



T.C.  
NECMETTİN ERBAKAN NİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



**DERİN ÖĞRENME İLE GÖĞÜS  
RÖNTGENLERİNDEN HASTALIK TEŞHİSİ**

Mahmut Sami TERZİ

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Kasım-2021  
KONYA  
Her Hakkı Saklıdır**

## ÖZET

### YÜKSEK LİSANS TEZİ

## DERİN ÖĞRENME İLE GÖĞÜS RÖNTGENLERİNDEN HASTALIK TEŞHİSİ

**Mahmut Sami TERZİ**

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman: Doç.Dr. Mehmet HACİBEYOĞLU**

**2021, 62 Sayfa**

**Jüri**

**Prof.Dr. Halife KODAZ**

**Doç.Dr. Mehmet HACİBEYOĞLU**

**Dr.Öğr. Üyesi Ayşe Merve ACILAR**

Tıpta erken tanı dendiği zaman kişide henüz hastalık belirtisi yokken veya herhangi bir sıkıntı duymazken hastalığın tanımlanması anlaşılır. Günümüzde tıp dünyasında hastalıkların tedavisinde erken tanı önemli bir rol oynamaktadır. Çünkü erken tanı birçok hastalığın ilerlemesinin önüne geçen çok önemli bir adımdır. Hastalıkta tanı ne kadar erken konulursa tedavinin başarısı da buna bağlı olarak artmaktadır. Ayrıca tedavi için kişiye ve doktora zaman kazandırmaktadır. Binlerce insanın sağlığını etkileyen göğüs hastalıklarının teşhisi için göğüs röntgenlerini kullanmak halen en iyi yöntemdir. Fakat uzman radyolog sayısının yeterli olmayışı raporların okunmasında ciddi zaman kaybına neden olmaktadır. Bu durum, göğüs röntgenlerine teşhis koyabilecek bir bilgisayar sistemine ihtiyaç olduğunu göstermektedir.

Bu tezin konusu olan çalışma, bu alandaki ihtiyacı gidermeye çalışacak derin öğrenme tabanlı bir konvolüsyonel sinir ağı modeli ortaya koymaktır. Tez çalışmasında geliştirilen konvolüsyonel sinir ağı ve literatürde sıklıkla kullanılan önceden eğitilmiş hazır modeller ulusal sağlık enstitülerinin yayınladığı 30.805 farklı hastanın 112.120 adet önden görünümü göğüs röntgeninden oluşan Chest X-ray14 veri seti kullanılarak eğitilmiştir. Veri setindeki röntgenler 14 farklı göğüs hastalığının bir ya da bir kaçını veya sağlıklı bir bireyi temsil etmektedir. Bu açıdan bakıldığında çözülmek istenen problem çoklu etiket sınıflandırma problemidir. Keras kütüphanesinde, python programlama dili kullanılarak geliştirilen model ve hazır modeller ile yapılan deneysel çalışmalarda literatüre oranla daha başarılı sonuçlar elde edilmiştir.

**Anahtar Kelimeler:** Derin Öğrenme, Göğüs Hastalıkları, Göğüs Röntgeni, Hastalık Teşhisi, Konvolüsyonel Sinir Ağı, Makine Öğrenmesi

## **ABSTRACT**

## **MS THESIS**

## **DIAGNOSIS FROM CHEST X-RAYS WITH DEEP LEARNING**

**Mahmut Sami TERZİ**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
NECMETTİN ERBAKAN UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE / DOCTOR OF PHILOSOPHY  
IN COMPUTER ENGINEERING**

**Advisor: Assoc.Prof. Mehmet HACIBEYOĞLU**

**2021, 62 Pages**

**Jury**

**Prof.Dr. Halife KODAZ**

**Assoc.Prof. Mehmet HACIBEYOĞLU**

**Asst.Prof. Ayşe Merve ACILAR**

When early diagnosis is mentioned in medicine, it is understood that the disease is defined when the person does not have any signs of the disease or does not have any distress. Today, early diagnosis plays an important role in the treatment of diseases in the medical world. Because early diagnosis is a very important step in preventing the progression of many diseases. The earlier the diagnosis is made, the more successful the treatment will be. It also saves time for the person and the doctor for treatment. Using chest X-rays is still the best method for diagnosing chest diseases that affect the health of thousands of people. However, the insufficient number of specialist radiologists causes a serious loss of time in reading the reports. This indicates the need for a computer system that can diagnose chest X-rays.

The study, which is the subject of this thesis, is to present a deep learning-based convolutional neural network model that will try to meet the need in this area. The convolutional neural network developed in the thesis study and pre-trained ready-made models that are frequently used in the literature were trained using the Chest X-ray14 dataset consisting of 112.120 frontal chest X-rays of 30,805 different patients published by the national health institutes. X-rays in the dataset represent one or more of 14 different chest diseases or a healthy individual. From this point of view, the problem to be solved is the multi-label classification problem. In the Keras library, more successful results were obtained in experimental studies with the model and ready-made models developed using the python programming language compared to the literature.

**Keywords:** Deep Learning, Chest Diseases, Chest X-ray, Disease Diagnosis, Convolutional Neural Network, Machine Learning

## ÖNSÖZ

Tez çalışmam sırasında yaptığı katkılar ve desteklerinden dolayı danışmanım Necmettin Erbakan Üniversitesi Bilgisayar Mühendisliği öğretim üyesi Doc. Dr. Mehmet HACIBEYOĞLU 'na ve bu süreçte sürekli olarak beni destekleyen ve teşvik eden sevgili eşime teşekkür ederim.

Mahmut Sami TERZİ

KONYA-2021



# İÇİNDEKİLER

ÖZET .....	iv
ABSTRACT.....	v
ÖNSÖZ .....	vi
İÇİNDEKİLER .....	vii
KISALTMALAR .....	ix
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Çalışmanın Amacı.....	2
1.2. Çalışmanın Önemi .....	2
1.3. Tezin Yapısı .....	3
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>4</b>
2.1. Göğüs röntgenleri üzerinde yapılan çalışmalar .....	4
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>8</b>
3.1. Göğüs Hastalıkları .....	8
3.1.1. Atelektazi ( <i>Atelectasis</i> ) .....	8
3.1.2. Kardiyomegali ( <i>Cardiomegaly</i> ) .....	8
3.1.3. Konsolidasyon ( <i>Consolidation</i> ) .....	8
3.1.4. Ödem ( <i>Edema</i> ) .....	8
3.1.5. Efüzyon ( <i>Effusion</i> ) .....	9
3.1.6. Amfizem ( <i>Emphysema</i> ) .....	9
3.1.7. Fibroz ( <i>Fibrosis</i> ) .....	9
3.1.8. Fıtık ( <i>Hernia</i> ) .....	9
3.1.9. Süzülme ( <i>Infiltration</i> ) .....	10
3.1.10. Kitle ( <i>Mass</i> ) .....	10
3.1.11. Doku Büyümesi ( <i>Nodule</i> ) .....	10
3.1.12. Plevral Kalınlaşma ( <i>Pleural Thickening</i> ) .....	10
3.1.13. Zatürre ( <i>Pneumonia</i> ).....	11
3.1.14. Akciğer Sönmesi ( <i>Pneumothorax</i> ).....	11
3.2. Sinir Ağları .....	11
3.2.1. Yapay Sinir Ağları (YSA) .....	12
3.2.2. Derin Öğrenme .....	16
3.2.2.1. Tarihçe .....	17
3.2.2.2. Derin Öğrenme Mimarileri .....	19
3.2.2.2.1. Konvolüsyonel Sinir Ağları .....	19
3.2.2.3. Hiper Parametreler .....	24
3.2.2.3.1. Aktivasyon Fonksiyonları .....	24
3.2.2.3.2. Loss Fonksiyonu .....	27
3.2.2.3.3. Öğrenme Katsayısı (Learning Rate) .....	27
3.2.2.3.4. Optimizasyon Algoritmaları .....	28

3.2.2.3.5. Seyreltme ( <i>Dropout</i> ) .....	30
3.2.2.4. Derin Öğrenme Uygulama Alanları .....	31
3.2.2.4.1. Görüntü ve Video İşleme .....	31
3.2.2.4.2. Doğal Dil İşleme .....	32
3.2.2.4.3. Biyomedikal Bilgi İşleme .....	34
3.2.2.4.4. Diğer Uygulama Alanları .....	34
3.3. Kullanılan Teknolojiler .....	35
3.3.1. Anaconda .....	35
3.3.2. Python .....	36
3.3.3. TensorFlow .....	36
3.3.4. Keras .....	37
3.4. Veri Seti .....	37
3.5. Çalışmada Kullanılan Fiziksel Donanım .....	40
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>41</b>
4.1. Ön İşlem.....	41
4.2. Eğitim, Doğrulama ve Test.....	42
4.3. Çalışmada Geliştirilen CNN Algoritması .....	42
4.4. Performans Ölçütleri.....	44
<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>53</b>
5.1 Sonuçlar .....	53
5.2 Öneriler .....	53
<b>6. KAYNAKLAR .....</b>	<b>54</b>
<b>ÖZGEÇMİŞ .....</b>	<b>Hata! Yer işareti tanımlanmamış.</b>

## KISALTMALAR

NIH	National Institutes of Health
CNN	Convolutional Neural Networks
ANN	Artificial Neural Networks
MLP	Multi Layer Perceptron
YSA	Yapay Sinir Ağları
SVM	Support Vector Machines
GPU	Graphics Processing Unit
CPU	Central Processing Unit
ReLU	Rectified Linear Unit
BGD	Batch Gradient Descent
MGD	Mini-Batch Gradient Descent
SGD	Stochastic Gradient Descent
Adam	Adaptive Moment Estimation
PACS	Picture Archiving Communication Systems

## 1. GİRİŞ

Hastalığın teşhisi (tıbbi tanı), hastadaki rahatsızlıkların doktorlar tarafından belirlenip uygun bir tedavinin uygulanması için hastanın tıbbi geçmişi göz önünde bulundurularak gerçekleşen fiziksel muayenedir.

Göğüs hastalıkları, virüs veya bakterilerin yol açtığı akut solunum yolu enfeksiyonlarıdır ve her yaşta insanda görülebilir. Bazı insanların hafif, bazılarının ise ağır şekilde geçirdiği bu hastalıklardan biri olan zatürre bile tek başına bir yılda 150 milyondan fazla insanda görülebilmektedir (Rudan ve diğ., 2004; Özlü ve diğ.,2007).

İnsan sağlığı ve yaşam kalitesini birçok farklı yönden etkileyen zatürre, kardiyomegali, fibrosis gibi göğüs hastalıkları dünyanın birçok ülkesinde ciddi sağlık sorunu ve ölüm sebepleri arasında yer almaktadır (Er ve diğ., 2010).

Göğüs hastalıklarına bağlı ölümler, erken tanı ve doğru tedavi ile önemli ölçüde azaltılabilir (Aydoğdu ve diğ., 2010). Gelişen dünyada bilgisayar tabanlı karar destek sistemleri doktorların tanı koymasında ve tedavi belirlemede önemini git gide arttırmaktadır. Yapay zekâ ve uzman sistemler gibi birçok yenilik farklı tıp branşlarında iyi birer problem çözücü olarak kullanılmaya başlanmıştır (Angeli, 2010).

Röntgen teknolojisi, vücudun çeşitli bölümlerini görüntüleyerek hastalık tespitinde yararlanan önemli bir yöntemdir. Göğüs röntgenleri hali hazırda akciğerlerdeki anormallikleri tespit edebilmek için sıkça başvurulmuş kolay erişilebilir bir tekniktir (WHO, 2001). Fakat röntgen görüntülerini yorumlayacak uzman radyolog sayılarının yetersiz oluşuna ek olarak kimi zaman yapılan hatalı sınıflandırmalar neticesinde hastalara uygulanan yanlış tedaviler hastaların durumunu daha da kötüleştirebilir (Davies ve diğ., 1996; Woolever, 2005). Ayrıca göğüs hastalıklarının çeşitliliği de doğru teşhis konulmasını önemli ölçüde zorlaştırmaktadır. Daha bunun gibi birçok neden göğüs hastalıklarının teşhis ve tedavisine yardımcı olacak bilgisayar destekli sistemlere ihtiyaç olduğunu göstermektedir.

Hastalık teşhisinde hız ve doğruluğun artması için bilgisayar destekli birçok uygulamaya başvurulmaktadır. Son yıllarda öne çıkan bu uygulamaların başında ise derin öğrenme destekli makine öğrenmesi uygulamaları gelmektedir. Günümüzde kanser ve tümör tespitinde bilgisayar destekli uygulamalardan yararlanılmaktadır (Kallianos ve diğ., 2019).

Derin öğrenme, etiketi bilinen verilerin özelliklerini öğrenerek etiketi bilinmeyen verilerin sınıflandırma ve analizini yapan bir makine öğrenmesi yaklaşımıdır. Temelinde

yapay sinir ağı bulunan derin öğrenme algoritmasında pek çok katman ile oluşturulan modeller ile çok yönlü bir öğrenme yapılmaktadır.

Bilgisayar hızlarındaki ve veri miktarlarındaki artış derin öğrenme algoritmasının başarımının da artmasını sağlamıştır. Özellikle görüntü işlemede yaygın olarak kullanılan algoritmaların başında gelen konvolüsyonel sinir ağları (*Convolutional Neural Network* – CNN) görüntü işleme alanında yapılan birçok yarışmadan galibiyetle veya iyi dereceler ile ayrılmıştır.

### **1.1. Çalışmanın Amacı**

Bu tez çalışmasında CNN algoritmaları kullanılarak göğüs röntgeni görüntüleri üzerinden göğüs hastalıklarının teşhis edilmesine yardımcı olmak amacıyla kullanılabilir bir sınıflandırma modeli oluşturulmuştur. Çalışmada önerilen CNN modelinin kodlanmasında bir Python kütüphanesi olan Keras kütüphanesi kullanılmıştır. Oluşturulan CNN modeli yardımıyla 14 farklı göğüs hastalığına ek olarak sağlık bireylerle birlikte 15 farklı sınıfa ait röntgenlerini sınıflandırılması amaçlanmıştır.

Görüntü işleme için önerilen CNN modeli, göğüs röntgen resimleri üzerinde temel derin öğrenme algoritmalarının Python tabanlı Keras kütüphanesi kullanılarak oluşturulmuştur. Ayrıca deneysel literatürde sıklıkla kullanılan ImageNet verikümesi ile eğitilmiş VGG-16 ve ResNet-152 modelleri üzerinde probleme yönelik eğitimler yapılarak önerilen CNN modeli ile karşılaştırılması gerçekleştirilmiştir.

### **1.2. Çalışmanın Önemi**

Göğüs hastalıklarında erken tanı hastalığın tedavisinin başarıya ulaşması açısından oldukça önemlidir. Son yıllarda yaşanan teknolojik gelişmelerle birlikte makine öğrenmesi ve görüntü işleme yöntemleri göğüs röntgenleri ile hastalık teşhisinde yaygın olarak kullanılan bir yöntem olmaya başlamıştır.

İnsan sağlığını ve yaşam kalitesini oldukça etkileyen birçok göğüs hastalığında erken tanı tedavinin başarıyla sonuçlanması için önemli bir etkidir. Uzman radyolog sayısının yetersiz oluşu ve kimi zaman röntgen görüntülerinin yorumlanmasında yapılan hataların önüne geçmenin en iyi yolu röntgen görüntülerinin bilgisayar destekli sistemler tarafından bir karar destek sistemi olarak yorumlanmasıdır.

Bu çalışmanın konusu olan CNN modeli bu alandaki eksiklikleri azaltmak amacıyla göğüs röntgenleri ile 14 farklı göğüs hastalığını tespit ederek hastalığın tedavisine katkı

sağlamaktadır. Geliştirilen model sayesinde uzman radyolog sayısının yetersiz olduğu durumlarda vakit kaybedilmeden hastalık tespit edilebilecek ve tedavi mümkün olan en kısa sürede başlatılabilecektir.

### **1.3. Tezin Yapısı**

Bu tez çalışması toplamda beş ana bölümden oluşmaktadır.

Birinci bölümde çalışmanın konusunu oluşturan göğüs hastalıklarının röntgen görüntülerinden tespitinde yaşanan problemler ve derin öğrenme yaklaşımından bahsedilmiştir.

İkinci bölüm olan kaynak araştırmasında ise literatürde bulunan önceki çalışmalar incelenmiştir.

Üçüncü bölüm, çalışmada sınıflandırılması amaçlanan göğüs hastalıkları, sınıflandırmada kullanılacak derin öğrenme algoritmaları ve kullanılan teknolojiler ile çalışmada kullanılan ChesXray-14 veri seti hakkında bilgiler içermektedir.

Dördüncü bölümde çalışma kapsamında oluşturulan CNN modeli ve eğitilmiş modeller veri setine uygulanmış ve yapılan test sonuçları paylaşılmıştır.

Beşinci bölümde ise elde edilen sonuçlar değerlendirilmiş, yorumlar yapılmış ve muhtemel yeni çalışmalar hakkında bilgilere verilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Göğüs röntgeni görüntülerini sınıflandırma problemi tıbbi tanı alanında uzun zamandır araştırılan ve üzerine birçok çalışma yapılan bir alandır. Yapılan araştırmalar neticesinde akciğer hastalıklarını teşhis etmek için birçok makine öğrenmesi tekniği kullanılarak çeşitli uygulamalar sunulmuştur. Sunulan bu tekniklerin önemli bir kısmı dikkate değer başarımlar elde etmişlerdir. Bu çalışmalarla ilgili yayınlanan makaleler bu bölümde verilecektir.

### 2.1. Göğüs röntgenleri üzerinde yapılan çalışmalar

Uçar, “*Akciğer Nodüllerinin Göğüs Röntgenlerinden Derin Evrişimsel Sinir Ağları Kullanılarak Bilgisayar Destekli Tespiti*” makalesinde bahsettiği Gauss Laplace filtresini (LoG) kullanarak konvolüsyonel derin öğrenme ile röntgen görüntülerinden akciğerde nodül tespit etmeyi amaçlamıştır. Çalışmasında, kamu erişimine açık olan Japon Radyoloji Teknolojileri Derneğine ait 247 göğüs röntgeni görüntüsünü kullanan Uçar, sonuçlar için Gauss Laplace filtre modeli kullanmış ve konvolüsyonel sinir ağının doğruluk değerini %82.43 olarak gözlemiştir (Uçar ve Uçar, 2019).

Akpolat ve Yalçın çalışmalarında derin öğrenme modellerini kullanarak pnömoni (zatürre) hastalığını tespit etmeyi amaçlamışlardır. Çalışmalarında Ulusal Sağlık Enstitüleri (*National Institutes of Health* (NIH))’nin kamuya açık olarak paylaştığı kapsamlı göğüs röntgeni veri seti (Chest X-ray) kullanılmıştır. CNN ve VGG-16 derin öğrenme algoritmaları incelenmiş olup çalışmada Python programlama dili kullanılmıştır (Akpolat ve Yalçın, 2019).

Wang çalışmasında, NIH klinik merkezinin paylaştığı göğüs röntgeni veri setini kullanmıştır. Veri setini, %70 eğitim, %10 validasyon ve %20 test verisi olarak ayıran Wang, yöntem olarak ilk önce Konvolüsyonel Sinir Ağları’nı (CNN) uygulamış, daha sonra ise başarı oranını arttırmak için ResNet-50 ağı üzerine yoğunlaşmıştır. ResNet-50 ile %63 başarımlar yakalamıştır (Wang ve ark., 2017).

Wang’dan sonra Li Yao da Chest X-ray veri seti üzerinde çalışma yapmıştır (Yao ve ark., 2017). Yao çalışmasında Tekrarlayan Sinir Ağı (Recurrent Neural Network - RNN) kullanmıştır. Eğitimi OpenI veri setinde eğiten Yao, aktivasyon fonksiyonu olarak Sigmoid aktivasyon fonksiyonunu kullanmıştır. Yao çalışmaları sonucunda %71 oranında başarımlar elde etmiştir.

Pranav Rajpurkar ve arkadaşları da Chest X-ray-14 veri seti üzerinde çalışmıştır. Rajpurkar, Dense Convolutional Network (DenseNet) kullanarak oluşturduğu modelini CheXNet olarak adlandırmıştır. Rajpurkar, CheXNet modelinde aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır. Ağırlık değerleri için ise ImageNet'te önceden tanımlanmış bir modelin ağırlıklarını başlangıç olarak kullanan Rajpurkar, geliştirmiş olduğu CheXNet isimli model ile %76'luk bir başarıyı elde etmeyi başarmıştır (Rajpurkar ve ark, 2017).

Gülgün ve Erol, çalışmalarında pnömoniye etkin bir şekilde teşhis etmek için kullanılan farklı derin öğrenme modellerinin göğüs röntgeni görüntülerinde performans karşılaştırması yapmışlardır. Çalışmada kullanılan veri seti, bireylerin toplam 5840 göğüs röntgen görüntüsünden oluşmaktadır. Bu verileri sınıflandırmak için üç farklı derin öğrenme modeli kullanılmıştır: Konvolüsyonel Sinir Ağı, Veri Artırmalı Konvolüsyonel Sinir Ağı ve Transfer Öğrenme. Veri setindeki görüntüler bu üç derin öğrenme modeli kullanılarak pnömoni ve sağlıklı insanlar olarak iki kategoriye ayrılmıştır. Sınıflandırmada kullanılan bu üç derin öğrenme modelinin performansları kayıp ve doğruluk açısından karşılaştırılmıştır. Çalışma sonunda en başarılı performans sonucu, %93,4'lük başarı oranı ile, veri artırma tekniği ile uygulanan konvolüsyonel sinir ağı modeli ile elde edilmiştir (Gülgün ve Erol, 2019).

Shelag, hazırlamış olduğu tezi ile normal ve anormal olan göğüs röntgenlerinin sınıflandırılmasında kullanmak amacıyla tasarlanmış, Oto-Kodlayıcı adı verilen bağımsız bir sinir ağının detaylı incelenmesini gerçekleştirmiştir. İncelemesi yapılan bu ağ, normal ve anormal röntgen filmleri üzerinde eğitilmiş ve test edilmiştir. Shelag, çalışmasında karşılaştırmalı uygulama yöntemini kullanmıştır. Çalışmada, işlenmeden veya yükseltilmeden kullanılan göğüs röntgen filmleri ile histogram dengeleme kullanılarak işlenmiş ve yükseltilmiş görseller arasındaki bağ incelenmiştir. Shelag yapmış olduğu çalışma ile Oto-Kodlayıcı'nın, normal ve anormal görünmez röntgen filmlerini teşhisinde genelleme yönünden güzel bir başarı elde ettiği ortaya koymuştur (Shelag, 2018).

Yahyaoui, yapmış olduğu doktora tezinde, göğüs hastalıklarının teşhisinde Naive Bayes sınıflandırma (NB) metodu ile birlikte destek vektör makinaları (Support Vector Machine-SVM), K-en yakın komşular (K-Nearest Neighbour-K-NN) metotlarını kullanmıştır. Ayrıca, bu çalışmada ilk defa uyarlamalı destek vektör makine metodunu (ASVM) göğüs hastalıklarının teşhisinde kullanmıştır. Kullanılan bu metot, SVM tekniğinin en uygun eşik değerini bulabilecek şekilde geliştirilmesine dayanan bir metottur. Çalışmada, veri seti olarak Diyarbakır Göğüs Hastalıkları hastanesinden temin

edilen deneysel veri seti kullanılmıştır. Çalışmanın sonunda elde edilen sonuçlar, kullanılan metotların özellikle de ASVM metodunun yüksek başarımla elde ettiğini göstermiştir. Böylece, ASVM metodunun göğüs hastalıklarında etkili bir şekilde kullanılabileceğini görülmüştür (Yahyaoui, 2017).

Er, araştırmasında zatürre tespiti için daha önce eğitilmiş derin öğrenme modellerinde göğüs röntgen görüntülerini kullanmayı önermiştir. Er, çalışmasında göğüs röntgen görüntülerinde zatürre olup olmadığını tespit etmek için derin öğrenme modelleri arasından AlexNet, VGG-16, ResNet (ResNet-18, ResNet-50, ResNet-101) modellerini kullanmayı tercih etmiştir. Bu modeller kullanılarak elde edilen özelliklerin hepsi birleştirilmiş ve hibrit bir özellik vektörü elde edilmiştir. SVM algoritmasını sınıflandırıcı olarak kullanmıştır. Yapılan çalışmanın en yüksek sınıflandırma başarımla %98,32'lik bir yüzde ile hibrit özellik vektöründen elde edilmiştir (Er, 2020).

Anthimopoulos ve arkadaşları, akciğer hastalığını belirleyebilmek için bir CNN modeli önermişlerdir. Önerilen model, ReLu (Rectified Linear Unit) aktivasyon fonksiyonu, ortalama havuzlama katmanları, üç adet tamamen bağlı katman ve beş adet de konvolüsyonel katmandan oluşmaktadır. Modelde kullanılan veri setinde ise yedi adet sınıf ve 14696 tane görüntü bulunmaktadır. Model, %85,5 oranında doğruluk elde etmiştir (Anthimopoulos ve diğ., 2016).

Rahman ve arkadaşlarının 2020 yılındaki çalışmalarında ise, dijital röntgen görüntüleri kullanılarak bakteriyel ve viral pnömoninin otomatik olarak tespiti amaçlanmıştır. Çalışmada önceden eğitilmiş dört farklı CNN modeli kullanılmıştır. Çalışmada kullanılan modeller, AlexNet, ResNet-18, DenseNet-201 ve SqueezeNet'dir. Veriler transfer öğrenme işlemine girmeden önce ön işlemden geçirilerek sınıflandırma yapılmıştır. Deneysel sonuçlardan %98 doğruluk oranı elde edilmiştir (Rahman ve diğ., 2020).

Guan ve arkadaşları 2019 yılında yaptıkları çalışmada göğüs röntgeni görüntülerinden toraks hastalığını saptamak için bir CNN modeli geliştirmişlerdir. Bu araştırma Chest X-ray14 veri seti üzerinde yapılan bu çalışma neticesinde Guan ve arkadaşlarının geliştirdiği CNN modelinin performansını diğer modellerle göre daha iyi bir performans sergilemiştir (Guan ve diğ., 2019).

Stephen ve arkadaşlarının çalışmasında ise göğüs röntgeni görüntü örneklerinden pnömoni varlığını tespit etmek ve sınıflandırmak için sıfırdan eğitilmiş CNN modeli önerilmektedir. Dikkate değer bir performans elde etmek için tasarlanan CNN modelinde

birkaç veri arttırma algoritmasıyla modelin sınıflandırma başarımını geliştirmek amaçlanmıştır (Stephen ve diğ., 2019).

Sirazitdinov, göğüs röntgeni görüntülerinde pnömoninin otomatik olarak tespiti ve lokalizasyonu için makine öğrenmesi modeli geliştirmiştir. Çalışmasında iki adet CNN modelini önermiştir. 26684 görüntüden oluşan veri seti Kaggle'dan alınmıştır. Çalışmasında elde ettiği %79,30 duyarlılık değeri sayesinde otomatik pnömoni teşhisi için güvenilir bir çözüm geliştirilmiştir (Sirazitdinov ve diğ., 2019).

Jain ve arkadaşları 2020 yılındaki çalışmalarında röntgen görüntülerinden pnömoni tespiti için CNN modelleri kullanmışlardır. Çeşitli hiperparametreler ve konvolüsyonel katmanın sayısını değiştirerek, röntgen görüntülerini pnömoni olan ve olmayan olarak iki farklı sınıfta sınıflandırmak için çeşitli CNN modellerini eğitmişlerdir. Altı farklı model üzerinde yapılan araştırmada %92,31 doğruluk elde edilmiştir (Jain ve diğ., 2020).

Menger ve arkadaşları yaptıkları çalışmada zatürre hastalarından elde edilen göğüs röntgeni görüntülerini, derin öğrenme modelleri ile eğiterek, mevcut yöntemlere nazaran daha başarılı sonuçlar elde etmeyi amaçlamışlardır (Menger ve diğ., 2018).

Rubin, MIMIC-CXR veri setini kullanılarak toraks hastalığının tespit edilmesi için ikili bir CNN modeli sunmuştur. Rubin, veri setinin %70'ini eğitim, %20'sini test ve %10'unu doğrulama için kullanmıştır. Rubin, çalışmasında %72,1 doğruluk değeri elde etmeyi başarmıştır (Rubin ve diğ., 2018).

Tıbbi görüntülerden anormalliklerin tespiti üzerine başka bir çalışmada, Setio ve arkadaşları pulmoner nodül tespiti için çok görüntülü bir CNN ağı (ConvNets) kullanan bilgisayar destekli bir algılama sistemi önermişlerdir. Modellerini 1186 akciğer nodülü içeren 888 akciğer tomografi taramasında test etmişler ve %85,7 başarımları sağlamışlardır (Setio ve diğ., 2016).

Varshni ve arkadaşları, özellik çıkarıcılar olarak önceden eğitilmiş CNN modellerini kullanmışlardır. En uygun CNN modelini belirlemek için anormal ve normal göğüs röntgenleri farklı makine öğrenme algoritmalarını kullanarak sınıflandırmışlardır (Varshni ve diğ., 2019).

Kumar Acharya ve Satapathy, siyam temelli bir derin sinir ağını kullanarak göğüs radyoloji görüntülerinden pnömoni tespitini önermişlerdir. Modeli eğitmek ve doğrulamak için Kaggle veri kümesi kullanılmıştır (Kumar Acharya ve Satapathy, 2020).

### 3. MATERYAL VE YÖNTEM

#### 3.1. Göğüs Hastalıkları

Göğüs, insan vücudu üzerinde önemli rolleri olan kalp, akciğer gibi organları içeren, boyun ile karın bölgeleri arasında kalan bölgedir. İnsanlarda, göğüsün göğüs kafesi ile korunan bölgesine aynı zamanda toraks denir (URL-1, 2021).

Göğüs hastalıklarıyla ilgilenen tıp dalına pulmonoloji denir. Pulmonologlar, zatürre, kardiyomegali ve akciğer kanseri gibi insan sağlığı için tehlikeli birçok hastalığın teşhis ve tedavisi üzerinde çalışmaktadırlar (URL-2, 2021).

##### 3.1.1. Atelektazi (*Atelectasis*)

Atelektazi, akciğerlerin tamamının veya bir kısmının fiziksel bir tıkaçıcı nedeniyle hava gidememesi sonucunda yeteri kadar şişememesi olarak tanımlanabilecek bir hastalıktır (URL-3, 2019). Atelektazinin teşhisi için detaylı bir tıbbi geçmiş ve muayenenin ardından doktorların başvurduğu ilk yöntem göğüs röntgenidir.

##### 3.1.2. Kardiyomegali (*Cardiomegaly*)

Kardiyomegali; göğüs röntgen görüntüleri ile belirlenebilen, kalbin tamamında ya da bazı kısımlarında görülen genişleme veya büyüme olarak ifade edebileceğimiz ciddi bir kalp rahatsızlığıdır (Buchanan JW ve Bucheler J., 1995).

##### 3.1.3. Konsolidasyon (*Consolidation*)

Akciğerlerde herhangi bir nedenden dolayı gerçekleşen katılaşma, akciğerlerin sıvıyla ya da gazla dolması gibi durumlar konsolidasyon olarak ifade edilir. Akciğer konsolidasyonu, alveollerin farklı sebeplerden dolayı tahriş ve tahrip olması ve böylece yumuşak dokunun katılaşarak sertleşmesidir. Konsolidasyon, akciğerin sadece bir lobunu etkileyebileceği gibi tüm akciğer yüzeyine yayılabilir (URL-4, 2021).

##### 3.1.4. Ödem (*Edema*)

Akciğer ödemi, ciğerlerde aşırı sıvı oluşmasından kaynaklanan bir durumdur. Bu sıvı, ciğerlerdeki çok sayıda hava kesesinde toplanır ve böylece nefes almak zorlaşır.

Eğer akciğer ödemimiz varsa normalde nefes aldığımızda havayla dolan ciğerlerimiz hava yerine sıvıyla dolar. Bu durumda kanımız ihtiyaç duyduğu oksijeni ciğerlerimiz tarafından alınamaz. Tedavi edilmediği takdirde ölümcül sonuçları olabilir.

### **3.1.5. Efüzyon (*Effusion*)**

Plevral efüzyon olarak da bilinen efüzyon, plevra (akciğer zarı) denen akciğerin dış yüzü ile göğüs duvarının iç yüzünü saran bu iki zar arasında kalan boşlukta su birikmesine denir (URL-7, 2021).

Sağlıklı bir insanda normalde bu iki zar arasında 20 ml kadar yani çok az miktarda sıvı bulunur. Birçok akciğere veya akciğer dışı herhangi bir hastalığa bağlı olarak, bu sıvının salgılanmasında artışa veya geri emilimindeki azalmaya bağlı olarak iki zar arasındaki sıvı miktarı normal değerlerin üzerine çıkar ve bu durum da plevral efüzyon oluşmasına sebep olur.

### **3.1.6. Amfizem (*Emphysema*)**

Amfizem, nefes darlığına yola açan bir akciğer hastalığıdır. Amfizem hastalarında, akciğerlerde bulunan alveol hava keseleri (alveol) zarar görür. Sigara ya da bir takım zararlı gazlara maruz kalan akciğerlerde zamanla alveollerde ve solunum yollarının duvarlarında geri dönüşü olmayan bir tahribat nedeniyle amfizem oluşur. Amfizem hastalarında alveollerdeki esneklik kaybolur. Küçük hava keseciklerinin yerine, büyük hava kesecikleri oluşur (URL-10, 2021).

### **3.1.7. Fibroz (*Fibrosis*)**

Akciğer fibrozisi, akciğerin süngerimsi dokusunun kalınlaşarak sertleşmesi ve bunun neticesinde hastalıklı alanların yara izini andıran bir görünüme sahip olması durumudur. “Fibroz” sözcüğü, bu yara iyileşmesi ile oluşan sert doku tabakasını tanımlamakta kullanılan tıbbi bir terimdir (URL-11, 2021).

### **3.1.8. Fıtık (*Hernia*)**

Diyafram, göğüs ve karın boşlukları arasında kubbe şeklinde bir kas bariyeridir. Kalp ve akciğerleri karın organlarından (mide, bağırsaklar, dalak ve karaciğer) ayırır. Karın organlarının bir veya daha fazlası diyaframdaki bir açıklıktan göğüs boşluğuna

dođru hareket ettiđinde diyafram fitiđı ortaya ıkar. Bu tr bir kusur dođumsal ya da herhangi bir yaralama neticesinde sonradan da olabilir. Sađlık aısından acil bir durumdur ve dzeltilmesi iin cerrahi mdahale gerekir (URL-12, 2021).

### **3.1.9. Szlme (*Infiltration*)**

Akciđer infiltrasyonu (szlme), akciđer dokusunda kademeli olarak biriken irin ve kan gibi havadan daha ađır anormal maddeleri ifade eder (URL-13, 2021).

### **3.1.10. Kitle (*Mass*)**

Akciđer hcrelerinde ortaya ıkan bir kitledir ve bu kitle akciđerde tmr olarak bilinir. Akciđerde kitle ıkması akciđer kanseri hastalıđı ile de bađdaştırılabilir. Akciđerde yer alan hcrelerin kontrolsz bir Őekilde ve hızlı bir Őekilde ođalmasına kitle artışı denilmektedir (URL-14, 2021).

### **3.1.11. Doku Bymesi (*Nodule*)**

Akciđer nodlleri, akciđer rntgen grntlerinde ya da bilgisayarlı tomografi taramalarında grlebilen yuvarlak, beyaz noktalar (kk dokular) olarak grlen, 3 cm'den kk apa sahip olan kitlelerdir (URL-8, 2019).

Akciđerde grlen bu nodlleri genellikle iyi huylu olduklarından dolayı grlen kiŐilerde herhangi bir tedaviye ihtiya duyulmaz. Eđer nodl belirli rutin aralıklarla yapılan radyolojik takiplerde aynı byklkte grlyorsa, habis yani kanser olma ihtimali ok dŐktr. Fakat yine de doktor tarafından titizlikle takip edilmeli, rutin taramalarla nodllerin boyutu ve Őekli gzlem altında tutulmalıdır.

Bazı akciđer nodllerinin bymesi ve Őekil bozukluđuna bađlı olarak habis (kanser) olup olmadıklarını belirlemek iin testler yapılır. Genellikle, 3 mm'den kk nodller iyi huylu olma eđilimindeyken, 20 mm ve daha byk nodllerin kt huylu olma ihtimali yksektir.

### **3.1.12. Plevral KalınlaŐma (*Pleural Thickening*)**

Akciđer zarı olarak da bilinen plevra, gđs boŐluđunu iten kaplayan ve akciđerleri evreleyen ince ve iki katlı bir zar tabakasıdır. Normalde plevra sođan zarı kadar son derece ince bir zardır. Fakat bazı kiŐilerde bu zarı bir kâđıt hatta bir parmak

kalınlığına kadar ulaşip sertleşebilir. Bu sertleşmeye çoğunlukla bir enfeksiyon neden olabildiği gibi bazı durumlarda bir tümör de plevral kalınlaşma nedeni olabilmektedir (URL-7, 2021).

### **3.1.13. Zatürre (*Pneumonia*)**

Pnömoni, halk arasındaki bilinen adıyla zatürre hastalığını kısaca akciğer dokusunun iltihaplanması olarak tanımlayabiliriz. Başta bakteriler olmak üzere birçok çeşitli mikroorganizmalara bağlı olarak meydana gelebilir. Zatürre hastalığı çoğunlukla, hastanın kendi ağız, boğaz veya sindirim kanalında bulunan mikropların akciğere ulaşmasıyla meydana gelmektedir. Buna karşın bazı türlerinde hasta olan bireylerden sağlam bireylere doğrudan bulaşma ihtimali de bulunur. Normal durumda hastalığa neden olmayan bu mikroplar, bağışıklık sistemi zayıflamış kişilerde zatürreye neden olur (URL-15, 2021).

### **3.1.14. Akciğer Sönmesi (*Pneumothorax*)**

Normalde göğüs kafesinde hava akciğerlerin içinde hapsolmuş bir şekilde bulunmaktadır. Akciğerler üzerinde oluşabilecek bir delik nedeniyle içerdeki hava akciğer dışına kaçarak göğüs kafesinin içine toplanır ve akciğerlere baskı yaparak sönmelerine sebep olur. Akciğer zarları arasına hava dolması durumuna akciğer sönmesi denir (URL-16, 2021).

## **3.2. Sinir Ağları**

Günümüzde, gelişen teknolojiler altında yer alan yapay zekâ; insana özgü olan, *algılama, öğrenme, düşünme, problem çözme, iletişim ve karar verme* gibi davranışları sergilemesi beklenen yapay bir işletim sistemi olarak tanımlanabilir. Başka bir ifadeyle yapay zekâ, insanların bilgisayarlardan daha hızlı yapabildikleri işlemleri bilgisayarların da benzer hızlarda yapabilmelerini sağlamak amacıyla geliştirilmekte olan sistemlerdir.

Yapay Zekânın bir alt kuramı olan makine öğrenimi ise, bilgisayarların canlı bir organizma gibi öğrenmesini amaçlayan algoritmaların tasarım ve geliştirme süreçlerini konu edinen bir bilim dalıdır. Makine öğrenimi araştırmalarının merkezindeki konu bilgisayarlara karmaşık örüntüleri algılama ve eldeki veriye göre akılcı kararlar verebilme

yetisi kazandırmaktır. Makine öğrenmesi yaklaşımlarının kalitesi doğru özellik seçimine bağlıdır.


Bu bağlamda, çoklu soyutlama yapısı ile verilerin temsil ettiği birimleri öğrenmek için bir araya getirilmiş çoklu işleme katmanlarına sahip olan derin öğrenme yaklaşımı; önceden bilinen veriler üzerinde pek çok katmandan oluşan yapay sinir ağı modeli oluşturarak bilinmeyen veriler için özelliklerin öğrenimine olanak sağlayan makine öğrenmesi yaklaşımıdır.

### 3.2.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları (YSA), insan beyninin bilgi işleme yeteneği gözlemlenerek geliştirilmiş bir yapay öğrenme teknolojisidir. Beyin hücrelerindeki ağların temelinde bulunan nöronların elektro kimyasal etkileşimlerini taklit etmek amacıyla McCulloch ve Pitts (1943) tarafından matematiksel nöron kavramı ortaya çıkarılmıştır. YSA ile biyolojik sinir sisteminin çalışma şeklinin taklit edilmesi amaçlanmıştır. Biyolojik bir nöronun çalışması aşağıdaki kavramlarla ifade edilebilir (Seymour, 1997).

- **Dendrit:** Hücrelerden gelen sinyallerin çekirdeğe iletilmesini sağlar.
- **Hücre Gövdesi:** Bir diğer ismi soma olan bu yapıyı dendrit üzerinden gelen sinyalleri toplayan merkezdir.
- **Akson:** Toplanan bilgileri diğer hücelere dağıtan yapıdır.
- **Sinaps:** Aksonlardan gelen bilgiyi ön işlemde geçirerek diğer hücelere iletir.

Öğrenmenin yapay bir şekilde gerçekleşmesi için yapay sinir ağı biyolojik sinirlerden esinlenilerek oluşturulmuştur.



Şekil 3.1. Sinir hücresi ve yapay sinir hücresi yapısı (URL-17, 2021)

Yapay sinir hücreleri, matematiksel olarak,

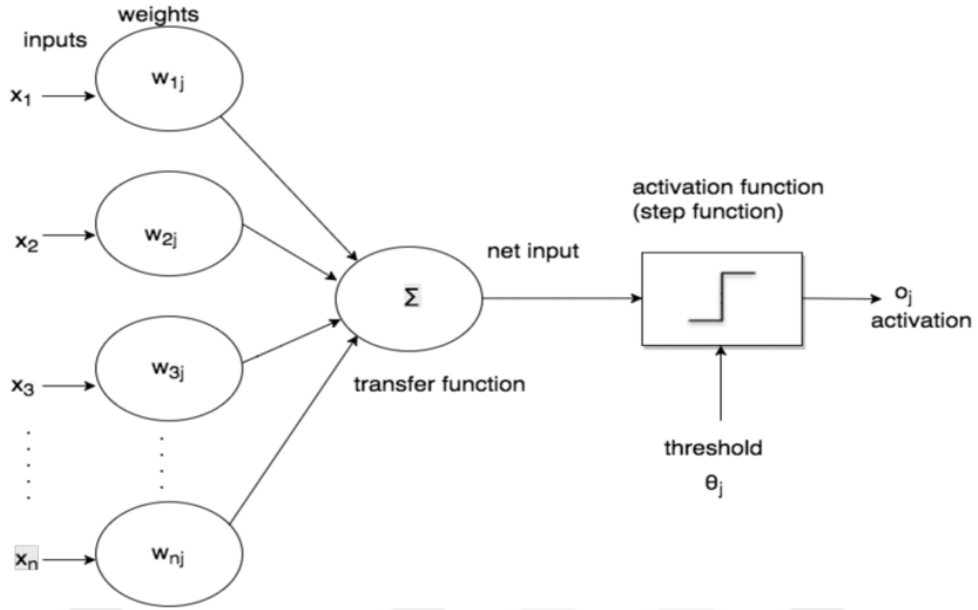
$$y(x) = \sum_{i=1}^N (w_i x_i + b)$$

şeklinde ifade edilen işlem neticesinde aldıkları giriş değerlerini belli eşik değerlerinden geçirerek çıkış değeri olarak iletirler. Yapay sinir hücresine ait kavramlar aşağıdaki gibi ifade edilebilir:

- **x** : Giriş değerleri (input)
- **w** : Ağırlık (weight)
- **b** : Sapma (bias)
- **f** : Aktivasyon fonksiyonu (activation function)
- **y** : Çıkış değeri (output)


İlk olarak McCulloch ve Pitts tarafından oluşturulan bu model, beyindeki biyolojik süreçlere ve yapay zekâ sinir ağlarının uygulanmasına odaklanan bir yaklaşım ortaya atmıştır (McCulloch and Pitts, 1943). 1940'ların sonlarına doğru Donald Hebb, Hebbian öğrenme olarak bilinen bir öğrenme hipotezi oluşturmuştur. Bu hipotezde bahsedilen denetimsiz öğrenme (*unsupervised learning*) kuralı sinir ağlarının temelini oluşturmaktadır (Hebb, 1949).

1958 yılına gelindiğinde Frank Rosenbalt tarafından iki katmanlı bir bilgisayar öğrenme ağına dayalı olan algılayıcı (*perceptron*) algoritması önerilmiştir (Rosenbalt, 1958).



Şekil 3.2. Rosenbaltt 'a göre algılayıcı modeli (URL-18, 2021)


Algılayıcılar ile beraber tek katmanlı yapay sinir ağı (Artificial Neural Networks-ANN) problem çözümünde kullanılmaya başlanmıştır. Tek katmanlı ağlar en basit ağ tipi olup bir girdi ve bir çıktı katmanından oluşmaktadır.



Şekil 3.3. Tek katmanlı yapay sinir ağı modeli (URL-19, 2021)

Tek katmanlı yapay sinir ağları karmaşık problemlerde istenilen başarıyı elde edememiştir. Dolayısıyla doğrusal olmayan problemleri çözebilmek için çok katmanlı yapay sinir ağı (MLP-*Multi Layer Perceptron*) kullanılmaya başlanmıştır. Çok katmanlı ağlarda; girdi katmanı, gizli (*hidden*) katmanlar ve çıktı katmanı bulunmaktadır (Rumelhart ve ark., 1986). Çok katmanlı ağlarda bir önceki katmandan elde edilen çıkış

değeri sonraki katmana yeniden giriş değeri olarak işleme alınarak katman sayısı artırılmıştır. Bu durumda birden çok girdi olabileceği gibi birden fazla da gizli katman olabilmektedir. Gizli katmanların sayısı problemin durumuna göre değişiklik gösterebilir.



Şekil 3.4. Çok katmanlı yapay sinir ağı modelin (URL-19, 2021)

Öğrenmenin iyileştirilmesi amacıyla oluşturulan gizli katmanlarda ileri yayılım (*forward-propagation*) ve geri yayılım (*back-propagation*) olmak üzere iki türlü işlem ön plana çıkmaktadır. Bir yapay sinir ağında gerçekleştirilen, girdi katmanından çıktı katmanına kadar bütün bu ileri yönlü hesaplama işlemleri ileri yayılım algoritması olarak adlandırılmaktadır. Her ileri yayılım algoritması sonucunda elde edilen değerler, sinir ağının oluşturduğu tahmini değerlerdir. Bu sebeple elde edilen bu tahminler çoğu zaman %100 doğrulukta olamamaktadır ve eğitim sonucunda elde edilen tahmin değeriyle gerçek değer arasında bir fark (hata) olması kuvvetle muhtemeldir. Bu hatayı mümkün olan en küçük haline getirebilmek için birçok farklı yöntem geliştirilmiştir. Bu yöntemlerin belki de en önemlisi geri yayılım algoritmasıdır (Werbos, 1975).

Geri yayılım algoritmasında ileri yayılım işlemi sonucunda elde edilen hata değeri, yapay sinir ağı üzerinde bu sefer çıktı katmanından girdi katmanına doğru olacak şekilde çeşitli türev işlemlerine dâhil edilerek “geriye doğru yayılmış” olur. Bu işlem neticesinde giriş ağırlık değerleri güncellenerek yeni girdilerle birlikte sinir ağı tekrar çalıştırılır ve öğrenmenin iyileştirilmesi sağlanır.

McClelland ve Rumelhart tarafından 1987 yılında yazılan “Paralel Dağıtık İşleme” kitabı ile YSA tam bir patlama yapmıştır (McClelland ve Rumerlhart, 1987). 1988 yılında da YSA alanındaki ilk dergi olan “Neural Network” dergisi kurulmuştur. Fakat bu yıllardan sonra gerekli donanım desteğinin olmaması YSA çalışmalarının


yavaşlamasına neden olmuştur. Hatta öyle ki, 2000’li yıllara kadar süren bu yavaşlama sinir ağları için bir kış dönemi olmuştur. Daha sonra gelişen donanımlar ve elde edilen büyük veriler (*big data*) sayesinde sığ ağların yerini derin ağlar almış ve yeniden büyük çalışmalar başlamıştır.

### 3.2.2. Derin Öğrenme

Derin öğrenme verilen bir veri seti ile sonuçları tahmin eden birden fazla katmandan oluşan yapay sinir ağı algoritmalarını kapsayan bir makine öğrenme yöntemidir. Derin Öğrenmenin, boyutu yüksek olan verileri boyutu daha düşük verilere dönüştürerek öğrenmeyi sağlayan bir yapısı vardır.

Derin öğrenme kavramının doğmasına imkân veren iki önemli etkenden biri gelişen donanımlar sayesinde eğitimin süre ve maliyetlerinin azalması, diğeri ise büyük veriler ile birlikte eğitim için gerekli argümanların kolay elde edilebilmesidir. Derin öğrenme algoritmalarının başarımının yüksek olmasındaki en önemli etken derin ağın çok fazla sayıda veri ile eğitilebilmesidir.

Derin öğrenme mimarileri, özellik çıkarma ve dönüştürme işlemleri için farklı soyutlama düzeylerinde birden fazla işlem katmanından oluşur. Ardışık her katman bir önceki katmandan aldığı çıktıyı kendi katmanı için girdi olarak kullanır (Deng ve Yu, 2014). Bu girdiler doğrusal olmayan dönüşüm fonksiyonları ile verilerin yeni temsillerine dönüştürülür. Katmanlar kademeli olarak azaltılarak hiyerarşik bir ağ oluşturulur. Bu ağ insan beyinin çalışmasına benzer bir şekilde tasarlanmıştır. Aldığı her yeni veriyi, farklı hiyerarşik soyutlama düzeylerinden geçirerek derin bir anlayış oluşturmaktadır. Bu şekilde her katmanda soyutlama artırılarak verilerin üstün özellikleri öğrenilmektedir (Bengio ve ark., 2014).



Şekil 3.5. LeNet ağı (El yazısı tanımak için) (URL-20, 2021)

Veriyi temsilinden öğrenmeye dayalı bir sistem olan derin öğrenmenin sağladığı en önemli avantaj manuel olarak çıkarılan özellikler yerine hiyerarşik olarak özellik çıkarımı için etkin algoritmalar kullanmasıdır (Song ve Lee, 2013).

### 3.2.2.1. Tarihçe

1960 yılında ilk nesil yapay sinir ağları Frank Rosenblatt tarafından keşfedilmiştir. Perceptron adı verilen bu yapıda, bütün özellikleri birleştirip ağırlık vektörü bularak nesne tanımaya yarayan ve elle yapılmış bir özellik katmanı kullanılmaktaydı. Perceptron üçgen ve kare gibi bazı geometrik şekilleri ayırt edebiliyordu. 1965 yılında ise Ivakhnenko ve Lapa tarafından denetimli derin beslemeli perceptronlar için bir öğrenme algoritması yayınlamıştır (Ivakhnenko ve Lapa, 1965). Bu algorithmada ağların uçtan uca eğitilmesi için geri yayılım (backpropagation) kullanılmıştır. 1979 yılında Fukushima tarafından önerilen “Neokognitron” mimarisi ile “öğretmensiz öğrenme” olarak isimlendirilen kendi kendini yönetebilen bir ağ geliştirilmiştir. Bu ağlarda modern ağların benzeri olan bükülme ve havuzlama bulunmaktadır (Fukushima, 1980).

Geri yayılım algoritması sayesinde 1985 yılında Geoffrey Hinton ikinci nesil sinir ağlarını oluşturmuştur. Derin öğrenme mimarilerinin en önemli eksikliği çoklu katmalardaki geri yayılma işlemiydi. Geri yayılım algoritmaları daha önceleri ortaya çıkmış olsa da ancak Yann LeCun ve arkadaşlarının posta kutusu yazıları üzerindeki çalışmaları ile ilk başarılı derin sinir ağı geliştirilmiştir (LeCun ve ark., 1989). Fakat oluşturulan bu ağı da en büyük dezavantajı eğitimin yaklaşık olarak 3 gün sürmesiydi. Sonraki süreçte Yann LeCun el yazısı rakamları (MNIST) sınıflandırmak için “LeNet” ağını kullanmıştır.

1995 yılına gelindiğinde ise Geoffrey Hinton’ın, Brendan Frey ve Peter Dayan ile birlikte oluşturdukları uyanık-uyku (*wake-sleep*) algoritması ile altı tane bağlı katman ve yüzlerce gizli katmandan oluşan bir ağı, eğitiminin iki gün sürmesine rağmen eğitilmesinin mümkün olduğunu göstermişlerdir (Hinton ve ark., 1995).

1997 yılında ise Hochreiter ve Schmidhuber uzun kısa vadeli bellek (long short-term memory - LSTM)’i RNN için geliştirmişlerdir (Hochreiter ve Schmidhuber, 1997).


Tüm bu gelişmelere ve avantajlarına rağmen, YSA’nın hesaplama maliyeti popülaritesinin azalmasına neden olmuştur. 2000’li yılların başına gelindiğinde SVM gibi probleme özgü çalışan, daha basit modeller YSA’nın yerine tercih edilir olmuştur. Öğrenmenin hızlı ve kolay olduğu SVM ise yapay zekâdaki birçok sorunu çözmesine

rağmen yüzeysel bir mimariydi. Bu aşamada yapay zekâ çalışmaları daha derin mimarilere ihtiyaç duyulmuştur.

Bilgisayarların hızlanması ve grafik işlemci birimlerinin (Graphics Processing Unit - GPU) kurulmasıyla birlikte derin öğrenme alanında büyük gelişmeler yaşanmıştır. Bu dönemde, GPU'ların gelişmesi ile birlikte hesaplama hızında neredeyse 1000 kata varan iyileşmeler sağlanmıştır. Bu iyileşme giderek SVM üzerinde yoğunlaşan ilginin tekrar sinir ağlarına dönmesini sağlamıştır. YSA bağlamında “Derin Öğrenme” kavramı ilk defa 2000 yılında Igor Aizenberg tarafından ortaya çıkarılmıştır (Aizenberg ve ark., 2000).

2007 yılında ise Geoffrey Hinton ve Ruslan Salakhutdinov'un birlikte yayınladıkları bir bilimsel makalede çok katmanlı ve beslemeli sinir ağlarını etkili bir şekilde nasıl eğiteceklerini göstermişlerdir (Hinton, 2007).

Sonraki yıllarda Ciresan ve arkadaşları medikal görüntüleme, karakter tanıma ve trafik işaretleri yarışmalarını kazanmaları, Krizhevsky, Sutskever ve Hinton'un benzer bir mimari ile katıldıkları ImageNet yarışmasında mükemmel sonuçlar elde etmeleri dikkatleri derin öğrenme üzerine çekmiştir. Bununla birlikte Google, Microsoft, Facebook, Intel gibi dev teknoloji firmalarının derin öğrenme alanındaki yatırımlarında bariz bir artış gerçekleşmiştir.



Şekil 3.6. Yapay Zekâ Girişimlerine Yatırım Yapan Şirketler (URL-9, 2021)

### 3.2.2.2. Derin Öğrenme Mimarileri

Katman sayılarının artması YSA'daki derin öğrenme mimarilerinde farklılıklara sebep olmuştur. Bu mimariler:

- Konvolüsyonel Sinir Ağları (CNN)
- Tekrarlayan Sinir Ağları (RNN)
- Uzun Kısa Vadeli Hafıza (LSTM)
- Sınırlı Bozltmann Makineleri (RBM)
- Derin İnanç Ağları (DBN)
- Derin Oto-Kodlayıcılar (DAE)

olarak sıralanabilir.

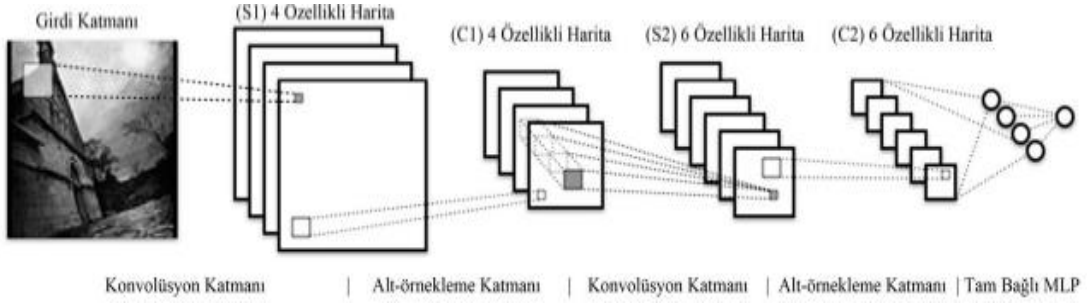
Bu bölümde ise tezin konusu olan modelin temelindeki CNN mimarisinden bahsedilecektir.

#### 3.2.2.2.1. Konvolüsyonel Sinir Ağları

Son yıllarda araştırma ve uygulamalarda alanında CNN modelleri dikkate değer gelişmeler göstermiştir. Bunu sağlayan en önemli etken CNN modellerinin günümüzde üretilen ve erişilebilirliği kolaylaşan çok büyük miktarda veri ile çalışabilir olmasıdır. CNN modelleri kullanılarak uydulardan üretilen resimler, videolar ve benzeri veriler ile yüksek bir doğrulukla sınıflandırma işlemi gerçekleştirilmektedir. Yüksek miktardaki veri ve bu verinin eğitimini kolaylaştıran yüksek performanslı GPU'lar sayesinde yeni nesil CNN modelleri ile hayatımıza giren otonom araçlar ve robotlar, endüstri devriminde yepyeni bir sayfa açmıştır.

Çok katmanlı algılayıcıların (MLP) bir ürünü olan CNN, hayvanların görme merkezinden esinlenmiştir. Beynin görsel bilgiyi işleme tekniğini taklit etmektedir. Görme merkezindeki hücreler tüm görseli kapsayacak şekilde alt bölgelere ayrılır. Basit hücreler kenar kısımlarına, karmaşık hücreler ise tüm görsele yoğunlaşarak işlem yapar (Hubel and Wiesel, 1968; Bengio, 2009).

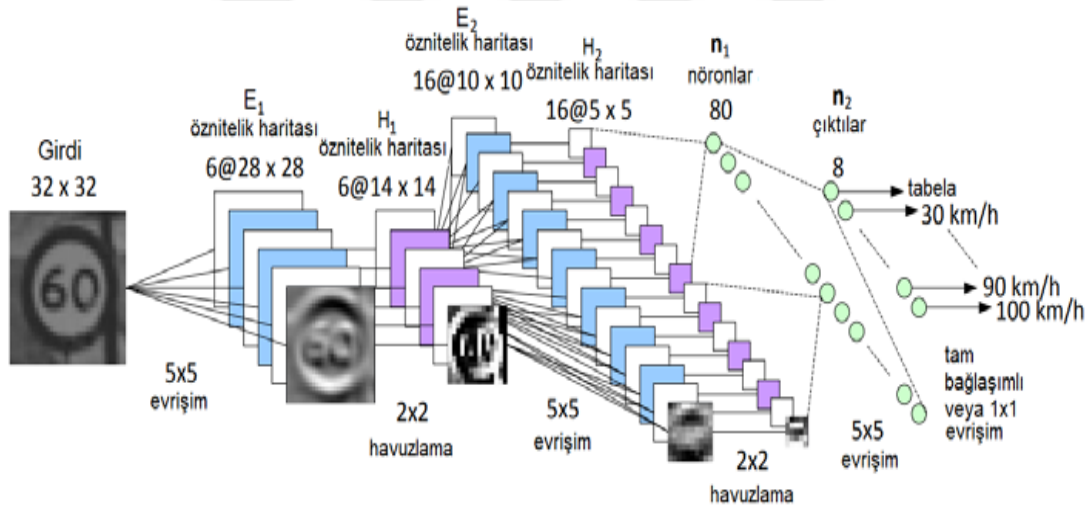
İlk CNN ağı 1988 yılında Yann LeCun tarafından kullanılan LeNet mimarisidir ve bu mimari 1998 yılına kadar geliştirilmeye devam edilmiştir (LeCun, 1988).



Şekil 3.7. LeNet ağı mimarisi (Şeker ve ark., 2017)

CNN mimarisinin en önemli yararı, tamamen bağlı ağlara göre daha az eğitime ihtiyaç duyması ve daha az sayıda parametreye sahip olmasıdır.

Geleneksel CNN mimarisinde girdi (input), konvolüsyon (convolution), havuzlama (pooling), tam bağlı (fully-connected) ve çıktı (output) katmanı olmak üzere beş ana katman bulunur. Bu katmalardan, konvolüsyonel katman, havuzlama katmanı ve tam bağlı katmanların sayılarındaki yapılan değişiklikler ile birçok farklı CNN mimarileri oluşturabilmektedir (LeCun ve Ark., 2015).



Şekil 3.8. Örnek bir CNN yapısı (Peemen ve ark., 2016)

Konvolüsyon işlemi; farklı büyüklükteki giriş verisini işleyebilen özelleştirilmiş bir doğrusal işlemdir (linear operation). Giriş verisi genellikle iki boyutlu bir dizidir. Kernel (çekirdek) ise konvolüsyonel katmanda giriş matrisi üzerinde işlem yapan, öğrenilebilir parametreleri içeren bir iki boyutlu dizidir. Bu diziler basit Gabor filtrelerine benzetilebilir. Bu kernellerin boyutu öğrenme üzerindeki etkisi yüksektir. Çünkü kernel boyutu sayesinde ne kadar genişlikteki verinin birbirini etkileyeceği belirlenmektedir. Belirli bir kuralı bulunmamakla birlikte genellikle 3x3, 5x5, 7x7 kerneller kullanılmaktadır.

Konvolüsyon işlemi matematiksel olarak;

$$s[i, j] = (IxK)[i, j] = \sum_m \left( \sum_n I[m, n]K[i - m, j - n] \right)$$

şeklindedir. Burada;

- $I$  :  $m \times n$  boyutlu resim için giriş değeri
- $K$  : kernel (çekirdek)
- $s$  :  $i$  ve  $j$  koordinatlarına sahip sonuç değeri


olarak tanımlanmıştır.

Konvolüsyonel katman CNN mimarisinin temel yapı taşıdır. Girdi olarak verilen resmin özelliklerini algılamaktan sorumludur. Konvolüsyonel katmanda, görüntüdeki düşük ve yüksek seviyeli özellikleri çıkarmak için resme birtakım filtreler uygulanır. Görüntü üzerinde adım adım hareket eden filtre her adımda çakışan değerler eleman eleman çarpılıp elde edilen toplam değer çıkış matrisine kaydedilmektedir.

2	0	2
2	2	1
2	0	1

Şekil 3.9. 3x3 boyutunda örnek bir filtre

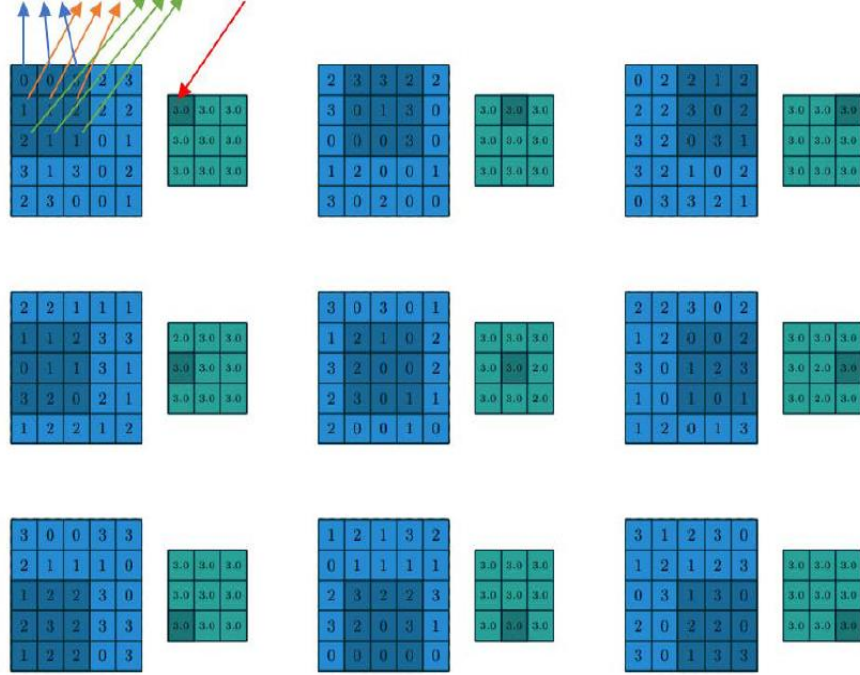
Bir konvolüsyonel katmanındaki girdi, “ $m \times m \times r$ ” boyutunda bir resimdir. Buradaki  $m$  değerleri sırasıyla görüntünün yüksekliğini ve genişliğini,  $r$  ise resmin kanal sayısını ifade eder (örneğin, bir RGB yani renkli bir görüntüde  $r$  değeri 3 ‘tür). Konvolüsyonel katman ise “ $n \times n \times q$ ” boyutlarında  $k$  tane filtreden oluşmaktadır. Filtreler için görüntünün boyutundan daha küçük olan  $n$  ve  $r$  (kanal) değeriyle genellikle aynı seçilen  $q$  değeri seçilir. Bu filtreler sayesinde, her biri “ $(m-n+1) \times (m-n+1)$ ” boyutunda  $k$  tane, birbirine yerel olarak bağlı özellik haritaları üretilir (Ciresan ve ark., 2011).



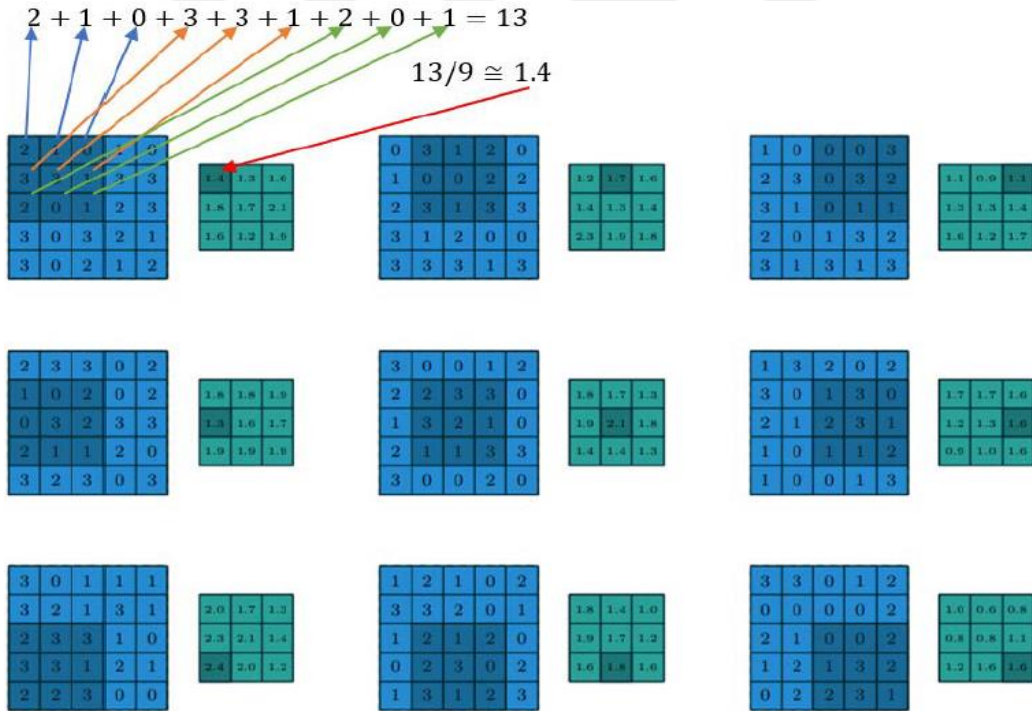
Şekil 3.10. 5x5 görüntü üzerine 3x3 filtrenin uygulanması (Dumoulin and Visin, 2016)

Daha sonra modelde boyutu azaltmak için havuzlama (*pooling*) olarak adlandırılan katmana geçilir. Havuzlama katmanında kayan pencere yöntemiyle “p x p” boyutunda alt örnekleme işlemi (p değeri, görüntü büyüklüğüne göre 2 ile 5 arasında seçilir) uygulanır (Scherer, 2010). Havuzlama katmanında konvolüsyon katmanında üretilen her harita içinde belirlenen bir alandaki değerlerin maksimum veya ortalaması alınarak bir değer çıkarılır. Havuzlama (*pooling*) katmanları sayesinde, daha önce bahsedilen girdinin küçük parçaları, tercih edilen yöntemle göre tek bir sabit değere indirgenmiş olur ve bu sayede hesaplama maliyetlerinde iyileştirme sağlanmış olur (Dumoulin ve Visin, 2016).

$$\text{maksimum}(0,0,3,1,1,2,2,1,1) = 3$$



Şekil 3.11. Maksimum havuzlama örneği (Dumoulin and Visin, 2016)



Şekil 3.12. Ortalama havuzlama örneği (Dumoulin and Visin, 2016)

CNN modelleri başta ses ve görüntü işleme alanı olmak üzere birçok farklı alanda kullanılmaktadır. Bu alanların başında da doğal dil işleme ve biyomedikal gelmektedir. CNN modelleri sayesinde özellikle görüntü işleme alanında mükemmel sonuçlar elde

edilmiştir. Cireşan ve arkadaşları MNIST veri kümesi üzerinde CNN mimarisini kullanarak yaptığı çalışmada hata oranını %2 seviyesine kadar düşürmeyi başarmışlardır (Cireşan ve ark., 2012).

2014 yılında, ImageNet Yarışması'nda, milyonlarca resim ve yüzlerce nesne sınıfı ile nesne sınıflandırması ve algılaması kriterlerinde en başarılı dereceleri alan ekiplerin hepsinin temelinde CNN modelleri vardı. 2015 yılında oluşturulan çok katmanlı bir CNN ağı, ters yüzler de dahil olmak üzere geniş açı aralıklarındaki yüzleri yakalayabilme yeteneğini göstermiştir.

CNN modelleri, anlamsal ayrıştırmada (Grefenstette ve ark., 2014), arama sorgusu elde etmede (Shen ve ark., 2014), cümle modelleme (Kalchbrenner ve ark., 2014) sınıflandırma (Kim, 2014), tahmin problemlerinde (Collobert and Weston, 2008) mükemmel sonuçlar elde ederek çeşitli doğal dil işleme problemleri için etkili oldukları gösterilmiştir.

Atomwise şirketinin 2015 yılında geliştirdiği AtomNet, ilaç tasarımı için geliştirilen ilk derin sinir ağı olarak CNN modelleri ilaç keşfinde de kullanılmıştır (Wallach ve ark., 2015).

### **3.2.2.3. Hiper Parametreler**

Derin öğrenme mimarilerinin içerdikleri ağ yapısının karmaşıklığıyla orantılı olarak başarımları ve maliyetleri artmaktadır. Eğitim başarımının yüksek olmasının yanı sıra maliyetinin de az olması derin ağın kullanılabilirliğini arttırmaktadır. Bu nedenle daha az maliyetle yüksek başarımın sağlamak amacıyla uygun hiper parametrelerin seçimi önem kazanmaktadır. Bu kısımda derin ağlarda kullanılan hiper parametrelerden bahsedilmektedir.

#### **3.2.2.3.1. Aktivasyon Fonksiyonları**

Aktivasyon fonksiyonu, yapay sinir hücresine gelen net bilgiyi analiz ederek, hücrenin giriş bilgisine göre üreteceği çıkış bilgisinin belirlenmesini sağlayan fonksiyondur. Eğitilen yapay sinir ağı modeline gerçek dünya verilerini, yani karmaşık verileri öğretebilmek için kullanılan fonksiyonlardır. Aktivasyon fonksiyonu olmayan bir yapay sinir ağı, verilerdeki kompleks yapıları öğrenip tespit etmekte çok zorlanacaktır hatta çoğu zaman da yetersiz kalacaktır. Bu sebeple güçlü bir yapay sinir ağı için iyi bir aktivasyon fonksiyonu kullanmamız gereklidir. Bazı problemler için daha kullanışlı

olduğu bilinen aktivasyon fonksiyonları olsa da hangi aktivasyon fonksiyonunun kullanılacağı ağ modelini tasarlayan kişiye göre değişkenlik gösterebilir. Yani ara katmanda ReLu aktivasyon fonksiyonu kullanılırken çıkış katmanında sigmoid fonksiyonu kullanılabilir. Bununla birlikte aktivasyon fonksiyonunu seçerken dikkat edilmesi gereken önemli bir diğer nokta da seçilen fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Bu hesaplama maliyeti açısından avantaj sağlayacaktır.

Genellikle doğrusal olmayan bir fonksiyon olarak seçilen aktivasyon fonksiyonu sayesinde yapay sinir ağlarının bir özelliği olan “doğrusal olmama” özelliği kazanılmış olmaktadır.

**Çizelge 3.1.** Aktivasyon Fonksiyonları


İsim	Fonksiyon
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$
Tanh	$\tanh(x) = 2\sigma(2x) - 1$
ReLU	$f(x) = \max(0, x)$
Leaky ReLU	$f(x) = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases}$
ELU	$f(x) = \begin{cases} x, & \text{if } x > 0 \\ \alpha(e^x - 1), & \text{if } x \leq 0 \end{cases}$
SELU	$\text{selu}(x) = \lambda \begin{cases} x, & x > 0 \\ ae^x - a, & x \leq 0 \end{cases}$
PReLU	$f(x) = \begin{cases} x, & \text{if } x > 0 \\ \alpha x, & \text{if } x \leq 0 \end{cases}$
Softmax	$f(x) = \frac{e^{z_j}}{\sum_k e^{z_k}}$

Bu çalışmada ara katmanlarda ReLu aktivasyon fonksiyonu kullanılmıştır. Son katmanda ise Sigmoid fonksiyonundan yararlanılmıştır.

Bir yapay sinir ağında, sıklıkla tanh veya sigmoid aktivasyon fonksiyonları tercih edilmektedir. Ancak doğrusal olmayan her iki fonksiyonun da yavaş çalışması ve konvolüsyonel ağların karmaşıklığı da göz önüne alındığında bu fonksiyonların yerine daha kullanışlı olan ReLU fonksiyonu ön plana çıkmaktadır.

ReLU, genellikle CNN ağlarında ara katmanlarda çok sık tercih edilir. ReLU fonksiyonunun ana avantajı aynı anda tüm nöronları aktive etmemesidir. Yani bir nöron negatif değer üretirse, aktive edilmeyeceği anlamına gelir.


Şekil 3.14'te de görebileceğimiz üzere negatif değerler üreten nöronlar sıfır değerini alır. Bu durum, ReLU'nun Hiperbolik Tanjant ve Sigmoid fonksiyonundan daha verimli ve hızlı çalışmasını sağlar. Bu nedenle ReLU, çok katmanlı sinir ağlarında daha çok tercih edilir (Hinton ve ark, 2010).



Şekil 3.13. ReLU aktivasyon fonksiyonu

Softmax aktivasyon fonksiyonu ise çoklu Sigmoid olarak da bilinen bir fonksiyondur. Çok sınıflı hedef değişkeni içeren sınıflandırma problemleri (*multi-class classification*) için uygun bir aktivasyon fonksiyonudur. Resim sınıflandırmasında CNN ağının son katmanında genellikle softmax aktivasyon fonksiyonu kullanılmaktadır (Bishop, 2006).

Softmax, çıktı olarak her sınıfa ait olasılıksal bir sonuç döndürür. Yani Softmax ile bir sinir ağı kuruyorsanız, çıktı katmanınızda hedef değişkeninize ait sınıf sayısı kadar nöron olması gereklidir.



Şekil 3.14. Softmax aktivasyon fonksiyonu

### 3.2.2.3.2. Loss Fonksiyonu

Loss fonksiyonu, modelin ürettiği sonuç ile gerçek değer arasındaki farkı hesaplayan ve aynı zamanda modelin başarımını ölçen fonksiyon olarak tanımlanabilir.

Loss fonksiyonu derin ağların son katmanında tanımlanır. Loss fonksiyonu temelde modelin yaptığı tahmin ile gerçek değer arasındaki farkı hesaplamaktadır. Bu nedenle iyi bir modelden beklenen loss değerinin sıfıra mümkün olduğunca yakın olmasıdır.

Elde edilen loss değeriyle birlikte geri yönde yayılım süreci başlatılır. Loss fonksiyonu kullanarak katmanların tümünde ağırlık değerlerini yeniden hesaplanır ve hata değeri minimize edilir. Bu süreç (ileri ve geri yönde yayılım), loss değerindeki düşüş duruncaya ya da artık önemsenmeyecek bir noktaya gelinceye kadar tekrarlanır.

Literatürde loss değerini hesaplamak için kullanılan birçok loss fonksiyonu bulunmaktadır. Bunlardan bazıları Sigmoid, Multiclass SVM, Softmax, Categorical Cross Entropy, Likelihood vb. dir. Bahsi geçen fonksiyonlardan sigmoid daha sıklıkla iki sınıftan oluşan problemlerin çözümünde kullanılırken diğer fonksiyonlar çok sınıflı problemlerin çözümünde kullanılmaktadır. Bu çalışmada ise loss fonksiyonu olarak binary cross entropy fonksiyonu kullanılmıştır.

Categorical cross entropy, çok sınıflı sınıflandırma görevlerinde kullanılan bir loss fonksiyonudur. Cross entropy, çıktısı 0 ile 1 arasında bir olasılıksal değeri olan bir sınıflandırma modelinin performansını ölçmede kullanılır. Tahmin edilen değer asıl değerden uzaklaştıkça cross entropy değeri artar.

Binary cross entropy fonksiyonu ise ikili sınıflandırma görevlerinde kullanılan bir loss fonksiyonudur. Mesela bir görüntüde kedi veya köpek olduğunu belirlememiz gerekmektedir. Bu aşamada loss fonksiyonu olarak binary cross entropy kullanılması daha avantajlı olur. Çünkü binary cross entropy fonksiyonu görüntüyü, kedi içeriyorsa 1; köpek içeriyorsa 0 olarak işaretlemekte ve böylelikle hesaplama maliyeti azalmış olmaktadır.

### 3.2.2.3.3. Öğrenme Katsayısı (Learning Rate)

Öğrenme katsayısı, optimizasyon algoritmalarında kullanılan bir katsayıdır. Hata düzeltme katsayısı da denilebilir. Basit bir tabirle öğrenme katsayısı sinir ağında ağırlıkların ya da katsayıların hangi hızla değişeceğini tanımlar. Öğrenme katsayısı,

optimizasyon algoritmalarının yakınsamasını sağlamaktadır. Öğrenme katsayısı fazla büyük olduğunda hedefe ulaşmak zorlaşabilir, çok küçük seçildiği durumlarda ise algortmada her döngüde çok küçük adımlar atılacağından yakınsama işlemi oldukça uzun sürecektir (Haykin, 2009). Bu çalışmada öğrenme katsayısı başlangıç olarak 0,005 olarak belirlenmiştir.

### 3.2.2.3.4. Optimizasyon Algoritmaları

Derin öğrenme algoritmalarında öğrenme işlemi temelde bir optimizasyon problemidir. Literatürde, doğrusal olmayan problemlerin çözümünde de en iyi değeri bulmak için birtakım optimizasyon yöntemleri kullanılmaktadır.

Eğim azalması (*gradient descent*), optimizasyonu gerçekleştirmek için kullanılan en popüler algoritmaların başında gelir ve sinir ağlarını optimize etmenin en yaygın yöntemidir. Aynı zamanda, en son teknolojiye sahip her derin öğrenme kütüphanesi, gradyan iniş tabanlı çeşitli optimizasyon algoritmalarını içermektedir.

Eğim azalması, hata oranını en aza indirmenin bir yoludur. Verinin büyüklüğü göz önünde bulundurulduğunda kullanabilecek üç adet eğim düşümü türü bulunmaktadır (Ruder, 2016). Bunlar;

- **Toplu Eğim Azalması** (*Batch Gradient Descent - BGD*)

Standart eğim azalması olarak da bilinen BGD tüm veri seti üzerinde eğim azalması hesaplamaktadır. Tek seferde tüm veri setini kullanmasından dolayı bellek problemleri ortaya çıkabilmektedir. Yüksek hesaplama maliyetine rağmen diğer eğim düşüm türlerine göre daha kararlı bir yapıya sahiptir. Hesaplama işlemi denklemi:

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t)$$

$\theta \in \mathbb{R}^d$ , model parametrelerini,  $\eta$  öğrenme katsayısını ve  $\nabla_{\theta} J(\theta_t)$  parametrelere bağlı hedef fonksiyon eğimini belirtmektedir.

- **Mini Toplu Eğim Azalması** (*Mini-Batch Gradient Descent - MGD*)

MGD yönteminde eğitim veri setindeki her bir mini paket için bir güncelleme gerçekleştirilir. Modelin güncellenme aralığı BGD yöntemindeki güncellenme aralığından daha kısadır. Bu yöntem, daha çok yerel minimum noktasından

kaçınıp genel minimum noktasına hızlıca ulaşmayı amaçlamaktadır. Yöntemin hesaplamada kullandığı matematiksel denklem:

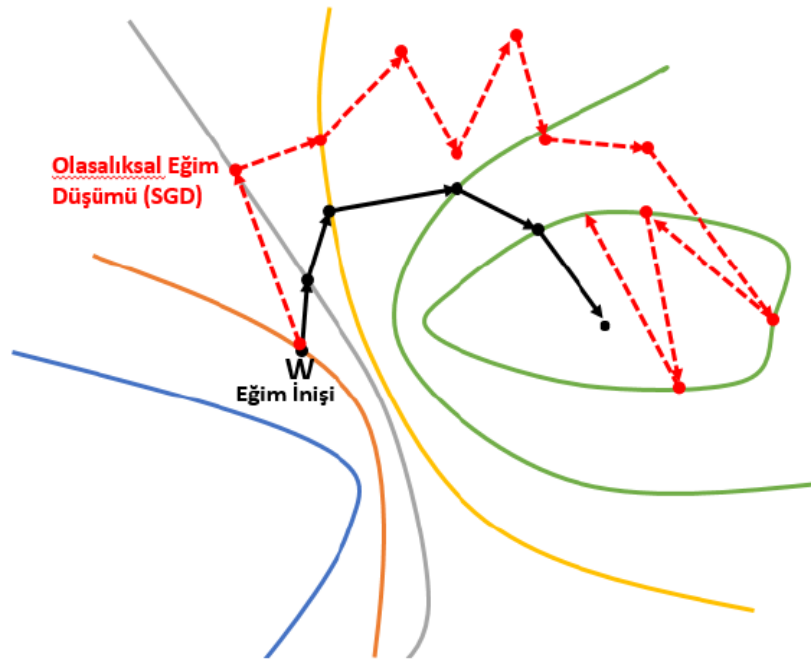
$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t; x^{i,t+n}; y^{i,t+n})$$

▪ **Olasılıksal Eğim Azalması** (*Stochastic Gradient Descent - SGD*)

Bu çalışmada da kullanılan SGD yöntemi, her eğitim örneği  $x^{(i)}$  ve etiket  $y^{(i)}$  için bir parametre güncellemesi yapar (Ruder, 2016). İşlem görecek her eğitim verisi rastgele seçilmektedir. Denklemi;

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)})$$

Bu yöntemde, global minimum noktasına giden yol, iki boyutlu oluşturulan paket eğim inişinde olduğu gibi doğrudan giden bir yol değildir. Burada gidilen yol zikzak çizerek ilerlenen bir yoldur. Zikzak çizmesine karşın yine de global minimum noktasına ulaşmayı başarmaktadır. Bu yöntem bir önceki yöntemin aksine, tüm eğitim verisi yerine sadece eğitim örneğini kullanarak ağırlık güncellemesi yapmaktadır. Böylelikle bu yöntem daha verimli çalışmaktadır (Soni, 2018).



Şekil 3.15. SGD eğim azalması (URL-21, 2021)

Derin öğrenmede yaygın olarak kullanılan optimizasyon algoritmaları stochastic gradient descent, adagrad, adadelta, adam ve adamax gibi optimizasyon algoritmalarıdır. Bu algoritmaların arasında hız ve başarımları yönünden farklılıklar bulunmaktadır. Aşağıdaki tabloda derin öğrenmede yaygın olarak kullanılan bazı optimizasyon algoritmaları verilmiştir. Bu çalışmada optimizasyon algoritması olarak SGD fonksiyonu kullanılmıştır.

**Çizelge 3.2.** Optimizasyon algoritmaları olarak kullanılan fonksiyonlar (Ruder, 2016)

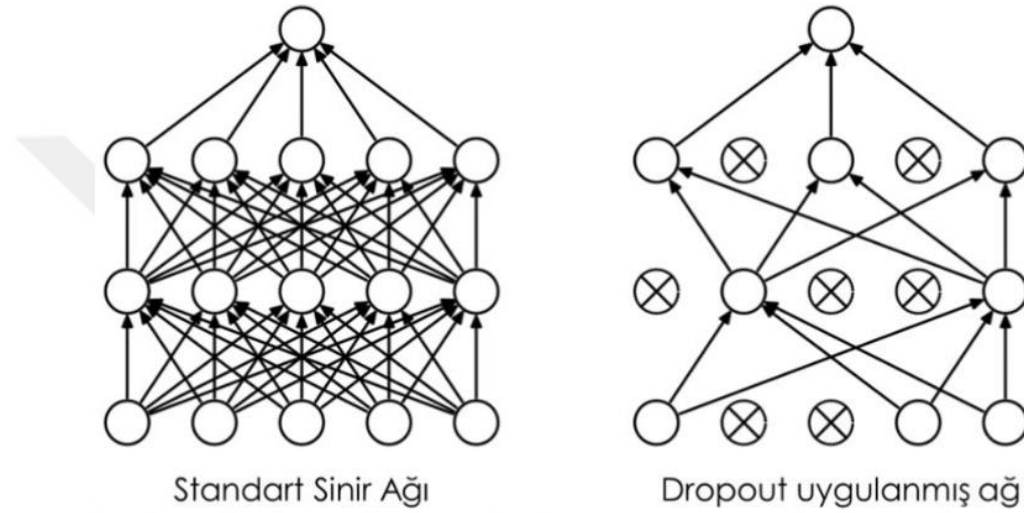
Fonksiyon	Denklemleri
SGD	$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)})$
Momentum	$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta)$ $\theta_{t+1} = \theta_t - v_{t+1}$
RMSprop	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t$
Adagrad	$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} g_{t,i}$
Adadelta	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t$
Adam	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\frac{v_t}{1 - \beta_2^t} + \epsilon}} \frac{m_t}{1 - \beta_1^t}$
Adamax	$\theta_{t+1} = \theta_t - \frac{\eta}{(1 - \beta_1^t)} \frac{m_t}{u_t}$
Nadam	$\theta_{t+1} = \theta_t - \frac{\alpha_t}{\sqrt{\hat{n}_t + \epsilon}} \hat{m}_t$

### 3.2.2.3.5. Seyreltme (Dropout)

Seyreltme (*dropout*), gizli nöronların çıktılarını daha önceden belirlenmiş bir olasılık ile sıfıra yaklaştırarak ezberleme (*overfitting*) önlemeye yardımcı bir yöntemdir. Derin öğrenme uygulamalarında bu değer çoğunlukla 0,5 ya da 0,7 olarak belirlenir (Krizhevsky ve ark. 2012, Szegedy ve ark., 2015). Buna karşın konvüsyonel katmanlarda az parametre olmasından dolayı seyreltme bu katmanlarda daha az etkilidir. Dahası, özellik haritalarında kodlanmış uzamsal ilişkiler nedeniyle, aktivasyonlar yüksek

derecede ilişkili olabilir. Buda seyreltmeyi etkisiz hale getirir. Bu durumda konvolüsyonel sinir ağını daha düzenli hale getirmek için kullanılan başka bir yöntem batch normalizasyon işlemidir.

Düzenleyici bir etkinin yanı sıra, batch normalizasyon aynı zamanda CNN ağının eğitim sırasında yok olma gradyanına bir direnç de verir. Bu da eğitim süresini azaltabilir ve modelin daha iyi performans göstermesini sağlayabilir. Bu çalışmada konvolüsyonel katmanda batch normalizasyon, tam bağlı katmanda ise 0,5 değerli seyreltme uygulanmıştır.



Şekil 3.16. Dropout (Srivastava ve ark., 2014)

### 3.2.2.4. Derin Öğrenme Uygulama Alanları

Derin öğrenme ile sınıflandırma, tanımlama, tahmin, teşhis ve görüntü ayırma gibi çok geniş alanlarda çalışmalar yapılabilmektedir. Mimariler üzerinde inceleme yapılan önceki bölümün ardından bu bölümde derin öğrenme yaklaşımının kullanıldığı alanlar bazında bir inceleme yapılmıştır. Burada, özellikle son yıllarda yapılan çalışmalar irdelenerek hangi yöntemler üzerinde yoğunlaşma olduğu araştırılmıştır.

#### 3.2.2.4.1. Görüntü ve Video İşleme

Derin öğrenmenin ortaya çıkışıyla birlikte özellikle görüntü ve ses analizi üzerinde yoğun bir şekilde kullanılmaya başlandı. Problemlerin çözümde elde edilen yüksek doğruluk yaygınlaşmasında önemli bir rol oynamıştır. Hatta ses ve görüntü

tanımlama gibi bazı alanlarda insan performansının bile üzerine çıkılması sayesinde bu alandaki kullanım popülaritesi giderek artmıştır.

Siyah beyaz resimlerin renklendirilmesinde derin öğrenmeden faydalanılmıştır (Hwang ve Zhou, 2016). Bunlara ilaveten geçmişte siyah-beyaz çekilen filmlerin renklendirilmesi de derin öğrenme kullanılarak yapılmıştır. Derin öğrenme ile sessiz bir videoda insanların dudak hareketinden konuşma tahmininde bulunularak videonun seslendirilmesi yapılmıştır (Assael ve ark., 2016). Dudak okumadaki başarı seviyesi %52 seviyelerinde seyredirken derin öğrenme kullanılarak yapılan bu çalışmada %93'lük bir başarı elde edilmiştir.

Yapılan bir diğer çalışmada bir resimdeki insanlara ait bakışı değiştirilmiştir (Ganin ve ark., 2016). Bir taslaktan resmin elde edilmesi, bir çizimden nesnenin şeklinin tahmin edilmesi ya da harita taslağı kullanılarak gerçek haritanın oluşturulması gibi durumlar derin öğrenme sayesinde başarılmıştır.

Ayrıca derin öğrenme modelleri ile Facebook ve Google gibi birçok büyük şirketin de kullandığı görüntülerde etiketleme yapılması, görüntüdeki objelerin tanımlanması ve görüntülerin sınıflandırılması gibi birçok yenilik yapılmıştır.

Derin öğrenme ile insanların önceki konuşmalarından sentez yapılarak daha önce hiç konuşmadığı bir metni canlı bir şekilde okur gibi seslendirilmesi yapılmıştır. Bu çalışmaya verilebilecek en meşhur örnek 2017 yılında yapılan Barack Obama'nın seslendirilmesi olabilir (Suwajanakorn ve ark., 2017). Önemli bir sorun olan trafikte yayaların tespitinde de seyrek (*sparse*) CNN kullanılarak geliştirilen denetimsiz öğrenme modeli oldukça önemli sonuçlar elde etmiştir.

#### **3.2.2.4.2. Doğal Dil İşleme**

Derin öğrenme algoritmalarından, özellikle CNN, DAE ve LSTM mimarileri doğal dil işleme alanında oldukça etkileyici sonuçlar vermektedir. Shusen Zhou, Aktif Derin Ağ (ADN) olarak adlandırdığı yarı eğitici öğrenme algoritması tasarlamış ve çalışmasını beş duyu analizinden elde edilen veri kümesi üzerine uygulamıştır (Zhou ve ark., 2013). Yarı eğitici öğrenme metodunun kullanıldığı bir diğer çalışmada Zhou ve arkadaşları bulanık DBN adını verdikleri bir öğrenme metodu sunmuşlardır. Yine duyu analizi üzerine yaptıkları bu çalışmada ise bulanık DBN ile eğittikleri veri setini derin mimari tarafından öğrenilmiş görüşleri baz alan üyelik fonksiyonu ile kıyaslamışlardır (Zhou ve ark., 2014).

Hapishanelerdeki kısa mesajların güvenlik denetimini (güvenli ve güvensiz olarak sınıflandırma) yapmak amacıyla oluşturulan derin öğrenme tabanlı RNN ağı da duyu analizinden esinlenerek yapılmıştır. You ve arkadaşlarının yapmış olduğu çalışmada kısa mesajlardan Word2Vec aracılığıyla belirleyici özellikleri çıkarıldıktan sonra RNN ağı kullanılarak sınıflandırma yapılmıştır. Elde edilen deneysel sonuçlar RNN kullanılarak geliştirilen modelin SVM'ye göre daha üstün olduğunu göstermiştir. Geliştirilen RNN modeli %92,7 başarımla elde etmiştir (You ve ark., 2016).

Onur Karasoy ve Serkan Ballı'nın 2017 yılındaki çalışmalarında, cep telefonlarına gelen mesajların normal veya spam mesaj olarak değerlendirebilmek amacıyla bir derin öğrenme metodu sunmuşlardır. Bu çalışmada da yazarlar, kelime özelliklerini çıkarmak amacıyla Word2Vec kullanmışlardır. Daha sonra Random Forest ile sınıflandırma işlemini gerçekleştirmişlerdir (Karasoy ve Ballı, 2017).

Yapılan bir başka çalışmada metnin içindeki anahtar kelimeleri tespit edebilmek için geliştirilen LSTM tabanlı bir uygulama bu alanda başarılı olan HMM ile karşılaştırılmış ve daha iyi sonuçlar elde edilmiştir (Fernández ve ark., 2007).

Cinsiyet belirlemek amacıyla oluşturulan bir diğer derin öğrenme çalışmasında CNN ve LSTM ağları birlikte kullanılmıştır. Geleneksel yöntemlerle yapılan çalışmalarla kıyaslanan uygulama Rusça metinler üzerinde test edilmiş ve %86 oranında bir başarımla elde etmiştir. Convolutional Latent Semantic Model (CLSM) olarak adlandırılan derin ağ modeli web sayfaları tıklanma verileri üzerinde eğitilmiştir. Doküman sıralaması yapılan testlerde önceki çalışmalara göre daha üstün sonuçlar elde etmiştir (Shen ve ark., 2014).

Jianfeng Gao ve arkadaşları geliştirdikleri CNN tabanlı bir derin sinir ağında anlamsal benzerlik modelini (DSSM) sunmuşlardır. Yaptıkları bu çalışmada kullanıcının okumuş olduğu kaynak metin çerçevesinde kullanıcıya ilgi duyabileceği metinleri tavsiye etmeyi amaçlamışlardır (Gao ve ark., 2014).

CNN kullanılarak yapılan bir diğer çalışma ise cümlelerin semantik modellemesi üzerine yapılmış ve yüzde yirmi beş hata oranı ile bu alanda şimdiye dek elde edilen en yüksek başarıma ulaşılmıştır. Bu çalışma dilin doğru anlaşılabilmesi açısından ayrı bir önem taşımaktadır (Kalchbrenner ve ark., 2014).

Son yıllarda e-postalardaki spam tespiti için de derin öğrenme alanında uygulamalar geliştirilmiştir. DAE metodu kullanılarak geliştirilen modeller geleneksel modellere kıyasla oldukça iyi sonuçlar vermiştir.

### 3.2.2.4.3. Biyomedikal Bilgi İşleme

Tıbbi görüntü analizi de bir görüntü işleme alanı olduğundan derin öğrenme, bu problemlerin çözümünde de oldukça başarılıdır. Beyin tümörü ile ilgili araştırmalarında ihtiyaç duyulan görüntü segmentasyonu için son yıllarda derin öğrenme yöntemleri sayesinde başarılı bir şekilde otomatik segmentasyon yapılmaktadır.

Derin öğrenme modelleri sayesinde çok daha büyük miktarda MRI veriler kullanılarak nesnel yorumlar yapılmasına olanak sağlamıştır. Beyin tümörü tespitinde otomatik MRI Segmentasyonu alanında CNN tabanlı algoritmalar, ayırt edici özellikleri çıkararak başarılı sonuçlar üretmiştir (Işın ve ark. 2016).

Share Wave Elastography (SWE) verisi, bilgisayar destekli meme kanseri teşhisinde önemli bir parametredir. Derin öğrenme kullanarak SWE verisinden elde edilen görüntüler sayesinde iyi ve kötü huylu tümör tespiti için özellik çıkarımı sağlanmıştır. İki katmanlı olarak oluşturulan model, 227 adet SWE verisiyle eğitilmiş ve yaklaşık yüzde doksan üç doğruluk oranına ulaşmıştır (Zhang, 2016).

Akciğer kanseri tespiti için yapılan bir başka çalışmada otomatik özellik çıkarımı kullanan derin öğrenme yöntemleri ile geleneksel yöntemler kullanarak özellik çıkarımı elde eden CADx sistemi kıyaslanmıştır. Elde edilen sonuçlar, Area Under Curve (AUC) değeri baz alınarak karşılaştırıldığında derin öğrenme yönteminin üstün olduğu gözlemlenmiştir (Sun ve ark., 2017)

George Dahl ve ekibi 2012 yılında girdikleri bir yarışmayı çoklu görev derin sinir ağı ile biyomoleküler hedef tahmini alanında kazanmayı başarmışlardır (Dahl ve ark., 2014).

2014 yılında ise Sepp Hochreiter ve ekibinin kazandığı bir diğer yarışmada ise ilaçlardaki hedef dışı toksik etkileri derin öğrenme kullanılarak tespit edilmiştir

### 3.2.2.4.4. Diğer Uygulama Alanları

Derin öğrenmenin en sık kullanıldığı alanlar “görüntü ve ses işleme”, “doğal dil işleme” ve “biyomedikal bilgi işleme” alanları olmasına karşın birçok farklı alanda derin öğrenme modellerinden yararlanılmaktadır.

Otonom araçlarda derin öğrenme modelleri geliştirilmekte ve denemeleri yapılmaktadır. Yakın gelecekte bu alanda önemli gelişmeler beklenmektedir. NVIDIA

tarafından geliştirilmekte olan devre kartları ile bu alanlarda kullanılacak süper bilgisayarlar için çalışılmaktadır.

Günümüzde önemi giderek hissedilen kapalı alan yönlendirmelerinde yapılan bir çalışmada bir quardcopter kapalı bir içi mekânda bağımsız olarak dolaştırılmıştır. Kamera yardımıyla ayakkabı, çanta gibi istenilen objeleri bulmayı amaçlayan bir sistem tasarlanmıştır. CNN modelleri sayesinde alanında uzman bir pilotun davranışları taklit edilmiş ve birçok kapalı alanda gerçek testler yapılmıştır.

İnsanlığın gelecek zaman hayalleri arasında yer alan akıllı şehir tasarımlarında da derin öğrenme yaklaşımları en önemli yardımcımız olarak öne çıkmaktadır. Bu hayalin ilk hedeflerinden olan akıllı trafik lambaları üzerindeki çalışmalar yavaş yavaş hayata geçirilmektedir. Bunun yanı sıra DeepSense adlı derin öğrenme uygulamasıyla taksilerin GPS verileri kullanılarak eğitimler yapılmış ve önerilen yaklaşımlar sayesinde hali hazırda kullanılan sistemlere nazaran %5 ‘e varan iyileştirmeler sağlanmıştır.

Doğal dil işlemenin yardımıyla “Derin Araştırma ve Metin Filtreleme” kısaca DEFT olarak adlandırılan bir program geliştirilmiştir. Bu uygulama sayesinde belge analizi yapanların büyük boyutlu verilerde dahi verimli çalışmalarına imkân tanınmıştır.

Günümüzde insan sağlığı için verimli uyku çok önemli bir etken haline gelmiştir. Gelişen teknoloji ile birlikte zaman ve mekân kavramındaki algının değişmesi, yeni ve alışılmış zamanlarda bulunun iş imkânları nedeniyle gece ve gündüz kavramı farklılaşmış birçok insanın uyku düzeni değişmiştir. Uyku kalitesinin belirlenmesi için yapılan bazı çalışmalarda derin öğrenme modellerinden CNN, RNN ve LSTM tabanlı uygulamalar öne çıkmaktadır.

### **3.3. Kullanılan Teknolojiler**

#### **3.3.1. Anaconda**

Anaconda, 700’den fazla açık kaynak paketi içeren bir paket ve çevre yöneticisidir. İçinde Python dağıtımı da bulunduran anaconda, kurulumu oldukça basit, ücretsizdir. Anaconda, yaklaşık 5 milyon kullanıcısıyla dünyanın en popüler ve güvenilir yazılımcı sistemidir. Birçok modern yazılıma öncülük eden anaconda, onlarca açık kaynak projenin temelini oluşturmaktadır. (URL-22, 2021)

Anaconda, içinde barındırdığı birden çok Python sürümü sayesinde Python kullanıcılarına farklı sürümler ile çalışma imkânı sunmaktadır.

### 3.3.2. Python

Python, yorumlanmış, etkileşimli, nesne yönelimli bir programlama dilidir. Modülleri, istisnaları, dinamik yazmayı, çok yüksek seviyeli dinamik veri türlerini ve sınıfları içerir. Prosedürel ve fonksiyonel programlama gibi nesne yönelimli programlamanın ötesinde çoklu programlama paradigmasını destekler (URL-5, 2021).

Girintilere dayalı olması, basit sözdizimine sahip olması gibi özellikleri, dilin öğrenilmesini ve akılda kalmasını kolaylaştıran faktörlerdir. Modüler yapısı sayesinde sınıf dizgesini (sistem) ve her türlü veri alanı girişini desteklemektedir. Neredeyse tüm platformlarda çalışabilir. Python ile sistem programlama, ağ programlama, kullanıcı arabirimi programlama, uygulama ve veritabanı yazılımı programlama ve web programlama gibi birçok alanda yazılım geliştirilmesinde kullanılmaktadır.

1990 yılında Guido van Rossum tarafından Amsterdam'da geliştirilmeye başlanmıştır. 1994 yılının Ocak ayında Python 1.0 sürümüne ulaşılmıştır. 16 Ekim 2000'de tarihinde ise 2.0 sürümü yayınlanmıştır. 3 Aralık 2008 tarihinden itibaren 3.x serisi yayınlanmaya devam etmektedir (URL-6, 2021).

Python sahip olduğu yaygın geliştirici ve kütüphane desteği sayesinde Web tabanlı uygulamalar, masaüstü uygulamaları, bilimsel ve matematiksel hesaplamalar başta olmak üzere her konuyla ilgili uygulama geliştirmek mümkündür.

Bu çalışmada geliştirilen uygulama Python programlama dili kullanılarak Spyder geliştirme ortamında yazılmıştır. Geliştirilen uygulama Windows işletim sistemi üzerinde çalıştırılmış ve sonuçlar elde edilmiştir.

### 3.3.3. TensorFlow

TensorFlow, makine öğrenimi için tasarlanmış veri grafiklerinden yararlanarak hesaplama işlemi yapan açık kaynaklı bir yazılım kütüphanesi olarak tanımlanabilir. Özellikle derin sinir ağlarının eğitimine odaklanmasına rağmen birçok alanda görev yapabilir. Esnek mimarisi sayesinde matematiksel hesaplamaları CPU, GPU ve son zamanlarda TPU olmak üzere farklı farklı platformlara, mobil cihazlara, masaüstüne ve sunuculara dağıtarak gerçekleştirebilmemize imkân verir. (URL-23, 2021)

TensorFlow, Google Beyin ekibi tarafından ortaya çıkarılmış ve gelişmeye devam etmektedir. İlk sürümü 2017 yılının şubat ayında yayınlanmıştır. Başlangıçta, makine

öğrenimi ve derin sinir ağları araştırması yürütmek amacıyla geliştirilmiş olmasına rağmen diğer alanlarda da geniş bir alanda kullanılmaya devam edilmektedir.

### 3.3.4. Keras

Keras, Python'da yazılmış açık kaynaklı bir sinir ağı kütüphanesidir. Keras TensorFlow, Microsoft Cognitive Toolkit, R, Theano veya PlaidML ile beraber çalışabilir. Keras kütüphanesi, kolay ve hızlı bir şekilde yapay sinir ağları oluşturmak ve çalıştırmak için geliştirilmiştir. Kullanıcı dostu, modüler ve genişletilebilirdir. Kerasta modellenmiş ve eğitilmiş sinir ağlarına ait ağırlıklar HDF5 dosya formatında kaydedilebilmekte ve daha sonra tekrar kullanılabilir. Geliştirilen modeller görselleştirebilmekte ve resim olarak kaydedilebilmektedir. Keras, Google mühendisi François Chollet tarafından geliştirilmiştir. (URL-24, 2021)

### 3.4. Veri Seti

Bu çalışmada Ulusal Sağlık Enstitüleri (*National Institutes of Health (NIH)*)'nin PACS sisteminden çıkarılan hastane ölçeğindeki göğüs röntgeni görüntüleriyle oluşturulan "ChestX-ray14" veri tabanı kullanılmıştır (Wang ve ark., 2017). Bu veri setinde 30.805 farklı hastanın 112.120 adet önden görünümlü göğüs röntgeni görüntüleri bulunmaktadır.


Görüntüler, radyologların geri bildirimlerine dayanarak, sıklıkla gözlemlenen ve teşhis edilen on dört yaygın göğüs hastalığı ile etiketlenmiştir. Görüntü etiketlerini oluşturmak için çeşitli Doğal Dil İşleme (*Natural Language Processing (NLP)*) teknikleri benimsenmiştir. Etiketler için kullanılan anahtar kelimeler tamamen radyoloji raporlarından alınmıştır. Bu nedenle veri setindeki birçok görüntünün çoklu etikete sahip olabileceği sınıflandırma yaparken göz önünde bulundurulmuştur.

Veri setinde bulunan görüntüler 1024 x 1024 piksel boyutunda, yüksek çözünürlüğe sahip ve png formatındadır. Veri seti yaklaşık 40 GB boyutundadır.

Veri setindeki 14 hastalık etiketi:

- Atelektazi (*Atelectasis*)
- Kardiyomegali (*Cardiomegaly*)
- Konsolidasyon (*Consolidation*)
- Ödem (*Edema*)
- Efüzyon (*Effusion*)

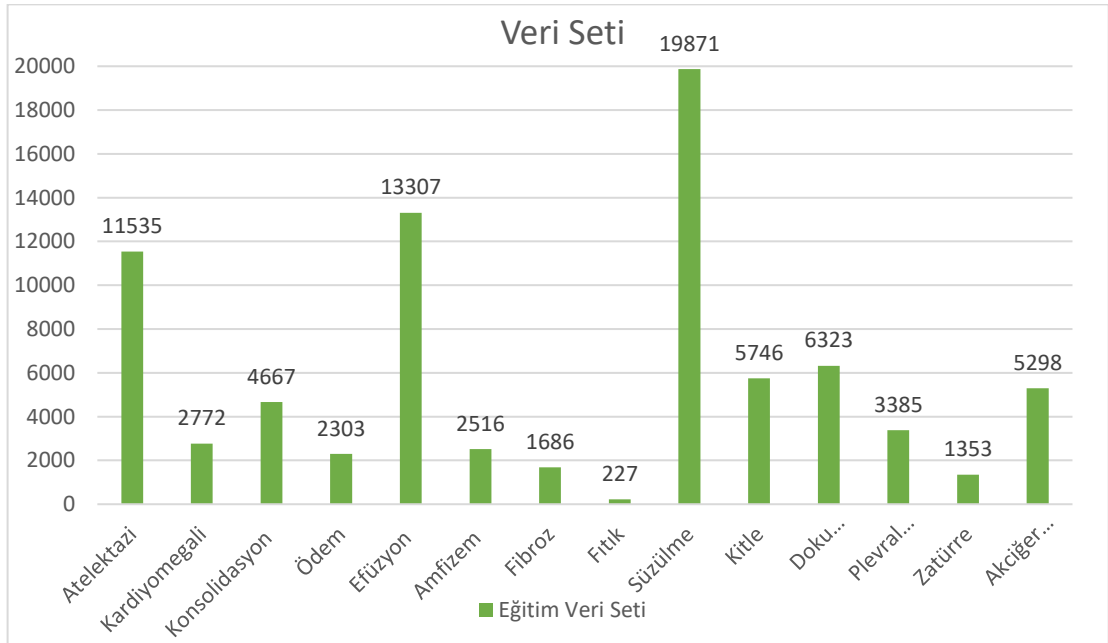
- Amfizem (*Emphysema*)
- Fibroz (*Fibrosis*)
- Fıtık (*Hernia*)
- Süzülme (*Infiltration*)
- Kitle (*Mass*)
- Doku Büyümesi (*Nodule*)
- Plevral Kalınlaşma (*Pleural Thickening*)
- Zatürre (*Pneumonia*)
- Akciğer Sönmesi (*Pneumothorax*) dir.



Şekil 3.17. Dairesel diyagram, 14 patoloji sınıfının her birinde çoklu etiketli görüntülerin oranlarını ve etiketlerin birlikte oluşma istatistiklerini gösterir (Wang ve ark, 2017).

Çizelge 3.3. Veri setinin sınıflara göre resim sayıları

Sınıf İsmi	Veri Seti
Atelektazi ( <i>Atelectasis</i> )	11535
Kardiyomegali ( <i>Cardiomegaly</i> )	2772
Konsolidasyon ( <i>Consolidation</i> )	4667
Ödem ( <i>Edema</i> )	2303
Efüzyon ( <i>Effusion</i> )	13307
Amfizem ( <i>Emphysema</i> )	2516
Fibroz ( <i>Fibrosis</i> )	1686
Fıtık ( <i>Hernia</i> )	227
Süzülme ( <i>Infiltration</i> )	19871
Kitle ( <i>Mass</i> )	5746
Doku Büyümesi ( <i>Nodule</i> )	6323
Plevral Kalınlaşma ( <i>Pleural Thickening</i> )	3385
Zatürre ( <i>Pneumonia</i> )	1353
Akciğer Sönmesi ( <i>Pneumothorax</i> )	5298
Bulgu Yok ( <i>No Finding</i> )	60412
<b>Toplam</b>	<b>112120</b>



Şekil 3.18. Veri setinde yer alan sınıflara ait histogram grafiği

### 3.5. Çalışmada Kullanılan Fiziksel Donanım

Derin öğrenme tabanlı makine öğrenmesi algoritmaları çok fazla hesaplama işlemi yaptığından oldukça iyi donanımlara ihtiyaç duymaktadır. Bu çalışmada yapılan çalışmalar Necmettin Erbakan Üniversitesi Bilgisayar Mühendisliği tarafından araştırmacıların kullanımına sunulmuş bir sistem üzerinde gerçekleştirilmiştir. Bu sisteme ait donanımsal bilgiler Çizelge 3.4 'te gösterilmiştir.

**Çizelge 3.4.** Donanımsal bilgiler

<b>İşlemci</b>	Intel(R) Core(TM) i9-10900 CPU @ 2.80GHz 2.81 GHz
<b>Bellek</b>	96 GB DD4 3000mHz
<b>Disk</b>	1 x Samsung 932GB SSD 1x ST4000VN008-2DR166 3.64TB HDD
<b>GPU</b>	NVIDIA Quadro RTX 4000
<b>Ağ Bağlantısı</b>	Intel® Ethernet Controller (2) I225V

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada geliştirilen algoritma ChestX-ray14 veri seti üzerinde adım adım uygulanmıştır. Python programlama dili kullanılarak geliştirilen uygulamaya ait açıklamalar alt başlıklar halinde verilmiştir.

Düzenlenen veri seti geliştirilen CNN modeli ve literatürde sıklıkla kullanılan VGG-16 ve ResNet-152 modelleri ile çalıştırılmış ve elde edilen sonuçlar bu bölümde paylaşılmıştır.

### 4.1. Ön İşlem

Geliştirilen algoritmada kullanılacak olan ChestX-ray14 veri setindeki her bir resmin boyutunun “1024 x 1024” piksel olması algoritmanın oldukça fazla kaynağa ihtiyaç duymasına neden olmuştur. Bu durum, “1024 x 1024” piksel boyutlarındaki resimlerin küçültülmesi ihtiyacını doğurmuştur. Veri setinin algoritmada kullanabilmek için resimler ön işlemde geçirilerek boyutları “224 x 224” piksel olarak yeniden boyutlandırılmıştır. Tüm resimler aynı yükseklik ve genişliğe sahiptir.

Resimlerin yeniden boyutlandırılması işlemi Çizelge 4.1 ‘de gösterilen kod bloğu yardımıyla OpenCV kütüphanesi kullanılarak yapılmıştır. Kod bloğunda her bir resim bir döngü kurularak bellekten okunup yeniden boyutlandırıldıktan sonra bir dizi olarak uygulamanın sonraki adımlarında kullanılmıştır.

**Çizelge 4.1.** Ön İşlem Kod Bloğu

<b>Kod Bloğu: (Ön İşlem)</b>
<p><b>Girdi:</b> Veri setindeki 1024x1024 piksel boyutundaki N adet resim</p> <p><b>Çıktı:</b> 224x224 piksel boyutunda N adet resim</p>
<p><b>Adım 1: Başla</b></p> <p><b>Adım 2: Döngü (N adet resim)</b></p> <ul style="list-style-type: none"> <li>▪ Klasörden resim yükle</li> <li>▪ Yüklenen resmi değişkene ata</li> <li>▪ Değişkene atanmış resmi yeniden boyutlandır</li> <li>▪ Yeniden boyutlandırılan resmi diziye kaydet</li> <li>▪ Döngüden çık</li> </ul> <p><b>Adım 3: Bitir</b></p>

## 4.2. Eğitim, Doğrulama ve Test

Veri seti, eğitim ve test olarak iki bölüme ayrılmıştır. Bu bölümlerden eğitim için toplam veri setinin %80'i, test için ise kalan %20'lik kısmı kullanılmıştır.

## 4.3. Çalışmada Geliştirilen CNN Algoritması

Geliştirilen modelde katmanlara göre yapılan işlemler aşağıdaki gibidir:

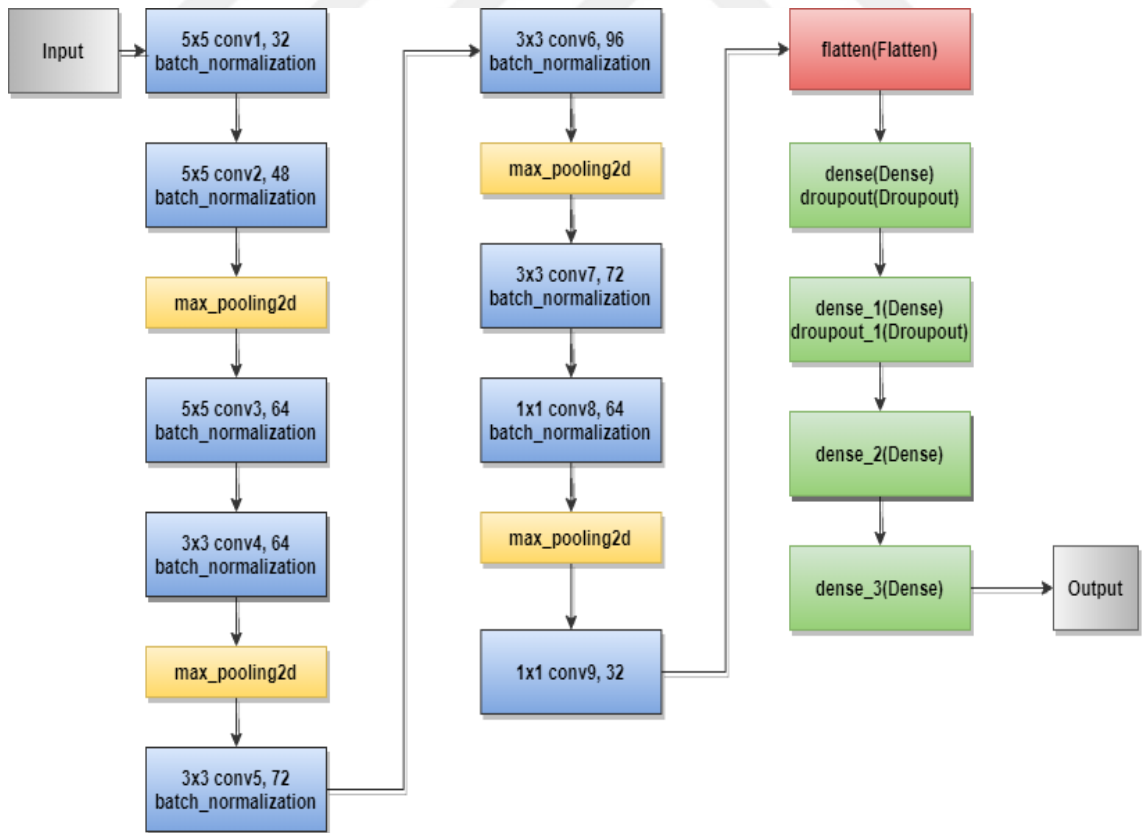
- **Giriş katmanı:** veriler yeniden boyutlandırma işlemi uygulanarak 224x224 piksel resimler halinde konvolüsyonel katmana gönderilmiştir.
- **Birinci konvolüsyon katman:** 224x224 piksel boyutlu resimlere 5x5 boyutlu 32 adet filtre uygulanmıştır.
- **İkinci konvolüsyon katman:** 5x5 boyutlu 48 adet filtre ve 2x2'lik maxpooling işlemi uygulanmıştır.
- **Üçüncü konvolüsyon katman:** 5x5 boyutlu 64 adet filtre uygulanmıştır.
- **Dördüncü konvolüsyon katman:** 3x3 boyutlu 64 adet filtre ve 2x2'lik maxpooling işlemi uygulanmıştır.
- **Beşinci konvolüsyon katman:** 3x3 boyutlu 72 adet filtre uygulanmıştır.
- **Altıncı konvolüsyon katman:** 3x3 boyutlu 96 adet filtre ve 2x2'lik maxpooling işlemi uygulanmıştır.
- **Yedinci konvolüsyon katman:** 3x3 boyutlu 72 adet filtre uygulanmıştır.
- **Sekizinci konvolüsyon katman:** 1x1 boyutlu 64 adet filtre ve 2x2'lik maxpooling işlemi uygulanmıştır.
- **Dokuzuncu konvolüsyon katman:** 1x1 boyutlu 32 adet filtre uygulanmıştır.

Dokuz katmandan oluşan konvolüsyon ağı tamamında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Ayrıca her katmanın sonunda batch normalizasyon işlemi uygulanmıştır. Dokuzuncu katmanın sonunda düzleştirme işlemi yapılarak veriler tek boyutlu dizi haline dönüştürülmüştür. Bu katmandan sonra veriler tam bağlı katmanında işlem görmeye devam etmiştir.

- **Onuncu katman:** 2048 nörondan oluşan katmanın sonunda ReLU aktivasyon fonksiyonu kullanılmıştır. Seyreltme değeri olarak 0,5 belirlenmiştir.

- **On birinci katman:** 512 nörondan oluşan katmanın sonunda ReLU aktivasyon fonksiyonu kullanılmıştır. Seyreltme değeri olarak 0,5 belirlenmiştir.
- **On ikinci katman:** 128 nörondan oluşan katmanın sonunda ReLU aktivasyon fonksiyonu kullanılmıştır. Seyreltme değeri olarak 0,5 belirlenmiştir.
- **On üçüncü katman:** 32 nörondan oluşan katmanın sonunda ReLU aktivasyon fonksiyonu kullanılmıştır. Bu katman çıkış katmanına bağlandığı için seyreltme kullanılmamıştır.
- **Çıktı katmanı:** Sınıf sayısı olan 15 nörondan oluşmaktadır. Bu katmanın sonunda aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmıştır.

Optimizasyon algoritması olarak Stokastik Eğitim Azalması (SGD) seçilmiştir. Algoritma üzerinde öğrenme oranı olarak 0,005, loss fonksiyonu olarak da binary\_crossentropy tercih edilmiştir. Bu şekilde öğrenme geç olmakta fakat algoritmanın minimumu kaçırma ihtimali azalmaktadır. Öğrenme esnasında geri besleme işlemi 800 tur (*epoch*) tekrarlanmıştır.



Şekil 4.1. Çalışmada kullanılan CNN modeli

**Çizelge 4.2.** Çalışmada kullanılan CNN mimarisinin yapısı

	<b>Katman</b>	<b>Boyut</b>	<b>Filtre Boyutu</b>	<b>Öznetelik Haritası</b>	<b>Aktivasyon Fonksiyonu</b>
Giriş	Görüntü	1024x1024x1	-	1	
1	Konvolüsyon	224x224	5x5	32	ReLU
2	Konvolüsyon	224x224	5x5	48	ReLU
3	Max.Pooling	128x128	2x2	48	ReLU
4	Konvolüsyon	128x128	5x5	64	ReLU
5	Konvolüsyon	128x128	3x3	64	ReLU
6	Max.Pooling	64x64	2x2	64	ReLU
7	Konvolüsyon	64x64	3x3	72	ReLU
8	Konvolüsyon	64x64	3x3	96	ReLU
9	Max.Pooling	32x32	2x2	96	ReLU
10	Konvolüsyon	32x32	3x3	72	ReLU
11	Konvolüsyon	32x32	1x1	64	ReLU
12	Max.Pooling	16x16	2x2	64	ReLU
13	Konvolüsyon	16x16	1x1	32	ReLU
14	Dense	2048	-	-	ReLU
15	Dense	512	-	-	ReLU
16	Dense	128	-	-	ReLU
17	Dense	32	-	-	ReLU
Çıkış	Dense	15	-	-	Sigmoid

#### 4.4. Performans Ölçütleri

Yapılan deneylerin performanslarının karşılaştırılması için gerçek pozitif (True Positive - TP), yanlış pozitif (False Positive - FP), gerçek negatif (True Negative - FN), ve yanlış negatif (False Negative - FP) verileri kullanılarak hesaplanan performans ölçütleri aşağıda Çizelge 4.3'te gösterilmektedir.

Çizelge 4.3. Performans Ölçütleri

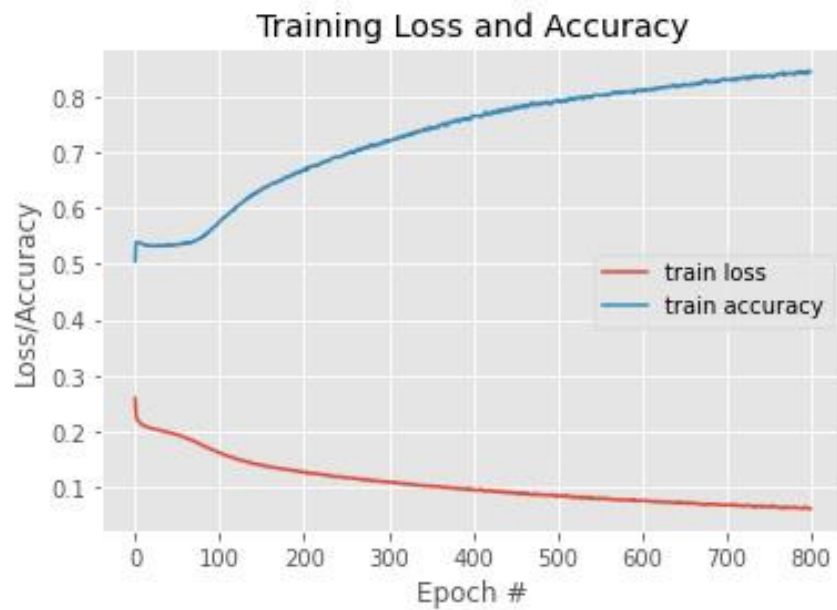
Performans Ölçütü	Denklemi
Doğruluk	$TN + TP / \text{Test Verisi Toplamı}$
Hata Oranı	$FN + FP / \text{Test Verisi Toplamı}$
Duyarlılık	$TP / (FN+TP)$
Yanlış Pozitif Oranı	$FP / (TN+FP)$
Seçicilik	$TN / (TN+FP)$
Kesinlik	$TP/(FP+TP)$

Ön işlem sonucunda elde edilen veri seti, geliştirilen CNN modeli üzerinde 800 tur eğitilmiş ve %91,04 başarı ve 0,089 hata elde edilmiştir. Eğitim sonuçları Çizelge 4.4'te paylaşılmıştır.

Çizelge 4.4. Elde edilen sonuçlar

	Sonuç
<b>Başarı</b>	%91,04
<b>Hata</b>	0,089

Eğitim esnasında elde edilen hata ve başarı değerleri Şekil 4.2 'de verilmiştir.



Şekil 4.2. Loss (Hata) ve Accuracy (Başarı) Grafiği

Geliştirilen CNN ağının eğitimi hastalık sınıfları bazında da değerlendirilmiş ve elde edilen sonuçlar Çizelge 4.5'te verilmiştir. Hastalık sınıfları bazında elde edilen sonuçların en yükseği %99,80 ile fıtık, en düşüğü ise %73,41 ile süzülme olarak belirlenmiştir. Tabloda genel başarı oranının en düşük olduğu sınıf ise %61,56 ile bulgu yok sınıfı elde etmiştir.

**Çizelge 4.5.** Sınıf bazında elde edilen sonuçlar

Sınıf İsmi	Başarım (%)
Atelektazi ( <i>Atelectasis</i> )	82,61
Kardiyomegali ( <i>Cardiomegaly</i> )	97,57
Konsolidasyon ( <i>Consolidation</i> )	95,28
Ödem ( <i>Edema</i> )	97,03
Efüzyon ( <i>Effusion</i> )	85,89
Amfizem ( <i>Emphysema</i> )	97,65
Fibroz ( <i>Fibrosis</i> )	98,45
Fıtık ( <i>Hernia</i> )	99,80
Süzülme ( <i>Infiltration</i> )	73,41
Kitle ( <i>Mass</i> )	94,66
Doku Büyümesi ( <i>Nodule</i> )	91,73
Plevral Kalınlaşma ( <i>Pleural Thickening</i> )	96,93
Zatürre ( <i>Pneumonia</i> )	98,82
Akciğer Sönmesi ( <i>Pneumothorax</i> )	94,14
Bulgu Yok ( <i>No Finding</i> )	61,56
<b>Genel Başarı</b>	<b>91,04</b>

Yapılan eğitim sonucunda elde edilen sınıf bazında hata matrisleri ve bazı oranlar Çizelge 4.6'da verilmiştir.

Çizelge 4.6. Sınıf bazında elde edilen hata matrisleri

ATELEKTAZİ			TAHMİN				TOPLAM		
			0		1			Doğruluk	
	GERÇEK	0	TN	17996	2062	FP	20058	Hata Oranı	0,1739
1		FN	1838	528	TP	2366	Duyarlılık	0,2232	
TOPLAM			19834	2590		22424	Yanlış Pozitif Oranı	0,1028	
							Seçicilik	0,8972	
							Kesinlik	0,2039	
							Yaygınlık	0,1055	

KARDİYOMEGALİ			TAHMİN				TOPLAM		
			0		1			Doğruluk	
	GERÇEK	0	TN	21878	0	FP	21878	Hata Oranı	0,0243
1		FN	546	0	TP	546	Duyarlılık	0,0000	
TOPLAM			22424	0		22424	Yanlış Pozitif Oranı	0,0000	
							Seçicilik	1,0000	
							Kesinlik	-	
							Yaygınlık	0,0243	

KONSOLIDASYON			TAHMİN				TOPLAM		
			0		1			Doğruluk	
	GERÇEK	0	TN	21357	62	FP	21419	Hata Oranı	0,0472
1		FN	996	9	TP	1005	Duyarlılık	0,0090	
TOPLAM			22353	71		22424	Yanlış Pozitif Oranı	0,0029	
							Seçicilik	0,9971	
							Kesinlik	0,1268	
							Yaygınlık	0,0448	

ÖDEM			TAHMİN				TOPLAM		
			0		1			Doğruluk	
	GERÇEK	0	TN	21723	274	FP	21997	Hata Oranı	0,0297
1		FN	393	34	TP	427	Duyarlılık	0,0796	
TOPLAM			22116	308		22424	Yanlış Pozitif Oranı	0,0125	
							Seçicilik	0,9875	
							Kesinlik	0,1104	
							Yaygınlık	0,0190	

EFÜZYON			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	18585	1182	FP	19767	Doğruluk	0,8589
1		FN	1983	674	TP	2657	Hata Oranı	0,1411	
TOPLAM		20568		1856		22424	Duyarlılık	0,2537	
							Yanlış Pozitif Oranı	0,0598	
							Seçicilik	0,9402	
							Kesinlik	0,3631	
							Yaygınlık	0,1185	

AMFİZEM			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	21895	18	FP	21913	Doğruluk	0,9765
1		FN	510	1	TP	511	Hata Oranı	0,0235	
TOPLAM		22405		19		22424	Duyarlılık	0,0020	
							Yanlış Pozitif Oranı	0,0008	
							Seçicilik	0,9992	
							Kesinlik	0,0526	
							Yaygınlık	0,0228	

FİBROSİS			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	22077	0	FP	22077	Doğruluk	0,9845
1		FN	347	0	TP	347	Hata Oranı	0,0155	
TOPLAM		22424		0		22424	Duyarlılık	0,0000	
							Yanlış Pozitif Oranı	0,0000	
							Seçicilik	1,0000	
							Kesinlik	-	
							Yaygınlık	0,0155	

HERNİA			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	22379	0	FP	22379	Doğruluk	0,9980
1		FN	45	0	TP	45	Hata Oranı	0,0020	
TOPLAM		22424		0		22424	Duyarlılık	0,0000	
							Yanlış Pozitif Oranı	0,0000	
							Seçicilik	1,0000	
							Kesinlik	-	
							Yaygınlık	0,0020	

INFILTRATION			TAHMİN				TOPLAM		
			0		1			Doğruluk	
GERÇEK	0	TN	15402	3059	FP	18461	Hata Oranı	0,2659	
	1	FN	2903	1060	TP	3963	Duyarlılık	0,2675	
TOPLAM			18305	4119		22424	Yanlış Pozitif Oranı	0,1657	
							Seçicilik	0,8343	
							Kesinlik	0,2573	
							Yaygınlık	0,1767	

MASS			TAHMİN				TOPLAM		
			0		1			Doğruluk	
GERÇEK	0	TN	21223	45	FP	21268	Hata Oranı	0,0534	
	1	FN	1152	4	TP	1156	Duyarlılık	0,0035	
TOPLAM			22375	49		22424	Yanlış Pozitif Oranı	0,0021	
							Seçicilik	0,9979	
							Kesinlik	0,0816	
							Yaygınlık	0,0516	

NODULE			TAHMİN				TOPLAM		
			0		1			Doğruluk	
GERÇEK	0	TN	20506	663	FP	21169	Hata Oranı	0,0827	
	1	FN	1191	64	TP	1255	Duyarlılık	0,0510	
TOPLAM			21697	727		22424	Yanlış Pozitif Oranı	0,0313	
							Seçicilik	0,9687	
							Kesinlik	0,0880	
							Yaygınlık	0,0560	

PALEVRAL KALINLAŞMA			TAHMİN				TOPLAM		
			0		1			Doğruluk	
GERÇEK	0	TN	21735	0	FP	21735	Hata Oranı	0,0307	
	1	FN	689	0	TP	689	Duyarlılık	0,0000	
TOPLAM			22424	0		22424	Yanlış Pozitif Oranı	0,0000	
							Seçicilik	1,0000	
							Kesinlik	-	
							Yaygınlık	0,0307	

PNEUMONİA			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	22160	0	FP	22160	Doğruluk	0,9882
1		FN	264	0	TP	264	Hata Oranı	0,0118	
TOPLAM		22424		0		22424	Duyarlılık	0,0000	
							Yanlış Pozitif Oranı	0,0000	
							Seçicilik	1,0000	
							Kesinlik	-	
							Yaygınlık	0,0118	

PNEUMOTHORAX			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	21020	329	FP	21349	Doğruluk	0,9414
1		FN	984	91	TP	1075	Hata Oranı	0,0586	
TOPLAM		22004		420		22424	Duyarlılık	0,0847	
							Yanlış Pozitif Oranı	0,0154	
							Seçicilik	0,9846	
							Kesinlik	0,2167	
							Yaygınlık	0,0479	

NO FINDING			TAHMİN				TOPLAM		
			0		1				
	GERÇEK	0	TN	6946	3468	FP	10414	Doğruluk	0,6156
1		FN	5151	6859	TP	12010	Hata Oranı	0,3844	
TOPLAM		12097		10327		22424	Duyarlılık	0,5711	
							Yanlış Pozitif Oranı	0,3330	
							Seçicilik	0,6670	
							Kesinlik	0,6642	
							Yaygınlık	0,5356	

Çalışmada kullanılan veri setini geliştirdiğimiz modelin başarımını kıyaslayabilmek adına görüntü işleme alanında şimdiye kadar birçok başarılar elde etmiş VGG-16 ve ResNet-152 CNN modelleri üzerinde test edilmiştir. Elde edilen sonuçları karşılaştırmalı olarak Çizelge 4.7’de verilmektedir.

**Çizelge 4.7.** VGG-16, ResNet-152 ve geliştirilen modelin karşılaştırılması

	Geliştirilen Model (%)	VGG-16 (%)	ResNet-152 (%)
<b>Başarı</b>	91,04	92,01	92,62
<b>Hata</b>	0,089	0,080	0,074

Yapılan karşılaştırmaların sınıf bazında elde edilen sonuçları çizelge 4.8’de gösterilmektedir. Geliştirilen CNN modeli, VGG-16 ve ResNet-152 modelleri ile yakın bir başarı oranı elde etmiştir.

**Çizelge 4.8.** VGG-16, ResNet-152 ve algoritmamızın sınıf bazında karşılaştırılması

Sınıf İsmi	Geliştirilen Model (%)	VGG-16 (%)	ResNet-152 (%)
Atelektazi ( <i>Atelectasis</i> )	82,61	87,36	88,40
Kardiyomegali ( <i>Cardiomegaly</i> )	97,57	97,16	97,47
Konsolidasyon ( <i>Consolidation</i> )	95,28	94,27	95,13
Ödem ( <i>Edema</i> )	97,03	97,51	97,94
Efüzyon ( <i>Effusion</i> )	85,89	87,62	88,61
Amfizem ( <i>Emphysema</i> )	97,65	97,36	97,64
Fibroz ( <i>Fibrosis</i> )	98,45	98,04	98,43
Fıtık ( <i>Hernia</i> )	99,80	99,79	99,80
Süzülme ( <i>Infiltration</i> )	73,41	78,25	80,11
Kitle ( <i>Mass</i> )	94,66	94,06	94,58
Doku Büyümesi ( <i>Nodule</i> )	91,73	93,18	93,94
Plevral Kalınlaşma ( <i>Pleural Thickening</i> )	96,93	96,15	96,70
Zatürre ( <i>Pneumonia</i> )	98,82	98,68	98,77
Akciğer Sönmesi ( <i>Pneumothorax</i> )	94,14	94,88	95,13
Bulgu Yok ( <i>No Finding</i> )	61,56	65,81	66,71
<b>Genel Başarı</b>	<b>91,04</b>	<b>92,01</b>	<b>92,62</b>

Ayrıca çalışmanın konusu olan CNN modeli, aynı veri seti üzerinde yapılan önceki çalışmaların sonuçlarıyla karşılaştırılmıştır. Geliştirilen model önceki çalışmalara göre daha iyi sonuçlar elde etmiştir. Sınıf bazında yapılan bu karşılaştırmalardan elde edilen sonuçlar Çizelge 4.9’da gösterilmektedir.

**Çizelge 4.9.** Veri seti üzerinde yapılan çalışmaların sonuçlarının karşılaştırılması

<b>Sınıf İsmi</b>	<b>Geliştirilen Model (%)</b>	<b>Wang ve ark. (%)</b>	<b>Yao ve ark. (%)</b>	<b>Gundel ve ark. (%)</b>
Atelektazi ( <i>Atelectasis</i> )	82,61	70,03	73,23	76,71
Kardiyomegali ( <i>Cardiomegaly</i> )	97,57	81,0	85,56	88,13
Konsolidasyon ( <i>Consolidation</i> )	95,28	70,32	71,01	74,25
Ödem ( <i>Edema</i> )	97,03	80,52	80,56	83,55
Efüzyon ( <i>Effusion</i> )	85,89	75,85	80,56	82,78
Amfizem ( <i>Emphysema</i> )	97,65	83,3	84,12	89,45
Fibroz ( <i>Fibrosis</i> )	98,45	78,59	74,23	81,88
Fıtık ( <i>Hernia</i> )	99,80	87,17	77,55	89,76
Süzülme ( <i>Infiltration</i> )	73,41	66,14	67,33	70,89
Kitle ( <i>Mass</i> )	94,66	69,33	71,88	82,01
Doku Büyümesi ( <i>Nodule</i> )	91,73	66,87	77,87	75,78
Plevral Kalınlaşma ( <i>Pleural Thickening</i> )	96,93	68,35	72,44	76,01
Zatürre ( <i>Pneumonia</i> )	98,82	65,8	68,45	73,01
Akciğer Sönmesi ( <i>Pneumothorax</i> )	94,14	79,93	80,52	84,56

## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

Bu tez çalışmasının amacı, bilgisayar destekli sistemler ile sağlık alanında yapılan çalışmalara bir nebze olsun katkıda bulunarak hizmet kalitesini yukarıya taşımaktır. Dünyadaki birçok ülkenin sağlık sisteminin karşı karşıya olduğu en temel sorun olan hastalıkta erken tanı problemi, bu çalışmanın ana fikrini oluşturmaktadır. Bu çalışmada, iyi tasarlanmış bir derin öğrenme modelinin hastalıkların erken teşhisinde başarıyla uygulanabileceği gösterilmiştir. Çalışmamızda elde edilen sonuçlar umut verici düzeydedir.

Bu tez çalışmasında yapılan deneyler göğüs röntgen görüntüleri üzerinde derin öğrenme modelleri kullanılarak Chest X-ray14 veri setinde eğitilerek CNN uygulamasında gerçekleştirilmiştir. CNN modelinin eğitimden sonra elde edilen ortalama test sonuçlarında hata değeri: 0,089 ve başarı değeri: %91,04 olarak elde edilmiştir. Sınıf bazında yapılan incelemelerde de hastalık türleri arasından en yüksek başarı %99,80 ile fitik, en düşük başarı ise %73,41 ile süzülme hastalığında elde edilmiştir. Tabloda genel başarı oranının en düşük olduğu sınıf ise %61,56 ile bulgu yok sınıfı olmuştur.

### 5.2 Öneriler

Bu çalışmada CNN modelleri ile göğüs röntgen görüntüleri üzerinde çalışılmış ve elde edilen sonuçlar incelenmiştir. Çalışmada kullanılan veri setinin hali hazırda gelişime açık bir veri seti olması ve derin öğrenme yaklaşımlarındaki günden güne elde edilen iyileştirmeleri de göz önüne aldığımızda elde edilen sonuçların zamanla daha da iyileştirilebileceği bir gerçektir. Sonraki çalışmalarımızda yeni yaklaşımlar, hibrit sistemler ve geliştirilmiş model ve algoritmalar ile başarımın artırılması hedeflenmektedir.

Bu çalışmadan elde edilen deneyim ve sonuçlara göre çalışmanın kapsamı genişletilerek yakın bir gelecekte farklı birçok hastalık tespiti için yeni derin öğrenme modellerinin kullanımının önü açık görülmektedir.

## 6. KAYNAKLAR

- Akpolat, G. ve Yalçın, H., 2019, "Diagnosis of Pneumonia Via Deep Learning Algorithms"
- Aizenberg, I. N., Aizenberg, N. N. and Vandewalle, J., 2000, "Multiple-Valued Threshold Logic and Multi-Valued Neurons," in Multi-Valued and Universal Binary Neurons, Boston, MA: Springer US, pp. 25–80.
- Angeli, C., 2010, Diagnostic expert systems: From expert's knowledge to real-time systems. *Advanced knowledge based systems: Model, applications & research*, 1: 50-73.
- 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>
- Assael, Y. M., Shillingford, B., Whiteson, S. and De Freitas, N., 2016, "LipNet: End-to-End Sentence-level Lipreading."
- 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.
- Barkmeyer, N., 2015, Deep learning: Convolutional neural networks for object recognition, TUM Advanced Seminar, Supervisor: Andreas Holzbach, TUM Institute for Cognitive Systems.
- Bengio, Y., 2009, Learning Deep Architectures for AI, *Foundations and Trends in Machine Learning*, vol. 2, no. 1, pp. 1– 127.
- Bengio, Y., Goodfellow, I. J., Courville, A., 2014, Deep learning. Book in preparation for MIT Press.
- Bishop, C. M., 2006, *Pattern Recognition and Machine Learning*, Springer.
- Buchanan J. W. and Bucheler J. Vertebral scale system to measure heart size in radiographs. *J Am Vet Med Assoc*. 1995; 206:194–199.
- Ciresan, D., Meier, U., Gambardella, L. M. and Schmidhuber, J., 2011, "Convolutional Neural Network Committees for Handwritten Character Classification," in 2011 International Conference on Document Analysis and Recognition, pp. 1135–1139.
- Ciresan, D., Meier, U. and Schmidhuber, J., 2012, "Multi-column Deep Neural Networks for Image Classification."
- Collobert, R. and Weston, J., 2008, "A unified architecture for natural language processing: Deep neural networks with multitask learning," in *Proceedings of the*

- 25th international conference on Machine learning - ICML ', vol. 20, no. 1, pp. 160–167.
- Dahl, G. E., Jaitly, N. and Salakhutdinov, R., 2014, "Multi-task Neural Networks for QSAR Predictions".
- 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>
- Deng, L. and Yu, D., 2014, "Deep Learning: Methods and Applications," *Found. Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387.
- Dumoulin, V. and Visin, F., 2016, "A guide to convolution arithmetic for deep learning," *CoRR*, vol. abs/1603.07285.
- Er, M., B., 2020, "Önceden Eğitilmiş Derin Ağlar ile Göğüs Röntgeni Görüntüleri Kullanılarak Pnömoni Sınıflandırması."
- Er, O., Yumuşak, N., Temurtas, F., 2010, Chest disease diagnosis using artificial neural networks. *Expert Syst Appl.*, 37(12): 7648-7655.
- Fernández, S., Graves, A. and Schmidhuber, J., 2007, "An Application of Recurrent Neural Networks to Discriminative Keyword Spotting," in *International Conference on Artificial Neural Networks*, pp. 220–229.
- Fukushima, K. . N., 1980, "A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position.," *Biol. Cybern.*, vol. 36, no. 4, pp. 193–202.
- Ganin, Y., Kononenko, D., Sungatullina D., and Lempitsky V., 2016, *DeepWarp: Photorealistic image resynthesis for gaze manipulation*. European Conference on Computer Vision, Springer.
- Gao, J., Deng, L., Gamon, M. and He, X., 2014, "Modeling interestingness with deep neural networks," 14/304,863.
- Grefenstette, E., Blunsom, P., Freitas, N. and Hermann, K. M., 2014, "A Deep Architecture for Semantic Parsing."
- 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>
- Gülgün, O. D. Ve Erol, H., 2019, "Classification Performance Comparisons of Deep Learning Models in Pneumonia Diagnosis Using Chest X-Ray Images."
- Graves, A., 2013, "Generating sequences with recurrent neural networks." arXiv preprint arXiv:1308.0850.

- Haykin, S. S., 2009, *Neural Networks and Learning Machines*, 3rd ed ed. New York: Pearson Education, p. 906 S.
- Hebb, D., 1949, *The Organization of Behavior*. New York: Wiley & Sons.
- Hinton, G. E., 2007, "Learning multiple layers of representation," *Trends Cogn. Sci.*, vol. 11, no. 10, pp. 428–434.
- Hinton, G. E., Dayan, P., Frey, B. J. and Neal, R. M., 1995, "The wake-sleep algorithm for unsupervised neural networks," *Science*, vol. 268, no. 5214, pp. 1158–61.
- Hinton, G. E., Nair, V., 2010, *Proceeding ICML'10 Proceedings of the 27th International Conference on International Conference on Machine Learning*, Pages 807-814.
- Hubel, D. H. and Wiesel, T. N., 1968, "Receptive fields and functional architecture of monkey striate cortex," *J. Physiol.*, vol. 195, no. 1, pp. 215–243.
- Hochreiter, S. and Schmidhuber, J., 1997, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780.
- Hwang, J. and Zhou, Y., 2016, "Image Colorization with Deep Convolutional Neural Networks." Iandola, F. N., S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally and K. Keutzer (2016). "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size." arXiv preprint arXiv:1602.07360.
- İşın, A., Direkoğlu, C. and Şah, M., 2016, "Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods," *Procedia Comput. Sci.*, vol. 102, pp. 317–324.
- Ivakhnenko, A. G. and Lapa, V. G., 1966, "Cybernetic Predicting Devices".
- 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>
- Kalchbrenner, N., Grefenstette, E. And Blunsom, P., 2014, "A Convolutional Neural Network for Modelling Sentences."
- 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>.
- Karasoy, O., Ballı, S., 2017, "Classification Turkish SMS with deep learning tool Word2Vec", *International Conference on Computer Science*.
- Kim, Y., 2014, "Convolutional Neural Networks for Sentence Classification."

- Krizhevsky, A., Sutskever, I., Hinton, G. E., 2012, ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems 25 (NIPS2012)*, pages 1–9.
- Kumar Acharya, A. and 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>
- LeCun Y. Et al., 1989, “Handwritten digit recognition: applications of neural network chips and automatic learning,” *IEEE Commun. Mag.*, vol. 27, no. 11, pp. 41–46.
- LeCun, Y. et al., 1989, “Backpropagation Applied to Handwritten Zip Code Recognition,” *Neural Comput.*, vol. 1, no. 4, pp. 541–551.
- LeCun, Y., Bengio, Y. and Hinton, G., 2015, “Deep learning,” *Nature*, vol. 521, pp. 436–444.
- Menger, V., Scheepers, F. and Spruit, M., 2018, “Comparing Deep Learning and Classical Machine Learning Approaches for Predicting Inpatient Violence Incidents from Clinical Text,” *Appl. Sci.*, vol. 8, p. 981.
- McClelland, and J., Rumelhart, D., 1987, *Parallel distributed processing*. The MIT Press.
- McCulloch, W. S. and Pitts, W., 1943, “A logical calculus of the ideas immanent in nervous activity,” *Bull. Math. Biophys.*, vol. 5, no. 4, pp. 115–133.
- Özlu, T., Bülbül, Y., Özsu, S., 2007, *Ulusal verilerle toplum kökenli pnömoniler, Tüberküloz ve Toraks Dergisi*.
- Peemen, M., Shi, R., Lal, S., Juurlink, B., Mesman, B., and Corporaal, H., 2016, "The neuro vector engine: Flexibility to improve convolutional net efficiency for wearable vision," in *Design, Automation & Test in Europe Conference & Exhibition (DATE)*, 2016, pp. 1604-1609: IEEE.
- 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>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T, Ding, D., Bagul, A., Ball, R. L., Langlotz, C., Shpanskaya, K., Lungren, M. P., Ng, A. Y., 2017, “CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with”Deep Learning.” *arXiv:1711.05225v3*.
- Rosenblatt, F., 1958, “The perceptron: A probabilistic model for information storage and organization in the brain.,” *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408.
- 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.
- Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986, *Learning Internal Representations by Error Propagation*, *Parallel distributed processing: Explorations in the microstructure of cognition*, Vol: 1, MIT Press.
- Ruder, S., 2016, "An overview of gradient descent optimization algorithms," *ArXiv e-prints*, vol. 1609, <http://adsabs.harvard.edu/abs/2016arXiv160904747R>
- Scherer, D., Müller, A. and Behnke, S., 2010, "Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition," Springer, Berlin, Heidelberg, pp. 92–101.
- Setio, A. A. A., Ciompi, F., Litjens, G., Gerke, P., Jacobs, C., Van Riel, S. J., Wille, M. M. W., Naqibullah, M., Sanchez, C. I. and van Ginneken, B., 2016, "Pulmonary nodule detection in CT images: false positive reduction using multi-view convolutional networks." *IEEE Transactions on Medical Imaging*, Vol. 35, No. 5, pp. 1160-1169.
- Seymour S., 1997, *The Brain: Our Nervous System*, New York: William Morrow.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015, Going Deeper With Convolutions, In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, pp. 1–9.
- Shelag, A., A., S., 2018, "Classification of Diseases on Chest X-rays Using Deep Learning."
- Shen, Y., He, X., Gao, J., Deng, L., and Mesnil, G., 2014, "Learning semantic representations using convolutional neural networks for web search," in *Proceedings of the 23rd International Conference on World Wide Web - WWW '14 Companion*, pp. 373–374.
- 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>
- Song, H. A., and Lee, S. Y., 2013, "Hierarchical Representation Using NMF," in *International Conference on Neural Information Processing*, pp. 466–473.
- Soni, D., 2018, *Improving Vanilla Gradient Descent*, <https://towardsdatascience.com/improving-vanilla-gradient-descentf9d91031ab1d>
- Srivastava, N, Hinton, G, Krizhevsky, A, Sutskever, I, Salakhutdinov, R, 2014, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting."

- 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>
- Sun, W., Zheng, B. and Qian, W., 2017, “Automatic Feature Learning Using Multichannel ROI Based on Deep Structured Algorithms for Computerized Lung Cancer Diagnosis,” *Comput. Biol. Med.*
- Suwajanakorn, S., Seitz, S. M. and Kemelmacher-Shlizerman, I., 2017, "Synthesizing obama: learning lip sync from audio." *ACM Transactions on Graphics (TOG)* 36(4): 95
- Şeker, A., Diri, B., Balık, H. H., 2017, “Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme”
- Uçar, M. ve Uçar, E., 2019, “Computer-Aided Detection of Lung Nodules in Chest X-Rays using Deep Convolutional Neural Networks.”
- URL-1, <https://tr.wikipedia.org/wiki/Göğüs>, Erişim Tarihi: 19.04.2021
- URL-2, <https://tr.wikipedia.org/wiki/Pulmonology>, Erişim Tarihi: 19.04.2021
- URL-3, <https://www.acibadem.com.tr/ilgi-alani/atelektazi>, Erişim Tarihi: 19.04.2021
- URL-4, <https://akciger.info/konsolidasyon-akciger.html>, Erişim Tarihi: 20.04.2021
- URL-5, <https://docs.python.org/3/faq/general.html#what-is-python>, Erişim Tarihi: 22.04.2021
- URL-6, <https://docs.python.org/3/whatsnew/3.0.html>, Erişim Tarihi: 22.04.2021
- URL-7, <http://www.tgcd.org.tr/3-soruda-akciger-zarlari-arasinda-su-birikmesi-plevral-efuzyon/>, Erişim Tarihi: 23.04.2021
- URL-8, <https://www.acibadem.com.tr/ilgi-alani/akciger-nodulleri>, Erişim Tarihi: 23.04.2021
- URL-9, <https://technotoday.com.tr/yapay-zeka-girisimi-satin-alma-yarisina-giren-teknoloji-devleri>, Erişim Tarihi: 12.08.2021
- URL-10, <https://www.medikalakademi.com.tr/amfizem-tedavi>, Erişim Tarihi: 28.08.2021
- URL-11, <https://www.acibadem.com.tr/ilgi-alani/pulmoner-fibrozis>, Erişim Tarihi: 26.08.2021
- URL-12, <https://www.turkiyeklinikleri.com/article/tr-gogus-duvarindan-akciger-herniasyonu>, Erişim Tarihi: 26.09.2021

- URL-13, <https://akciger.info/akcigerde-infiltrasyon-nedir.html>, Erişim Tarihi: 28.09.2021
- URL-14, <https://www.milliyet.com.tr/pembenar/akcigerde-kitle-nedir-neden-olusur-akcigerde-kitle-tumor-nasil-tedavi-edilir>, Erişim Tarihi: 25.09.2021
- URL-15, <https://www.acibadem.com.tr/ilgi-alani/zature-pnomoni>, Erişim Tarihi: 18.09.2021
- URL-16, <https://okanhastanesi.com.tr/akciger-sonmesi-hakkinda-her-sey>, Erişim Tarihi: 20.09.2021
- URL-17, <https://www.udemy.com/course/yapayzeka/learn/lecture/8955540#overview>, Erişim Tarihi: 21.09.2021
- URL-18, [https://www.researchgate.net/figure/Rosenblatts-Perceptron-60\\_fig2\\_322699604](https://www.researchgate.net/figure/Rosenblatts-Perceptron-60_fig2_322699604) Erişim Tarihi: 28.09.2021
- URL-19, <https://ayyucekizrak.medium.com/%C5%9Fu-kara-kutuyu-a%C3%A7alim-yapay-sinir-a%C4%9Flar%C4%B1-7b65c6a5264a>, Erişim Tarihi: 15.09.2021
- URL-20, [https://www.researchgate.net/figure/Architecture-of-LeNet-5-a-Convolutional-Neural-Network-for-digits-digits-recognition-An\\_fig1\\_329891470](https://www.researchgate.net/figure/Architecture-of-LeNet-5-a-Convolutional-Neural-Network-for-digits-digits-recognition-An_fig1_329891470), Erişim Tarihi: 12.09.2021
- URL-21, <https://towardsdatascience.com/improving-vanilla-gradient-descent-f9d91031ab1d>, Erişim Tarihi: 12.09.2021
- URL-22, <https://medium.com/kodcular/python-ve-anaconda-kurulumu-b8931bd80e64>, Erişim Tarihi: 15.09.2021
- URL-23, <https://devnot.com/2019/tensorflow-nedir-nasil-kullanilir>, Erişim Tarihi: 19.09.2021
- URL-24, <https://teknoloji.org/keras-kutuphanesi-nedir-derin-ogrenme-modeli-olusturma>, Erişim Tarihi, 19.09.2021
- 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>
- Wallach, I., Dzamba, M. and Heifets, A., 2015, “AtomNet: A Deep Convolutional Neural Network for Bioactivity Prediction in Structure-based Drug Discovery.”
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., and Summers, R, 2017, “M. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases.” arXiv preprint arXiv:1705.02315.

- Werbos, P. J., 1975, *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Harvard University.
- WHO, 2001, Standardization of interpretation of chest radiographs for the diagnosis of pneumonia in children.
- Woolever, D., 2005, R; The impact of a patient safety program on medical error reporting.
- Yahyaoui, A., 2017, “Göğüs Hastalıklarının Teşhis Edilmesinde Makine Öğrenmesi Algoritmalarının Kullanılması.”
- Yao, L., Poblenz, E., Dagunts, D., Covington, B., Bernard, D. and Lyman, K., 2017, “Learning to diagnose from scratch by exploiting dependencies among labels.” arXiv preprint arXiv:1710.10501.
- You, L., Li, Y., Wang, Y., Zhang, J. and Yang, Y., 2016, “A deep learning-based RNNs model for automatic security audit of short messages,” in *2016 16th International Symposium on Communications and Information Technologies (ISCIT)*, pp. 225–229.
- Yousefi-Azar, M. and Hamey, L., 2017, “Text Summarization Using Unsupervised Deep Learning,” *Expert Syst. Appl.*, vol. 68, pp. 93–105.
- Zhang, Q., 2016, “Deep learning based classification of breast tumors with shear-wave elastography,” *Ultrasonics*, vol. 72, pp. 150–157.
- Zhou, S., Chen, Q., and Wang, X., 2013, “Active deep learning method for semi-supervised sentiment classification,” *Neurocomputing*, vol. 120, pp. 536–546.
- Zhou, S., Chen, Q., and Wang, X., 2014, “Fuzzy deep belief networks for semi-supervised sentiment classification,” *Neurocomputing*, vol. 131, pp. 312–322.