



ÖNCE DEN EĞİTİLMİŞ DERİN AĞLAR İLE GÖĞÜS RÖNTGENİ GÖRÜNTÜLERİ KULLANARAK PNÖMONİ SINIFLANDIRILMASI

Mehmet Bilal ER

Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Şanlıurfa, TÜRKİYE
bilal.er@harran.edu.tr

(Geliş/Received: 14.09.2020; Kabul/Accepted in Revised Form: 05.12.2020)

ÖZ: Pnömoni, bakterilerin, virüslerin veya mantarların neden olabileceği bir akciğer enfeksiyonudur. Enfeksiyon, akciğerlerin hava keselerinin iltihaplanmasına ve sıvı veya irin ile dolmasına neden olur. Ciddi ve hayatı tehdit eden bir hastalık olabilir. Dünya genelinde her yıl pnömoni nedeniyle çok sayıda kişi ölmektedir. Pnömoninin erken tespiti ve tedavisi, ölüm oranlarını önemli ölçüde azaltabilmektedir. Bu nedenle, bu çalışmada pnömoniyi tespit etmek için röntgen görüntüleri kullanarak önceden eğitilmiş derin öğrenme modellerine dayanan yöntem önerilmektedir. Göğüs röntgen görüntülerini pnömoni ve pnömoni olmayan iki sınıfta sınıflandırmak için çeşitli önceden eğitilmiş Evrişimsel Sinir Ağları özellik çıkarıcı olarak kullanılmıştır. Önceden eğitilmiş derin öğrenme modelleri olarak AlexNet, VGG16, ResNet (ResNet18, ResNet50, ResNet101) modelleri tercih edilmiştir. Bu modellerden elde edilen özellikler birleştirilerek hibrit özellik vektörü elde edilmiştir. Sınıflandırıcı olarak Destek Vektör Makineleri (DVM) ve derin öğrenme modellerinin son katmanında bulunan Softmax kullanılmıştır. Deneyler literatürde yaygın kullanılan veri seti üzerinde yapılmıştır. En yüksek sınıflandırma başarısı %98,32 olarak hibrit özellik vektöründen elde edilmiştir.

Anahtar Kelimeler: Pnömoni, Evrişimsel Sinir Ağlar, AlexNet, ResNet, VGG16

Classification of Pneumonia Using Pre-Trained Deep Networks with Chest X-Ray Images

ABSTRACT: Pneumonia is a lung infection that can be caused by bacteria, viruses, or fungi. The infection causes the lungs to become inflamed and filled with fluid or pus. It can be a serious and life-threatening disease. Many people die every year due to pneumonia worldwide. Early detection and treatment of pneumonia can significantly reduce mortality. For this reason, this research is to propose a method based on pre-trained deep network models using x-ray images to detect pneumonia. Various pre-trained Convolutional Neural Networks were used as feature extractors to classify chest x-ray images into two classes without pneumonia and pneumonia. AlexNet, VGG16, ResNet (ResNet18, ResNet50, ResNet101) models are preferred as pre-trained deep network models. The hybrid feature vector is obtained by combining the features obtained from these models. As the classifier, Support Vector Machines (SVM) and Softmax in the last layer of deep networks are used. Experiments are carried out on the data set commonly used in the literature. The highest classification success is obtained from the hybrid feature vector as 98.32%.

Keywords: Pneumonia, Convolutional Neural Networks, AlexNet, ResNet, VGG16

GİRİŞ (INTRODUCTION)

Pnömoni, en sık virüs veya bakterilerin neden olduğu bir akut solunum yolu enfeksiyonu türüdür ve her yaşta insanın hayatını hafif ya da ağır şekilde tehdit edebilir. Sağlıklı bir insan nefes aldığı anda akciğerler hava ile dolan alveol denilen küçük keselerden oluşur. Bir birey zatürree olduğunda, alveoller

irin ve sıvı ile doldurulur, bu da nefes almayı ağırlı hale getirir ve oksijen alımını sınırlar. Bu enfeksiyonlar genellikle enfekte kişilerle doğrudan temas yoluyla yayılır. Özellikle 5 yaşın altındaki çocuklar dahil olmak üzere yıllık bazda 150 milyondan fazla insan pnömoni ile enfekte olmaktadır (Rudan ve diğ., 2004). Semptomlar bir kişinin yaşına ve pnömoniyeye neyin neden olduğuna bağlı olarak değişir. Fakat sık görülen semptomlar, çok hızlı nefes alma, hırıltılı seslerle nefes almak, ateş, öksürük ve göğüs ağrısı gibidir. Fakat bu hastalık antiviral ilaçlar ile iyi tedavi edilebilir.

Pnömoninin daha hızlı teşhisi ve doğru tedavinin uygulanması, bu hastalığın ölümcül seyretme oranını önemli ölçüde azaltır. (Aydoğdu ve diğ., 2010). Göğüs röntgenleri şu anda pnömoni teşhisi için en sık kullanılan yöntemdir (WHO, 2001). Fakat pnömoninin röntgen görüntüleri çok net değildir. Bakteriyel veya viral pnömoni görüntüleri bazen uzmanlar tarafından yanlış sınıflandırılır, bu da hastalara yanlış ilaç verilmesine yol açar ve bu duruma bağlı olarak hastaların durumları kötüleşebilir (Davies ve diğ., 1996). Pulmoner ödem, kanama, akciğer kanseri gibi hastalıklar pnömoni teşhisini daha zor ve karmaşık hale getirir. Ayrıca radyologların pnömoni tanısı koyma kararlarında önemli derecede öznel tutarsızlıklar vardır. Bu nedenle, doktorların pnömoni teşhisi koymalarına yardımcı olmak için bilgisayar destekli tanı sistemlerine acil bir ihtiyaç vardır.

Günümüzde, beyin tümörü ve meme kanseri tespiti gibi birçok medikal alanda bilgisayar destekli çözümler kullanılmaktadır (Kallianos ve diğ., 2019). İstatistiksel analiz, makine öğrenimi ve derin öğrenme, bilgisayar destekli tanı sistemlerinde oldukça güçlü araçlardır ve tıbbi görüntüleme alanında yaygın olarak kullanılır. Bu araştırmanın amacı, göğüs röntgeni görüntüsünde en çok pnömoniyeye benzeyen alanları bilgisayar destekli tanı sistemleri ile vurgulayarak pnömoni teşhisini kolaylaştırmaktır.

Bu çalışmanın ana katkıları aşağıdaki gibidir:

- Pnömoni tespitinde derin öğrenmeye dayalı bir yöntem önerilmiştir.
- Pnömoni hastalığının derin özelliklerle sınıflandırılabilceği gösterilmiştir.
- Literatürdeki çalışmaların aksine daha önceden eğitilmiş derin öğrenme modelleri özellik çıkarıcı olarak kullanılmıştır.
- Önceden eğitilmiş derin mimarilerden elde edilen hibrit özellik vektörü sayesinde sınıflandırma başarımı arttırılmıştır.

Bu makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2’de literatürdeki çalışmalar gözden geçirilmiştir ve aralarındaki farklar ortaya koyulmuştur. Bölüm 3 ve 4’de materyal ve önerilen yöntem tanıtılmıştır. Bölüm 5’de çalışmada kullanılan veri seti ve pnömoni hastalarını tespit edilmesiyle ilgili deneysel uygulamalar verilmiştir. Bölüm 6’de ise araştırmanın bulguları tartışılmıştır.

İLGİLİ ÇALIŞMALAR (RELATED WORKS)

Göğüs röntgeni görüntülerini farklı sınıflara ayırma problemi tıbbi tanı alanında önemli ölçüde araştırılmıştır bu sorunu ele alan birçok araştırma makalesi yayınlanmıştır. Pnömoni hastalığının sınıflandırılması ile ilgili önemli çalışmalar bu bölümde verilecektir.

(Rajpurkar ve diğ., 2017), araştırmacılar, ChestXray14 veri setindeki göğüs röntgeni görüntülerini kullanarak pnömoniyi tespit etmek için derin bir ağ modelini eğitmişlerdir. 121 katmalı Evrişimsel sinir ağ (ESA) modeli kullanılarak sınıflandırma işlemi yapılmıştır. Pnömoniyi tespit etmenin yanı sıra, oluşturulan model sayesinde 14 başka hastalık tespit edilebilmektedir.

(Guan ve diğ., 2019), göğüs röntgeni görüntülerinden toraks hastalığını saptamak için bir ESA modeli yaklaşımı geliştirilmiştir. Bu araştırma ChestXray14 veri seti üzerinde yapılmıştır. Modellerinin performansını diğer modellerle karşılaştırılmıştır. Yazarların yaklaşımları daha iyi performans göstermiştir.

(Rubin ve diğ., 2018), MIMIC-CXR veri setini kullanarak göğüs röntgeni ön ve yan görüntülerinin büyük ölçekli otomatik olarak tanınmasını sağlayan ikili bir ESA sunulmuştur. Bu model, toraks hastalığını tespit etmek için kullanılmıştır. Veri artırma ve piksel normalleştirme tekniklerini kullanarak modellerinin performansını arttırmayı amaçlamışlardır. Verilerin %70’i eğitim, %20’si test ve %10’u doğrulama için kullanılmıştır. Genel olarak %72,1 doğruluk elde edilmiştir.

(Anthimopoulos ve diğ., 2016), akciğer hastalığı paternlerini tanımlamak için bir ESA modeli sunmuşlardır. Önerilen model, ReLu aktivasyon fonksiyonu, ortalama havuzlama katmanları, üç tamamen bağlı katman ve 5 evrimsel katmanından oluşur. Veri setinde yedi sınıf ve 14696 görüntü bulunur. Modelden %85,5 doğruluk elde edilmiştir.

(Jain ve diğ., 2020), röntgen görüntüleri kullanarak pnömoniye tespit etmek için ESA modelleri kullanılmıştır. Çeşitli hiperparametreler ve evrimsel katmanların sayısını değiştirerek, x-ışını görüntülerini pnömoni ve pnömoni olmayan iki sınıfta sınıflandırmak için çeşitli ESA modelleri eğitilmiştir. Araştırmada altı tane modelden bahsedilmiştir ve %92,31 doğruluk elde edilmiştir.

(Sirazitdinov ve diğ., 2019), göğüs röntgeni görüntülerinde pnömoninin otomatik tespiti ve lokalizasyonu için makine öğrenmesi uygulaması geliştirilmiştir. Pnömoni tespiti ve lokalizasyonu için iki adet ESA mimarisi önerilmiştir. Veri seti Kaggle'dan alınmıştır ve 26684 kayıt vardır. %79,30 duyarlılık değeri ile otomatik pnömoni teşhisi için güvenilir bir çözüm geliştirilmiştir.

(Rahman ve diğ., 2020), dijital röntgen görüntülerini kullanarak bakteriyel ve viral pnömoniye otomatik olarak tespit etmek amaçlanmıştır. Pnömoninin doğru tespitinde yapılan ilerlemeler hakkında ayrıntılı bilgiler sunulmuştur ve daha sonra yazarlar tarafından benimsenen metodolojiye yer verilmiştir. Transfer eğitimi için dört farklı önceden eğitilmiş ESA modeli kullanılmıştır. Bu modeller, AlexNet, ResNet18, DenseNet201 ve SqueezeNet'dir. Veriler ön işlemden geçirildikten sonra transfer öğrenme işlemi uygulanarak sınıflandırma yapılmıştır. Deneysel sonuçlardan %98 doğruluk elde edilmiştir.

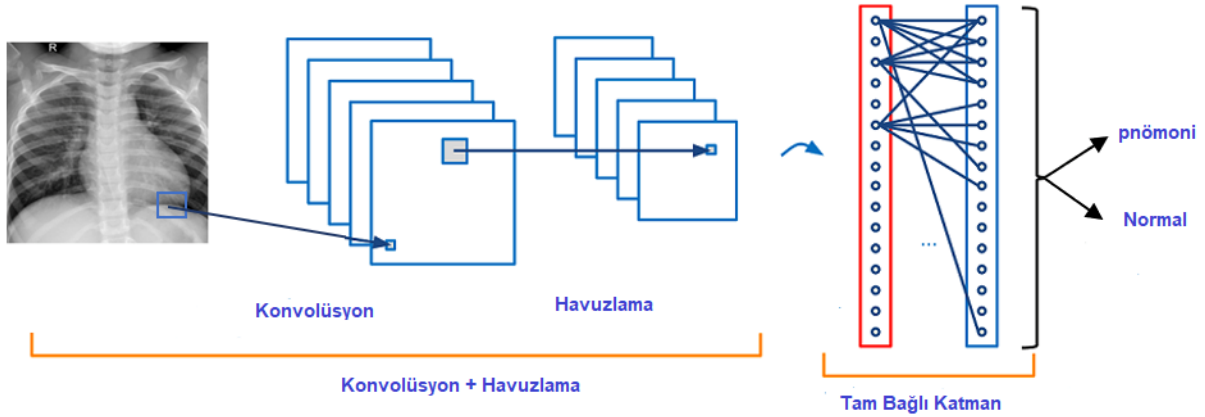
(Stephen ve diğ., 2019), göğüs röntgeni görüntü örnekleri koleksiyonundan pnömoni varlığını sınıflandırmak ve tespit etmek için sıfırdan eğitilmiş ESA modeli önermektedir. Dikkat çekici bir sınıflandırma performansı elde etmek için sıfırdan eğitilmiş bir ESA modeli tasarlanmıştır. ESA modelinin sınıflandırma doğruluğunu geliştirmek için birkaç veri artırma algoritması uygulanmıştır.

(Kumar Acharya & Satapathy, 2020), derin Siyam temelli sinir ağını kullanarak göğüs radyografisi görüntüsünden pnömoninin otomatik olarak saptanması önerilmektedir. Viral ve bakteriyel pnömoni enfeksiyonları, göğüs röntgeni görüntüsünün iki segmentine yayılmış beyaz madde miktarı analiz edilerek ayırt edilir. Derin Siyam ağı, problemi hesaplamak veya sınıflandırmak için iki giriş görüntüsünün simetrik yapısını kullanır. Kaggle veri kümesi, modeli eğitmek ve doğrulamak için kullanılmıştır.

(Varshni ve diğ., 2019), özellik çıkarıcılar olarak önceden eğitilmiş ESA modelleri tercih edilmiştir. Anormal ve normal göğüs röntgenlerinin sınıflandırılması için farklı makine öğrenmesi algoritmaları kullanılmıştır. Çalışmadaki amaç için en uygun ESA modelini analitik olarak belirlemektir.

EVRIŞİMSEL SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORKS)

ESA'lar görüntü sınıflandırmasındaki gelişmiş performansları nedeniyle oldukça popülerdir. Ağdaki evrişim katmanındaki filtreler, görüntüdeki uzaysal ve zamansal özelliklerin çıkarılmasına yardımcı olur. Bir KSA modeli genel olarak üç yapı taşından oluşur. İlk olarak özelliklerin öğrenilmesi için evrimsel katmanı yer alır. İkinci olarak, görüntüyü yeniden örnekleme, boyutu azaltmak ve hesaplama maliyetini düşürmek için havuzlama katmanı bulunur. Son olarak ise sınıflandırma özelliğine sahip tam bağlı katmanlar bulunur. Tam bağlı katmanda bulunan nöronlar bir önceki katmandaki nöronlara tam bağlı şekildedir (Er & Aydılek, 2019). ESA'nın mimari görünümü Şekil 1'de verilmiştir.



Şekil 1. ESA Mimarisinin Genel Görünümü

Figure 1. General View of CNN Architecture

ÖNERİLEN YÖNTEM (PROPOSED METHOD)


Pnömoni tespiti için önerilen yöntem üç adımdan oluşmaktadır. İlk olarak röntgen görüntüleri ön işlemden geçirilerek yeniden boyutlandırılmıştır. Daha sonra eğitim kümesindeki veri sayısını arttırmak için veri artırma işlemi uygulanmıştır ve röntgen görüntüleri önceden eğitilmiş ESA modellerinde girdi olarak verilmiştir. Önceden eğitilmiş derin öğrenme modeli olarak AlexNet VGG16, ResNet18, ResNet50 ve ResNet101 özellik çıkarıcı olarak kullanılmıştır. Son olarak DVM ve Softmax sınıflandırıcılar kullanılarak röntgen görüntüleri sınıflandırılmıştır. Her adımın detayı aşağıdaki alt bölümlerde açıklanmıştır. Önerilen yöntem şekil 3’de verilmiştir.

Ön İşleme (Pre-Processing)

Farklı derin öğrenme modelleri için görüntü girişi farklı olduğundan X-Ray görüntülerini yeniden boyutlandırılmıştır. AlexNet için görüntüler 227×227 piksele, VGG16, ResNet18, ResNet50 ve ResNet101 için ise görüntüler 224×224 piksele ayarlanmıştır.

Veri Arttırma (Data Augment)

ESA mimarileri büyük veri setleri ile daha iyi performans gösterirler. Derin öğrenme modellerinin performansı yeni veri toplamak yerine mevcut verileri artırarak geliştirilebilir. Çalışmamızdaki veri setinin boyutu çok büyük olmadığı için veri artırma işlemi uygulanmıştır. Veri büyütme tekniklerini kullanarak nispeten daha küçük veri kümesi büyük bir veri tabanına dönüştürülür ve derin öğrenme algoritmaları bu veri setleri ile eğitilir. Veri çoğaltmadaki temel ilke, mevcut verilere bazı deformasyon işlemi uygulayarak ek eğitim verileri oluşturulmasıdır (Salamon & Bello, 2017). Görüntüyü farklı açılarda döndürmek, yatay olarak dikey döndürmek, görüntüye gürültü ve renk manipülasyonu eklemek gibi birçok veri artırma tekniği vardır. Bu çalışmada veri artırma için 3 farklı teknik uygulanmıştır. Bunlar, rastgele döndürme, Gauss filtresi ve tuz ve biber gürültüsü şeklindedir. Orijinal görüntülerin kenarlarında siyah alanlar olduğu için döndürme işleminden sonra oluşan siyah alanlar üzerinde herhangi bir işlem yapılmamıştır. Orijinal röntgen görüntüsü ve veri artırma tekniklerinin uygulandığı görüntüler şekil 2’de verilmiştir.




Şekil 2: (a) Orijinal Göğüs Röntgeni görüntüsü (b), Döndürmeden Sonrası Göğüs Röntgeni görüntüsü (c), Gauss filtresi Sonrası Göğüs Röntgeni görüntüsü (d) Tuz ve biber filtresi Sonrası Göğüs Röntgeni görüntüsü

Figure 2: (a) Original Chest X-ray image (b), Chest X-ray image after Rotation (c), Chest X-ray image after Gaussian filter (d) Chest X-ray image after salt and pepper filter

Önceden Eğitilmiş Evrişimsel Sinir Ağlarından Özellik Çıkarma (Extracting Features From Pre-Trained Convolution Neural Networks)

Bu çalışmada, iyi bilinen beş tane önceden eğitilmiş derin öğrenme modelleri pnömoni tespiti için kullanılmıştır. AlexNet modeli, ImageNet veri tabanında bulunan yaklaşık 1.2 milyon görüntü kullanılarak eğitilmiştir (Russakovsky ve diğ., 2014). Önceden eğitilmiş AlexNet modeli genelde olarak 5 evrişimsel ve 3 tam bağlı katmandan oluşur. Önceden eğitilmiş VGG16 mimarisi, ILSVRC 2014 yarışmasında Simonyan ve Zisserman tarafından geliştirilmiştir. Temel olarak 13 evrişimsel, 3 tam bağlı katmanından oluşan bir modeldir. Mimaride havuzlama, tam bağlı, ReLu, Dropout ve Softmax katmanlarıyla birlikte toplamda 41 katman yer almaktadır. Girdi katmanında yer alacak görüntü 224x224x3 boyutundadır. Son katman ise sınıflandırma katmanıdır. Boyut azaltmak için AlexNet'e benzer şekilde evrişimsel katmanlarından bazılarını havuzlama katmanı izler (Zisserman, 2014). ResNet birçok varyasyonları vardır ve yaygın olarak kullanılan ResNets18, ResNet50 ve ResNet101'dir. ResNet 2015 yılında düzenlenen ILSVRC yarışmasında %3,37 ile en düşük hata oranını sağlayarak birinci olmuştur. Bu çalışmada, önceden eğitilmiş ResNets (ResNet18, ResNet50, ResNet101) modelleri kullanılmıştır. Bu ağlar sırasıyla 18 (72 alt katman), 50 (177 alt katman) ve 101 (347 alt katman) katmanına sahiptir.

Temel olarak, AlexNet, VGG16 ve ResNet özellik çıkarıcı katmanlar olarak kullanılabilen evrişimsel ve tam bağlantılı katmanlara sahiptir. AlexNet ve VGG16 mimarilerinin fc7 katmanı 4094 nörona sahiptir ve bu katman özellik çıkarıcı katman olarak seçilmiştir. ResNets18, ResNet50 ve ResNet101 ağların hepsinde ise fc1000 (1000 nöron) katmanı bulunur ve bu katman özellik çıkarıcı katman olarak kullanılmıştır. Son olarak her modelden çıkarılan birleştirilerek hibrit özellik vektörü elde edilmiştir.



Şekil 3. Önerilen Yöntem
Figure 3. Proposed Method

Sınıflandırma İşlemi (Classification)

Öncede eğitilmiş modellerinin fc7 ve fc1000 katmanından derin özellikler çıkarılmıştır ve bu derin özellikler sınıflandırıcıları eğitmek için kullanılmıştır. Önceden eğitilmiş derin modelinin sınıflandırma katmanında genellikle Softmax kullanılır. Bu çalışmada sınıflandırma için Softmax ve doğrusal DVM kullanıldı. Softmax formülü 1’de verilmiştir. Softmax, nöronlardaki çıkış verilerini 0 ve 1 aralığına getirir. Burada N toplam örnek sayısı, x_i ise i’nci ağırlıklı giriş örneğidir.

$$\text{softmax}(x)_j = \frac{e^{x_j}}{\sum_{n=1}^N e^{x_n}} \quad \text{for } j=1, \dots, N \quad (1)$$

DVM algoritmasının amacı, N-boyutlu bir alanda veri noktalarını ayrı ayrı sınıflandıran bir hiper düzlem bulmaktır. İki veri noktası sınıfını ayırmak için seçilebilecek birçok olası hiper düzlem vardır. Hedef her iki sınıfın veri noktaları arasındaki maksimum mesafeyi bulmaktır (Kabir ve diğ., 2016). Marj mesafesini en üst düzeye çıkarmak, gelecekteki veri noktalarının daha doğru bir şekilde sınıflandırılabilmesini sağlayacaktır.

$\{x_i, i = 1, \dots, n\}$ giriş vektörü $y_i \{-1, 1\}$ iki sınıftan birine aittir, hiper düzlem şu şekilde tanımlanır:

$$w_0 \cdot x + b_0 = 0 \quad (2)$$

Burada w ağırlık vektörüdür, x giriş vektörüdür, b bir bias dır. Belirli bir w ve b için, veriler aşağıdaki durumlarda doğrusal olarak ayrılabilir:

$$w \cdot x_i + b \geq 1 \quad \text{if } y_i = 1 \quad (3)$$

$$w \cdot x_i + b \leq -1 \quad \text{if } y_i = -1 \quad (4)$$

DENEYSEL UYGULAMALAR (EXPERIMENTAL APPLICATIONS)

Veri Seti (Data Set)

Bu çalışmada çözünürlüğü 400p ile 2000p arasında değişen 5856 göğüs röntgeni görüntüsünden oluşan kaggle veri seti kullanılmıştır (Mooney, 2020). 5856 göğüs röntgeni görüntülerinden 1583'ü normal, 4273'ü ise pnömoni olarak etiketlenmiştir. Veri setinin %70'i eğitim, %30'u ise test için kullanılmıştır. Ayrıca veri arttırma işlemi sonucu veri setinin boyutu dört katına çıkarılmıştır. Veri arttırma öncesi ve sonrası farklı sınıflardaki veri sayıları Çizelge 1'de verilmiştir.

Çizelge 1. Veri Arttırma Öncesi ve Sonrası Veri Sayısı

Table 1. Number of Data Before and After Data Augment

Veri	Veri Arttırma Öncesi		Veri Arttırma Sonrası	
	Test	Eğitim	Test	Eğitim
Normal	475	1108	1900	4432
Pnömoni	1282	2991	5128	11964

DeneySEL Sonuçlar (Experimental Results)

Önerilen yöntemin başarımlı kriterleri doğruluk, kesinlik ve F-skoru oranlarına dayalı olarak yapılmıştır.

- Yanlış pozitifler (YP): negatif sınıftan olan, pozitif olarak tahmin edilen örnekler.
- Yanlış negatifler (YN): gerçek sınıfı pozitif olan negatif olarak tahmin edilen örnekler.
- Doğru pozitifler (DP): pozitif sınıfa ait doğru tahmin edilen örnekler.
- Doğru negatifler (DN): negatif sınıfa ait olarak doğru tahmin edilen örnekler.
- Doğruluk = $\frac{|DN|+|DP|}{|YN|+|YP|+|DN|+|DP|}$ (5)

Kesinlik (P), pozitif bir tahminin doğru olma olasılığını tahmin eden bir ölçüdür. Kesinlik ölçümü denklem 6'de verilmiştir.

$$\text{Kesinlik}(P) = \frac{|DP|}{|DP|+|YP|} \quad (6)$$


F-skoru, pozitif kestirim oranı ve duyarlılık ölçülerinin uyumlu bir ortalaması olup denklem 7'de gösterildiği gibi hesaplanır.

$$F - \text{skor} = \frac{2*|DP|}{2*|DP|+|YP|+|YN|} \quad (7)$$

Veri setlerinden rastgele seçilen verilerin bir kısmı eğitim için bir kısmı da test için kullanılmıştır. Veriler 5 kat çapraz doğrulama tekniği kullanılarak test ve eğitim için ayrılmıştır. Çizelge 2'de veri arttırma işleminin uygulanmasından önce elde edilen sınıflandırma sonuçları verilmiştir. Veri arttırma öncesi en yüksek doğruluk %97,81 olarak AlexNet (fc7)&VGG16 (fc7)& ResNet18 (fc1000)& ResNet50 (fc1000)& ResNet101 (fc1000) hibrit özellik vektörü ve DVM sınıflandırıcı ile elde edilmiştir. Veri arttırma öncesi her modelden elde edilen sonuçların karşılaştırması şekil 4'de verilmiştir. Çizelge 3'de veri arttırma işleminin uygulanmasından sonra elde edilen sınıflandırma sonuçları verilmiştir. Veri arttırma sonrası en yüksek doğruluk %98,32 olarak AlexNet (fc7)&VGG16 (fc7)& ResNet18 (fc1000)& ResNet50 (fc1000)& ResNet101 (fc1000) hibrit özellik vektörü ve DVM sınıflandırıcı ile elde edilmiştir. Beklenildiği gibi veri arttırma sonrası sınıflandırma başarımlı artmıştır. Veri arttırma öncesi her modelden elde edilen sonuçların karşılaştırması şekil 5'de verilmiştir. Veri arttırma öncesi ve sonrası en iyi sınıflandırma sonuçlarına ait karışıklık matrisleri şekil 6'de verilmiştir.


Çizelge 2. Veri Artırma Öncesi Sınıflandırma Sonuçları*Table 2. Classification Results Before Data Augment*

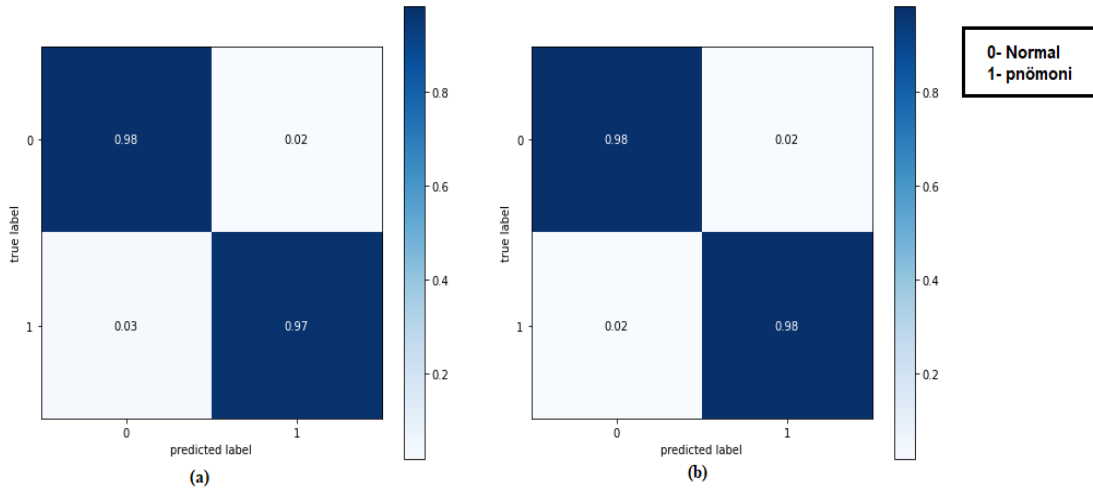
Model	Sınıflandırıcı	Doğruluk %	Kesinlik %	F Skoru %
AlexNet (fc7)	Softmax	94,08	96,02	95,94
VGG16 (fc7)	Softmax	95,06	96,35	96,61
ResNet18 (fc1000)	Softmax	95,42	96,96	96,89
ResNet50 (fc1000)	Softmax	95,45	97,58	96,90
ResNet101 (fc1000)	Softmax	95,79	98,36	97,15
AlexNet (fc7)	DVM	93,74	95,71	95,71
VGG16 (fc7)	DVM	94,78	96,11	96,41
ResNet18 (fc1000)	DVM	95,48	97,11	96,93
ResNet50 (fc1000)	DVM	95,16	97,19	96,70
ResNet101 (fc1000)	DVM	96,30	98,75	97,50
AlexNet (fc7)&VGG16 (fc7)	Softmax	95,27	97,42	96,48
VGG16 (fc7)&ResNet18 (fc1000)	Softmax	96,27	96,63	96,57
ResNet18 (fc1000)& ResNet50 (fc1000)	Softmax	96,57	97,68	97,83
ResNet50 (fc1000)&ResNet101(fc1000)	Softmax	95,48	96,39	97,35
AlexNet (fc7)&VGG16 (fc7)& ResNet18 (fc1000)& ResNet50 (fc1000)& ResNet101 (fc1000)	Softmax	97,75	97,37	96,72
AlexNet (fc7)&VGG16 (fc7)	DVM	94,32	96,23	96,57
VGG16 (fc7)&ResNet18 (fc1000)	DVM	95,67	97,34	97,67
ResNet18 (fc1000)& ResNet50 (fc1000)	DVM	96,46	97,32	97,73
ResNet50 (fc1000)&ResNet101(fc1000)	DVM	96,18	97,43	97,50
AlexNet (fc7)&VGG16 (fc7)& ResNet18 (fc1000)& ResNet50 (fc1000)& ResNet101 (fc1000)	DVM	97,81	98,83	97,96

**Şekil 4. Veri Artırma Öncesi Performans Karşılaştırması***Figure 4. Performance Comparison Before Data Augmentation*

Çizelge 3. Veri Artırma Sonrası Sınıflandırma Sonuçları*Table 3. Classification Results After Data Augment*

Model	Sınıflandırıcı	Doğruluk %	Kesinlik %	F Skoru %
AlexNet (fc7)	Softmax	95,84	91,67	92,62
VGG16 (fc7)	Softmax	96,23	92,65	93,33
ResNet18 (fc1000)	Softmax	96,57	93,82	93,96
ResNet50 (fc1000)	Softmax	97,65	94,85	95,77
ResNet101 (fc1000)	Softmax	97,82	94,67	96,07
AlexNet (fc7)	DVM	95,98	92,16	92,89
VGG16 (fc7)	DVM	96,51	93,92	93,86
ResNet18 (fc1000)	DVM	96,60	93,82	94,01
ResNet50 (fc1000)	DVM	97,37	94,66	95,23
ResNet101 (fc1000)	DVM	97,89	96,87	96,19
AlexNet (fc7)& VGG16 (fc7)	Softmax	96,35	92,46	93,47
VGG16 (fc7)& ResNet18 (fc1000)	Softmax	97,67	95,56	95,57
ResNet18 (fc1000)& ResNet50 (fc1000)	Softmax	97,77	95,67	95,36
ResNet50 (fc1000)& ResNet101(fc1000)	Softmax	97,21	95,78	96,51
AlexNet (fc7)& VGG16 (fc7)& ResNet18 (fc1000)& ResNet50 (fc1000)& ResNet101 (fc1000)	Softmax	98,11	97,46	96,46
AlexNet (fc7)& VGG16 (fc7)	DVM	96,34	94,45	93,45
VGG16 (fc7)& ResNet18 (fc1000)	DVM	96,57	94,36	94,56
ResNet18 (fc1000)& ResNet50 (fc1000)	DVM	96,45	94,82	95,22
ResNet50 (fc1000)& ResNet101(fc1000)	DVM	97,56	96,47	96,75
AlexNet (fc7)& VGG16 (fc7)& ResNet18 (fc1000)& ResNet50 (fc1000)& ResNet101 (fc1000)	DVM	98,32	97,48	97,62

**Şekil 5.** Veri Artırma Sonrası Performans Karşılaştırması*Figure 5. Performance Comparison After Data Augmentation*



Şekil 6: Karışıklık matrisleri (a) Veri Arttırma Öncesi (b) Veri Arttırma Sonrası

Figure 6: Confusion matrices (a) Before Data Augment (b) After Data Augment

Performans değerlendirmesi için elde ettiğimiz bulgularla literatürde kullanılan diğer yöntemlerden elde edilen sonuçlar karşılaştırılmıştır. Çizelge 4’de önemli bazı çalışmalar verilmiştir.

Çizelge 4. Kaggle Göğüs Röntgeni Pnömoni Veri seti için Performans Karşılaştırılması

Table 4. Performance Comparison for Kaggle chest X-ray Pneumonia Dataset

Yöntem	Model	Verilerin Test ve Eğitim için Bölünme Yöntemi	Doğruluk %
(Rajaraman ve diğ., 2018)	VGG16	-	96,20
(Jakhar & Hooda, 2018)	KSA	5 kat çapraz doğrulama	84,00
(Rahman ve diğ., 2020)	DenseNet201	5 kat çapraz doğrulama	98,00
(Saraiva ve diğ., 2019)	Yapay Sinir Ağı	5 kat çapraz doğrulama	94,40
Önerilen Yöntem (Veri Arttırmadan Öncesi)	AlexNet&VGG16& ResNet18& ResNet50& ResNet101	5 kat çapraz doğrulama	97,81
Önerilen Yöntem (Veri Arttırma Sonrası)	AlexNet&VGG16& ResNet18& ResNet50& ResNet101	5 kat çapraz doğrulama	98,32

Çizelge 4’de görüldüğü gibi önerilen yöntem, literatürde kullanılan diğer yöntemlerden daha iyi bir performansa göstermiştir.

SONUÇLAR (RESULTS)

Ölümcül olabilen pnömoni hastalığı nedeniyle her yıl ölen milyonlarca çocuk vardır. Hastalığın doğru teşhisi ve uygun tedavi planı ile zamanında müdahale etmek önemli sayıda hayat kurtarabilir. Bu çalışma, pnömoni tespiti için derin ESA tabanlı bir yaklaşım sunulmaktadır. Beş farklı popüler ESA derin öğrenme algoritması ve göğüs röntgeni görüntüleri kullanılarak normal ve zatürree hastalarının sınıflandırılması yapılmıştır. Kullanılan ESA mimarileri AlexNet, VGG16, ResNet18, ResNet50 ve ResNet101’ dir. Bu modellerden elde edilen özellikler hem kendi içinde hem de birleştirilerek deneyler yapılmıştır. Yöntemin performansını değerlendirmek için kaggle veri seti kullanılmıştır. Sınıflandırma başarımını arttırmak için veri arttırma işlemi uygulanarak veri seti dört katına çıkarılmıştır ve sınıflandırıcı olarak ise DVM ve Softmax kullanılmıştır. Hibrit özellik vektörü ise %98,32 genel doğruluk elde edilmiştir. Modellerin genel performansı, daha büyük veri kümeleri kullanılarak iyileştirilebilir. Gelecekteki çalışmalarda sınıflandırma performansının iyileştirilmesi amaçlanmaktadır.

KAYNAKLAR (REFERENCES)

- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, 35(5), 1207–1216. <https://doi.org/10.1109/tmi.2016.2535865>
- Aydoğdu, M., Ozyilmaz, E., Aksoy, H., Gürsel, G., & Ekim, N. (2010). Mortality prediction in community-acquired pneumonia requiring mechanical ventilation; values of pneumonia and intensive care unit severity scores. *Tüberküloz ve Toraks*, 58, 25–34.
- Davies, H. D., Wang, E. E., Manson, D., Babyn, P., & Shuckett, B. (1996). Reliability of the chest radiograph in the diagnosis of lower respiratory infections in young children. *The Pediatric Infectious Disease Journal*, 15(7), 600–604. <https://doi.org/10.1097/00006454-199607000-00008>
- Er, M. B., & Aydilek, I. B. (2019). Music Emotion Recognition by Using Chroma Spectrogram and Deep Visual Features. *International Journal of Computational Intelligence Systems*, 12(2), 1622–1634. <https://doi.org/https://doi.org/10.2991/ijcis.d.191216.001>
- Guan, Q., Huang, Y., Zhong, Z., Zheng, Z., Zheng, L., & Yang, Y. (2019). Thorax Disease Classification with Attention Guided Convolutional Neural Network. *Pattern Recognition Letters*, 131. <https://doi.org/10.1016/j.patrec.2019.11.040>
- Jain, R., Nagrath, P., Kataria, G., Sirish Kaushik, V., & Jude Hemanth, D. (2020). Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, 165, 108046. <https://doi.org/10.1016/j.measurement.2020.108046>
- Jakhar, K., & Hooda, N. (2018). Big Data Deep Learning Framework using Keras: A Case Study of Pneumonia Prediction. In 2018 4th International Conference on Computing Communication and Automation (ICCCA). IEEE. <https://doi.org/10.1109/ccaa.2018.8777571>
- Kabir, E., Siuly, & Zhang, Y. (2016). Epileptic seizure detection from EEG signals using logistic model trees. *Brain Informatics*, 3(2), 93–100. <https://doi.org/10.1007/s40708-015-0030-2>
- Kallianos, K., Mongan, J., Antani, S., Henry, T., Taylor, A., Abuya, J., & Kohli, M. (2019). How far have we come? Artificial intelligence for chest radiograph interpretation. *Clinical Radiology*, 74(5), 338–345. <https://doi.org/10.1016/j.crad.2018.12.015>
- Kumar Acharya, A., & Satapathy, R. (2020). A Deep Learning Based Approach towards the Automatic Diagnosis of Pneumonia from Chest Radio-Graphs. *Biomedical and Pharmacology Journal*, 13(1), 449–455. <https://doi.org/10.13005/bpj/1905>
- Mooney, P. (2020). Chest X-Ray Images (Pneumonia). <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>
- 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>
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G., & Antani, S. (2018). Visualization and Interpretation of Convolutional Neural Network Predictions in Detecting Pneumonia in Pediatric Chest Radiographs. *Applied Sciences*, 8, 1715. <https://doi.org/10.3390/app8101715>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., Shpanskaya, K., Lungren, M., & Ng, A. (2017). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning.
- Rubin, J., Sanghavi, D., Zhao, C., Lee, K., Qadir, A., & Xu-Wilson, M. (2018). Large Scale Automated Reading of Frontal and Lateral Chest X-Rays using Dual Convolutional Neural Networks.
- Rudan, I., Tomaskovic, L., Boschi-Pinto, C., & Campbell, H. (2004). Global estimate of the incidence of clinical pneumonia among children under five years of age. *Bulletin of the World Health Organization*, 82(12), 895–903.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A., & Li, F. F. (2014). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115. <https://doi.org/10.1007/s11263-015-0816-y>

- Salamon, J., & Bello, J. P. (2017). Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification. *IEEE Signal Processing Letters*, 24(3), 279–283. <https://doi.org/10.1109/LSP.2017.2657381>
- Saraiva, A., Santos, D., Costa, N., Sousa, J., Ferreira, N., Valente, A., & Soares, S. (2019). Models of Learning to Classify X-ray Images for the Detection of Pneumonia using Neural Networks. In *Proceedings of the 12th International Joint Conference on Biomedical Engineering Systems and Technologies*. SCITEPRESS - Science and Technology Publications. <https://doi.org/10.5220/0007346600760083>
- Sirazitdinov, I., Kholiavchenko, M., Mustafaev, T., Yixuan, Y., Kuleev, R., & Ibragimov, B. (2019). Deep neural network ensemble for pneumonia localization from a large-scale chest x-ray database. *Computers & Electrical Engineering*, 78, 388–399. <https://doi.org/10.1016/j.compeleceng.2019.08.004>
- Stephen, O., Sain, M., Maduh, U. J., & Jeong, D.-U. (2019). An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare. *Journal of Healthcare Engineering*, 2019, 4180949. <https://doi.org/10.1155/2019/4180949>
- Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R., & Mittal, A. (2019). Pneumonia Detection Using CNN based Feature Extraction. In *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)*. IEEE. <https://doi.org/10.1109/icecct.2019.8869364>
- WHO. (2001). Standardization of interpretation of chest radiographs for the diagnosis of pneumonia in children.
- Zisserman, K. S. and A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. <https://arxiv.org/abs/1409.1556>