



The Effect of Image Preprocessing Techniques on Pneumonia Detection from Lung X-ray Images

Enver Yiğitbaş^{1*}

¹ Department of Computer Engineering, Iskenderun Technical University, Hatay, Türkiye.

ABSTRACT

Early and accurate detection of pneumonia is of great importance, particularly in accelerating diagnostic processes and improving treatment success in the healthcare field. In this study, a pretrained MobileNet model was used for the automatic classification of pneumonia using chest X-ray images. The model was configured using the transfer learning approach, and only the final classification layers were retrained. The training process was carried out for 20 epochs, allowing the model to benefit from the strong feature extraction capabilities of the pretrained architecture. In order to improve model performance, image preprocessing techniques including CLAHE, Histogram Equalization, and Image Sharpening were applied. These methods enhanced the contrast levels of chest X-ray images, made low-contrast regions more distinguishable, and enabled the model to learn more discriminative features. The performances of the developed models were evaluated using accuracy, precision, recall, and F1-score metrics. Experimental results showed that the highest performance was achieved using the Histogram Equalization preprocessing method, with an accuracy of 87.02% and an F1-score of 90.37%. In particular, the high recall values demonstrated that the developed system was highly successful in detecting pneumonia cases. The obtained results indicate that image preprocessing methods can significantly improve the performance of deep learning-based pneumonia detection systems.

ARTICLE INFO

Received 15.03.2026,

Accepted 17.05.2026,

Publication Date 30.06.2026

Keywords:

Pneumonia Classification,
Chest X-ray Images,
Transfer Learning,
MobileNet, CLAHE,
Histogram Equalization,
Deep Learning.

Distributed Under CC-BY 4.0



*Corresponding Author: Enver YİĞİTBAŞ, E-mail: enver.yigitbas.lee25@iste.edu.tr

Görüntü Ön İşleme Tekniklerinin Akciğer Röntgen Görüntülerinden Pnömoni Tespiti Etkisi

ÖZET

Özellikle sağlık alanında tanı süreçlerini hızlandırmak ve tedavi başarısını artırmak açısından zatürrenin erken ve doğru teşhisi büyük önem taşımaktadır. Bu çalışmada, göğüs röntgeni görüntüleri kullanılarak zatürrenin otomatik sınıflandırılması için önceden eğitilmiş bir MobileNet modeli kullanılmıştır. Model, transfer öğrenme yaklaşımı kullanılarak yapılandırılmış ve yalnızca son sınıflandırma katmanları yeniden eğitilmiştir. Eğitim süreci 20 epoch boyunca gerçekleştirilmiş ve modelin önceden eğitilmiş mimarının güçlü özellik çıkarma yeteneklerinden faydalanması sağlanmıştır. Model performansını iyileştirmek için CLAHE, Histogram Eşitleme ve Görüntü Keskinleştirme gibi görüntü ön işleme teknikleri uygulanmıştır. Bu yöntemler, göğüs röntgeni görüntülerinin kontrast seviyelerini artırmış, düşük kontrastlı bölgeleri daha ayırt edilebilir hale getirmiş ve modelin daha ayırt edici özellikler öğrenmesini sağlamıştır. Geliştirilen modellerin performansları doğruluk, hassasiyet, geri çağırma ve F1-skor metrikleri kullanılarak değerlendirilmiştir. Deneysel sonuçlar, en yüksek performansın Histogram Eşitleme ön işleme yöntemi kullanılarak elde edildiğini, doğruluk oranının %87,02 ve F1 puanının %90,37 olduğunu göstermiştir. Özellikle yüksek geri çağırma değerleri, geliştirilen sistemin zatürre vakalarını tespit etmede son derece başarılı olduğunu göstermiştir. Elde edilen sonuçlar, görüntü ön işleme yöntemlerinin derin öğrenmeye dayalı zatürre tespit sistemlerinin performansını önemli ölçüde artırabileceğini göstermektedir..

MAKALE BİLGİSİ

Keywords:

Pnömoni
Sınıflandırması, Chest
X-ray Görüntüleri,
Transfer Learning,
MobileNet, CLAHE,
Histogram Equalization,
Derin Öğrenme

GİRİŞ

Pnömoni, akciğer dokusunun iltihaplanması sonucu ortaya çıkan ve özellikle çocuklar ile yaşlı bireylerde ciddi sağlık sorunlarına neden olabilen önemli bir solunum yolu hastalığıdır. Dünya genelinde pnömoni nedeniyle her yıl milyonlarca insan hayatını kaybetmekte olup, hastalığın erken teşhisi tedavi sürecinde büyük önem taşımaktadır. Röntgeni (X-ray) görüntüleri, düşük maliyetli olması ve hızlı sonuç verebilmesi nedeniyle yaygın olarak kullanılmaktadır (Duruel ve Kutlu, 2025). Bununla birlikte chest X-ray görüntülerinin manuel olarak değerlendirilmesi uzman

radyolog deneyimi gerektirmekte ve bazı durumlarda yanlış teşhisler oluşabilmektedir. Bu nedenle bilgisayar destekli tanı sistemleri sağlık alanında önemli bir araştırma konusu haline gelmiştir. (Atik, 2024; Rahman ve ark., 2020).

Son yıllarda yapay zekâ ve derin öğrenme tabanlı yöntemler, tıbbi görüntü analizinde yaygın olarak kullanılmaya başlanmıştır. Özellikle evrişimsel sinir ağları (CNN), görüntü sınıflandırma problemlerinde yüksek başarı sağlaması nedeniyle biyomedikal görüntüleme çalışmalarında önemli bir yere sahiptir. Derin öğrenme modelleri sayesinde chest X-ray görüntülerinden otomatik pnömoni tespiti gerçekleştirilebilmekte ve uzmanlara hızlı karar desteği sağlanabilmektedir. Yapılan çalışmalarda AlexNet, ResNet, DenseNet ve SqueezeNet gibi pretrained modellerin yüksek doğruluk oranları elde ettiği belirtilmiştir. (Toğaçar ve ark., 2019; Rahman ve ark., 2020).

Transfer öğrenme yaklaşımı, büyük veri kümeleri üzerinde önceden eğitilmiş modellerin farklı problemlere uyarlanması sağlayarak eğitim süresini azaltmakta ve sınırlı veri kümelerinde dahi başarılı sonuçlar elde edilmesine katkı sunmaktadır. Özellikle ResNet tabanlı modellerin artık blok bağlantıları sayesinde derin ağ yapılarında performansı artırdığı ve gradyan kaybolması problemini azalttığı ifade edilmektedir. Bu sayede daha derin mimariler ile yüksek doğruluk oranları elde edilebilmektedir. (Atik, 2024).

Rajpurkar ve arkadaşları tarafından geliştirilen CheXNet modeli, chest X-ray görüntülerinden pnömoni tespitinde radyolog seviyesinde performans göstermiştir. DenseNet tabanlı 121 katmanlı derin öğrenme modeli kullanılarak gerçekleştirilen çalışmada, sistemin uzman radyolog ortalamasından daha yüksek F1 skoru elde ettiği belirtilmiştir. Bu çalışma, derin öğrenme yöntemlerinin tıbbi görüntü analizindeki potansiyelini ortaya koymuştur. (Rajpurkar ve ark., 2017).

Bunun yanında veri artırma (data augmentation), görüntü ön işleme ve öznitelik çıkarımı gibi yöntemlerin derin öğrenme modellerinin başarımını önemli ölçüde etkilediği belirtilmektedir. Özellikle görüntülerin yeniden boyutlandırılması, normalize edilmesi ve veri çeşitliliğinin artırılması sayesinde modellerin farklı görüntü koşullarına karşı daha dayanıklı hale geldiği ifade edilmektedir. (Rahman ve ark., 2020; Toğaçar ve ark., 2019).

Son yıllarda klasik derin öğrenme yöntemlerinin yanında kuantum tabanlı yapay zekâ modelleri de sağlık alanında kullanılmaya başlanmıştır. Kuantum Evrişimli Sinir Ağları (QCNN), daha düşük özellik boyutlarıyla yüksek başarı sağlamayı hedeflemekte ve özellikle tıbbi görüntü sınıflandırma problemlerinde gelecek vadeden yöntemler arasında gösterilmektedir. Akciğer röntgen görüntülerinden Covid-19 ve viral pnömoni tespiti üzerine yapılan çalışmalarda kuantum tabanlı modellerin başarılı sonuçlar verdiği belirtilmiştir. (Şahin ve Harman, 2024).

AlexNet tabanlı derin öğrenme modeli kullanılarak chest X-ray görüntülerinden pnömoni tespiti gerçekleştirilmiş ve elde edilen öznitelikler çeşitli makine öğrenmesi algoritmaları ile sınıflandırılmıştır. Çalışmada en yüksek başarı oranı Destek Vektör Makineleri (DVM) kullanılarak %95,8 doğruluk olarak elde edilmiştir (Toğaçar ve ark., 2019).

ResNet tabanlı artık blok bağlantılarına sahip bir CNN modeli kullanılarak 5617 adet chest X-ray görüntüsü üzerinden pnömoni tespiti gerçekleştirilmiştir. Çalışmada transfer öğrenme yaklaşımı uygulanmış ve önerilen model %98,42 doğruluk ile %98,40 F1-skor değeri elde ederek başarılı sonuçlar vermiştir (Atik, 2024).

Kuantum Evrişimli Sinir Ağları (QCNN) tabanlı hibrit bir model kullanılarak Kaggle'dan elde edilen Covid-19, viral pnömoni ve normal chest X-ray görüntüleri sınıflandırılmıştır. Çalışmada ResNet-50 tabanlı transfer öğrenme yaklaşımından yararlanılmış ve farklı öznetelik sayılarıyla yaklaşık %70, %72 ve %76 doğruluk oranları elde edilirken, genel doğruluk oranının %96,97 olduğu belirtilmiştir (Şahin ve Harman, 2024).

DenseNet121 tabanlı CheXNet modeli kullanılarak 112.120 adet chest X-ray görüntüsü üzerinden pnömoni tespiti gerçekleştirilmiştir. Çalışmada transfer öğrenme ve veri artırma yöntemleri uygulanmış, CheXNet modeli %43,5 F1-skor ve 0,768 AUROC değeri elde ederek uzman radyolog ortalamasından daha başarılı sonuç vermiştir (Rajpurkar ve ark., 2017).

Transfer öğrenme tabanlı AlexNet, ResNet18, DenseNet201 ve SqueezeNet modelleri kullanılarak 5247 adet chest X-ray görüntüsü üzerinden bakteriyel ve viral pnömoni tespiti gerçekleştirilmiştir. Çalışmada en başarılı sonuç DenseNet201 modeli ile elde edilmiş; normal ve pnömoni sınıflandırmasında %98, bakteriyel ve viral pnömoni sınıflandırmasında %95 ve üç sınıflı sınıflandırmada %93,3 doğruluk oranına ulaşılmıştır (Rahman ve ark., 2020).

Transfer öğrenme ve ensemble derin öğrenme yöntemleri kullanılarak Kaggle'dan elde edilen 7750 adet chest X-ray görüntüsü üzerinde pnömoni tespiti gerçekleştirilmiştir. Çalışmada VGG16, ResNet50, Inception-V3 ve özel CNN modelleri değerlendirilmiş, en başarılı sonuç Inception-V3 + CNN ensemble modeli ile %99,29 doğruluk, %98,83 precision, %99,73 recall ve %99,28 F1-skor değeri olarak elde edilmiştir (Mujahid ve ark., 2022).

Transfer öğrenme tabanlı AlexNet modeli kullanılarak farklı açık erişimli veri setlerinden elde edilen 11.568 adet chest X-ray görüntüsü ile COVID-19, viral pnömoni, bakteriyel pnömoni ve normal akciğer görüntülerinin sınıflandırılması gerçekleştirilmiştir. Çalışmada COVID-19 ve normal görüntülerin ayırımında %99,16 doğruluk elde edilirken, dört sınıflı sınıflandırma probleminde %93,42 doğruluk oranına ulaşılmıştır (İbrahim ve ark., 2021).

Attention mekanizmaları ile güçlendirilmiş EfficientNetB0 ve DenseNet121 tabanlı derin öğrenme modeli kullanılarak Kaggle'dan elde edilen 5856 adet chest X-ray görüntüsü üzerinde pnömoni tespiti gerçekleştirilmiştir. Çalışmada histogram eşitleme ve veri artırma yöntemleri uygulanmış, model %95,19 doğruluk, %98,38 precision, %93,84 recall ve %96,06 F1-skor değeri elde etmiştir (An ve ark., 2024).

CNN tabanlı bir model kullanılarak 5863 adet chest X-ray görüntüsü üzerinden pnömoni tespiti gerçekleştirilmiştir. Çalışmada veri artırma ve normalizasyon işlemleri uygulanmış, geliştirilen model %91,03 doğruluk, %89,76 precision, %96,67 recall ve %93,09 F1-skor değeri elde etmiştir (Dutta ve ark., 2025).

Pandemi döneminde COVID19 verileriyle derin öğrenme tabanlı analizler yapılmış korona virüs hastalıkları görüntülerin sınıflandırılmasında güzel sonuçlar alınmıştır (Camgözlü ve Kutlu, 2021).

Hafif ve hızlı çalışan CNN tabanlı bir model kullanılarak COVID-19, viral/bakteriyel pnömoni ve normal chest X-ray görüntülerinin sınıflandırılması gerçekleştirilmiştir. Kaggle veri seti üzerinde yapılan çalışmada geliştirilen model %97,03 accuracy, %97,05 precision, %97,03 recall ve %97,03 F1-skor değeri elde etmiş, düşük parametre sayısına rağmen yüksek performans sağladığı belirtilmiştir (Yen ve Tsao, 2024).

Bu çalışmada, akciğer röntgen (Chest X-ray) görüntüleri kullanılarak pnömoni hastalığının otomatik olarak tespit edilmesi amacıyla derin öğrenme tabanlı sınıflandırma modelleri geliştirilmiştir. Çalışmada, transfer öğrenme yaklaşımı kapsamında yaygın olarak kullanılan MobileNetV2 mimarisi tercih edilmiştir. MobileNetV2 modeli; düşük hesaplama maliyeti, hızlı eğitim süreci ve başarılı sınıflandırma performansı nedeniyle seçilmiş olup, özellikle sınırlı donanım kaynaklarına sahip sistemlerde uygulanabilirliği açısından avantaj sağlamaktadır.

Model performansını artırmak amacıyla görüntü ön işleme tekniklerinden CLAHE (Contrast Limited Adaptive Histogram Equalization), Histogram Equalization ve Image Sharpening yöntemleri uygulanmıştır. Bu ön işleme teknikleri sayesinde chest X-ray görüntülerindeki kontrast seviyeleri artırılmış, düşük kontrastlı bölgelerdeki detayların daha belirgin hale getirilmesi ve modelin daha ayırt edici özellikler öğrenebilmesi hedeflenmiştir.

Transfer öğrenme yaklaşımı ile eğitilen MobileNetV2 modelinin son katmanları problem yapısına uygun şekilde yeniden düzenlenmiş ve eğitim süreci 20 epoch boyunca gerçekleştirilmiştir. Elde edilen modeller accuracy, precision, recall ve F1-score metrikleri kullanılarak değerlendirilmiş, ayrıca confusion matrix analizleri ile sınıflandırma performansları ayrıntılı olarak incelenmiştir.

Çalışma kapsamında farklı ön işleme yöntemlerinin model başarımına etkileri karşılaştırılmıştır. Yapılan deneyler sonucunda Histogram Equalization yöntemi ile eğitilen modelin diğer yöntemlere göre daha yüksek accuracy ve F1-score değerleri elde ettiği gözlemlenmiştir. Özellikle recall değerlerinin yüksek olması, geliştirilen sistemin pnömoni vakalarını başarılı şekilde tespit edebildiğini göstermiştir. Bu çalışma ile birlikte, görüntü ön işleme tekniklerinin transfer öğrenme tabanlı medikal görüntü sınıflandırma sistemleri üzerindeki etkileri analiz edilmiş ve düşük maliyetli, yüksek doğruluklu ve uygulanabilir bir yapay zeka destekli pnömoni tespit sistemi geliştirilmiştir.

MATERYAL VE METHOD

Veri Seti


Bu çalışmada, chest X-ray görüntülerinden pnömoni tespiti amacıyla Kaggle platformunda yer alan “Chest X-Ray Images (Pneumonia)” veri seti kullanılmıştır. Veri seti toplam 5.863 adet chest X-

ray görüntüsünden oluşmakta olup “NORMAL” ve “PNEUMONIA” olmak üzere iki farklı sınıf içermektedir. Pnömoni sınıfı içerisinde bakteriyel ve viral pnömoni görüntüleri bulunmaktadır. Veri setindeki görüntüler, Guangzhou Women and Children’s Medical Center’da 1–5 yaş aralığındaki pediatrik hastalardan elde edilmiş ve uzman doktorlar tarafından doğrulanmıştır. Ayrıca düşük kaliteli veya okunamayan görüntüler veri setinden çıkarılmıştır.

Veri seti; train, test ve validation olmak üzere üç ayrı klasör yapısında organize edilmiştir. Çalışmada kullanılan görüntüler model eğitime uygun hale getirilebilmesi amacıyla yeniden boyutlandırılmış, normalize edilmiş ve veri artırma (data augmentation) işlemleri uygulanmıştır. Veri artırma aşamasında döndürme, yakınlaştırma, yatay çevirme ve parlaklık değişimi gibi yöntemlerden yararlanılarak veri çeşitliliği artırılmıştır. Böylece modelin farklı görüntü koşullarına karşı daha dayanıklı hale gelmesi amaçlanmıştır.

Çalışmada kullanılan veri seti, farklı görüntü özelliklerine sahip normal ve pnömonili akciğer görüntülerini içermesi sayesinde derin öğrenme modellerinin chest X-ray görüntülerinden otomatik pnömoni tespiti performansının değerlendirilmesi için uygun bir yapı sunmaktadır. Ayrıca veri setinin açık erişimli olması, farklı çalışmalar arasında performans karşılaştırması yapılabilmesine olanak sağlamaktadır.

Şekil 1. Örnek Görseller



Veri Hazırlama

Veri kümesi üzerinde modelin daha başarılı ve genellenebilir sonuçlar verebilmesi amacıyla eğitim öncesinde çeşitli ön işleme ve veri artırma yöntemleri uygulanmıştır. İlk aşamada, veri setindeki chest X-ray görüntüleri herhangi bir görüntü iyileştirme işlemi uygulanmadan modele verilmiş ve temel performans sonuçları elde edilmiştir. Daha sonra model performansını artırmak amacıyla eğitim veri setindeki görüntüler üzerinde keskinleştirme (sharpening), Histogram Equalization ve CLAHE (Contrast Limited Adaptive Histogram Equalization) yöntemleri ayrı ayrı uygulanarak yeni veri kümeleri oluşturulmuştur.

Keskinleştirme işlemi ile görüntülerdeki kenar ve doku detaylarının daha belirgin hale getirilmesi amaçlanırken, Histogram Equalization yöntemi ile görüntülerin genel kontrast seviyesi artırılmıştır. CLAHE yöntemi ile ise özellikle düşük kontrastlı bölgelerdeki detayların adaptif olarak iyileştirilmesi sağlanmıştır. Böylece akciğer bölgesindeki yapısal farklılıkların modele daha belirgin şekilde sunulması hedeflenmiştir.

Tüm deneylerde görüntüler modele verilmeden önce 224×224 boyutuna yeniden ölçeklendirilmiş ve tensör formatına dönüştürülmüştür. Ayrıca eğitim verileri üzerinde rastgele yatay çevirme, döndürme, yakınlaştırma ve parlaklık değişimi gibi veri artırma (data augmentation) yöntemleri uygulanmıştır. Bu işlemler sayesinde modelin farklı görüntü koşullarına karşı daha dayanıklı hale gelmesi ve aşırı öğrenmenin (overfitting) azaltılması amaçlanmıştır. Test verileri üzerinde ise yalnızca yeniden boyutlandırma ve normalizasyon işlemleri uygulanmıştır.

Pretrained Modeller

Bu çalışmada, chest X-ray görüntülerinden pnömoni tespiti amacıyla farklı derin öğrenme tabanlı CNN mimarileri kullanılmıştır. Çalışmada Custom CNN, Refined CNN, Augmented Refined CNN Modeli ve transfer öğrenme tabanlı MobileNetV2 modelleri değerlendirilmiştir. Ayrıca modellerin performansını artırmak amacıyla veri artırma (augmentation) yöntemleri ile birlikte keskinleştirme (sharpening), Histogram Equalization ve CLAHE gibi görüntü ön işleme teknikleri uygulanmıştır. Modellerin performansları doğruluk (accuracy), precision, recall ve F1-skor metrikleri kullanılarak karşılaştırılmıştır.

Baseline CNN Modeli

Çalışmada temel sınıflandırma modeli olarak özel oluşturulmuş bir CNN mimarisi kullanılmıştır. Model yapısında evrişim (Conv2D), havuzlama (MaxPooling), Batch Normalization, Dropout ve tam bağlı (Dense) katmanlardan yararlanılmıştır. Görüntüler yeniden boyutlandırılarak modele verilmiş ve model test verileri üzerinde değerlendirilmiştir. Yapılan analizler sonucunda Baseline CNN modeli %81,89 test doğruluğu elde etmiş, kayıp (loss) değeri ise 0.7000 olarak hesaplanmıştır. Model performansı accuracy ve loss değerleri üzerinden değerlendirilmiştir.

Refined CNN Modeli

Çalışmada, pnömoni tespiti amacıyla geliştirilmiş bir Refined CNN modeli kullanılmıştır. Model yapısında üç farklı evrişimsel blok yer almakta olup her blokta Conv2D, Batch Normalization ve

MaxPooling2D katmanları kullanılmıştır. İlk katmanda 32, ikinci katmanda 64 ve üçüncü katmanda 128 filtre kullanılarak görüntülerden derin öznitelikler çıkarılmıştır. Sınıflandırma aşamasında Flatten, 128 nöronlu Dense ve %30 Dropout katmanları kullanılarak aşırı öğrenmenin azaltılması hedeflenmiştir. Son katmanda sigmoid aktivasyon fonksiyonuna sahip tek nöron kullanılarak ikili sınıflandırma gerçekleştirilmiştir. Model Adam optimizasyon algoritması ve binary cross-entropy kayıp fonksiyonu ile eğitilmiştir. Yapılan testler sonucunda model %77,88 doğruluk oranı elde etmiş, kayıp (loss) değeri ise 1.9735 olarak hesaplanmıştır.

Augmented Refined CNN Modeli

Refined CNN modelinin geliştirilmiş bir versiyonu olarak veri artırma (data augmentation) destekli CNN modeli kullanılmıştır. Bu modelde temel CNN mimarisine ek olarak eğitim sürecinde görüntüler üzerinde rastgele döndürme, yakınlaştırma ve çevirme gibi veri artırma işlemleri uygulanmıştır. Böylece modelin farklı görüntü varyasyonlarına karşı daha dayanıklı hale gelmesi ve aşırı öğrenmenin azaltılması hedeflenmiştir. Model yapısında Conv2D, Batch Normalization, MaxPooling2D, Dropout ve Dense katmanları kullanılmıştır. Model Adam optimizasyon algoritması ve binary cross-entropy kayıp fonksiyonu ile eğitilmiştir. Yapılan testler sonucunda Augmented Refined CNN modeli %62,50 doğruluk oranı elde etmiş, kayıp (loss) değeri ise 39.7709 olarak hesaplanmıştır.

Transfer Learning Modeli (MobileNet)

Çalışmada transfer öğrenme yaklaşımı kapsamında ImageNet veri kümesi üzerinde önceden eğitilmiş MobileNetV2 mimarisi kullanılmıştır. Modelde include_top=False parametresi kullanılarak son sınıflandırma katmanları kaldırılmış ve önceden eğitilmiş katmanlar dondurularak yalnızca yeni eklenen sınıflandırma katmanlarının eğitilmesi sağlanmıştır. Özellik çıkarımı için MobileNetV2 tabanı kullanılmış, ardından GlobalAveragePooling2D, 128 nöronlu Dense ve %30 Dropout katmanları eklenmiştir. Son katmanda sigmoid aktivasyon fonksiyonu kullanılarak ikili sınıflandırma gerçekleştirilmiştir.

Model Adam optimizasyon algoritması ve binary cross-entropy kayıp fonksiyonu ile eğitilmiş, eğitim süreci 50 epoch boyunca gerçekleştirilmiştir. Eğitim sırasında doğrulama verileri kullanılarak model performansı takip edilmiş ve accuracy ile loss değerleri değerlendirilmiştir. Test verileri üzerinde elde edilen sonuçlara göre transfer öğrenme tabanlı MobileNetV2 modeli, diğer CNN modellerine göre daha yüksek sınıflandırma performansı sağlamıştır.

Şekil 2. Performans degerleri

Model	Accuracy	Loss	Precision	Recall	F1-score
Baseline CNN	0.81	0.7000	-	-	-
Refined CNN	0.78	1.9735	-	-	-
Augmented Refined CNN	0.62	39.7709	-	-	-
Transfer Learning (MobileNetV2)	0.85	-	0.81	1.00	0.89

Keskinleştirme

Çalışmada, görüntü ön işleme aşamasında chest X-ray eğitim görüntülerine yumuşak keskinleştirme (image sharpening) işlemi uygulanmıştır. Bu işlem kapsamında görüntüler grayscale formatta okunmuş ve OpenCV kütüphanesinin filter2D fonksiyonu kullanılarak convolution tabanlı bir keskinleştirme filtresi uygulanmıştır. Kullanılan kernel yapısı merkez piksel değerini güçlendirirken komşu piksel etkilerini azaltarak kenarların ve doku geçişlerinin daha belirgin hale gelmesini sağlamıştır. İşlenen görüntüler yeni klasör yapısına kaydedilmiş ve tüm veri seti üzerinde otomatik toplu işlem gerçekleştirilmiştir. Keskinleştirme uygulanmış görüntüler kullanılarak MobileNetV2 tabanlı transfer öğrenme modeli eğitilmiş ve model sonucunda %78.37 accuracy, %74.38 precision, %99.74 recall ve %85.21 F1-score performansı elde edilmiştir. Model performansı ayrıca confusion matrix kullanılarak değerlendirilmiş ve özellikle pozitif sınıf tespitinde yüksek recall değeri elde edildiği gözlemlenmiştir.

CLAHE (Contrast Limited Adaptive Histogram Equalization)

Görüntü ön işleme aşamasında CLAHE (Contrast Limited Adaptive Histogram Equalization) yöntemi uygulanarak chest X-ray görüntülerinin kontrast seviyeleri iyileştirilmiştir. Bu işlem ile düşük kontrastlı bölgelerdeki detayların daha belirgin hale getirilmesi ve modelin daha ayırt edici özellikler öğrenebilmesi hedeflenmiştir. CLAHE uygulanmış görüntüler kullanılarak önceden ImageNet veri kümesi üzerinde eğitilmiş olan MobileNetV2 mimarisi ile transfer öğrenme gerçekleştirilmiştir. Modelin son katmanı problem yapısına uygun şekilde yeniden düzenlenmiş ve eğitim süreci 10 epoch boyunca sürdürülmüştür. Eğitim sonucunda model, %75.48 doğruluk (accuracy), %71.90 precision, %99.74 recall ve %83.56 F1-score performansı elde etmiştir. Model performansı ayrıca confusion matrix kullanılarak değerlendirilmiş ve özellikle pozitif sınıf tespitinde oldukça yüksek recall değeri elde edildiği gözlemlenmiştir.

HISTOGRAM EQUALIZATION (HE)

Görüntü ön işleme aşamasında Histogram Equalization yöntemi uygulanarak chest X-ray görüntülerinin kontrast seviyeleri iyileştirilmiştir. Bu işlem sayesinde görüntülerdeki düşük kontrastlı bölgelerde bulunan detayların daha belirgin hale getirilmesi ve modelin daha ayırt edici özellikler öğrenebilmesi amaçlanmıştır. Histogram Equalization uygulanmış görüntüler

kullanılarak önceden ImageNet veri kümesi üzerinde eğitilmiş olan MobileNetV2 mimarisi ile transfer öğrenme gerçekleştirilmiştir. Modelin son katmanları problem yapısına uygun şekilde yeniden düzenlenmiş ve eğitim süreci 20 epoch boyunca sürdürülmüştür.

Eğitim sonucunda model performansı accuracy, precision, recall ve F1-score metrikleri ile değerlendirilmiştir. Model %87.02 accuracy, %84.26 precision, %97.44 recall ve %90.37 F1-score değeri elde etmiştir. Özellikle recall değerinin yüksek olması, modelin pnömoni vakalarını başarılı şekilde tespit edebildiğini göstermektedir.

SONUÇLAR ve TARTIŞMA

Bu çalışmada, akciğer röntgen (Chest X-ray) görüntülerinden pnömoni tespiti amacıyla transfer öğrenme tabanlı MobileNet modeli kullanılmış ve farklı görüntü ön işleme tekniklerinin model performansına etkileri karşılaştırmalı olarak incelenmiştir. Çalışma kapsamında herhangi bir ön işleme uygulanmayan MobileNet modeli ile birlikte CLAHE, Histogram Equalization ve Image Sharpening yöntemleri kullanılarak oluşturulan veri kümeleri üzerinde ayrı deneyler gerçekleştirilmiştir. Elde edilen sonuçlar, görüntü ön işleme tekniklerinin sınıflandırma performansı üzerinde önemli etkileri olduğunu göstermiştir. (Tablo 2)

Tablo 2. Önışlem Yöntemlerine göre Mobilnet Tarsnfer learnin Model performasn karşılaştırması

Model	Accuracy	Precision	Recall	F1-Score
Transfer Learning (MobileNetV2)	85.00%	81.00%	100.00%	89.00%
Transfer Learning + CLAHE	75.48%	71.90%	99.74%	83.56%
Transfer Learning + Histogram Equalization	87.02%	84.26%	97.44%	90.37%
Transfer Learning + Image Sharpening	78.37%	74.38%	99.74%	85.21%

Deneyisel sonuçlar incelendiğinde, en yüksek performansın Histogram Equalization yöntemi ile elde edildiği görülmüştür. Bu yöntemde model %87.02 doğruluk (accuracy), %84.26 precision, %97.44 recall ve %90.37 F1-score değerlerine ulaşmıştır. Özellikle yüksek recall değeri, modelin pnömoni vakalarını tespit etme konusunda oldukça başarılı olduğunu göstermektedir. Tıbbi karar destek sistemlerinde yanlış negatif sonuçların (False Negative) mümkün olduğunca düşük olması büyük önem taşımaktadır. Bu çalışmada Histogram Equalization yöntemi ile yalnızca 10 adet yanlış negatif sonucun elde edilmesi, modelin pnömoni vakalarını kaçırma oranının düşük olduğunu ortaya koymaktadır.

Temel MobileNetV2 modeli herhangi bir ön işleme uygulanmadan %85 doğruluk ve %89 F1-score değeri elde etmiştir. Histogram Equalization yöntemi bu sonuçları iyileştirerek doğruluk oranında

yaklaşık %2, F1-score değerinde ise yaklaşık %1.4 oranında artış sağlamıştır. Bu durum, kontrast artırma işlemlerinin akciğer görüntülerindeki patolojik bölgelerin daha belirgin hale gelmesine katkı sağladığını ve modelin daha ayırt edici özellikler öğrenmesine yardımcı olduğunu göstermektedir.

CLAHE ve Image Sharpening yöntemleri de yüksek recall değerleri üretmelerine rağmen doğruluk ve precision değerleri açısından Histogram Equalization yönteminin gerisinde kalmıştır. CLAHE yönteminde %75.48 doğruluk ve %83.56 F1-score, Image Sharpening yönteminde ise %78.37 doğruluk ve %85.21 F1-score elde edilmiştir. Her iki yöntemde de recall değerlerinin yüksek olması, pnömoni vakalarının büyük ölçüde doğru şekilde tespit edildiğini göstermektedir. Ancak düşük precision değerleri, normal görüntülerin pnömoni olarak sınıflandırıldığı yanlış pozitif sonuçların arttığını ortaya koymaktadır. Bu durum özellikle CLAHE yönteminin görüntü kontrastını yerel olarak artırırken bazı normal dokuları da patolojik yapılar gibi belirgin hale getirmesinden kaynaklanmış olabilir.

Elde edilen sonuçlar literatürdeki benzer çalışmalarla karşılaştırıldığında önerilen yaklaşımın kabul edilebilir düzeyde performans gösterdiği görülmektedir. Literatürde bazı çalışmalarda %95'in üzerinde doğruluk oranları rapor edilmesine rağmen bu çalışmaların çoğunda daha karmaşık mimariler, ensemble modeller veya daha yoğun eğitim süreçleri kullanılmıştır. Buna karşılık MobileNetV2 mimarisi düşük parametre sayısı ve düşük hesaplama maliyeti sayesinde sınırlı donanım kaynaklarına sahip sistemlerde uygulanabilir bir çözüm sunmaktadır. Bu nedenle elde edilen %87.02 doğruluk ve %90.37 F1-score sonuçları, modelin pratik uygulamalar açısından önemli bir potansiyele sahip olduğunu göstermektedir.

Sonuç olarak bu çalışma, görüntü ön işleme tekniklerinin transfer öğrenme tabanlı pnömoni tespit sistemlerinin performansını anlamlı ölçüde etkileyebildiğini ortaya koymuştur. Özellikle Histogram Equalization yöntemi, MobileNetV2 modeli ile birlikte kullanıldığında en başarılı sonuçları vermiştir. Gelecekte yapılacak çalışmalarda farklı transfer öğrenme mimarilerinin (DenseNet, EfficientNet ve ResNet gibi) değerlendirilmesi, dikkat mekanizmalarının (attention mechanisms) kullanılması ve daha büyük veri kümeleri üzerinde testler gerçekleştirilmesi ile sistem performansının daha da artırılabilirliği düşünülmektedir. Ayrıca açıklanabilir yapay zekâ (Explainable AI) yöntemlerinin kullanılması, model kararlarının klinik açıdan yorumlanabilirliğini artırarak sağlık alanındaki kullanım potansiyelini güçlendirebilir.

KAYNAKÇA

- Atik, İ. (2024). Pneumonia detection on chest x-ray images using residual convolutional neural network. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39(3), 1719–1731. <https://doi.org/10.17341/gazimmfd.1271385>
- Camgözlü Y, Kutlu Y. (2021). Detection of coronavirus disease (COVID-19) from X-ray images using deep convolutional neural networks. *Natural and Engineering Sciences*, 6(3), 204-211., Doi: 10.28978/nesciences.868087

- Duruel, O.M., Kutlu, Y. (2025). Artificial Intelligence in Dental Imaging for Disease Detection and Treatment. *Tethys Environmental Science*, 2(3), 122-128, doi : 10.5281/zenodo.17220181
- Şahin, S., & Harman, G. (2024). Akciğer röntgen görüntülerinden Covid-19 ve zatürre hastalığının kuantum evrişimli sinir ağları yöntemi ile tahmini. *Karaelmas Fen ve Mühendislik Dergisi*, 14(2), 37–51. <https://doi.org/10.7212/karaelmasfen.1416331>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Ball, R. L., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). ***CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning***. arXiv. <https://doi.org/10.48550/arXiv.1711.05225>
- Rahman, T., Chowdhury, M. E. H., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., Kadir, M. A., & Kashem, S. (2020). Transfer learning with deep convolutional neural network (CNN) for pneumonia detection using chest X-ray. *Applied Sciences*, 10(9), 3233. <https://doi.org/10.3390/app10093233>
- Mujahid, M., Rustam, F., Álvarez, R., Vidal Mazón, J. L., de la Torre Díez, I., & Ashraf, I. (2022). Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network. *Diagnostics*, 12(5), 1280. <https://doi.org/10.3390/diagnostics12051280>
- Ibrahim, A. U., Ozsoz, M., Serte, S., Al-Turjman, F., & Yakoi, P. S. (2021). Pneumonia Classification Using Deep Learning from Chest X-ray Images During COVID-19. ***Cognitive Computation***, 16, 1589–1601. Springer. <https://doi.org/10.1007/s12559-020-09787-5>
- An, Q., Chen, W., & Shao, W. (2024). *A Deep Convolutional Neural Network for Pneumonia Detection in X-ray Images with Attention Ensemble*. *Diagnostics*, 14(4), 390. MDPI. <https://doi.org/10.3390/diagnostics14040390>
- Dutta, P. K., Chowdhury, A., Bhattacharyya, A., Chakraborty, S., & Dey, S. (2025). *Deep Learning-Based Pneumonia Detection from Chest X-ray Images: A CNN Approach with Performance Analysis and Clinical Implications*. arXiv. <https://doi.org/10.48550/arXiv.2510.00035>
- Toğaçar, M., Ergen, B., & Sertkaya, M. E. (2019). Zatürre hastalığının derin öğrenme modeli ile tespiti. ***Firat Üniversitesi Mühendislik Bilimleri Dergisi***, 31(1), 223–230. https://dergipark.org.tr/tr/pub/fumbd/article/498364?issue_id=43638
- Yen, C.-T., & Tsao, C.-Y. (2024). Lightweight convolutional neural network for chest X-ray images classification. *Scientific Reports*, 14, 29759. <https://doi.org/10.1038/s41598-024-80826-z>