, %99.4 özgüllük, %99.6 kesinlik ve %98.2 F1-skoru elde edilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Duyarlılık} = \frac{TP}{(TP+FN)} \quad (2)$$

$$\text{Özgüllük} = \frac{TN}{(TN+FP)} \quad (3)$$

$$\text{Kesinlik} = \frac{TP}{(TP+FP)} \quad (4)$$

$$F1 - \text{skor} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{(\text{Duyarlılık} + \text{Kesinlik})} \quad (5)$$

**Tablo 3.** Model test performans skorları ve her bir görüntü için tahmin süreleri.

Platform	Model Tahmin süresi	Performans Metrikleri				F1-Skoru
		Doğruluk	Duyarlılık	Özgüllük	Kesinlik	
<b>Kişisel Bilgisayar</b>	36.57 milisaniye	%98.1	%97.8	%98.5	%98.9	%98.4
<b>Jetson Nano Platformu</b>	111.2 milisaniye	%97.8	%96.8	%99.4	%99.6	%98.2

Kişisel bilgisayar, model tahmin süresi ve bazı performans metriklerinde (doğruluk, duyarlılık) Jetson Nano'ya kıyasla daha iyi sonuçlar vermektedir. Ancak, Jetson Nano, özgüllük ve kesinlik metriklerinde daha iyi performans göstermektedir. Her iki platform da yüksek performans metriklerine sahip olup, Jetson Nano'nun avantajı, taşınabilir, düşük maliyetli, düşük güç tüketimli bir platform olmasıdır. Bu, Jetson Nano'yu gerçek zamanlı uygulamalar için avantajlı yapmaktadır.



Şekil 5. Kullanılan deney kurulumu.

Şekil 5’te, tasarlanan deney kurulumu gösterilmiştir. Kurulum, Nvidia Jetson Nano gömülü platformu, monitör ve klavye gibi çeşitli çevre birimlerinden oluşmaktadır.

#### 4. SONUÇ VE ÖNERİLER

Bu çalışmada, önceden eğitilmiş MobileNetV2 modeli kullanılarak göğüs röntgeni görüntülerinden pnömoni tespiti gerçekleştirilmiş ve modelin performansı düşük maliyetli, yüksek performanslı ve taşınabilir bir platform olan Nvidia Jetson Nano üzerinde incelenmiştir. Çalışmanın bulguları, MobileNetV2 modelinin Jetson Nano platformunda yüksek doğruluk (%97.8), duyarlılık (%96.8), özgüllük (%99.4), kesinlik (%99.6) ve F1 skoru (%98.2) ile düşük hesaplama maliyetleriyle etkili şekilde çalışabileceğini göstermektedir. Literatürdeki Lou vd. (2023) ve Satheeshkumar vd. (2024) çalışmalarına kıyasla, MobileNetV2 modeli daha düşük hesaplama maliyetleriyle benzer veya daha yüksek doğruluk oranlarına ulaşmıştır. Tahmin süreleri açısından Jetson Nano'da 111.2 milisaniye olan ortalama süre, sistemin gerçek zamanlı uygulamalarda pratik bir çözüm sunduğunu göstermektedir. Bu çalışma, pnömoni teşhisinde düşük maliyetli ve enerji verimli çözümler sunarak sağlık hizmetlerinin kalitesini ve erişilebilirliğini artırmada önemli katkılar sağlayabilir. Gelecekteki araştırmalar, daha büyük veri kümeleri ve çeşitli derin öğrenme modelleri kullanarak sınıflandırma performansını daha da artırabilir. Jetson Nano'nun sunduğu taşınabilirlik, düşük

maliyet ve enerji verimliliği avantajları, çalışmamızın literatürdeki diğer çalışmalara göre üstünlüklerini ortaya koymaktadır.

## **KAYNAKÇA**

Antin, B., Kravitz, J., & Martayan, E. (2017). Detecting pneumonia in chest X-Rays with supervised learning. 2017.

Feng, Y., Xu, X., Wang, Y., Lei, X., Teo, S. K., Sim, J. Z. T., ... & Tan, C. H. (2021). Deep supervised domain adaptation for pneumonia diagnosis from chest x-ray images. *IEEE Journal of Biomedical and Health Informatics*, 26(3), 1080-1090.

Naralasetti, V., Shaik, R. K., Katepalli, G., & Bodapati, J. D. (2021). Deep Learning Models for Pneumonia Identification and Classification Based on X-Ray Images. *Traitement du Signal*, 38(3), 903-909.

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.

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.

Avola, D., Bacciu, A., Cinque, L., Fagioli, A., Marini, M. R., & Taiello, R. (2022). Study on transfer learning capabilities for pneumonia classification in chest-x-rays images. *Computer Methods and Programs in Biomedicine*, 221, 106833.

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.

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.

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.

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.

Romera, T., Petreto, A., Lemaitre, F., Bouyer, M., Meunier, Q., & Lacassagne, L. (2021, August). Implementations impact on iterative image processing for embedded GPU. In 2021 29th European Signal Processing Conference (EUSIPCO) (pp. 736-740). IEEE.

Srinivasan, A., & Wang, N. (2021, October). An Effective approach for implementing COVID-19 CT Lung Segmentation using Low-Cost System On Chip. In 2021 IEEE 12th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON) (pp. 0754-0759). IEEE.

Lou, L., Liang, H., & Wang, Z. (2023). Deep-Learning-Based COVID-19 Diagnosis and Implementation in Embedded Edge-Computing Device. *Diagnostics*, 13(7), 1329.

Satheeshkumar, K. G., Arunachalam, V., & Deepika, S. (2024). Hand-held GPU accelerated device for multiclass classification of X-ray images using CNN model. *Microprocessors and Microsystems*, 106, 105046.

Lekshmy, S., Sridhar, K. P., & Roberts, M. K. (2024). Analyzing the performance of a bio-sensor integrated improved blended learning model for accurate pneumonia prediction. *Results in Engineering*, 22, 102063.

Abubeker, K. M., & Baskar, S. (2023). B2-Net: an artificial intelligence powered machine learning framework for the classification of pneumonia in chest x-ray images. *Machine Learning: Science and Technology*, 4(1), 015036.

Ulutas, H., Sahin, M. E., & Karakus, M. O. (2023). Application of a novel deep learning technique using CT images for COVID-19 diagnosis on embedded systems. *Alexandria Engineering Journal*, 74, 345-358.

Sait, U., Lal, K., 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(J).

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).