



**T.C.**  
**SELÇUK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**



**GÖĞÜS X-RAY GÖRÜNTÜLERİ**  
**KULLANILARAK PNÖMONİNİN TESPİTİ VE**  
**SINIFLANDIRILMASI**

**Husham Salah Al Deen Omar OMAR**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Ağustos -2019**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Husham Salah Al Deen Omar OMAR tarafından hazırlanan “Göğüs X-Ray Görüntüleri Kullanılarak Pnömoninin Tespiti ve Sınıflandırılması” adlı tez çalışması 26/08/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Dr. Öğr. Üyesi M. Akif ŞAHMAN


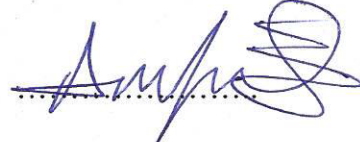
#### Danışman

Dr. Öğr. Üyesi Ahmet BABALIK

#### Üye

Doç. Dr. Mesut GÜNDÜZ

### İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Mustafa YILMAZ  
FBE MÜDÜRÜ

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Husham Salah Al Deen Omar OMAR

Tarih: 26/08/2019



## ÖZET

### YÜKSEK LİSANS TEZİ

## GÖĞÜS X-RAY GÖRÜNTÜLERİ KULLANILARAK PNÖMONİNİN TESPİTİ VE SINIFLANDIRILMASI

**Husham Salah Al Deen Omar OMAR**

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman: Dr. Öğr. Üyesi Ahmet BABALIK**

**2018, 49 Sayfa**

**Jüri**

**Dr. Öğr. Üyesi M. Akif ŞAHMAN**

**Dr. Öğr. Üyesi Ahmet BABALIK**

**Doç. Dr. Mesut GÜNDÜZ**

X-ray görüntüleme, akciğer hastalıklarının tespiti için önemli yöntemlerden birisidir. Göğüs bölgesinin röntgen görüntüleri uzman doktorlar tarafından değerlendirilmektedir. Ancak bu değerlendirme zaman alıcı bir süreçtir ve uzmanlık gerektirir. Bilgisayar destekli tanı (BDT) makine öğreniminde popüler araştırma konularından birisidir ve doktorlara tıbbi görüntülerin analizi için yardımcı olmaktadır. Tıbbi görüntülerin analiz sürecinde evrimsel sinir ağları (ESA) gibi derin öğrenme tekniklerinden bazıları kullanılmaktadır. Bu çalışmada Guangzhou'daki Guangzhou Kadın ve Çocuk Tıp Merkezi'nden alınan göğüs bölgesinin röntgen görüntüleri kullanılarak pnömoninin tespiti için ESA temelli bir BDT sistemi önerilmiştir. Veri seti 5.840 göğüs röntgeni görüntüsünü (ön-arka) içermektedir. Eğitim seti 5.216 görüntüden (1.341 normal, 3.875 pnömani) ve test seti 624 görüntüden (234 normal, 390 pnömani) oluşmaktadır. Çalışma kapsamında 5 katmanlı ESA, VGG-16 ve ResNet50 modelleri ele alınmıştır. ESA'lar eğitim aşamasında yüksek miktarda veriye ihtiyaç duyarlar. Veri azlığı durumunda veriler yapay olarak çoğaltılabilir. Veri çoğaltma işleminin sistem performansına etkisini incelemek amacıyla veri çoğaltma işlemi yapılmadan ve veri çoğaltma işlemi yapılarak 3 farklı ESA modelini başarıları incelenmiş ve literatürde yer alan bazı danışmanlı öğrenme algoritmalarının başarıları ile karşılaştırılmıştır.

**Anahtar Kelimeler:** Derin Öğrenme, Evrimsel Sinir Ağları, Medikal Görüntü İşleme.

## **ABSTRACT**

### **MS THESIS**

# **DIAGNOSIS AND CLASSIFICATION OF PNEUMONIA USING CHEST X-RAY IMAGES**

**Husham Salah Al Deen Omar OMAR**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
SELÇUK UNIVERSITY THE DEGREE OF MASTER OF SCIENCE IN  
COMPUTER ENGINEERING**

**Advisor: Assist. Prof. Dr. Ahmet BABALIK**

**2019, 49 Pages**

**Jury**

**Assist. Prof. Dr. M. Akif ŞAHMAN**

**Assist. Prof. Dr. Ahmet BABALIK**

**Assoc. Prof. Dr. Doç. Dr. Mesut GÜNDÜZ**

X-ray imaging is one of the important methods for the lung diseases detection. The images of the chest region are evaluated by specialist doctors. But this evaluation requires some time and specialized expertise. Computer Aided Diagnosis (CAD) is recent research topics in the machine learning and it assists doctors in the analysis of medical images. For the analysis of medical images methods of deep learning techniques such as convolutional neural networks (CNN) are used. In this study, a CAD system based on CNN was purposed for detection of pneumonia using chest X-ray images taken from the Guangzhou Women's and Children's Medical Center in Guangzhou. The dataset contains 5.840 chest X-ray images (anterior-posterior). The training set consists of 5.216 images (1.341 normal, 3.875 pneumonia) and the test set consist of 624 images (234 normal, 390 pneumonia). Within the scope of the study, 5-layer CNN, VGG-16 and ResNet50 models are discussed. CNN need a high amount of data during the training phase. In case of the lack of data, the data can be augmented. In order to examine the effect of data augmentation on the system performance, the successes of 3 different CNN models were examined and compared with the achievements of some of the supervised learning algorithms in the literature.

**Keywords:** Deep Learning, Convolutional Neural Networks, Medical Image Processing.

## ÖNSÖZ

Çalışma sırasında danışmanlığımı yürüten Dr. Öğr. Üyesi Ahmet BABALIK'a yardımları, kıymetli bilgi ve önerileri için teşekkürlerimi ve saygılarımı sunarım. Ayrıca tez boyunca değerli, yapıcı eleştirileri ve dostane tavsiyeleri için bütün hocalarıma ve arkadaşlarıma teşekkür ederim. Eğitim hayatımda en büyük destekçim olan ve her zaman yanımda hissettiğim rahmetli ağabeyim Haşim OMAR'a, maddi ve manevi desteklerinden dolayı kardeşim Safaa OMAR ve aileme sonsuz teşekkür ederim.

Husham Salah Al Deen Omar OMAR  
KONYA-2019

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iv</b>
<b>ABSTRACT.....</b>	<b>v</b>
<b>ÖNSÖZ .....</b>	<b>vi</b>
<b>İÇİNDEKİLER .....</b>	<b>vii</b>
<b>SİMGELER VE KISALTMALAR .....</b>	<b>ix</b>
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1. Pnömoni .....	2
1.2. Bilgisayar Destek Tanı (BDT).....	2
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>3</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>7</b>
3.1. Veri Seti ( <i>Chest X-Ray Images (Pneumonia)</i> ) .....	7
3.1.1 Ön İşleme ve Veri Çoğaltma .....	8
3.2. Yapay Sinir Ağları (YSA) .....	10
3.2.1. Aktivasyon Fonksiyonları .....	11
3.2.2. Hatanın geri yayılımı (Backpropagation) algoritması .....	15
3.3. Derin Öğrenme .....	17
3.4. Evrişimsel Sinir Ağları (ESA) .....	20
3.4.1. Evrişim Katmanı .....	21
3.4.2. Dolgu (Padding) İşlemi.....	23
3.4.3. Havuzlama Katmanı ( Pooling Layer ) .....	23
3.4.4. Tamamen Bağlı Katmanlar (Fully Connected Layers).....	25
3.4.5. Bırakma (Dropout) İşlemi.....	26
3.5. Transfer Öğrenmesi (Transfer Learning).....	27
3.5.1. VGG-16 Modeli .....	27
3.5.2. ResNet50 Modeli .....	28
3.6. Önerilen ESA Modeli .....	28

3.7. Kullanılan Yazılım ve Donanım .....	30
3.7.1. Kullanılan Yazılım.....	30
3.7.2. Kullanılan Donanım.....	30
3.8. Performans Ölçütleri.....	30
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>33</b>
4.1. Araştırma Sonuçları .....	33
4.1.1. 5 Katmanlı ESA Modeli Sonuçları .....	34
4.1.2. Resnet50 Modeli Sonuçları.....	36
4.1.3. VGG-16 Modeli Sonuçları.....	38
<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>41</b>
5.1. Sonuçlar .....	41
5.2. Öneriler .....	41
<b>KAYNAKLAR .....</b>	<b>43</b>
<b>ÖZGEÇMİŞ .....</b>	<b>49</b>

## SİMGELER VE KISALTMALAR

### Simgeler

$x$	: Girdiler
$w$	: Ağırlıklar
$b$	: Bias değeri
$\sigma$	: Aktivasyon fonksiyonu
$e$	: Hata değeri
$B$	: Beklenen çıktı
$\mathcal{C}$	: Ağın ürettiği çıktı değeri

### Kısaltmalar

2D	: 2 Boyutlu
3D	: 3 Boyutlu
AUC	: Area Under Curve
BT	: Bilgisayarlı Tomografi
BDT	: Bilgisayar Destekli Tanı
CAD	: Computer Aided Detection (Bilgisayar Destekli Tanı)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
CUDA	: Compute Unified Device Architecture
DBN	: Deep Belief Networks (Derin İnanç Ağları)
DSA	: Derin Sinir Ağı
DVM	: Destek Vektör Makinesi
ESA	: Evrimsel Sinir Ağı
FAST	: Features from Accelerated Segment Test
GPU	: Graphic Processing Unit (Grafik İşleme Ünitesi)
MNIST	: Modified National Institute of Standards and Technology
MRI	: Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
NIH	: National Institutes of Health

## 1. GİRİŞ

Halk arasında zatürre olarak isimlendirilen Pnömoni, dünya genelinde yaygın olan hastalıklardan birisidir. Kişiden kişiye bulaşma riski olan Pnömoni ölüme de neden olmaktadır. Doktorlar akciğer hastalıklarını hızlı ve kolay bir şekilde teşhis etmek için göğüs bölgesinden X-ray ışınları kullanılarak elde edilen röntgen görüntülerini sıklıkla kullanmaktadırlar. Bilgisayarlı tomografi (BT) veya manyetik rezonans görüntüleme (MRI) gibi görüntüleme teknikleride bu tür hastalıkları teşhis etmek için kullanılmaktadır, ancak röntgen görüntüleme daha ucuz ve hızlıdır (Antin ve ark., 2019). Son yıllarda gerçekleştirilen röntgen görüntüleme sayısı önemli ölçüde artmıştır ve bu görüntülerin değerlendirilmesi, onları manuel olarak kontrol eden uzmanların çok zamanını almaktadır.

Bilgisayar destekli tanı (BDT) makine öğrenmesi alanında popüler bir araştırma konusudur ve doktorlara tıbbi görüntülerin analizinde yardımcı olmaktadır. Günümüzde BDT radyoloji alanına hızla girmektedir. BDT sistemlerinin çıktısı, radyologların görüntü yorumlarına yardımcı olmak için "ikinci görüş" olarak kullanılır. BDT'de kullanılan makine öğrenmesi algoritmaları genellikle yapay sinir ağları (YSA) gibi araçların kullanılmasıyla görüntü işleme, görüntü özellik analizi ve veri sınıflandırmasını içeren birkaç adımdan oluşmaktadır (Suzuki ve Surgery, 2012).

Evrışimsel sinir ağları (ESA), son yıllarda kullanılan tipik bir makine öğrenme algoritmasıdır. ESA, bilgisayarlı görme uygulamalarında başarıyla kullanılan derin öğrenme ağlarından biridir. ESA'lar, yüksek boyutlu ham resimlerden özellikleri çıkarmak ve sınıflandırmak için kullanılmaktadır (Jia ve ark., 2014; LeCun ve ark., 2015; Shen ve ark., 2017). Bilgisayarlı görmede kullanılan en popüler ESA modelleri VGGNet (Simonyan ve Zisserman, 2014), AlexNet (Krizhevsky ve ark., 2012) , ResNet (He ve ark., 2016) olarak sıralanabilir.

Çalışma beş bölümden oluşmaktadır. Giriş bölümünde, pnömoni ve bilgisayar destekli tanı ile ilgili temel bilgiler sunulmuştur. Kaynak araştırması bölümünde, medikal görüntülerden özellik çıkarımı ve makine öğrenme tekniklerinin kullanıldığı bazı çalışmalar özetlenmiştir. Materyal ve yöntem bölümünde kullanılan veri kümesi, veri ön işleme ve ESA ile ilgili temel bilgiler sunulmuştur. Bir sonraki bölümde araştırma sonuçları verilmiş ve tartışılmıştır. Beşinci bölümde ise araştırma sonuçları ve öneriler sunulmuştur.

### **1.1. Pnömoni**

Pnömoni, bakteri ve hava ile taşınan virüslerin neden olduğu akciğer dokusu iltihabıdır. Pnömoni, genellikle insanların yoksulluk ile karşı karşıya kaldığı ve hava kirliliğinin fazla olduğu gelişmekte olan ülkelerde çok fazla görülmektedir. Dünya Sağlık Örgütü, her yıl 4 milyondan fazla gerçekleşen erken ölümün, zatürre de dahil olmak üzere hava kirliliğine bağlı hastalıklardan kaynaklandığını tahmin etmektedir. Yıllık bazda özellikle 5 yaşından küçük çocuklar olmak üzere 150 milyondan fazla insan zatürreye yakalanmaktadır (Stephen ve ark., 2019). Zatürre çocuk ölümlerinin önde gelen nedenlerinden biridir. Her yıl 2 milyon çocuk bu hastalıktan ölmektedir ve bu oran tüm çocuk ölümlerinin yaklaşık %18'idir (Rajaraman ve ark., 2018). Geri kalmış ülkelerde tıbbi kaynak ve personel yetersizliğinden dolayı sorun daha da kötüleşebilmektedir. Örneğin; Afrika'nın 57 ülusunda 2,3 milyon doktor ve hemşireden oluşan bir boşluk bulunmaktadır (Rajpurkar ve ark., 2017; Stephen ve ark., 2019). Doğru ve hızlı tanı bu topluluklar için çok önemlidir. Hem gelişmiş ülkeler hem de gelişmekte olan ve yoksul ülkeler için tedaviye zamanında erişebilmek ve paradan tasarruf edebilmek çok önemlidir. Zatürre, Türkiye'de ölüme neden olan hastalıklar arasında 5. sırada gelmektedir. Her 10 kişiden biri bu hastalığa yakalanmaktadır. Türkiye'de her yıl 90 bin kişi bu hastalığa yakalanmakta ve 3 binden fazla insan bu sebeple hayatını kaybetmektedir. Ölümler en fazla bebeklerde ve 1 ile 5 yaş arasındaki çocuklarda görülür. Pnömoninin nedenlerinden biri, mikropların ağızdan veya sindirim kanalından akciğere girmesidir. İnsanlar, kapalı alanlarda, okullarda ve özellikle kalabalık yerlerde bu hastalığa karşı savunmasızdırlar (Keskinel, 2015).

### **1.2. Bilgisayar Destek Tanı (BDT)**

BDT, yapay zeka ve bilgisayarlı görme unsurlarını, radyolojik ve patolojik görüntü işleme ile birleştiren disiplinlerarası bir alandır. BDT, doktorlara tıbbi görüntülerin yorumlanmasında yardımcı olan sistemlerdir. BDT sistemleri X-ray, MRI, ultrason vb. görüntüleme teknikleri ile elde edilen görüntülerin değerlendirilmesinde radyolog veya doktorlara bu görüntülerin kısa sürede ve kapsamlı bir şekilde analiz etmeleri ve değerlendirmelerinde yardımcı olur. BDT sistemleri, dijital görüntüleri işler ve olası hastalıklar için uzmanlar tarafından alınacak kararları destekleyici bilgiler sunar (Laak, 2017).

## 2. KAYNAK ARAŞTIRMASI

Brown ve ark. (1998), göğüs bölgesi resimlerindeki akciğer sınırlarının analizini ve bölümlendirmesini yapan bilgi tabanlı bir yaklaşım geliştirmişlerdir. Görselin kenarları bir anatomik modelin akciğer sınırları ile parametrik özellikler kullanılarak eşleştirilmiştir. Model, görüntü işleme şablonları, bir arayüz ve bir karakutu barındıran modüler sistem mimarisinden oluşmaktadır. Kenarlar, akciğer sınırları ile bağdaştırılmış ve otomatik tanımlama ile birlikte anormal özellikler raporlanmıştır. 18 tespit edilebilir anormalite seti için verilen 14 görsellik ön testte, sistem, deneyimli bir radyoloğa göre %88 oranında hassasiyet ve %95 oranında doğruluk başarısı göstermiştir.

Park ve ark. (2004), göğüs röntgenlerinde anormal dokuların saptanması ve kaburgaları tespit etmek için Gabor benzeri filtre kullanarak göğüs röntgeninden genel görüntü kazanma algoritması sunmuşlardır. Akciğer bölgesi, ciğer bölgesi çıkarma metodu ve kaburga bölgesinden gelen bilgileri kullanılarak işlenecek bölgenin sınırlanması için çıkarılmış ve ciğer desenine odaklanılmıştır.

Karagyris ve ark. (2011), sağlık kurumlarında akciğer hastalıkları için (pnömoni, verem vb.) bir görüntüleme sisteminin geliştirilmesini amaçlamışlardır. Bu amaçla ilk olarak, göğüs röntgenlerinde akciğerler ve kaburgaların tespitte yeni bir yaklaşım sunmuşlardır. Bu yaklaşımda iki farklı tespit şemasını birleştirerek, özellikle piksel ile kontrol tekniği yerine bölgesel çalışan ve anatomik yapının yönelimini göz önünde bulunduran wavelet (dalgacık) özellikleri hesaplanmıştır. Sonraki adımda, verem enfeksiyonunu düşündüren radyografik modeller için kaburga dışı akciğer bölgelerini sınıflandırmışlardır.

Bourcier ve ark. (2014), akut zatürre hastalarında ultrason görüntüsünü değerlendirmek amacıyla, Ocak 2010 ve Haziran 2012 yılları arasında genel bir hastanenin acil biriminde 144 yetişkin hastanın analizini gerçekleştirmişlerdir. Ultrason muayenesi 5 acil servis hekiminden birisi ile ve bir radyolog tarafından kontrol edilen akciğer röntgeni ile yapılmıştır. Yapılan değerlendirme sonucunda röntgen görüntüleri kullanılan değerlendirmede hassasiyet oranı %60, ultrason muayenesinde ise hassasiyet oranı %95 olduğu gözlenmiştir. Elde edilen sonuçlar, zatürrenin ilk tanısında torasik ultrasonun kullanılmasını teşvik edecek şekildedir.

Bar ve ark. (2015), göğüs röntgeni verisiyle hastalık tespitinde derin öğrenme kullanmışlardır. ESA, derin mimari sınıflandırma çalışması, orta ve yüksek seviye

görsel betimlemelerindeki kabiliyetinden dolayı popülerlik kazanmıştır. ESA'nın göğüs röntgeni görsellerinden farklı türdeki hastalıkları tespit etme yeteneği incelenmiştir. Ek olarak, derin öğrenmenin sağlık dışındaki çalışmalarında elverişliliğini incelemişlerdir. 93 görsellik bir veri setinde algoritmalar test edilmiştir. Geniş çaplı sağlık dışı görsel veri tabanlarında kullanılan ImageNet modeli ile eğitilen bir ESA kullanılmıştır. ESA'dan elde edilen özellikler ve düşük seviyeli özelliklerin kombinasyonu kullanılarak en iyi performans elde edilmiştir. Tüm hastalıkların tek bir geniş sınıfta toplandığı bir yerde, sağ plöral efüzyon tespiti için %93'lük, kalp genişlemesi tespitinde %89'luk, ve sağlıklı ile anormal göğüs röntgenleri arasında sınıflandırma için %79'luk başarı elde edilmiştir.

Son yıllarda tanısal görüntüleme büyük oranda artmış durumdadır. Birçok hastalığın tanısında kullanılan tanısal görüntüleme, göğüs röntgenlerinde de görülmektedir. Bu tanımlar, halen radyologlar tarafından her taramanın üzerinde yapılan incelemelerle, herhangi bir otomatik paylaşım veya asistan olmadan izlenmektedir. Hsu ve ark. (2019), 110.000 X-ray görüntüsünü içeren NIH veri setindeki verileri derin öğrenme kullanarak göğüs hastalıklarının kategorilerini tahmin etmeye çalışan bir model önermişlerdir ve sonuç olarak %71,8 başarı elde etmişlerdir.

Rajpurkar ve ark. (2017), pratisyen radyologları aşan seviyelerde göğüs röntgenlerinden zatürre tespiti yapabilecek bir algoritma geliştirmişlerdir. CheXNet isimli algoritma, 14 hastalıkla birlikte 100.000'den fazla önden çekim göğüs röntgeni üzerinde çalışan 121 katmanlı bir ESA modelidir. Görseller dört akademik pratisyen radyolog tarafından sınıflandırılmıştır. CheXNet'in F1 ölçeğinde, ortalama radyolog performansını geçtiği tespit edilmiştir. CheXNet'i, ChestX-ray14'te bulunan 14 hastalığı tespit edebilecek ve bu 14 hastalık için başarılı sonuçlar üretecek şekilde geliştirmişlerdir ve sistem doğruluğu %95 olarak bulunmuştur.

Kalp ve akciğer hastalıkları Amerika'da yılda ortalama 500.000 kişinin ölümüne sebep olmaktadır. Bu hastalıklar genellikle akciğer röntgeni kullanarak tespit edilebilmektedir. Radyologların kısıtlı sürelerinden dolayı direkt bakımla ilgilenen hekimlerin vakit ayıramamaları, hastaların tedavi süresinin daha da uzamasına sebep olmaktadır. Bilgisayar destekli sınıflandırma sistemi, hekimlerin daha çok teste ihtiyacı olduğunda hızlı bir şekilde hizmet verilmesini ve hekimle direkt olarak görüşülmesini sağlamaktadır; ancak çok çeşitli olabilen göğüs röntgenleri ve kayıtlı verilerin azlığı, bu tür sistemlerin gelişmesine engel olmaktadır. Stanford Normal Radyoloji Tanılama Verisi (NeRDD), normal, anormal ve yüksek risk (acil) olmak üzere sınıflandırılmış

400.000 göğüs röntgeni verisi içermektedir. Tataru ve ark. (2017), NeRDD veri setini sınıflandırmak için derin öğrenme yöntemlerini (GoogLeNet, InceptionNet ve ResNet) kullanmışlardır. GoogLeNet modeli kullanarak %80 doğruluk ve %66 F1 değeri ile en başarılı sonuç elde edilmiştir.

Antin ve ark. (2019), göğüs röntgenlerinde radyolog düzeyinde zatürree tespiti için bir yöntem önermişlerdir. NIH tarafından derlenen bir veri kümesini kullanarak, 30.805 hastadan 112.120 akciğer grafisi görüntüsünü değerlendirmek için derin öğrenme modeli olan DenseNet-121 modelini kullanmışlar ve AUC değeri 0,609 elde edilmiştir.

Deepak ve Ameer, (2019) transfer öğrenme yoluyla derin ESA özelliklerini kullanarak beyin tümörünü sınıflandırmışlar. Üç önemli beyin tümörü türü olan glioma, meningioma ve hipofiz tümörlerinin sınıflandırılması için daha önceden eğitilmiş GoogLeNet modeli kullanmışlardır ve sonuç olarak % 98 başarı elde etmişlerdir.

Chen ve ark., (2019), akciğer lezyonlarını benign veya malign sınıflandırması için bir BDT sistemi önermişlerdir. ImageNet veri seti kullanılarak eğitilen CaffeNet modelini kullanmışlar. Deney sonuçlarına göre sistemin doğruluğu, duyarlılığı, özgüllüğü, PPV, NPV ve AUC değerleri sırasıyla %85,4, %87,0, %82,1, %90,4, %76,6 ve 0,8705 olarak raporlanmıştır.

Zhu ve ark., (2019) mide kanserinin yayılma derinliğini tespit etmek için Resnet50 modeli kullanmışlardır. Veri setinde eğitim için 790 görüntü ve test için 203 görüntü yer almaktadır. Toplam başarı oranını % 89,16 olarak elde etmişlerdir.

Raghavendra ve ark., (2018) dijital fundus görüntülerindeki doğru glokom tanısı tespit etmesi için ESA kullanmışlardır. Deneysel çalışma sonucu, maksimum görüntü sayısı için sırasıyla %98,13, %98 ve %98,30 doğruluk, hassasiyet ve özgüllük değerlerini elde etmişlerdir.

Jing Li ve ark. (2019), hepatosellüler karsinom tespiti için Vgg-16 modelini kullanan BDT sistemi önermişlerdir. Önerilen sistemin performansını değerlendirmek için 46 difüz tümör, 43 nodüler tümör ve 76 büyük tümör içeren toplam 165 venöz faz BT görüntüsü kullanılmışlardır. Yaygın, nodüler ve masif tümörler için önerilen sistemin sınıflandırma doğruluğu %98,4 olarak elde edilmiştir.

Fujita ve Cimr, (2019), fibrilasyonlar ve çarpıntı tespiti için 8 katmanlı ESA modeli kullanan bilgisayar destekli algılama yöntemi önermişlerdir. Önerilen model, verilerin ön işleme tabi tutulmadan sadece temel veri normalizasyonu ile değerlendirmesini yapmaktadır. Ham EKG örneklerinden doğruluk, özgüllük ve


duyarlılık deęerleri sırasıyla %98,45, %99,27 ve %99,87 olarak elde edilmiştir. Önerilen sistemin klinik ortamda karar destek sistemi gibi doğrudan uygulanabilir olduğu belirtilmiştir.



### 3. MATERYAL VE YÖNTEM

#### 3.1. Veri Seti (*Chest X-Ray Images (Pneumonia)*)

Çalışmada Chest X-ray Images (Pneumonia) isimli veri seti kullanılmıştır. Veri setine <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia> internet adresinden online erişilebilir (Erişim tarihi: Şubat 2019). Veri seti 2 klasörde (eğitim, test) düzenlenmiştir ve her bir görüntü kategorisi için alt klasörler içermektedir (*Pnömoni/Normal*). 5.840 X-ray görüntüsü (JPEG) ve 2 kategori (*Pnömoni/Normal*) vardır. Göğüs röntgeni görüntüleri (ön-arka) Guangzhou Kadın ve Çocuk Tıp Merkezi'nden 1 ile 5 yaş arası pediatrik hastalardan seçilmiştir. Tüm göğüs röntgen görüntüleme, hastaların rutin klinik bakımının bir parçası olarak gerçekleştirilmiştir. Görüntüler iki uzman hekim tarafından derecelendirilmiştir. Herhangi bir derecelendirme hatalarını gidermek için, değerlendirme seti de üçüncü bir uzman tarafından kontrol edilmiştir. Veri setinde yer alan örnek bir görüntü Şekil 3.1'de gösterilmektedir. Veri setinin detayları Çizelge 3.1' de verilmiştir (Kermany ve ark., 2018, Livieris ve ark., 2019).



Şekil 3.1 Veri setinde yer alan örnek X-ray göğüs görüntüsü (Kermany ve ark., 2018).

Çizelge 3.1. X-ray veri setinde yer alan görüntü sayıları

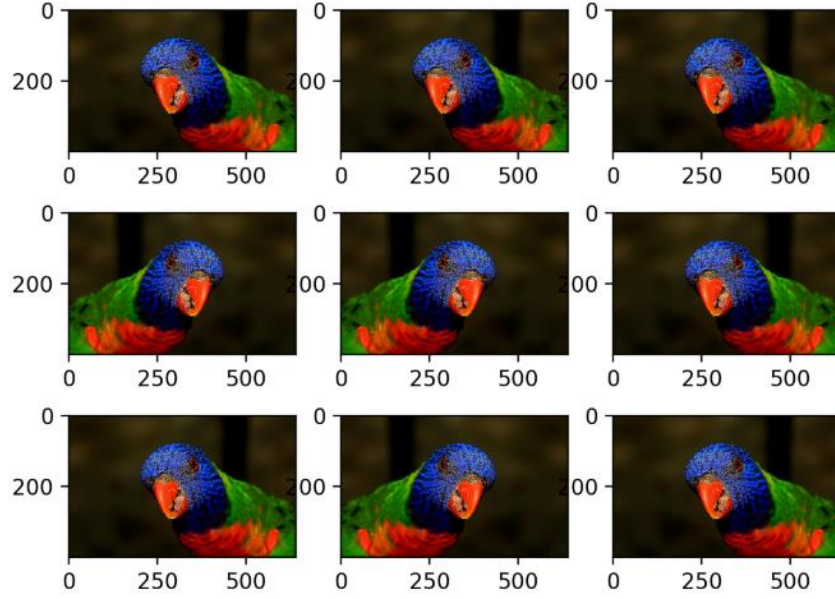
X-Ray görüntüsü	# Eğitim	# Test
Pneumonia	3.875	390
Normal	1.341	234
Toplam	5.216	624

### 3.1.1 Ön İşleme ve Veri Çoğaltma

Evrişimsel sinir ağlarında kilit noktalardan biri veridir. Büyük veri setlerine erişimin olması, ağa yapılması gereken her işte daha iyi olma şansını verir. Ağın öğrendiği her şey mevcut eğitim verilerinden gelecektir ve bu nedenle karar vermek için gereken tüm ana yönleri içermesi önemlidir. Veri çoğaltma (büyütme), derinlemesine öğrenmenin aşırı öğrenme etkisini azaltmak için kullanılan yaygın bir yöntemdir. Veri büyütmeye işlemi genellikle eğitim veri setine uygulanır, doğrulama veya test veri setine uygulanmaz. Bu, görüntü yeniden boyutlandırma ve piksel ölçeklendirme gibi veri hazırlığından farklıdır; modelle etkileşime giren tüm veri kümelerinde tutarlı bir şekilde gerçekleştirilmeleri gerekir. Örneğin; bir görüntüdeki bir kediyi tespit edebilen bir ağ oluşturmak istiyorsanız, bir kedinin hemen hemen her ortamda görülebileceğini bilmek önemlidir. Bu, kedinin karda, çimlerde, yolda, ahşap bir yerde ve benzeri yerlerde görülebileceği anlamına gelir. Tüm eğitim verileri stüdyo ortamında beyaz arka plana sahip resimlerden gelirse, bu, ağın gerçek dünya uygulamasında var olan tüm gerekli parametreleri öğrenmesini önleyecektir. Bu nedenle, genel olarak aynı nesne tipinin daha fazla versiyonunu içerecek daha büyük veri setlerine sahip olmak daha iyidir. Kedinin farklı arka planlarından ayrı olarak, farklı açılar, ışıklandırma veya renkler içerebilir. Görüntü verileri özellikle büyütmeye için uygundur, çünkü varyasyonların çoğu kolayca taklit edilebilir. Çeşitli veriler sunulmuş, görüntü verisi artırıldıktan sonra bir makine öğrenme algoritmasının performansı daha da artabilir. Birçok görüntü uygulaması türünde yaygın olarak kullanılan ve bazıları belirli bir sorun için daha uzmanlaşmış olan bazı artırmalar vardır. Daha genel büyütme türlerinden bazıları döndürme, çevirme, kırpma ve gürültü eklemedir (Klep, 2016).

Literatürde yer alan bazı veri çoğaltma yöntemleri aşağıda listelenmiştir.

**Yatay ve Dikey Çevirme Arttırma (Random Flips Augmentation)** :Bir görüntü çevirme, sırasıyla dikey veya yatay çevirme durumunda piksel satırlarını veya piksel sütunlarını ters çevirmek anlamına gelir. Hava fotoğrafları, kozmoloji fotoğrafları ve mikroskobik fotoğraflar gibi diğer görüntü türleri için, dikey düşmeler anlamlıdır. Şekil 3.2'de seçilen fotoğrafın `horizontal_flip` argümanı ile yatay çevirmelerle büyütülmesi gösterilmiştir (Klep, 2016).



Şekil 3.2. Horizontal\_flip argümanı ile yatay çevrim örneği

***Rastgele Kaydırma ve Döndürme (Random Shifts and Rotate Augmentation):***


Resimlerinizdeki nesnelere çerçevede ortalanmamış olabilir. Çok çeşitli şekillerde merkez dışı olabilirler. Çalışılan verilerin yapay versiyonları oluşturularak, merkez dışındaki nesnelere beklemek ve kullanmak için derin öğrenme ağı eğitilebilir. Keras kütüphanesi, eğitim verilerinin width\_shift\_range ve height\_shift\_range argümanlarıyla ayrı yatay ve dikey rasgele kaydırılmasını destekler. Ayrıca nesnelere görüntü üzerindeki duruş açıları her zaman aynı olmayabilir. Bu etkiyi oluşturabilmek için görüntülerin saat yönünde ve saat yönünün tersinde döndürülmesi ile bu etki yapay olarak oluşturulabilir. Örnek bir görüntü için oluşturulan rastgele döndürme etkisi Şekil 3.3'te gösterilmektedir (Sinha ve ark., 2019).



a) Yatay kaydırma b) Rastgele döndürme  
Şekil 3.3. Görüntülerin kaydırılması ve döndürülmesi

***Rasgele Yakınlaştırma Büyütme (Random Zoom Augmentation):*** Bu işlemde, görüntü rasgele oranlarda yakınlaştırılır ve görüntünün etrafına yeni piksel değerleri eklenir veya sırasıyla piksel değerlerini enterpole edilir. Keras kütüphanesinde görüntü yakınlaştırma, ImageDataGenerator yapıcısına zoom\_range argümanı ile


yapılandırılabilir. Yakınlaştırmanın yüzdesi tek bir kayan nokta veya bir dizi olarak belirlenebilir (Sinha ve ark., 2019). Rasgele yakınlaştırma örneği Şekil 3.4'de gösterilmektedir.



Şekil 3.4. Rasgele yakınlaştırma

### 3.2. Yapay Sinir Ağları (YSA)


1940'lı yıllardan bu yana popülerlik kazanan ve yükselişe geçen makine öğrenmesi algoritmalarından biri de yapay sinir ağlarıdır. YSA beyindeki biyolojik sinir ağlarından ilham alırlar ve beynin davranışlarını taklit etmeye çalışırlar. YSA bir girdi katmanı, bir veya daha fazla gizli katmandan ve bir çıktı katmanından oluşmaktadırlar. İleri beslemeli bir ağda giriş katmanı herhangi bir hesaplama yapmaz giriş değerlerini bir sonraki katmana aktarır (Kröse ve ark., 1993). Üç katmanlı bir YSA örneği Şekil 3.5'de görülmektedir.



Şekil 3.5 Üç katmanlı bir sinir ağı modeli

İleri beslemeli çok katmanlı bir YSA'da her katmanda yer alan nöronlar bir sonraki katmanda yer alan nöronlara bağlıdır ve hepsinin öğrenilebilir ağırlıkları vardır. Ancak temelde giriş ve çıkış arasında sadece kara bir kutu bulunur ve bu nedenle analiz edilmesi zordur. Ayrıca görüntülerin girdi olarak kullanımı için iyi ölçeklendirilemezler.  $x$  girdiler,  $w$  ağırlıklar,  $b$  bias değeri,  $\sigma$  aktivasyon fonksiyonudur. Şekil 3.6'da yapay nöron modeli gösterilmektedir. Nöronlara gelen değerler Eşitlik 3.1 kullanılarak hesaplanır.

$$y = \sum_{i=1}^m w_i x_i + b \quad (3.1)$$



Şekil 3.6. Yapay nöron modeli


### 3.2.1. Aktivasyon Fonksiyonları

Transfer işlevi olarak da bilinir, tipik olarak ağırlıklı toplamını bir çıktı değerine dönüştüren doğrusal veya doğrusal olmayan bir fonksiyondur. Değişik YSA modelleri için farklı aktivasyon fonksiyonları kullanılarak daha iyi performanslar elde edilebilir. Genellikle sinir ağlarında kullanılan iki tip aktivasyon fonksiyonu vardır. Bunlar doğrusal ve doğrusal olmayan aktivasyon fonksiyonlarıdır. Aktivasyon fonksiyonunun seçimi, eğitim algoritmasının performansı için önemlidir. Bir geri yayımlı YSA için aktivasyon fonksiyonu birkaç önemli özelliğe sahip olmalıdır. Aktivasyon fonksiyonu sürekli, farklılaşabilir ve monoton bir şekilde azalmamalıdır. Geri yayılım öğrenme algoritması kullanılarak, kullanılan aktivasyon fonksiyonu, fonksiyonun belirli sınır aralıklarında sınırlandırılması için farklılaştırılmalıdır (Nwankpa ve ark., 2018). Ayrıca kullanılacak aktivasyon fonksiyonu türevlenebilir olmalıdır.

YSA’larda kullanılan bazı aktivasyon fonksiyonları:

- 1- Lineer
- 2- Softmax
- 3- Sigmoid
- 4- Hiperbolik tanjant
- 5- ReLu -Rectified doğrusal birimler

**1- Doğrusal Aktivasyon Fonksiyonu:** Doğrusal bir aktivasyon fonksiyonunda, her nöronun ağırlıkları ile çarpılan girişleri alır ve girişle orantılı bir çıkış sinyali oluşturur. Bir anlamda, bir doğrusal işlev, bir basamak işlevinden daha iyidir, çünkü yalnızca evet ve hayır değil, birden fazla çıkışa izin verir. Şekil 3.7’de doğrusal aktivasyon fonksiyonu gösterilmiştir.



Şekil 3.7. Doğrusal aktivasyon fonksiyonu

Bununla birlikte, doğrusal bir aktivasyon fonksiyonunun iki ana problemi vardır:

- Modelin eğitilmesi için geri yayılımın (eğim iniş) kullanılması mümkün değildir. Bu algoritma türev alan bir sistemden oluşuyor.  $A=c.x$ ,  $x$ 'e göre türevi alındığında  $c$  sonucuna erişiriz. Bu  $x$  ile bir ilişkinin kalmadığı anlamına gelir. Bu nedenle geri dönmek ve giriş nöronlarında hangi ağırlıkları anlamak mümkün değildir.
- Sinir ağının tüm katmanları, sinir ağında kaç katman olursa olsun, son katman, birinci katmanın doğrusal bir işlevi olacaktır (doğrusal işlevlerin doğrusal bir birleşimi hala doğrusal işlev). Böylece doğrusal bir aktivasyon fonksiyonu sinir ağını sadece bir katmana dönüştürür.


Doğrusal aktivasyon işlevine sahip bir sinir ağı sadece doğrusal bir regresyon modelidir. Girdi verilerinin karmaşıklık değişken parametrelerini işlemek için sınırlı güce ve yeteneğe sahiptir (Anonymous, 2018).

**2- Softmax Aktivasyon Fonksiyonu:** Genellikle sınıflandırma görevi yapmak için oluşturulmuş çok katmanlı sinir ağlarının çıktı katmanında kullanılır. Aslında her bir sınıfın olasılığını hesaplar. Olasılıklardan bahsettiğimizden, tüm softmax'ların toplamı bire eşittir. Sınıflar arasında katı bir seçim yapmak yerine, softmax, girdinin büyük olasılıkla hangi sınıfa ait olduğunu tahmin etmektedir. M sınıfının olduğu varsayılarak, softmax fonksiyonu Eşitlik 3.2 ile temsil edilebilir (Martins ve Astudillo, 2016).

$$\text{softmax}(x_k) = \frac{e^{x_k}}{\sum_{i=1}^M e^{x_i}} \quad (3.2)$$

**3- Sigmoid Aktivasyon Fonksiyonu:** En çok kullanılan aktivasyon fonksiyonlarından biridir. Sigmoid aktivasyon fonksiyonuna ait matematiksel ifade Eşitlik 3.3'de verilmiştir. S harfi şeklinde bir eğridir. Anlaması ve uygulaması kolaydır. Aralığı 0 ile 1 arasındadır (Sibi ve ark., 2013). Sigmoid aktivasyon fonksiyon grafiği Şekil 3.8 'de görülmektedir.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (3.3)$$




Şekil 3.8 Sigmoid aktivasyon fonksiyonu (Nwankpa ve ark., 2018)

**4- Hiperbolik Tanjant Aktivasyon Fonksiyonu:** Hiperbolik tanjant aktivasyon fonksiyonuna ait matematiksel ifade Eşitlik 3.4'de verilmiştir. Çıkış sıfır merkezlidir, çünkü aralığı  $-1$  ile  $1$  arasındadır, yani  $-1 < \text{çıkış} < 1$ 'dir. Dolayısıyla, bu yöntemde optimizasyon daha kolaydır, bu nedenle pratikte Sigmoid fonksiyon yerine tercih edilir


(Alencar ve ark., 2003). Şekil 3.9'da hiperbolik tanjant fonksiyonun grafiği gösterilmektedir.

$$f(x) = \frac{1 - \exp(-2x)}{1 + \exp(-2x)} \quad (3.4)$$



Şekil 3.9. Hiperbolik tanjant fonksiyonu (Tanh)

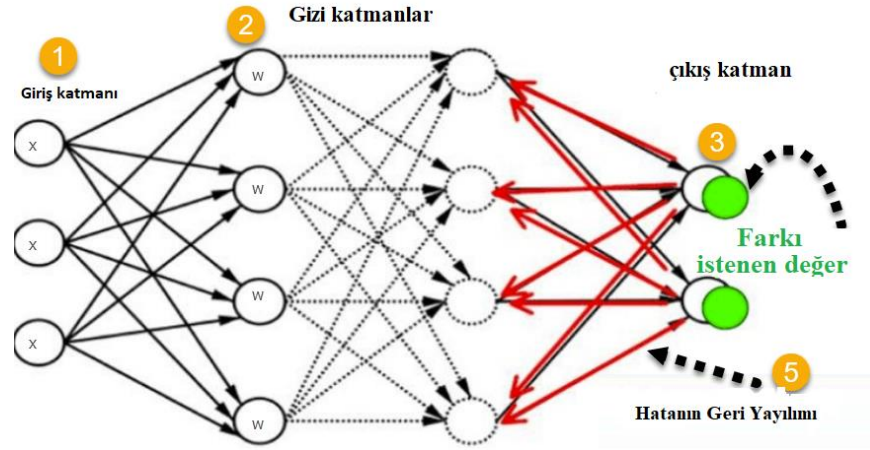
**5- Rectified Lineer Üniteleri (ReLU) :** Son yıllarda popüler olan, Tanh fonksiyonundan yakınsamada 6 kat iyileşme olduğu kanıtlanmıştır. Sadece  $R(x)=\max(0,x)$  yani  $x < 0$ ,  $R(x)=0$  ve  $x \geq 0$  ise,  $R(x)=x$  olmaktadır. Hemen hemen tüm derin öğrenme modelleri günümüzde ReLu'yu kullanmaktadır. Sadece bir sinir ağı modelinin gizli katmanları içinde kullanılması gerekmektedir. Bu nedenle, çıktı katmanları için, sınıfların olasılıklarını hesaplamak adına bir sınıflandırma problemi için Softmax fonksiyonunu kullanmalı ve bir regresyon problemi için basitçe doğrusal bir fonksiyon kullanılmalıdır. ReLu ile ilgili diğer bir problem, bazı eğitimlerin eğitim sırasında kırılma ve kayıplı olabilmesidir. Hiçbir veri noktasında tekrar aktive etmemesini sağlayacak bir ağırlık güncellemesine neden olabilmektedir. Basitçe söylemek gerekirse, ReLu kırılma ve kayıp nöronlar ile sonuçlanabilmektedir. Bu sorunu çözmek için yani ölmekte olan nöronların problemini çözmek için Leaky ReLu adı verilen başka bir değişiklik daha yapılmıştır. Güncellemeleri canlı tutmak için küçük bir eğim sunulmaktadır (Ramachandran ve ark., 2017). Şekil 3.10'de ReLu aktivasyonuna ait grafik gösterilmektedir.



Şekil 3.10 ReLu aktivasyon fonksiyonu

### 3.2.2. Hatanın geri yayılımı (Backpropagation) algoritması

Geri yayılım, veri madenciliği ve makine öğreniminde tahminlerin doğruluğunu arttırmada önemli bir matematiksel araçtır. Temel olarak, geri yayılma, türevleri hızlı bir şekilde hesaplamak için kullanılan bir algoritmadır. YSA, ağırlıklara göre eğitim inişini hesaplamak için bir öğrenme algoritması olarak geri yayılımı kullanır. İstenen çıkışlar, elde edilen sistem çıkışlarıyla karşılaştırılır ve ardından sistemler, ikisi arasındaki farkı mümkün olduğunca azaltmak için bağlantı ağırlıklarını günceller. Ağırlıklar çıktıdan girdilere doğru geriye doğru güncellendiğinden algoritma adını buradan alır. Ağırlıkları bias değiştirmenin YSA'nın genel davranışını nasıl etkilediğini tam olarak anlamamanın zorluğu, sinirsel ağ uygulamalarının daha geniş bir şekilde uygulanmasını engelleyen faktörlerden biridir. Geri yayılma, hata fonksiyon eğimini hesaplamak için her giriş değeri için bilinen ve istenen bir çıktı gerektirdiğinden, genellikle danışmanlı makine öğrenmesi yöntemlerinde kullanılır. Naive Bayesian filtreleri ve karar ağaçları gibi sınıflandırıcılarla birlikte, geri yayılım algoritması, tahmine dayalı analitik içeren makine öğrenme uygulamalarının önemli bir parçası olarak ortaya çıkmıştır. Geri yayılım algoritmasının adımları aşağıda verilmiştir (Riedmiller ve Braun, 1993). Şekil 3.11'de geri yayılımın çalışma şekli görülmektedir.



Şekil 3.11. Geri yayılım (Anonymous, 2019).

- 1- Ara katmanlara gelen değerler Eşitlik 3.5 kullanılarak hesaplanır. (İleri doğru hesaplama)

$$NET_i = \sum_{i=1}^m w_i x_i + b \quad (3.5)$$

Burada;

$w$  : ağırlıklar,

$x$  : girdiler,

$b$  : bias değeridir.

- 2- Kullanılacak aktivasyon fonksiyonuna göre ara katmanın çıkış değeri Eşitlik 3.6 kullanılarak hesaplanır. Aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanıldığı varsayılarak;

$$\zeta_{NET_i} = \frac{1}{1+e^{-(NET_i)}} \quad (3.6)$$

İlk 2 aşama, girdi katmanından alınan değerlerden ara katmandaki çıktı değeri hesaplanırken bir sonraki ara katmanın yeni girdi değerinden çıktı değeri hesaplanacaktır. Bu işlemler sonuncu katmana kadar böyle devam edecektir.

- 3- Geri doğru hesaplamayla beklenen çıktı ile hesaplanan çıktı arasındaki fark değeri Eşitlik 3.7'ye göre hesaplanır.

$$e_j = B_j - \zeta_j \quad (3.7)$$

Burada;

$e$  : hata değeri,

$B$  : beklenen çıktı,

$\zeta$  : ağın ürettiği çıktıdır.

- 4- Toplam hata hesaplanırken hata karelerinin ortalaması Eşitlik 3.8'e göre hesaplanır.

$$E = \frac{1}{2} \sum_j e_j^2 \quad (3.8)$$

- 5- Elde edilen hata değeri geriye doğru dağıtılarak ağırlıkların güncellenmesi sağlanmaktadır. Hata fonksiyonunun türevi ağırlıklara göre hesaplanmaktadır. Bunun için sigmoid fonksiyonu gibi bir aktivasyon fonksiyonu kullanılmaktadır. Ağın ürettiği çıktının aktivasyon fonksiyonu cinsinden yazılması Eşitlik 3.9 kullanılarak hesaplanır. Toplam hatanın herhangi bir ağırlığa göre türevi Eşitlik 3.10'da verildiği gibi zincir kuralına göre alınmaktadır. Ağırlığın yeni değeri Eşitlik 3.11'e göre hesaplanmaktadır. Burada  $\eta$ ; öğrenme katsayısıdır.

$$C_j = f(a_j) = \sum_j x_i w_{ji} \quad (3.9)$$

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial C_j} \cdot \frac{\partial C_j}{\partial w_{ji}} \quad (3.10)$$

$$w_{ji} = w_{ji} - \eta \frac{\partial E}{\partial w_{ji}} \quad (3.11)$$

### 3.3. Derin Öğrenme


Derin öğrenme derin yapılandırılmış öğrenme veya hiyerarşik öğrenme olarak da isimlendirilir. Göreve özgü algoritmaların aksine, öğrenme bilgi tasvirlerine dayanan daha geniş bir makine öğrenme tekniklerinin bileşenidir. Öğrenme şekli izlenebilir, kısmi denetlenebilir veya denetlenemez. Derin sinir ağları, derin inanç ağları ve tekrarlayan sinir ağları gibi derin öğrenme mimarileri, bilgisayarlı görüntü işleme, tanıma, doğal dil işleme, ses tanıma, sosyal ağ filtreleme, biyobilişim, ilaç tasarımı gibi alanlara uygulanmıştır. Derin öğrenme terimi Rina Dechter tarafından 1986'da tanıtılmıştır (Pascanu ve ark., 2013).

Derin öğrenmenin tarihi, Walter Pitts ve Warren McCulloch'un insan beyninin sinir ağlarını temel alan bir bilgisayar modelini icat ettiği 1943 yılına kadar eskiye gitmektedir. Düşünme sürecini çoğaltmak için "eşik mantığı" olarak adlandırdıkları bir algoritma ve matematik karışımı kullanmışlardır. Derin öğrenme o zamandan beri sürekli olarak gelişmiştir (Pouyanfar ve ark., 2018).

Henry J. Kelley, 1960'da geri yayılma modelinin temellerini oluşturmuştur. 1962'te Stuart Dreyfus, basit merkezli bir sürüm oluşturmuştur. 1960'ların başında geri yayılma fikri ortaya çıkarken, 1985'e kadar kullanılmamıştır ve etkisiz bir durumda kalmıştır (Rahman, 2005).

Derin öğrenme algoritmaları oluşturmada ilk girişimler 1971'de Alexey Grigoryevich Ivakhnenko (İleri Veri İşleme Grubu Yöntemi) ve Valentin Grigorjevich Lapa (Sibernetik ve Tahmini Teknikleri yazarı) tarafından yapılmıştır. Onlar polinom canlandırma fonksiyonlu modeli kullanmışlar ve bunu istatistiksel olarak analiz etmişlerdir. Her katmandan, istatistiksel olarak en iyi seçilen özellikler bir sonraki katmana iletilmiştir (Schmidhuber, 2015).

Kunihiko Fukushima ilk olarak "Evrimsel Sinir Ağlarını" kullanmıştır. Fukushima, çeşitli evrimsel katmanlara sahip sinir ağı inşa etmiştir. 1979'da Neocognitron adında hiyerarşik, çok katmanlı bir mimari kullanarak bir yapay sinir ağı modeli önermiştir. Bu model çağdaş versiyonlara benziyordu, ancak zaman içinde güç kazanan çeşitli katmanlardaki tekrarlanan aktivasyonların takviye edici bir yaklaşımı ile eğitildiler. Ek olarak, Fukushima'nın tasarımı, belirli bağlantıların "ağırlığı" yükseltilecek şekilde uyarlanacak önemli özelliklere izin verdi (Ganeshan, 2017). Şekil 3.12'da Fukushima tarafından önerilen Neocognitron adındaki model görülmektedir.




Şekil 3.12 Fukushima tarafından önerilen Neocognitron adındaki modeli (Fukushima, 1980)

Yukarıdan aşağı doğru bağlantıların ve yeni öğrenme tekniklerinin kullanılması, çeşitli sinir ağlarının gerçekleştirilmesini sağlamıştır. Aynı anda birden fazla desen gösterildiğinde, seçici dikkat modeli, dikkatlerini birinden diğerine taşıyarak desenleri ayırt edebilir ve onaylayabilir. Çağdaş bir Neocognitron yalnızca eksik veri içeren kalıpları tanınamazlık yapmaz, aynı zamanda eksik veri ekleyerek resmi de tamamlayabilmektedir. Bu işlem çıkarım olarak isimlendirilmektedir (Kukacka, 2011).

YSA modellerinin eğitiminde hataların kullanımı olan geri yayılım, 1970 yılında önemli ölçüde gelişti. Bu kavram 1985'e kadar sinir ağlarına uygulanmamıştır.

Rumelhart, Williams ve Hinton, bir sinir ağında yayılmanın ilginç dağıtım gösterimleri sağlayabildiğini göstermiştir. Felsefi olarak, bu keşif, bilişsel psikoloji içindeki sorunun, insan anlayışının sembolik mantığına (hesaplamalı) ya da dağıtılmış temsillerine (bağlantıcılık) dayanıp dayanmadığına ışık tutmuştur. 1989'da, LeCun ve ark., Bell Laboratuvarlarında geri yayılımın ilk pratik gösterimi yapılmıştır. Evrimsel sinir ağı, okuma “el yazısı” rakamları üzerine geri yayılma ile birleştirilmiştir. Bu sistem, sonuç olarak el yazısı tanımak için kullanılmıştır (Ranganathan ve Natarajan, 2018). Şekil 3.13’de LeCun tarafından önerilen ESA modeli gösterilmektedir.



Şekil 3.13. LeCun tarafından Önerilen ESA modeli için (LeCun ve ark., 1998)

1995 yılında, destek vektör makinesi Dana Cortes ve Vladimir Vapnik tarafından önerilmiştir (Schölkopf ve ark., 1996). Tekrarlayan sinir ağı için, 1997'de Sepp Hochreiter ve Juergen Schmidhuber tarafından kurulmuştur (Hochreiter ve Schmidhuber, 1997).

Derin Öğrenme için bir sonraki önemli adım, bilgisayarların bilgi ve GPU'da (grafik işleme birimleri) işlendiğinde daha hızlı gelişmeye başladığı 1999'da gerçekleşmiştir (Platt, 1999). Görüntüler GPU' lar tarafından işlenerek daha hızlı işlenmiştir ve 10 yıl boyunca işlem hızını 1.000 kat daha artırmıştır. Bu süre zarfında sinir ağı, destek vektör makineleriyle (SVM) rekabet etmeye başlamıştır. Bir sinir ağı bir destek vektör makinesine kıyasla yavaş olabilirken, aynı bilgiyi kullanarak sinir ağı daha iyi sonuçlar vermiştir. Sinir ağlarına, daha fazla eğitim verisi eklendikçe, geliştirmeye devam etme avantajına da sahiptir.

Sinir ağlarını eğitmek için, etiketli görüntüler gereklidir. İnternet, etiketlenmemiş resimlerle doludur. Fei-Fei ve ark. (2009) ImageNet'i geliştirmiştir ve 14 milyondan fazla etiketli görüntüden oluşan ücretsiz bir veri tabanı oluşturmuştur.

2011 yılına kadar, GPU' ların hızı önemli ölçüde artmıştır, bu da evrimsel sinir ağlarını kat-tabaka ön eğitim olmadan mümkün kılmıştır. Gelişmiş bilgi işlem hızıyla,

derin öğrenmenin etkinlik ve hız açısından önemli faydaları olduğu ortaya çıkmıştır. Bunun bir örneği, 2011 ve 2012'de mimarisi çeşitli küresel yarışmalar kazanan, evrişimli bir sinir ağı olan AlexNet'tir. Hız ve düşüşü artırmak için düzeltilmiş doğrusal birimler kullanılmıştır (Yeager ve ark., 2015).

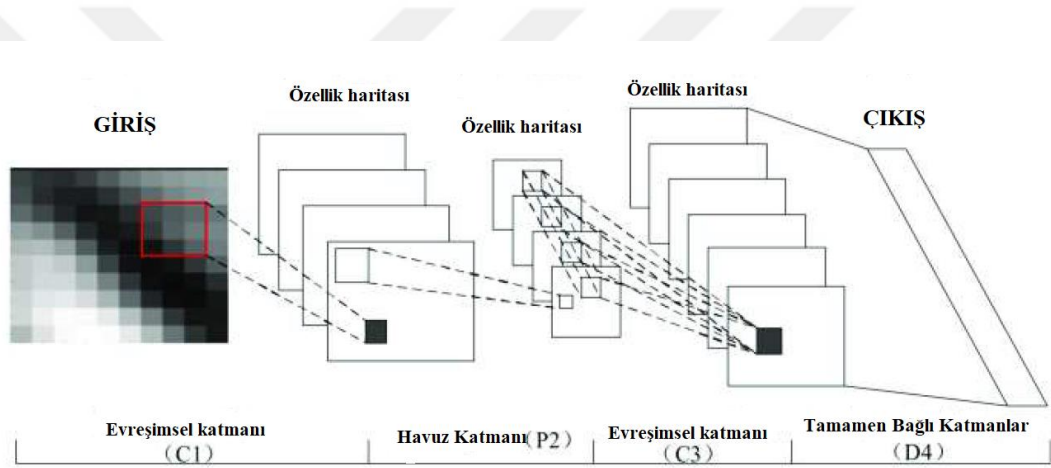
Google Brain, 2012 yılında "Kedi Deneyi" olarak bilinen bir projenin sonuçlarını da yayımlamıştır. Proje "danışmansız öğrenmenin" sorunlarını incelemiştir. Danışmansız öğrenmeyi kullanarak, evrimsel bir sinir ağına etiketsiz bir bilgi verilmekte ve daha sonra tekrar eden kalıpları aramak için talep edilmektedir. Kedi deneyinde, 1.000 bilgisayara yayılmış bir sinir ağı kullanılmıştır. On milyon "etiketsiz" görüntü Youtube'dan rastgele çekilmiştir, sisteme gösterilmiş ve daha sonra eğitim yazılımının çalışmasına izin verilmiştir. Eğitim sonunda, en alt katmandaki bir nöronun kedilerin resimlerine tepki gösterdiği keşfedilmiştir. Kedi deneyi, etiketlenmemiş görüntülerin işlenmesinde önceki uygulamalardan yaklaşık %70 daha iyi çalışmıştır. Bununla birlikte, eğitim için kullanılan nesnelere %16'sından daha azını tanımış ve başarı döndürülen veya taşınan nesnelere daha da azalmıştır (Anonymous, 2017).

### **3.4. Evrişimsel Sinir Ağları (ESA)**

Evrişimsel sinir ağı (ESA), derin öğrenmenin popüler bir yöntemidir. Beyinde meydana gelen sinir hücrelerinin biyolojik süreçlerinden esinlenmiştir. David Hubel ve Torsten Wisel, göz tanınmasını simüle eden beynin kısımlarını incelemek amacıyla 1959'da bir araştırma gerçekleştirmiştir. Bu çalışmada bir kediye anestezi uygulanmış, iğne elektrotlar yerleştirmişler ve görsel faz esnasında beynin farklı alanlarında meydana gelen sinyalleri değerlendirmek amacıyla deneyler gerçekleştirmişlerdir. Kedinin görme sürecinin, beynin başlıca görsel çekirdeğindeki kenarları tanımlayarak hareketi algılayan erişilebilir yapılarla başladığını ve beynin daha derin bölgelerinde daha karmaşık yapılar olduğunu bulmuşlardır. Yazarlar, görsel işlemenin görsel küreden gelen kolay yapılarla başladığını ve beynin nesnelere tanıyana kadar karmaşık görsel işleme rotasından verinin aktığını keşfetmişlerdir. Bu araştırma, ESA'nın oluşturulması için temel arz etmektedir (Hubel ve Wiesel, 1959). Warren McCulloch ve Walter Pitts, 1943 yılında yapay sinir ağlarına doğru ilk girişimde bulunmuşlardır. Pitts ve McCulloch, yapay sinir mimarileri için temel bir birim olan algılayıcının matematiksel modelini sunmuştur. Frank Rosenblatt, 1960 yılında görsel tanıma için algılayıcı modeli kullanarak bir örüntü tanıma şeması önermiştir. Bu araştırma, 20x20 fotoselden oluşan bir kamera ile çekilen 400 piksellik resimlerden alfabetik karakterleri tanımayı

amaçlamıştır (Rosenblatt, 1960). ESA modelleri, 2012 yılından beri dünya çapındaki bilgisayarla görme, görüntü sınıflandırma uygulamalarında başarı sonuçlar üretmeye başlamıştır. ESA yapısı birkaç katmandan oluşmaktadır. ESA girdi, özellik çıkarma ve sınıflandırma katmanından oluşur. İlk ve son katmanlar arasında birçok gizli katman bulunmaktadır. ESA algoritması, özelliklerin mekânsal hiyerarşilerini otomatik olarak öğrenmektedir. Algoritma, ardışık sonuçlar elde etmek için büyük miktarda veriye ihtiyaç duymaktadır. ESA, el yazısı tanıma, yüz tanıma, görüntü sınıflandırma ve görüntü segmentasyonu gibi birçok farklı alanlarda kullanılmaktadır.

ESA yapısı tipik olarak üç farklı katman türünden oluşmaktadır. Her katman türünde hatanın ilerletilmesi ve geriye dönük sinyal yayması için farklı katmanları vardır. Şekil 3.14’de genel bir ESA yapısı gösterilmektedir.



Şekil 3.14. Evrişimsel ağların genel yapısı (Sallam, 2018).

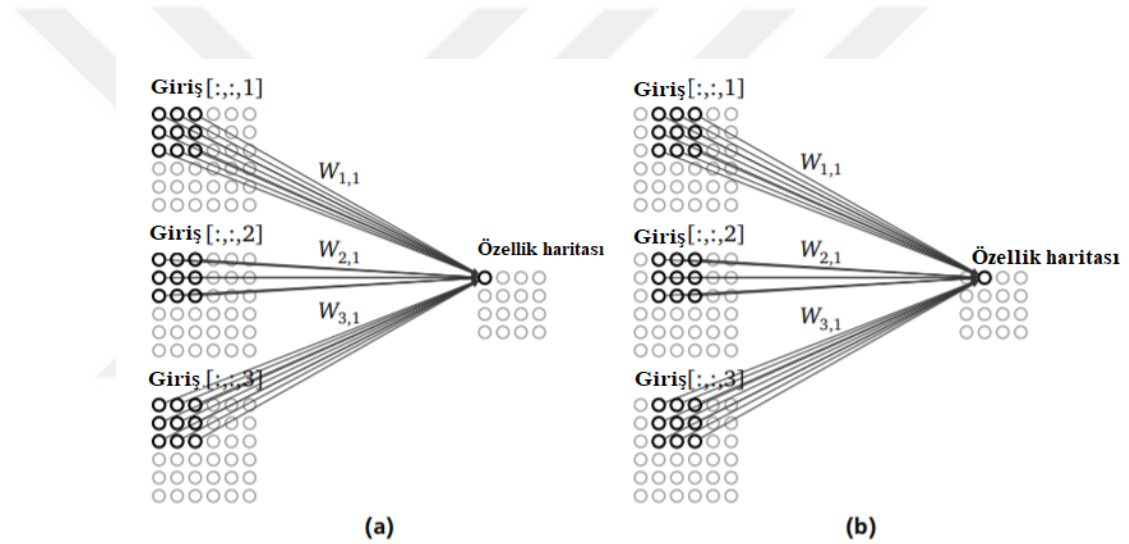
### 3.4.1. Evrişim Katmanı

Bir evrişim katmanı, normal bir sinir ağının yanı sıra farklı birimlerden oluşmuştur, ancak birimler farklı bir düzenleme ve farklı bir bağlantı mekanizmasından oluşmaktadır. Sinir ağları arasındaki ana farklar:

- Birimlerin yerine 1 boyutlu üç boyutlu düzenleme,
- Ağırlık paylaşımı,
- Yerel bağlantı olarak sıralabilir.



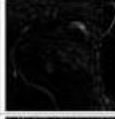

Üç boyutlu düzenleme görüntüden gelmektedir. Renkli bir görüntü genellikle üç kanala (kırmızı, yeşil, mavi) sahiptir ve her kanal iki boyutlu bir matris ile tanımlanmaktadır. Bu nedenle, ESA'in girişi üç boyutlu bir matristir. Bir evrişim tabakasının çıktısı, yine iki boyutlu özellik haritaları olan üç boyutlu bir matristir. Her

filtre bir özellik haritası oluşturmaktadır. Ağırlık paylaşımı, çeşitli çıktı birimleri için aynı ağırlıkları kullanmak anlamına gelmektedir. Bu sayede ESA, özelliklerin çeviriye karşı değişmez olduğu özelliğini kazanmaktadır. Bu, girişin tamamında keşfedilebilecek bir özellik olduğunu göstermektedir. Bunu Sobel filtresiyle karşılaştırmak gerekirse, ağırlıklar filtredir ve bu filtre tam girdideki çıktıyı üretmek için kullanılmıştır. Şekil 3.15’de gösterilmiş olduğu iki şekil, evrişim katmanının giriş ve iki çıkış birimi arasındaki bağlantıyı oluşturmaktadır. Ayrıca, evrişim katmanı çıktı için sadece bir özellik haritasına sahiptir. Aktivasyon fonksiyonu ve bias daha iyi bir genel bakış için göz ardı edilmiştir. Yerel bağlantı iki şekilde gösterilmiştir. 3x3 filtre boyutu ile (a) ve (b) özellik haritasının hesaplanması için aynı ağırlıkları paylaşır. Başka bir özellik haritası için, yeni ağırlıklar kullanılacaktır (Johannes Fürnkranz, 2016).



**Şekil 3.15.** Evrişim katmanının giriş ve iki çıkış birimi arasındaki bağlantı (Johannes Fürnkranz, 2016)


Görüntünün farklı filtrelerle çevrilmesi, kenar algılama, bulanıklaştırma ve keskinleştirme gibi işlemleri filtreler uygulayarak gerçekleştirebilmektedir. Şekil 3.16’da farklı filtre türlerini uyguladıktan sonra çeşitli evrişim görüntüleri gösterilmektedir.

Operasyon	Filtre	Evrışmiş görüntü
Identity	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	
Edge detection	$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
	$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
	$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	

Şekil 3.16. Farklı filtre türlerini uyguladıktan sonra çeşitli evrişim görüntüleri (Sallam, 2018)

### 3.4.2. Dolgu (Padding) İşlemi

Görüntünün etrafına yerleştirilen sıfır değerlerin bir kenar boşluğudur. Dolgu derinliği, mevcut evrişimsel tabakadan gelen çıktı, evrişimden sonra boyut olarak küçülmeyecek şekilde ayarlanabilir. Ardışık evrişim katmanlarının çoğunda, çıktı boyutundaki azalma bir sorun olabilir, çünkü her evrişimde bir alan kaybolur. Çok sayıda katmana sahip olan bir ESA, çıkışı küçültmenin bu etkisi, girişin sıfır doldurulmasıyla azaltılabilir. Sıfır dolgu Şekil 3.17'de gösterildiği gibi, boyutsal küçültmeyi iptal etme ve girdi boyutunu çıktıda tutma etkisine sahip olabilir. Çok katmana sahip ağlarda, çıktıların çok azalmasını önlemek için bu yaklaşım gerekli olabilir (Murphy, 2016).

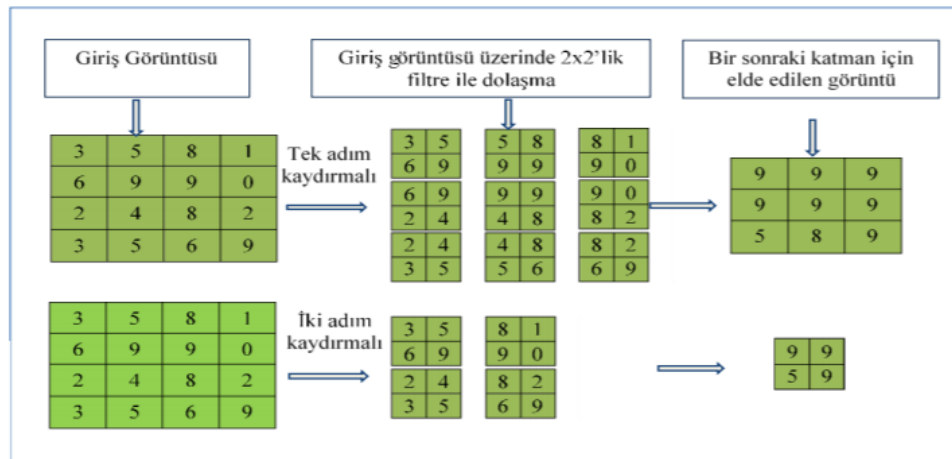


Şekil 3.17. Dolgu işlemi (Murphy, 2016).


### 3.4.3. Havuzlama Katmanı ( Pooling Layer )

Bu katman tipik olarak herhangi bir öğrenme sürecini temsil etmez, ancak giriş boyutunu aşağı örneklemek için kullanılmaktadır. İlke, girdilerin sayısız üst üste binmiş dikdörtgen bileşene bölünmesi ve her bir bileşen içindeki birimlerin tek bir çıktı birimi

üretmek için kullanılmasıdır. Bu, girdi katmanında bulunan en önemli verileri korurken, çıktı katmanının boyutunu azaltmaktadır. Başka bir deyişle, havuz katmanı girdiler içindeki bilgileri sıkıştırılmaktadır. Her bir bileşen üzerinde taşınan prosedür türü, bir tür havuzlama katmanı belirlemiştir. Bu prosedür, eleman içindeki birimler üzerinden ortalama değer alabilir, elemandan maksimum değer seçmekte veya eleman içindeki birimlerin dönüşümlü olarak alternatif kombinasyonunu öğretmektedir. Öğrenilmiş doğrusal kombinasyon, öğrenme türünü havuzlama katmanına getirir, fakat çok yaygın değildir. Maksimum değer seçimi, en yaygın havuzlama işlemi türüdür ve bu durumda katman Maksimum Havuzlama (Max-Pooling) olarak adlandırılır. Maksimum havuzlama aşağı örnekleme pozitif etkisi ve evrişimden çıkarılan özellikleri küçük girdi değişimlerine karşı değişmez olmasıdır (He ve ark., 2015). Maksimum havuzlama ve ortalama havuzlama prensipleri, Şekil 3.18 ve Şekil 3.19’da gösterilmiştir.



**Şekil 3.18.** 1x1 ve 2x2 basamak kullanarak 5x5 girişinde 2x2 maksimum havuzlama işleminin çıkış değerlerinin hesaplanması (Özkan ve Ülker, 2017).




**Şekil 3.19.** 1x 1 basamak kullanarak 5x5 girişinde ortalama 3x3 havuzlama işleminin çıkış değerlerinin hesaplanması (Dumoulin ve Visin, 2016).

Daha önce belirtildiği gibi, evrişim katmanı ile birleştiğinde, maksimum havuzlamanın bir başka avantajı ortaya çıkmaktadır. Maksimum havuzlama, sonuçta ortaya çıkan özellik haritasının, çekirdeğe değişmeyen kolay bir detektör oluşturmak için en yüksek sinyale sahip çekirdekten (yani, özelliğin bu özel dönüşü için eğitilmiş olan) çıktı almasını sağlamaktadır (He ve ark., 2015).

#### 3.4.4. Tamamen Bağlı Katmanlar (Fully Connected Layers)


Tamamen bağlı katmanlar, son sınıf bir etikete ulaşmak için özellik bilgilerini kullanır. Tamamen bağlanmış katmanların düğümleri, önceki katmanın her çıkışına bağlanmış ve çıkışları sonraki katmanın her bir düğümüne bağlanmıştır. Tamamen bağlı katmanların son katmanındaki düğümleri genellikle her bir etiket için olasılıklı bir sonuç üretecek özel bir aktivasyon fonksiyonuna sahiptir. Bu aktivasyon fonksiyonu genellikle bir softmax fonksiyonudur veya ikili sınıflandırma durumunda bir sigmoid fonksiyondur (Çalli, 2017). Tamamen bağlı katmanlar Şekil 3.20’de gösterilmektedir.



Şekil 3.20. Tamamen bağlı katmanlar (Çalli, 2017)

### 3.4.5. Bırakma (Dropout) İşlemi

Bırakma (Dropout) Srivastava ve ark. (2014)'ları tarafından sinir ağı modellerini düzenlemek için önerilen bir tekniktir. Sinir ağlarının aşırı öğrenmesinin önleniminin kolay bir yoludur. Bırakma işleminde, eğitim sırasında rastgele seçilen nöronlar ihmal edilerek, gelen ve giden bağlantılar geçici olarak ağdan kaldırılır. ESA'nın başarısını artırmak için, eğitim aşamasında daha fazla veri kullanmak gerekir. Eğitimin fazla yapılması aşırı öğrenmeye neden olmaktadır. ESA'larda aşırı öğrenmeyi engellemek için bırakma işlemi uygulanır. Şekil 3.21'de bir ESA modelinde bırakma işleminden önce ve sonra oluşan bağlantılar görülmektedir (Srivastava ve ark., 2014).




Şekil 3.21. Bir ESA modelinde bırakma işleminden önce ve sonra oluşan bağlantılar (Srivastava ve ark., 2014).

### 3.5. Transfer Öğrenmesi (Transfer Learning)

Transfer öğrenmesi, daha önce edinilmiş bilgi ve becerilerin yeni öğrenme veya problem çözme durumlarında kullanılması anlamına gelmektedir. Yani, yeni görevlerle karşılaşıldığında önceki öğrenme deneyimleriyle alakalı bilgiler tanınmakta ve uygulanmaktadır. Transfer öğrenimi, bir veya daha fazla kaynak görevde öğrenilen bilginin, ilgili bir hedef görevin öğrenmesini geliştirmek için aktarıldığı ve kullanıldığı yaklaşımı içermektedir. Makine öğrenim algoritmalarının çoğu tek görev ele almak için tasarlanmış olsa da, transfer öğrenmeyi kolaylaştıran algoritmaların geliştirilmesi, makine öğrenmesi alanında sürekli ilgi duyulan bir konudur. Transfer öğreniminde, ilk önce temel bir veri kümesi ve görevi üzerine temel bir ağ eğitilir ve daha sonra öğrenilen özellikler yeniden hedeflenir veya bunlar bir hedef veri kümesi ve görevi için eğitmek üzere ikinci bir hedef ağa aktarılmaktadır (Torrey ve ark., 2010). Bu işlem, eğer özellikler genelse, yani temel göreve özgü olmak yerine hem temel hem de hedef görevlere uygunsa işe yararmaktadır. Uygulamada, çok az sayıda ESA modeli sıfırdan eğitilmektedir, çünkü yeterli büyüklükte bir veri kümesine sahip olmak nispeten zordur. Bunun yerine, bir ESA çok büyük bir veri setinde (örneğin, 1.000 kategoride 1,2 milyon görüntü içeren ImageNet) önceden eğitmek ve ardından ESA ilgili görev için bir başlatma veya sabit bir özellik çıkarıcı olarak kullanmak yaygındır. Yeni bir veri setinde yapılması gereken öğrenme transferinin türünü nasıl belirleneceği, tüm ağırlıkları kaldırmak veya birkaç katmanın kaldırılması gerekir gibi faktörler geliştirici tarafından belirlenir, fakat daha önemlisi, iki yeni veri setinin orijinal veri setine boyut ve benzerliği daha önemlidir (He ve ark., 2018).

#### 3.5.1. VGG-16 Modeli


VGG-16, ImageNet veritabanından bir milyondan fazla resim üzerinde eğitilmiş evrişimsel bir sinir ağıdır. VGG-16 ağı 16 katmandan oluşmaktadır ve görüntüleri klavye, fare, kurşun kalem ve birçok hayvan gibi 1.000 nesne kategorisine ayırabilir. Sonuç olarak, ağ çok çeşitli görüntüler için zengin özellik gösterimleri öğrenmiştir. VGG-16 224x224 görüntü giriş boyutuna sahiptir (Simonyan ve Zisserman, 2014). VGG-16 ağının mimarisi Şekil 3.22'de gösterilmektedir.



Şekil 3.22. VGG-16 modelinin genel mimarisi

### 3.5.2. ResNet50 Modeli

ResNet50, He ve ark. (2016) tarafından geliştirilmiştir. ResNet50 ImageNet veritabanından bir milyondan fazla resim üzerinde eğitilmiş evrişimsel bir sinir ağıdır. Ağ 50 katmandan oluşmaktadır. Görüntüleri klavye, fare, kurşun kalem ve birçok hayvan gibi 1000 nesne kategorisine ayırabilir. Bu veri setinde insan seviyesi performansını aşan %3,57'lik bir hata oranı elde etmişlerdir (He ve ark., 2016). ResNet50 ağının mimarisi Şekil 3.23' de gösterilmektedir.



Şekil 3.23. Resnet50 modelinin genel mimarisi

### 3.6. Önerilen ESA Modeli


Evrişimsel sinir ağı (ESA), derin sinir ağları modellerinden biridir. Görüntü ve video analizine yaygın olarak uygulanır. Biyolojik süreçlerden esinlenmiştir. Otomatik öğrenme alanındaki popüler algoritmalarından biridir, çünkü indirgeme boyutları sırasında görüntülerin ilişkisini sürdürme özellikleri nedeniyle, görüntülerde (piksellere katılarak kenarların oluşumu gibi) önemli özellikleri yakalamaya ve algoritma tarafından hesaplanan parametrelerin sayısını azaltarak hesaplama verimliliğini artırmaya yol açar. ESA ağları, iki veya üç boyutlu X-ray, MR, CT gibi çeşitli görüntüleri işleyebilir. Yüksek kaliteli sonuçlar ve çıktılar elde etmek için büyük miktarda veriye ihtiyaç duyar. ESA, el yazısı, yüz algılama, görüntü sınıflandırması, kayıt ve perakende gibi birçok farklı alanda kullanılır. ESA yapısı birçok katmandan

oluşur. Giriş ile başlar, çıktı ile biter ayrıca ilk ve son katman arasında birçok gizli katman vardır. Sinir ağındaki gizli katmanlar genellikle üst üste binen katmanlardan, bir havuzlama katmanından ve tam bağlı katmanlardan oluşmaktadır.

Göğüs bölgesi X-ray görüntülerinden pnömoni tespiti ve sınıflandırılması amacıyla bir ESA modeli önerilmiştir. Önerilen model 30 epoch eğitilmiştir. Giriş katmanı 150x150x3 olarak belirlenmiştir. Dropout değeri 0,2 ve öğrenme katsayısı (learning rate) 0.0001, son katmanda softmax aktivasyon kullanılmıştır. Önerilen ESA parametreleri Çizelge 3.2’de verilmiştir. Önerilen ESA modelinin genel mimarisi ise Şekil 3.24’da gösterilmektedir.

**Çizelge 3.2.** Önerilen ESA modelinin parametreleri

<b>Katman</b>	<b>Parametreler</b>	<b>Değer</b>
Giriş Katmanı	Giriş boyutu	150x150x3
Evrişimsel Katman	Filtre sayısı	16
	Filtre boyutu	3 x 3
	Aktivasyon fonksiyonları	Relu
Havuzlama Katmanı ( <i>Max pooling</i> )	Çekirdek boyutu	2 x 2
Evrişimsel Katman	Filtre sayısı	32
	Filtre boyutu	3 x 3
	Aktivasyon fonksiyonları	Relu
Havuzlama Katmanı ( <i>Max pooling</i> )	Çekirdek boyutu	2 x 2
Evrişimsel Katman	Filtre sayısı	64
	Filtre boyutu	3 x 3
	Aktivasyon fonksiyonları	Relu
Havuzlama Katmanı ( <i>Max pooling</i> )	Çekirdek boyutu	2 x 2
Evrişimsel Katman	Filtre sayısı	128
	Filtre boyutu	3 x 3
	Aktivasyon fonksiyonları	Relu
Havuzlama Katmanı ( <i>Max pooling</i> )	Çekirdek boyutu	2 x 2
Evrişimsel Katman	Filtre sayısı	64
	Filtre boyutu	3 x 3
	Aktivasyon fonksiyonları	Relu
Havuzlama Katmanı ( <i>Max pooling</i> )	Çekirdek boyutu	2 x 2
Tamamen Bağlı Katman	Nöron sayısı	64
	Aktivasyon fonksiyonları	Relu
Çıkış katmanı	Softmax	2 ( <i>Sınıf</i> )



Şekil 3.24. Önerilen ESA modelinin genel mimarisi

### 3.7. Kullanılan Yazılım ve Donanım

#### 3.7.1. Kullanılan Yazılım

Önerilen ESA ve kullanılan diğer modeller (VGG-16, ResNet50) Windows 10 işletim sistemi altında Python programlama dilinde Keras kütüphanesi kullanarak eğitilmiş ve test edilmiştir. Eğitim aşamasında CUDA paralel hesaplama ortamı kullanılmıştır. CUDA, NVIDIA GPU'lar paralel hesaplama motorundan yararlanan genel amaçlı bir paralel hesaplama platformudur. Böylece GPU'nun paralel işlem yeteneğinden faydalanılmış ve eğitim sürecinin daha hızlı bir şekilde yapılması amaçlanmıştır.

#### 3.7.2. Kullanılan Donanım

Deneysel çalışmalar, Intel Core i7 2,20 Ghz işlemci, 16GB RAM, NVIDIA Geforce GTX 1060 GPU (6GB GPU RAM) donanıma sahip bilgisayar ortamında gerçekleştirilmiştir. ESA'ların eğitim aşamasında işlem yükü çok fazla olduğundan dolayı geliştirilen kodların sadece işlemci (CPU) üzerinde çalışması yerine grafik işlemci (GPU) üzerinde çalıştırılması eğitim aşamasında zaman açısından avantaj sağlamıştır.

### 3.8. Performans Ölçütleri

Karşılık matrisi veri setinde var olan durum ile sınıflandırma modeli tarafından tahmin edilen durumun gösterildiği bir matristir. İkili sınıflandırma problemlerinde pozitif ve negatif olmak üzere iki durum söz konusudur. Buna göre 2x2'lik bir karşılık matrisi Çizelge 3.3.'de verilmiştir. Gerçek durumlar veri setinde uzmanlar tarafından

belirlenmiş durumlardır ve doğru olarak kabul edilirler. Tahmin ise sınıflandırma modeli tarafından üretilen sonuçları temsil eder (Babaoğlu, 2010).

Çizelge 3.3. Karşılıklı Matrisi

		GERÇEK	
		<i>Pozitif</i>	<i>Negatif</i>
TAHMİN	<i>Pozitif</i>	Gerçek Pozitif (GP)	Yanlış Pozitif (YP)
	<i>Negatif</i>	Yanlış Negatif (YN)	Gerçek Negatif (GN)

**Gerçek Pozitif (GP)** : Veri setinde pozitif olan verilerin sınıflandırıcı tarafından pozitif olarak tahmin edilmesidir.

**Yanlış Pozitif (YP)** : Veri setinde negatif olan verilerin sınıflandırıcı tarafından pozitif olarak tahmin edilmesidir.

**Yanlış Negatif (YN)** : Veri setinde pozitif olan verilerin sınıflandırıcı tarafından negatif olarak tahmin edilmesidir.

**Gerçek Negatif (GN)** : Veri setinde negatif olan verilerin sınıflandırıcı tarafından negatif olarak tahmin edilmesidir.

Duyarlılık, özgüllük ve doğruluk ikili sınıflandırma testinin performansını değerlendirmede yaygın olarak kullanılan istatistiksel ölçümlerdir(Santra ve Christy, 2012).

**Duyarlılık** : Veri setinde hasta olarak etiketli verilerin sınıflandırıcı tarafından pozitif olarak sınıflandırma olasılığıdır ve Eşitlik 3.12 kullanılarak hesaplanır.

$$\text{Duyarlılık} = \frac{GP}{GP + YN} \quad (3.12)$$

**Özgüllük** : Veri setinde sağlıklı (hasta olmayan) olarak etiketli verilerin sınıflandırıcı tarafından negatif olarak sınıflandırma olasılığıdır ve Eşitlik 3.13 kullanılarak hesaplanır.

$$\text{Özgüllük} = \frac{GN}{GN + YP} \quad (3.13)$$

**Doğruluk** : Veri setinde hasta olarak etiketli verilerin sınıflandırıcı tarafından hasta (pozitif) olarak, sağlıklı olarak etiketli verilerin de sağlıklı (negatif) olarak sınıflandırma olasılığıdır ve Eşitlik 3.14 kullanılarak hesaplanır.

$$\text{Doğruluk} = \frac{GP + GN}{GP + YP + GN + YN} \quad (3.14)$$



## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

### 4.1. Araştırma Sonuçları

Bu çalışmada göğüs bölgesi X-ray görüntülerinden pnömoni tespiti amacıyla 3 farklı ESA modelinin performansı incelenmiştir. Veri tabanında 5.840 adet X-ray görüntüsü bulunmaktadır. Veri setinde 5.216 resim eğitim, 624 resim ise test seti olarak ayrılmıştır. Eğitim setinde yer alan resimlerin 3.875 tanesi pnömoni, 1.341 tanesi sağlıklı ve test setinde yer alan resimlerin 390 tanesi pnömoni, 234 tanesi sağlıklı olarak etiketlenmiştir (Kermany ve ark., 2018).

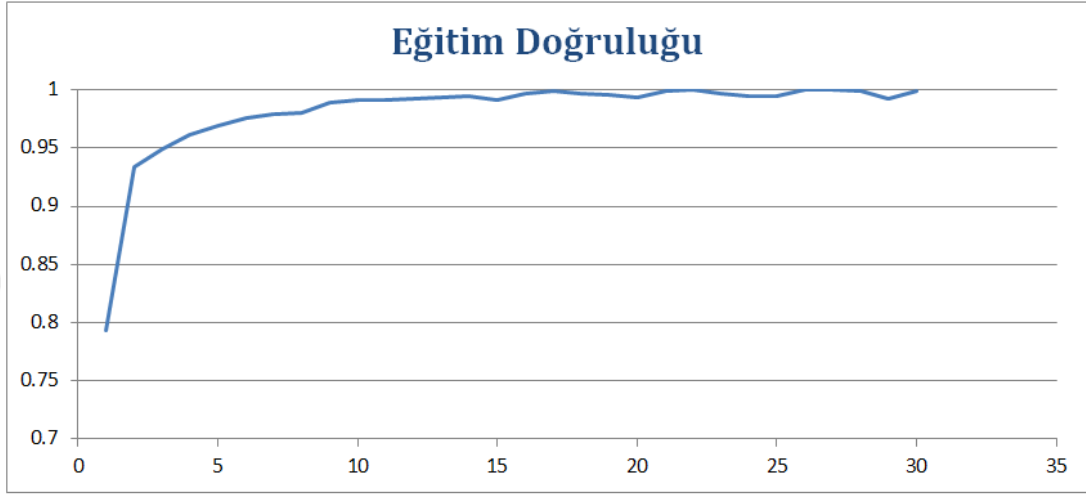
Çalışmada 5 katmandan oluşan ESA modeli, ResNet50 ve VGG-16 modellerinin başarıları incelenmiştir. Tüm modellerin eğitiminde epoch sayısı 30 olarak belirlenmiştir. Veri tabanında yer alan görüntüler farklı boyutlarda bulunmaktadır. Bu nedenle ilk olarak tüm görüntüler 150 x 150 x 3 boyutuna yeniden boyutlandırılmıştır ve resimlerin piksel değerleri 255'e bölünerek 0-1 aralığına normalize edilmiştir. Bunun yanında ResNet50 ve VGG-16 modellerinin girişleri 224x224 boyutundadır. Veri setindeki resimlerin boyutları göz önünde bulundurularak bu modeller, girişleri 150x150x3 ve çıkışları ise 2 olacak şekilde yeniden yapılandırılmıştır.

Eğitim setinde bulunan veri sayısı modellerin başarısı üzerinde etkilidir. Veri sayısının az olması durumunda veri çoğaltma teknikleri yardımıyla verilerin sayısı sentetik olarak artırılabilir. Veri çoğaltma işleminin modellerin başarılarına etkilerini gözlemek amacıyla tüm modeller veri artırımı yapılmadan ve veri artırımı yapılarak eğitilmiş, test verilerinin değerlendirilmesinde başarıları incelenmiştir. Veri artırmada kullanılan Keras kütüphanesine ait parametreler aşağıda verilmiştir.

Yatay Kaydırma (*width\_shift*) : 0,2  
 Dikey Kaydırma (*height\_shift*) : 0,2  
 Yatay Döndürme (*horizontal\_flip*) : true  
 Yakınlaştırma Oranı (*zoon\_range*) : 0,2  
 Kırpma Oranı (*shear\_range*) : 0,2

#### 4.1.1. 5 Katmanlı ESA Modeli Sonuçları

Eğitim setinde bulunan resimlere veri çoğaltma işlemi yapılmadan kullanıldığı, 5 katmandan oluşan ESA modeline ait eğitim doğruluğu grafiği Şekil 4.1'de gösterilmiştir.



Şekil 4.1. 5 katmandan oluşan ESA modeline ait eğitim doğruluğu (Veri çoğaltma yok)


Şekil 4.1 incelendiğinde eğitim doğruluğunun %99,95 olduğu görülmektedir. Bu model için test doğruluğu ise %82,85 olarak belirlenmiştir. Test verileri için karşıtlık matrisi Çizelge 4.1'de verilmiştir.

Çizelge 4.1. 5 katmandan oluşan ESA modelinde test verileri için karşıtlık matrisi (Veri çoğaltma yok)

		Gerçek değer	
		Hasta	Sağlıklı
Tahmin edilen değer	Hasta	386	103
	Sağlıklı	4	131

Çizelge 4.1 incelendiğinde bu modelde 390 hasta görüntüsünden 386 tanesi hasta olarak 4 tanesi sağlıklı olarak sınıflandırılmıştır. Benzer şekilde 234 sağlıklı görüntüden 131'i sağlıklı, 103 tanesi ise hasta olarak sınıflandırılmıştır. Buna göre bu modele ait duyarlılık değeri %98,97, özgüllük değeri %55,98 ve doğruluk değeri %82,85 olarak hesaplanmıştır.

Eđitim setinde bulunan resimlere veri ođaltma iřlemi uygulandıktan sonra kullanıldıđı, 5 katmandan oluřan ESA modeline ait eđitim dođruluđu grafiđi Őekil 4.2’de gsterilmiřtir.



Őekil 4.2. 5 katmandan oluřan ESA modeline ait eđitim dođruluđu (Veri ođaltma uygulandı)

Őekil 4.2 incelendiđinde eđitim dođruluđunun %94,46 olduđu grlmektedir. Bu model iin test dođruluđu ise %92,15 olarak belirlenmiřtir. Test verileri iin karřıtlık matrisi izelge 4.2’de verilmiřtir.


izelge 4.2. 5 katmandan oluřan ESA modelinde test verileri iin karřıtlık matrisi (Veri ođaltma uygulandı)

		Gerek deđer	
		Hasta	Sađlıklı
Tahmin edilen deđer	Hasta	367	26
	Sađlıklı	23	208

izelge 4.2 incelendiđinde bu modelde 390 hasta grntsnden 367 tanesi hasta olarak 23 tanesi sađlıklı olarak sınıflandırılmıřtır. Benzer Őekilde 234 sađlıklı grntden 208’i sađlıklı, 26 tanesi ise hasta olarak sınıflandırılmıřtır. Buna gre bu modele ait duyarlılık deđerı %94,10, zgllk deđerı %88,88 ve dođruluk deđerı %92,15 olarak hesaplanmıřtır.

#### 4.1.2. Resnet50 Modeli Sonuçları

Eğitim setinde bulunan resimlere veri çoğaltma işlemi yapılmadan kullanıldığı, Resnet50 modeline ait eğitim doğruluğu grafiği Şekil 4.3’de gösterilmiştir.



Şekil 4.3. Resnet50 modeline ait eğitim doğruluğu (Veri çoğaltma yok)


Şekil 4.3 incelendiğinde eğitim doğruluğunun %98,22 olduğu görülmektedir. Bu model için test doğruluğu ise %82,53 olarak belirlenmiştir. Test verileri için karşıtlık matrisi Çizelge 4.3’de verilmiştir.

Çizelge 4.3. Resnet50 modelinde test verileri için karşıtlık matrisi (Veri çoğaltma yok)

		Gerçek değer	
		Hasta	Sağlıklı
Tahmin edilen değer	Hasta	387	106
	Sağlıklı	3	128

Çizelge 4.3 incelendiğinde bu modelde 390 hasta görüntüsünden 387 tanesi hasta olarak 3 tanesi sağlıklı olarak sınıflandırılmıştır. Benzer şekilde 234 sağlıklı görüntüden 128’i sağlıklı, 106 tanesi ise hasta olarak sınıflandırılmıştır. Buna göre bu modele ait duyarlılık değeri %99,23, özgüllük değeri %54,70 ve doğruluk değeri %82,53 olarak hesaplanmıştır.

Eğitim setinde bulunan resimlere veri çoğaltma işlemi uygulandıktan sonra kullanıldığı, Resnet50 modeline ait eğitim doğruluğu grafiği Şekil 4.4’de gösterilmiştir.



Şekil 4.4. Resnet50 modeline ait eğitim doğruluğu (Veri çoğaltma uygulandı)

Şekil 4.4 incelendiğinde eğitim doğruluğunun %95,17 olduğu görülmektedir. Bu model için test doğruluğu ise %88,30 olarak belirlenmiştir. Test verileri için karşıtlık matrisi Çizelge 4.4’de verilmiştir.


Çizelge 4.4. Resnet50 modelinde test verileri için karşıtlık matrisi (Veri çoğaltma uygulandı)

		Gerçek değer	
		Hasta	Sağlıklı
Tahmin edilen değer	Hasta	361	44
	Sağlıklı	29	190

Çizelge 4.4 incelendiğinde bu modelde 390 hasta görüntüsünden 361 tanesi hasta olarak 29 tanesi sağlıklı olarak sınıflandırılmıştır. Benzer şekilde 234 sağlıklı görüntüden 190’i sağlıklı, 44 tanesi ise hasta olarak sınıflandırılmıştır. Buna göre bu modele ait duyarlılık değeri %92,56 özgüllük değeri %81,19 ve doğruluk değeri %88,30 olarak hesaplanmıştır.

#### 4.1.3. VGG-16 Modeli Sonuçları

Eğitim setinde bulunan resimlere veri çoğaltma işlemi yapılmadan kullanıldığı, VGG-16 modeline ait eğitim doğruluğu grafiği Şekil 4.5’de gösterilmiştir.



Şekil 4.5. VGG-16 modeline ait eğitim doğruluğu (Veri çoğaltma yok)


Şekil 4.5 incelendiğinde eğitim doğruluğunun %97,16 olduğu görülmektedir. Bu model için test doğruluğu ise %80,92 olarak belirlenmiştir. Test verileri için karşıtlık matrisi Çizelge 4.5’de verilmiştir.

Çizelge 4.5. VGG-16 modelinde test verileri için karşıtlık matrisi (Veri çoğaltma yok)

		Gerçek değer	
		Hasta	Sağlıklı
Tahmin edilen değer	Hasta	387	116
	Sağlıklı	3	118

Çizelge 4.5 incelendiğinde bu modelde 390 hasta görüntüsünden 387 tanesi hasta olarak 3 tanesi sağlıklı olarak sınıflandırılmıştır. Benzer şekilde 234 sağlıklı görüntüden 118’i sağlıklı, 116 tanesi ise hasta olarak sınıflandırılmıştır. Buna göre bu modele ait duyarlılık değeri %99,23, özgüllük değeri %50,42 ve doğruluk değeri %80,92 olarak hesaplanmıştır.

Eđitim setinde bulunan resimlere veri ođaltma iřlemi uygulandıktan sonra kullanıldıđı, VGG-16 modeline ait eđitim dođruluđu grafiđi Őekil 4.6'de gsterilmiřtir.



Őekil 4.6. VGG-16 modeline ait eđitim dođruluđu (Veri ođaltma uygulandı)

Őekil 4.6 incelendiđinde eđitim dođruluđunun %93,10 olduđu grlmektedir. Bu model iin test dođruluđu ise %88,30 olarak belirlenmiřtir. Test verileri iin karřıtlık matrisi izelge 4.6'de verilmiřtir.

izelge 4.6. VGG-16 modelinde test verileri iin karřıtlık matrisi (Veri ođaltma uygulandı)

		Gerek deđer	
		Hasta	Sađlıklı
Tahmin edilen deđer	Hasta	374	57
	Sađlıklı	16	177

izelge 4.6 incelendiđinde bu modelde 390 hasta grntsnden 374 tanesi hasta olarak 16 tanesi sađlıklı olarak sınıflandırılmıřtır. Benzer Őekilde 234 sađlıklı grntden 177'i sađlıklı, 57 tanesi ise hasta olarak sınıflandırılmıřtır. Buna gre bu modele ait duyarlılık deđer i %95,89 , zgllk deđer i %75,64 ve dođruluk deđer i %88,30 olarak hesaplanmıřtır.

Eđitim setinde yer alan verilere veri ođaltma teknikleri uygulanmadan ve veri ođaltma teknikleri uygulandıktan sonra eđitimi yapılmıř ve test verileri üzerindeki bařarı oranları hesaplanmıřtır. Elde edilen bařarı oranları izelge 4.7'de verilmiřtir. Buna gre test verileri üzerinde en yksek bařarı oranı %92,15 olarak, 5 katmanlı ESA modelinde eđitim setindeki verilere veri ođaltma uygulandıktan sonra yapılan eđitimde elde edilmiřtir.

Çizelge 4.7. Kullanılan modellerin test başarı oranları

Model	<i>Eğitim seti verilerine veri çoğaltma işlemi uygulanmadan</i>	<i>Eğitim seti verilerine veri çoğaltma işlemi uygulanarak</i>
<b>5 katmanlı ESA</b>	%82,85	%92,15
<b>Resnet50</b>	%82,53	%88,30
<b>VGG-16</b>	%80,92	%88,30

Çizelge 4.7 incelendiğinde eğitim setindeki verilere veri çoğaltma işlemi uygulandıktan sonra modellerin test başarılarının arttığı gözlenmiştir. Eğitim setine veri çoğaltma işlemi uygulanmadan yapılan denemede en başarılı model %82,85 başarı oranı ile 5 katmanlı ESA modeli olmuştur. Eğitim setine veri çoğaltma işlemi uygulandıktan sonra yapılan denemede de en başarılı model %92,15 test başarıları ile 5 katmanlı ESA modeli olmuştur.

Livieris ve ark. (2019), aynı veri setinde bazı danışmanlı eğitim algoritmalarının, A New Weighted Voting Ensemble Self-Labeled Algorithm (WvEnSL3), Voting Algorithm (Voting), k-nearest neighbors algorithm (3NN), C4.5 algoritması (C4.5) ve Sequential Minimal Optimization (SMO) başarılarını incelemişlerdir. Bu çalışmanın ve kullanılan modellerin sınıflandırma doğrulukları Çizelge 4.8'de verilmiştir. Buna göre başarıları en düşük algoritma %74,51 ile 3NN algoritması, başarıları en yüksek model ise eğitim setindeki verilere veri çoğaltma uygulandıktan sonra eğitimin yapıldığı 5 katmanlı ESA modelinde %92,15 olarak bulunmuştur.

Çizelge 4.8 Bazı danışmanlı eğitim algoritmalarının başarı oranları

Kullanılan Model	Test Doğruluğu
SMO*	76,76%
C4.5*	74,83%
3NN*	74,51%
Voting*	76,12%
WvEnSL3*	83,49%
5 katmanlı ESA modeli	92,15%
Resnet50	88,30%
VGG-16	88,30%

\* Livieris ve ark., (2019)'dan alınmıştır.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Hastalıkların teşhisinde hekimler çok farklı görüntüleme tekniklerinden yararlanmaktadır. X-ray görüntüleme tekniği diğer tıbbi görüntüleme tekniklerine (MRI, BT, ultrason vb.) göre daha hızlı ve ucuz bir görüntüleme tekniğidir. Akciğerde oluşan pek çok hastalık ve anomalinin tespitinde X-ray görüntüleme tekniğinden sıklıkla yararlanılmaktadır. X-ray görüntülerinin manuel olarak incelenmesi zaman alıcı ve uzmanlık gerektiren bir işlemdir. BDT sistemleri X-ray görüntülerinin değerlendirilmesinde hekimlere yardımcı olarak kullanılabilir.

Bu çalışmada göğüs bölgesinden çekilen X-ray görüntüleri kullanarak sağlıklı ve pnömoni hastalıklı görüntülerin sınıflandırılması amaçlanmıştır. Görüntüler Guangzhou'daki Guangzhou Kadın ve Çocuk Tıp Merkezi'nden 1 ile 5 yaş arası pediatrik hastalardan seçilmiştir (Kermany ve ark., 2018). Veri setinde 5.840 görüntü bulunmaktadır. Bunların 5.216 tanesi eğitim seti, 624 tanesi ise test seti olarak ayrılmıştır. Görüntülerin sınıflandırılmasında 5 katmanlı ESA modeli, Resnet50 ve VGG-16 ESA modellerinin sınıflandırma başarıları incelenmiştir. ESA'ların eğitiminde yüksek sayıda eğitim verisinin olması istenir. Yüksek sayıda eğitim verisinin olmadığı durumlarda veri çoğaltma yöntemleri kullanılarak eğitim setindeki verilerin artırılması sağlanabilir. Çalışma kapsamında ele alınan 3 ESA modeli eğitim setinin orijinal hali ve artırılmış verilerle ayrı ayrı eğitilmiş ve veri artırma işleminin test başarısını olumlu etkilediği gözlenmiştir. Elde edilen sonuçlar ayrıca literatürde yer alan bazı danışmanlı eğitim algoritmalarının başarıları ile karşılaştırılmıştır.

VGG-16 ve ResNet50 modelleri daha önce farklı problemler için geliştirilmiş modellerdir. Giriş ve çıkış boyutları bu probleme uygun olarak değiştirilmiştir. Bu işlem transfer öğrenmesi olarak isimlendirilmektedir.

Sonuçları incelendiğinde 5 katmanlı ESA modelinin test seti için %92,15 olarak en yüksek sınıflandırma başarısına ulaştığı görülmektedir. ESA modellerinin sınıflandırma başarılarının diğer bazı danışmanlı eğitim algoritmalarına göre daha yüksek olduğu görülmektedir.

### 5.2. Öneriler

Bilindiği üzere eğitim setindeki verilerin sayısı kullanılan makine öğrenmesi yöntemlerinin başarısına doğrudan etki etmektedir. Daha geniş veri setleri kullanılarak

modellerin başarılarına etkisi incelenebilir. Benzer şekilde epoch sayısının artması eğitim başarısını etkilemektedir. Farklı epoch sayılarında eğitim yaparak bu etki incelenebilir. Literatürde yer alan Alexnet, Googlenet gibi modern ESA modellerinin başarılarını incelemek literatüre katkı sağlayabilir. Bu çalışmada X-ray görüntüleme tekniğiyle elde edilen görüntüler kullanılmıştır. Farklı görüntüleme teknikleri ile elde edilen görüntüler ile farklı hastalıkların tespiti amacıyla benzer çalışmalar yapılabilir.



## KAYNAKLAR

- Alencar, G., Caloba, L. ve Assis, M., 2003, Artificial neural networks as rain attenuation predictors in earth-space paths, *Proceedings of the 2003 International Symposium on Circuits and Systems, 2003. ISCAS'03*.
- Anonymous, 2017, Google Brain, *quartz*. <https://qz.com/954530/> ErişimTarihi [25/01/2018]
- Anonymous, 2018, Types of Neural Network Activation Functions, *Neural Network Concepts*. <https://missinglink.ai/guides/neural-network-concepts/7-types-neural-network-activation-functions-right/>. ErişimTarihi [10/01/2018]
- Anonymous, 2019, Back Propagation Neural Network: Explained With Simple Example, *Guru*. <https://www.guru99.com/backpropogation-neural-network.html>. ErişimTarihi [ 22.01.2018]
- Antin, B., Kravitz, J. ve Martayan, E., 2019, Detecting Pneumonia in Chest X-Rays with Supervised Learning., *Semanticscholar*, <https://pdfs.semanticscholar.org/> ErişimTarihi [07.05.2017]
- Bar, Y., Diamant, I., Wolf, L. ve Greenspan, H., 2015, Deep learning with non-medical training used for chest pathology identification, *Medical Imaging 2015: Computer-Aided Diagnosis*, Vol. 9414, p. 94140V.
- Babaoğlu, İ., 2010, Koroner arter hastalığı ve lezyon lokalizasyonu tahminlerinde efor stres testinin yapay zeka yöntemleri ile değerlendirilmesi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.
- Bourcier, J., Paquet, J., Seinger, M., Gallard, E., Redonnet, J., Cheddadi, F., Garnier, D., Bourgeois, J. ve Geeraerts, T., 2014, Performance comparison of lung ultrasound and chest x-ray for the diagnosis of pneumonia in the ED, *American Journal of Emergency Medicine*, 32 (2), 115-118.
- Brown, M., Wilson, L., Doust, B., Gill, R., Sun, C. ve graphics, E. 1998, Knowledge-based method for segmentation and analysis of lung boundaries in chest X-ray images, *Computerized Medical Imaging and Graphics*, 22 (6), 463-477.
- Chen, C., Lee, Y., Huang, Y., Lan, W., Chang, R., Tu, C., Chen, C. ve Liao, W., 2019, Computer-aided diagnosis of endobronchial ultrasound images using convolutional neural network, *Computer Methods and Programs in Biomedicine*, 177, 175-182.

- Çalli, E., 2017, Faster Convolutional Neural Networks, *Nederlands Educational Repository*. <https://theses.uibn.ru.nl/handle/123456789/5233> ErişimTarihi [03.04.2017]
- Dumoulin, V. ve Visin, F., 2016, A guide to convolution arithmetic for deep learning, *arXiv*. <https://arxiv.org/abs/1603.07285>. ErişimTarihi [07.01.2017]
- Deepak, S. ve Ameer, P., 2019, Brain tumor classification using deep CNN features via transfer learning, *Computers in Biology and Medicine*, 111, 103345.
- Fujita, H. ve Cimr, D., 2019, Computer aided detection for fibrillations and flutters using deep convolutional neural network, *Information Sciences*, 486, 231-239.
- Fei-Fei, L., Deng, J. ve Li, K., 2009, ImageNet: constructing a large-scale image database, *Journal of Vision*, 1037-1037.
- Fukushima, K., 1980, Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological Cybernetics*, 36 (4), 193-202.
- Ganeshan, A., 2017, Per-Pixel Feedback for improving Semantic Segmentation. *arXiv preprint arXiv,1712.02861*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), 1904-1916.
- He, K., Zhang, X., Ren, S. and Sun, J., 2016. Deep residual learning for image recognition. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. p 770-778.
- Hochreiter, S. ve Schmidhuber, J., 1997, Long short-term memory, *Neural Computation*, 9 (8), 1735-1780.
- Hsu, J., Lu, P. ve Khosla, K., 2019, Predicting Thorax Diseases with NIH Chest X-Rays. *Department of Computer Science and Department of Mathematics Stanford University*. 1901.11210
- Hubel, D. ve Wiesel, T., 1959, Receptive fields of single neurones in the cat's striate cortex, *The Journal of Physiology*, 148 (3), 574-591.
- He, K., Girshick, R. ve Dollár, P., 2018, Rethinking imagenet pre-training. *arXiv preprint arXiv,1811.08883*.
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S. ve Darrell, T., 2014, Caffe: Convolutional architecture for fast feature

- embedding, *Proceedings of the 22nd ACM International Conference on Multimedia*, Orlando, Florida, USA. P 675-678.
- Jing Li, Y., Nanyan Shen, 2019, A fully automatic computer-aided diagnosis system for hepatocellular carcinoma using convolutional neural networks, *Biocybernetics and Biomedical Engineering*. P1–11
- Johannes Fürnkranz, J., 2016, Using Convolutional Neural Networks to distinguish vehicle pose and vehicle class, *Fachbereich Informatik Knowledge Engineering Group*, P 33-99.
- Karargyris, A., Antani, S. ve Thoma, G., 2011, Segmenting anatomy in chest x-rays for tuberculosis screening, *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, P 7779-7782.
- Klep, D., 2016, Data augmentation of a handwritten character dataset for a Convolutional Neural Network and integration into a Bayesian Linear Framework. *Radboud University, Nijmegen*.  
<https://theses.ubn.ru.nl/handle/123456789/2620> Erişim Tarihi [18/01/2018]
- Kermany, D., Goldbaum, M., Cai, W., Valentim, C., Liang, H., Baxter, S., McKeown, A., Yang, G., Wu, X. ve Yan, F., 2018, Identifying medical diagnoses and treatable diseases by image-based deep learning, *Cell*, 172 (5), 1122-1131.
- Keskinel, İ., 2015, Türkiye'de yılda 3 bin kişi zaturreden oluyor, *ntv sađl*.  
<https://www.ntv.com.tr/saglik/turkiyede-yilda-3-bin-kisi-zaturreden-oluyor,tQG4qp1St02L67T3WfMyQA>. Erişim Tarihi [03.04.2018]
- Krizhevsky, A., Sutskever, I. ve Hinton, G., 2012, Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, P 1097-1105.
- Kröse, B., Krose, B., van der Smagt, P. ve Smagt, P., 1993, An introduction to neural networks, *Cite Seerx*. P 18-135
- Kukacka, M., 2011, Neocognitron: A Survey of a Classical Hybrid Neural Network Model, *WDS'11 Proceedings of Contributed Papers*, P 112-118.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- LeCun, Y., Bengio, Y. ve Hinton, G. J. n., 2015, Deep learning, *Nature*, 521, (7553), 436.

- Livieris, I., Kanavos, A., Tampakas, V. ve Pintelas, P., 2019, A Weighted Voting Ensemble Self-Labeled Algorithm for the Detection of Lung Abnormalities from X-Rays, *Algorithms*, 12 (3), P 64.
- Laak, J., 2017, "Computer-aided Diagnosis: The Tipping Point for Digital Pathology, *Digital Pathology Association*.
- Martins, A. ve Astudillo, R., 2016, From softmax to sparsemax: A sparse model of attention and multi-label classification, *International Conference on Machine Learning*, Lisboa, Portugal. P 1614-1623.
- Murphy, J., 2016, An Overview of Convolutional Neural Network Architectures for Deep Learning, *Microway*. P 8-22
- Nwankpa, C., Ijomah, W., Gachagan, A. ve Marshall, S., 2018, Activation functions: Comparison of trends in practice and research for deep learning, *arXiv*. <https://arxiv.org/abs/1811.03378>. ErişimTarihi [07.012.2018].
- Özkan, İ. ve Ülker, E., 2017 Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Park, M., Jin, J. S. ve Wilson, L. S., 2004, Detection of abnormal texture in chest X-rays with reduction of ribs, *Proceedings of the Pan-Sydney Area Workshop on Visual Information Processing*, P 71-74.
- Pascanu, R., Gulcehre, C., Cho, K. ve Bengio, Y., 2013, How to construct deep recurrent neural networks, *arXiv preprint arXiv*. <https://arxiv.org/abs/1312.6026> ErişimTarihi [06.06.2018].
- Platt, J., (1999), Fast training of support vector machines using sequential minimal optimization. In *Advances in kernel methods: support vector learning*, MIT Press., P 185– 208.
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M., Shyu, M., Chen, S. ve Iyengar, S., 2018, A survey on deep learning: Algorithms, techniques, and applications, *ACM Computing Surveys* ,51 (5), 92.
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G. ve Antani, S., 2018, Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs, *Applied Sciences*, 8 (10), 1715.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C. ve Shpanskaya, K., 2017, Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning, *arXiv preprint arXiv*. 1711.05225

- Ramachandran, P., Zoph, B. ve Le, Q., 2017, Searching for activation functions, *arXiv preprint arXiv:1710.05941*.
- Rahman, J., 2005, Knowledge-based trade, technical change and location environment: the case of small and medium sized enterprises engaged in advanced producer software services in the South East region, *University College London*. P 1228
- Ranganathan, V. ve Natarajan, S., 2018, A new backpropagation algorithm without gradient descent. *arXiv preprint arXiv:1802.00027*
- Riedmiller, M. ve Braun, H., 1993, A direct adaptive method for faster backpropagation learning: The RPROP algorithm, *Proceedings of the IEEE International Conference on Neural Networks*, 586-591.
- Raghavendra, U., Fujita, H., Bhandary, S., Gudigar, A., Tan, J. ve Acharya, U. R., 2018, Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images, *Information Sciences*, P 441, 41-49.
- Rosenblatt, F., 1960, Perceptron simulation experiments, 48 (3), 301-309.
- Sallam, M., 2018, Deep Structure Based On Convolutional Neural Networks For Identification Of Chest Diseases, *Near East University*.
- Santra, A. ve Christy, C. J., 2012, Genetic algorithm and confusion matrix for document clustering, *International Journal of Computer Science Issues (IJCSI)*, 9 (1), 322.
- Schölkopf, B., Burges, C. ve Vapnik, V., 1996, Incorporating invariances in support vector learning machines, *International Conference on Artificial Neural Networks*, P 47-52.
- Schmidhuber, J., 2015, Deep learning in neural networks: An overview, *Neural Networks*, 61, P 85-117.
- Shen, D., Wu, G. ve Suk, H., 2017, Deep learning in medical image analysis, *Annual Review of Biomedical Engineering*, 19, P 221-248.
- Sibi, P., Jones, S., Siddarth, P. ve Technology, A., 2013, Analysis of different activation functions using back propagation neural networks, *Journal of Theoretical and Applied Information Technology*, 47 (3), 1264-1268.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv*, 1409.1556.
- Sinha, R., Lee, S., Rim, M. ve Hwang, S., 2019, Data Augmentation Schemes for Deep Learning in an Indoor Positioning Application, *Electronics*, 8 (5), 554.

- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research* , 15 (1), 1929-1958.
- Stephen, O., Sain, M., Maduh, U. ve Jeong, D., 2019, An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare, 2019. *Journal of Healthcare Engineering*, 4180949, P7
- Suzuki, K. ve Surgery, 2012, A review of computer-aided diagnosis in thoracic and colonic imaging, *Quant Imaging Med Surg.* 2 (3), 163.
- Tataru, C., Shenoyas, A. ve Ma, A., 2017, Deep Learning for abnormality detection in Chest X-Ray images, June. *Stanford University Computer Science*, P1-7
- Torrey, L., Shavlik, J., Walker, T. ve Maclin, R., 2010, Transfer learning via advice taking, *In Advances in Machine Learning*, P 147-170.
- Zhu, Y., ve ark. 2019, Application of convolutional neural network in the diagnosis of the invasion depth of gastric cancer based on conventional endoscopy, *Gastrointestinal Endoscopy*, 89 (4), 806-815.
- Yeager, L., Bernauer, J., Gray, A. ve Houston, M., 2015, DIGITS: the deep learning GPU training system, *ICML 2015 AutoML Workshop*. 95050.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Husham Salah Al Deen Omar OMAR  
**Uyruğu** : Irak  
**Doğum Yeri ve Tarihi** : Kerkük, 28.04.1989  
**Telefon** : 00905393123720, 009647702325441  
**Faks** :  
**e-mail** : husham.s.o.89@gmail.com

### EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: El-hikme Lisesi, Irak, Kerkük	2008
Üniversite	: Al-Qalem Üniversitesi, Irak, Kerkük	2014
Yüksek Lisans	: Selçuk Üniversitesi Bilgisayar Mühendisliği, Konya	Devam ediyor
Doktora	:	

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
-----	-------	--------

### UZMANLIK ALANI

**YABANCI DİLLER** : İngilizce, Türkçe

### BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

### YAYINLAR

H. S. Omar ve A. Babalık, 2019, Detection of Pneumonia from X-Ray Images using Convolutional Neural Network, *International Conference on Data Science, Machine Learning and Statistics - 2019 (DMS-2019)*,p:183-185.