



**T.C.**

**SELÇUK ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

**MANYETİK PARÇACIK TESTİ SONRASI ÇATLAK TESPİTİNDE DERİN  
ÖĞRENME ALGORİTMALARININ UYGULANMASI**

**Yasin ULUS**

**YÜKSEK LİSANS TEZİ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**OCAK 2025**

**KONYA**

**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Yasin ULUS tarafından hazırlanan “Manyetik Parçacık Testi Sonrası Çatlak Tespitinde Derin Öğrenme Algoritmalarının Uygulanması” adlı tez çalışması 03/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Mustafa Servet KIRAN

.....

#### Danışman

Doç. Dr. Mehmet Akif ŞAHMAN

.....

#### Üye

Prof. Dr. Hasan Erdinç KOÇER

.....

Yukarıdaki sonucu onaylıyorum.

Prof. Dr. Ömer Faruk YÜKSEL

FBE Müdürü

Bu tez çalışması Selçuk Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 24201044 nolu proje ile desteklenmiştir.

## TEZ BİLDİRİMİ

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

## DECLARATION PAGE

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

İmza

Yasin ULUS

Tarih:

## ÖZET

### YÜKSEK LİSANS

# MANYETİK PARÇACIK TESTİ SONRASI ÇATLAK TESPİTİNDE DERİN ÖĞRENME ALGORİTMALARININ UYGULANMASI

Yasin ULUS

Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Mehmet Akif ŞAHMAN

2025,56 Sayfa

Jüri

Prof. Dr. Hasan Erdiñ KOÇER  
Prof. Dr. Mustafa Servet KIRAN  
Doç. Dr. Mehmet Akif ŞAHMAN

Günümüzde, metal ve malzeme endüstrisinde çatlak tespiti, yapısal sağlamlık ve güvenlik açısından kritik bir öneme sahiptir. Manyetik Parçacık Testi (MPT), metal parçalardaki yüzey kusurlarını belirlemek için yaygın olarak kullanılan bir yöntemdir. Malzemelerin doğru yöntemler kullanarak analiz edilmesi malzeme ömrü ve güvenliği açısından önem arz etmektedir. Malzemelerin gözle görülmeyen içyapısındaki hasarların tespitinde doğru yöntemler kullanılmaması kalite güvenliğini ve uzun süre dayanıklılığını negatif etkilemektedir. Geleneksel MPT teknikleri insan tabanlı yorumlama ve manuel analize dayandığından, çatlakların doğru ve hızlı bir şekilde tespit edilmesini zorlaştırmaktadır. Bu çalışmada manyetik parçacık testi görüntülerinde derin öğrenme modellerinin kullanımı incelemeyi amaçlamaktadır. Derin öğrenme algoritmaları, özellikle Evrişimli Sinir Ağları (CNN) ve benzeri modeller, büyük veri setlerinden öğrenme yeteneği sayesinde karmaşık desenleri tanıma ve sınıflandırma konusunda başarı göstermektedir. Bu çalışmanın ana hedefi manyetik parçacık testi için derin öğrenme modellerinin performansını değerlendirmek ve uygulamak olacaktır. Tez çalışmasında çatlak ve çatlak olmayan iki farklı sınıf görüntülerinden oluşan veri seti üzerinde çalışılmıştır. Bu veri seti iyi bilinen derin öğrenme yaklaşımları kullanılarak sınıflandırılmıştır ve elde edilen sonuçlar temel metrikler kullanılarak yaklaşımların performansını karşılaştırmada kullanılmıştır. Yapılan sınıflandırma sonucunda VGG16 yaklaşımı en iyi sonucu %89.04 başarı ile elde etmiştir.

Bu tez çalışması, endüstriyel uygulamalarda çatlak tespiti süreçlerini otomatize etmek ve insan hatasını en aza indirmek için önemli bir adım olacaktır. Ayrıca, manyetik parçacık testi yöntemlerinin doğruluğunu ve verimliliğini artırmak için derin öğrenme modellerinin potansiyelini göstererek, bu alanda yeni bir araştırma ve uygulama alanı açacaktır. Yapılan bu tez çalışmasına benzer bir çalışma yapılmadığı için literatüre önemli bir katkısının olacağı düşünülmektedir.

**Anahtar Kelimeler:** Manyetik Parçacık Testi, Derin Öğrenme, Evrişimli Sinir Ağları, Çatlak Tespiti, Endüstriyel Uygulamalar.

## ABSTRACT

### MS THESIS APPLICATION OF DEEP LEARNING ALGORITHMS IN CRACK DETECTION AFTER MAGNETIC PARTICLE TESTING

Yasin ULUS

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
SELÇUK UNIVERSITY  
THE DEGREE OF MASTER IN ELECTRICAL-ELETRONIC  
ENGINEERING

Advisor: Assoc. Prof. Dr. Mehmet Akif ŞAHMAN

2025,56 Pages

Jury

Prof. Dr. Hasan Erdinç KOÇER  
Prof. Dr. Mustafa Servet KIRAN  
Assoc. Prof. Dr. Mehmet Akif ŞAHMAN

In the metal and materials industry today, crack detection holds critical importance for structural integrity and safety. Magnetic Particle Testing (MPT) is a widely used method to detect surface defects in metal components. Analyzing materials using accurate methods is crucial for ensuring material longevity and safety. Failure to use proper techniques to identify invisible internal damages in materials can negatively impact quality assurance and long-term durability. Traditional MPT techniques rely on human interpretation and manual analysis, making it challenging to detect cracks accurately and efficiently. This study aims to examine the use of deep learning models in magnetic particle testing images. Deep learning algorithms, particularly Convolutional Neural Networks (CNN) and similar models, have demonstrated success in recognizing and classifying complex patterns due to their ability to learn from large datasets. The primary objective of this study is to evaluate and implement the performance of deep learning models for magnetic particle testing. In this thesis, a dataset comprising two classes crack and non-crack images was utilized. This dataset was classified using well-known deep learning approaches, and the results were compared based on key performance metrics. Among the methods employed, the VGG16 approach achieved the best result with an accuracy of 89.04%.

This thesis study represents a significant step toward automating crack detection processes in industrial applications and minimizing human error. Moreover, it demonstrates the potential of deep learning models to enhance the accuracy and efficiency of magnetic particle testing methods, thereby opening new avenues for research and application in this field. As no similar study has been conducted previously, this thesis is expected to make a significant contribution to the literature.

**Keywords:** Magnetic Particle Testing, Deep Learning, Convolutional Neural Networks, Crack Detection, Industrial Applications.

## ÖNSÖZ

Tez çalışmam boyunca bana yol gösteren, bilgi ve tecrübelerini benimle paylaşarak akademik gelişimime büyük katkı sağlayan, ne zaman danışsam ilgi ve desteğini esirgemeyen, güler yüzü ve samimiyetiyle her zaman yanımda olan değerli hocam Doç. Dr. Mehmet Akif ŞAHMAN' a en içten teşekkürlerimi sunuyorum. Onun motive edici yaklaşımı, anlayışı ve hayat felsefesi, çalışmalarımı bu noktaya getirmemde büyük bir rol oynamıştır. Ayrıca çok değerli hocalarım Prof. Dr. Mustafa Servet KIRAN ve Prof. Dr. Hasan Erdiç KOÇER meslek hayatımda da bana örnek olmuşlardır, yardımseverliği ve mütevazılığıyla ilham veren hocalarımdan öğrendiğim değerli bilgiler, hayatım boyunca rehberim olacaktır. Ayrıca, her zaman yanımda olan, sevgisi ve desteğiyle beni motive eden, zorluklarla mücadele ederken en büyük dayanağım olan sevgili eşim Uçak Bakım Öğretmeni Özlem ULUS' a şükranlarımı sunuyorum. Bu süreçte beni üzmeyen canım oğlum Bulut Uraz ULUS' a da şükranlarımı sunarım. Onların fedakârlıkları, sabırları ve duaları, bu yolculuğu başarıyla tamamlamamda en önemli güç kaynağım olmuştur. Bu çalışmanın gerçekleşmesinde emeği geçen herkese, bana kattıkları değerli bilgiler ve destekleri için minnettarım.

Yasin ULUS  
Konya-2025

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>iii</b>
<b>ABSTRACT</b> .....	<b>iv</b>
<b>ÖNSÖZ</b> .....	<b>v</b>
<b>İÇİNDEKİLER</b> .....	<b>vi</b>
<b>KISALTMALAR</b> .....	<b>viii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. LİTERATÜR ARAŞTIRMASI</b> .....	<b>3</b>
<b>3. MATERYAL</b> .....	<b>7</b>
3.1. Yüzey Hazırlığı .....	8
3.2. Manyetize Etme .....	8
3.3. Manyetik Parçacıkların Uygulanması .....	9
3.4. Görsel İnceleme .....	9
<b>4. YÖNTEM</b> .....	<b>11</b>
4.1. Görüntü İşleme Teknikleri ve Uygulamaları .....	11
4.1.1. Görüntü Edinme .....	11
4.1.2. Ön İşleme .....	12
4.1.3. Özellik Çıkarma .....	12
4.1.4. Tanıma ve Sınıflandırma .....	13
4.2. Makine Öğrenmesi .....	14
4.2.1. Yapay Sinir Ağları .....	17
4.2.2. Derin Öğrenme .....	19
4.2.2.1. Evrişimsel Sinir Ağları .....	21
4.2.2.1.1. Evrişimsel Katman .....	21
4.2.2.1.2. Havuzlama Katmanı .....	22
4.2.2.1.3. Tam Bağlı Katman .....	23
4.2.2.1.4. Seyreltme Katmanı .....	24
4.2.2.1.5. Aktivasyon Fonksiyonu .....	25
4.2.2.1.6. Normalizasyon Katmanları .....	29
4.2.2.1.7. Eğitim Tur Sayısı (Epoch) .....	30
4.2.2.1.8. Hiper-parametre .....	31
4.2.2.1.9. Mini Batch Boyutu .....	31

4.2.2.1.10.	Öğrenme Hızı .....	31
4.2.2.1.11.	Kayıp Fonksiyonu.....	32
4.2.2.1.12.	Ön Eğitimli VGG-16 Modeli.....	32
4.2.2.1.13.	Ön Eğitimli VGG-19 Modeli.....	33
4.2.2.1.14.	ResNet-50 Modeli.....	33
4.2.2.1.15.	Inception-V3 Modeli .....	34
4.2.2.1.16.	Optimizasyon Algoritmaları .....	35
4.2.2.1.16.1.	Stochastic Gradient Descent (SGD) .....	35
4.2.2.1.16.2.	Momentum.....	35
4.2.2.1.16.3.	Nesterov Accelerated Gradient (NAG) .....	36
4.2.2.1.16.4.	AdaGrad.....	36
4.2.2.1.16.5.	RMSprop .....	36
4.2.2.1.16.6.	Adam (Adaptive Moment Estimation) .....	36
<b>5.</b>	<b>DEĞERLENDİRME METRİKLERİ.....</b>	<b>38</b>
5.1.	Doğruluk (Accuracy).....	38
5.2.	Kesinlik (Precision) .....	39
5.3.	Duyarlılık (Recall).....	39
5.4.	F1 Skoru .....	39
5.5.	AUC-ROC Eğrisi.....	39
<b>6.</b>	<b>DENEYSEL ÇALIŞMALAR.....</b>	<b>41</b>
<b>7.</b>	<b>SONUÇ VE ÖNERİLER.....</b>	<b>52</b>
	<b>KAYNAKLAR.....</b>	<b>54</b>

## KISALTMALAR

NDI	: Tahribatsız Muayene (Non-Destructive Inspection)
MPT	: Manyetik Parçacık Testi
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
PT	: Penetrant Testi
UT	: Ultrason Testi
YSA	: Yapay Sinir Ağı
ML	: Makine Öğrenme (Machine Learning)
AI	: Yapay Zeka (Artificial Intelligence)
OA	: Genel Doğruluk (Overall Accuracy)
TP	: Gerçek Pozitif (True Positive)
FN	: Yanlış Negatif (False Negative)
TN	: Gerçek Negatif (True Negative)
FP	: Yanlış Pozitif (False Positive)
RI	: Radiografik Muayene (Radiographic Inspection)
SG	: Stokastik Gradyan İnişi (Stochastic Gradient Descent)
NAG	: Nesterov Hızlandırılmış Gradyan (Nesterov Accelerated Gradient)
AUC	: Eğrinin Altındaki Alan (Area Under Curve)
ROC	: Alıcı Çalışma Karakteristik Eğrisi (Receiver Operating Characteristic Curve)
FMPI	: Floresan Manyetik Parçacık Muayenesi (Fluorescent Magnetic Particle Inspection)

## 1. GİRİŞ

Günümüzde endüstriyel üretim ve yapısal güvenlik açısından malzeme değerlendirmesi ve kusur tespiti kritik öneme sahiptir. Metal ve benzeri malzemelerdeki çatlakların erken tespiti, yapısal sağlamlık ve işletme güvenliği açısından hayati bir rol oynamaktadır. Manyetik Parçacık Testi (MPT), malzeme yüzeyindeki çatlakları tespit etmek için yaygın olarak kullanılan bir tahribatsız muayene yöntemidir. Ancak, geleneksel MPT teknikleri genellikle insan tabanlı yorumlama ve manuel analize dayandığı için zaman alıcı ve altında yatan kusurları doğru bir şekilde tespit etmede sınırlı olabilir. MPT, malzeme yüzeyindeki çatlakları tespit etmek için yaygın olarak kullanılan bir tahribatsız muayene yöntemidir. Ancak, geleneksel MPT teknikleri genellikle insan tabanlı yorumlama ve manuel analize dayandığı için zaman alıcı ve altında yatan kusurları doğru bir şekilde tespit etmede sınırlı olabilir. Son yıllarda, derin öğrenme modelleri gibi yapay zekâ tekniklerinin ilerlemesi, endüstriyel muayene ve kusur tespiti gibi alanlarda yeni olanaklar sunmaktadır. Bu sayede son karar vericinin makine olması daha hızlı ve minimum hata ile sonuçlar verebilmektedir. Derin öğrenme kullandığı farklı algoritmalar ile görüntü üzerindeki kusurların tespitinde bizlere en optimum sonuçları vermektedir. Derin öğrenme algoritmaları, özellikle Evrişimli Sinir Ağları (CNN'ler), büyük miktarda veriden desenleri otomatik olarak öğrenme ve tanıma yeteneğine sahiptir (Yu, 2015). Evrişimli Sinir Ağı (CNN), derin ileri beslemeli mimariye sahiptir ve tamamen bağlı katmanlara sahip ağlara kıyasla daha iyi bir şekilde genelleme yapma konusunda şaşırtıcı bir yeteneğe sahiptir (Nebauer, 1998). Bu özellikleri sayesinde, MPT görüntülerindeki çatlakları tespit etmek için derin öğrenme modellerinin kullanımı önemli bir potansiyele sahiptir. Evrişimli Sinir Ağları (CNN'ler), görüntü işleme ve desen tanıma alanında başarılı sonuçlar veren derin öğrenme mimarileridir. CNN'ler, görüntülerdeki özellikleri hiyerarşik olarak öğrenerek, doğrudan piksel değerlerinden yüksek seviyeli öznitelikler çıkarabilir ayrıca CNN'ler, görüntü sınıflandırması gibi dikkat çekici performansları nedeniyle çeşitli alanlarda yaygın olarak kullanılmaktadır (Wang ve ark., 2016) MPT görüntülerindeki çatlakları tespit etmek için CNN'ler, doğrudan görüntü verilerini işleyerek özgün ve etkili sonuçlar üreteceği değerlendirilmektedir. Bu tez çalışması, manyetik parçacık testi görüntülerinde derin öğrenme modellerinin kullanılmasıyla ilgili mevcut literatürü değerlendirmeyi ve bu tekniklerin endüstriyel uygulamalardaki etkinliğini incelemeyi amaçlamaktadır. Bu tez çalışmasının odak noktası, derin öğrenme modellerinin

manyetik parçacık testi görüntülerindeki çatlak tespiti performansını değerlendirmek ve bu tekniklerin endüstriyel süreçlerde nasıl kullanılabileceğini araştırmaktır.



## 2. LİTERATÜR ARAŞTIRMASI

Tahribatsız muayene (NDT), malzeme ve bileşenlerin servis edilebilirliğini bozmadan, yüzey ve içyapılarındaki kusurları tespit etmek için kullanılan bir inceleme yöntemidir. Bu yöntem, özellikle endüstriyel üretim süreçlerinde güvenliği ve kaliteyi sağlamak adına kritik bir öneme sahiptir. Son yıllarda, derin öğrenme algoritmalarının gelişimi, tahribatsız muayene süreçlerine yeni bir boyut kazandırmıştır. Geleneksel yöntemlerin sınırlamaları, özellikle karmaşık yüzeylerde ve zorlu arka plan koşullarında, yapay zekâ tabanlı tekniklerle büyük ölçüde aşılmaktadır. Manyetik Parçacık Testi (MPT), ferromanyetik malzemelerdeki yüzey ve yüzeye yakın çatlakları tespit etmek için sıkça kullanılan bir yöntemdir. Derin öğrenme ve görüntü işleme teknikleriyle birleştirildiğinde MPT, daha hassas ve hızlı sonuçlar üretebilen modern bir yaklaşıma dönüşmektedir. Bu literatür taraması, derin öğrenme ve görüntü işleme yöntemlerinin MPT ve diğer tahribatsız muayene tekniklerinde kullanımına dair güncel araştırmaları incelemektedir. Çalışmalar, farklı malzeme türleri ve uygulama alanları için geliştirilen yöntemlerin performanslarını değerlendirirken, bu teknolojilerin sunduğu yenilikleri ve karşılaşılan zorlukları ortaya koymaktadır.

Derin öğrenmenin tahribatsız muayeneye entegrasyonu, öncelikle metal parçalardaki çatlak kusurlarının tespitine odaklanmıştır. Qiang Wu ve ark. (Wu ve ark., 2023), kirli arka planlarda dahi yüksek doğrulukla tespit yapabilen bir sistem geliştirmiştir. İki aşamalı CNN modeli, pikseller düzeyinde segmentasyon yaparak çatlakların 3 boyutlu koordinatlarını tespit etmiştir. Bu çalışma, %98,3 gibi yüksek bir IoU oranı elde etmiş ve gerçek zamanlı bir çözüm olarak 19 FPS verimlilikle dikkat çekmiştir. Bu ilerleme, MPI'nin yalnızca metal yüzeylerde değil, aynı zamanda karmaşık yüzeylerde de etkili bir şekilde kullanılabileceğini göstermiştir. Wu ve ark.'nın çalışması, ilerleyen yıllarda farklı sektörlerdeki uygulamalar için bir temel teşkil etmiştir.

Metal yüzeylerdeki çatlak tespiti üzerine elde edilen başarı, demiryolu endüstrisindeki uygulamalara yön vermiştir. Ma Tao ve ark. (Ma ve ark., 2018), çalışmalarını demiryolu tekerlek takımları için Floresan Manyetik Parçacık Muayenesinin (FMPI) görüntülerindeki çatlakları ve özelliklerini incelemiştir. İlk olarak çatlakların eğrisel yapısına göre görüntü yapılarının sırt çizgilerini şüpheli çatlaklar olarak çıkarmak için bir sırt çizgisi tespiti yaklaşımı kullanmışlardır. İkinci olarak sırt çizgilerinden şekil özelliklerinin çıkarılmasına ve sırt çizgisi tespitinde ek bir kısıtlamaya yol açmıştır. Üçüncü olarak şüpheli çatlakların yerel dokuları analiz edilir ve şüpheli çatlaklar üzerindeki noktaların değiştirilmiş ölçekle değişmez özellik dönüşümü tanımlayıcılarının ortalamasına dayalı olarak bir doku özelliği önerilir.

Demiryolu tekerlek takımlarının gerçek FMPI görüntüleri üzerinde yapılan deneyle, önerilen özelliklerin etkinliğini kanıtlamıştır. Yapılan testlerde elde edilen algoritmalar arasında şüpheli çatlakları çıkarmak için değiştirilmiş sırt çizgisi algılama yaklaşımını ve gerçek çatlakları tüm şüpheli çatlaklardan ayırmak için doku özelliği kullanan algoritmanın her ikisi de %90'ın üzerinde yüksek hassasiyet elde ettiği sonucuna varılmıştır. Bu çalışma, demiryolu güvenliği açısından kritik bir yenilik sunmuştur.

Metalden farklı olarak, yarı gevrek malzemelerde çatlak tespiti daha karmaşıktır. Gehri ve ark. (Gehri ve ark., 2023) çalışmaları beton, harç veya duvar gibi yarı gevrek malzemeler üzerinde yapılan deneylerde çatlak davranışının elde edilmesi ve değerlendirilmesi üzerine olmuştur. Çatlak çizgileri, fiziksel çatlak modeliyle mükemmel uyum gösteren köklü görüntü işleme yöntemlerini kullanmışlardır. Çatlak detektörünün ve çatlak kinematik ölçümlerinin performansını ve belirsizliğini değerlendiren çeşitli hassasiyet analizi yapılmıştır. Bu analizle elde edilen sonuçların DIC konfigürasyonuna bağlı olduğunu ve çok yakın aralıklı çatlaklar olması durumunda prosedürün sınırlı olduğu görülmüştür. Önerilen çatlak tespit ve ölçüm algoritması, dallanmayan ve iyi ayrılmış çatlaklar için mükemmel çalışırken, çatlak detektörünün, çok yakın aralıklı çatlaklar ve çatlak yerlerine yakın alanlarda, tek tek çatlakların neden olduğu üst üste binen yüksek gerinim alanları nedeniyle başarısız olduğu görülmüştür. Güvenilir sonuçlar ancak çatlak dudağı ile referans noktaları arasındaki her iki çatlak tarafındaki bölgeler rijit cisimler olarak hareket ederse elde edilebileceği tespit edilmiştir.

Malzeme çeşitliliği genişledikçe, yöntemler farklı yüzeylerde test edilmeye başlanmıştır. Ibrahim ve ark, (Ibrahim ve Tapamo, 2024) çelik yüzeylerde delik, çizik ve pas gibi kusurların tespiti için görüntü işleme algoritmaları geliştirmiştir. İnsan denetçileri kusurları nedenlerine ve kökenlerine göre sınıflandırılır çünkü denetim sonuçları üretim sürecini düzeltmek için geri bildirim olarak kullanılır. Bu araştırmayla çelik kusurlarını görüntü işleme algoritmasıyla tespit etmek amaçlanmıştır. Delik, çizik, bobin kırılması ve pas gibi dört popüler çelik kusuru tespit etmek için görüntü işleme algoritmaları uygulanmıştır. Önerilen yöntemi test etmek için 250 çelik kusur görüntüsünden oluşan bir set kullanılmıştır. Sonuçlar, uygulanan algoritmaların çelik kusur tespitinde iyi bir performansa sahip olduğunu göstermektedir. Sayısal sonuçlara göre uygulanan görüntü işleme algoritmalarının delik, çizik, bobin üzerinde sırasıyla %88,4, %78, %90,4, %90,3 doğruluğuna sahip olduğu görülmüştür. Bu çalışma, özellikle insan denetiminin yoğun olduğu çelik üretim hatlarında otomasyonun mümkün olduğunu göstermiştir.

Yang ve ark. (Yang ve ark., 2022) derin öğrenme tabanlı yöntemlerin endüstriyel rulmanlarda uygulanabilirliğini incelemiştir. Floresan Manyetik Parçacık Testi (MPI), uygulanmış rulman bileziği yüzeylerinin muayenedeki karmaşıklığı nedeniyle görüntü işlemeyle dayalı olarak rulman bileziklerinin otomatik tespiti için uygulanması tespiti daha kolaylaştırmıştır. Rulman bileziği numuneleri, rulman fabrikasının 519 çatlak kusurunun görüntüsünü içeren kusur tespit odasında endüstriyel bir kamera kullanarak toplanmıştır. Tüm bu rulmanların yüzeylerinde en az bir çatlak bulunur. Tespit algoritmasının doğrulama yöntemi olarak eğitim ve test analizi kullanılmıştır. Tüm orijinal görüntüler iki gruba ayrılmıştır: CNN modelinin eğitimi için 419, test için 100. Deneysel sonuçlar önerilen yöntemin %96,5'lik bir çağırma oranına %91,7'lik bir hassasiyet oranına ulaştığını göstermektedir. CNN modellerinden çıkarılan üst düzey özellikler, güçlü ifade yeteneğine ve yüksek tanımlama verimliliğine sahip olduğu görülmüştür. Önerilen yöntemin rulman halkalarının floresan MPI işleminde uygulanması planlanmış olup diğer alanlardaki çatlak tespiti için de referans teşkil edeceği anlaşılmıştır.

Benzer şekilde, Tout ve ark. (Tout ve ark., 2021) krank milleri üzerine çalışmışlardır. Manyetik parçacık tekniğine dayalı olarak krank millerinin yüzeylerini incelemek için tam otomatik bir görüntüleme sistemi önermişlerdir. Krank milinin tüm yüzeyinin gerçek zamanlı olarak denetlenmesini sağlamak amacıyla birden fazla kamerayla birleştirilmiş bir adım motoru kullanmışlardır. Krank millerinin yüzeylerinin çok dokulu olması ve kusur şekil ve türlerindeki değişiklik nedeniyle derin öğrenme algoritmalarına daha doğrusu Evrişimli Sinir Ağlarına (CNN) dayalı hata tespiti yöntemleri geleneksel yöntemlere göre daha verimli bir çözüm haline geldiğini göstermişlerdir. Görüntüleme sisteminde denetleme yapan kişinin önüne kurulu dört kameradan oluşan krank mili, üstüne ve altına iki adet UV LED çubuğuyla aydınlatılmıştır. Her bir krank mili için 32 görüntü elde edilmiştir. Krank millerinde gerçek zamanlı kusur tespiti için her yaklaşımın avantajları ve zayıf yönlerine odaklanılarak üç ana yaklaşım, daha kesin olarak sınıflandırma, neşen tespiti ve anlamsal bölümlenme değerlendirilmektedir. Her yaklaşım için en son teknolojiye ilham alan bir veya daha fazla CNN önermiştir. Semantik segmentasyona dayalı yöntemlerin gerçek zamanlı uygulamalar için en hızlı yöntem olmakla birlikte en yüksek kusur lokalizasyon hassasiyetini sağladığı ancak ağır eğitimi için yalnızca kusurlu görüntülerin kullanılabilmesi nedeniyle en büyük eğitim veri kümesini gerektirdiği sonucuna varılmıştır.

Derin öğrenme ve MPT' nin bir diğer kritik uygulama alanı ise havacılık sektörü olmuştur. Serrati ve ark. (Serrati ve ark., 2023) bu çalışmada manyetik parçacık inceleme

teknolojisiyle havacılık da kullanılan ferromanyetik parçalarda otomatik hata tespiti için bir DeepLabv3+ anlamsal bölümlenme algoritması önermiştir. Ağ yapısında hafif MobileNetV2, omurga özellik çıkarma ağıdır. Özellik çıkarımını güçlendirmek için yoğun atrous uzamsal piramit havuzu (DenseASPP) yapısı kullanılmıştır. Deneysel sonuçlar DeepLabv3+ ağ modelinin havacılık ferromanyetik parçalarında MPI sonrasında otomatik hata tespitinde etkili bir şekilde kullanılabileceğini göstermiştir. Hassasiyet, Geri Çağırma, F1 puanı ve birleşme üzerinde kesişme sırasıyla %81,64, %83,12, %82,37, %71,23 olup orijinal DeepLabv3+'dan %7,48, %5,45, %6,5, %10,1 daha yüksektir ve kusur detay segmentasyonu daha doğru olduğu anlaşılmıştır.

Manyetik parçacık testi ile elde edilen görüntülerin derin öğrenme yöntemleri kullanılarak çatlak tespiti üzerine gerçekleştirilen bu tez çalışmasında literatürdeki benzer çalışmalardan ayıran önemli özellikler vardır. Özelleştirilmiş derin öğrenme mimarisi yönünden literatürde yaygın olarak klasik CNN kullanılmaktadır bu tez çalışmasında temel derin öğrenme mimarisiyle birlikte VGG16, VGG19, ResNet-50 Inception-V3 modelleri de kullanılarak çatlak tespiti yapılmış ve elde edilen sonuçlar detaylı olarak karşılaştırılmıştır. Literatürde genellikle farklı tahribatsız muayene yöntemlerinden elde edilen görüntüler birleştirilerek veri setleri oluşturulup kullanılırken, bu çalışmada yalnızca manyetik parçacık testiyle elde edilen görüntüler veri seti olarak kullanılmıştır. .Bu tez çalışmasında seçilen derin öğrenme yaklaşımları literatürde kabul edilen metrikler (accuracy, recall, precision, f-1 skoru, ACU ve Roc eğrisi) kullanılarak kıyaslanmıştır. Ayrıca literatürde genellikle belirli bir sektöre odaklanan çalışmalar bulunurken, bu çalışmada geniş bir endüstriyel yelpazeye hitap eden ve önemli bir bağlantı elemanı olan somunlar üzerinde odaklanılmıştır. Tez çalışmasının 3. bölümünde materyallerin özellikleri ve veri setinin oluşturulması için görselleri elde etme süreci, 4. bölümde kullanılan yaklaşımlar, 5. bölümde derin öğrenme algoritmalarının performans değerlendirmesi için kullanılan metriklerden ve son olarak 6. bölümde yapılan deneysel çalışmaların sonuçları verilmiştir.

### 3. MATERYAL

Tahribatsız muayene malzemedeki kusurları veya hataları tespit etmek için kullanılan temel yöntemlerden biridir. Endüstriyel uygulamalarda büyük öneme sahiptir. Muayene, malzemelerdeki hataları tespit etmeye odaklanır. Bu tespitler, malzemenin uzun süreli ve güvenli bir şekilde kullanılmasını sağlar. Böylece malzeme kalitesinin sürekliliği desteklenir ve kullanım ömrü uzatılabilir. Özellikle havacılık, otomotiv, enerji, inşaat gibi sektörlerde kullanılan parçaların doğru ve sağlam olması, can güvenliği ve yapısal dayanıklılık için kritiktir. Kusurların erken tespiti, üretim süreçlerindeki maliyetleri düşürür. Hatalı parçaların üretilmesi ve sonradan düzeltilmesi yerine, ilk aşamada kusurların önlenmesi veya tespit edilmesi, üretim verimliliğini artırır. Hatalı ürünlerin azaltılması ve malzeme kaynaklarının verimli kullanılması, çevre dostu üretim uygulamalarına katkı sağlar. Ayrıca, doğru ve güvenilir parçaların kullanılmasıyla ürün ömrü uzar, kaynakların sürdürülebilir kullanımı teşvik edilir. Malzeme yüzeyinde veya içindeki kusurları erken aşamada tespit ederek, daha ciddi problemlerin önlenmesini sağlar. Bu sayede, potansiyel tehlikeler önceden belirlenir ve gerekli önlemler alınabilir.

Tahribatsız muayene yöntemleri, birçok endüstriyel sektörde kalite kontrolünün temel bir parçasıdır. Malzeme mühendisliği, imalat endüstrisi, havacılık, otomotiv, gemi inşası, nükleer enerji ve sağlık sektörü gibi birçok alanda güvenilir ve doğru sonuçlar sağlamak için kullanılırlar. Bu yöntemlerin yaygın olarak kullanılanları ise Sıvı Penetrant Testi (PT), Ultrasonik Muayene (UT), Radyografik Muayene (RT)' Manyetik Parçacık Testi (MPT)' tir. Sıvı Penetrant Testi, yüzey hatalarını tespit etmek için kullanılır. Test sırasında malzeme yüzeyine özel bir sıvı (penetrant) uygulanır. Bu sıvı, yüzeydeki çatlak gibi açıklıklara nüfuz eder. Ardından fazla sıvı yüzeyden temizlenir ve malzeme üzerine bir geliştirici uygulanır. Bu geliştirici, sıvının kusurdan geri çıkmasını sağlayarak kusuru görünür hale getirir. Ultrasonik Muayene, malzeme içerisindeki kusurları tespit etmek için yüksek frekanslı ses dalgalarını kullanır. Bu yöntem, bir prob aracılığıyla malzemeye ultrasonik dalgalar gönderir. Dalgalardan bir kısmı malzemenin içinde bulunan kusurdan geri yansır ve bu yansıma cihaz tarafından algılanır. UT, özellikle iç kusurların tespitinde etkili bir yöntemdir. Radyografik Muayene, malzemenin iç yapısındaki kusurları tespit etmek için X ışınları veya gama ışınlarını kullanır. Malzeme, bir radyasyon kaynağı ile taranır ve çıkan ışınlar bir film veya dijital bir algılayıcı üzerinde kaydedilir. Kusurlar, filmde farklı yoğunluk seviyeleri olarak görünür. RT, özellikle kaynak hataları ve iç çatlakların tespitinde kullanılır.


Manyetik Parçacık Testi (MPT) ise yüzeyel kusurların tespiti için kullanılan tahribatsız muayene yöntemlerinden biridir ve malzeme yüzeyinde bulunan süreksizliklerin yerlerinin tespit edilmesi amaçlanmaktadır. Bu sebeple uygulanan bu teknikte, malzeme üzerinde kaçak bir akı oluşturulur. Malzemenin üzerine dağıtılan manyetik tozlar oluşturulan kaçak akılar tarafından çekilerek malzeme yüzeyindeki süreksizliklerin çevresine yerleşir. Bu sayede süreksizliklerin yerleri tespit edilmiş olur. Manyetik parçacık testleri ferromanyetik olan tüm malzemelere uygulanabilmektedir. Malzemenin üzerinde kaçak akılar Şekil 3.1' deki tezgahta oluşturulmaktadır.



Şekil 3.1 Manyetik test tezgahı

### 3.1. Yüzey Hazırlığı

Malzeme yüzeyi temizlenir ve gerekirse yağ, kir veya boya gibi kaplamalar uzaklaştırılır. Temiz bir yüzey, testin doğru şekilde uygulanabilmesi için önemlidir. Yüzey hazırlığı yapılmış malzeme Şekil 3.2' de verilmiştir.



Şekil 3.2 Yüzey temizliği yapılmış malzeme

### 3.2. Manyetize Etme

Malzeme manyetik bir alanla etkileşime girecek şekilde hazırlanır. Bu adım, muayene edilecek malzemenin manyetik bir karakteristik kazanmasını sağlar. Manyetize etme işlemi


farklı yöntemlerle yapılabilir: Elektromanyetik yöntemler: Elektromıknatis veya elektromıknatis bobinler kullanılarak manyetik alan oluşturulur. Yarı manyetik yöntemler: Geçici mıknatis veya doğal manyetik alan kullanılarak malzeme manyetize edilir. Malzemenin manyetize edilmesi Şekil 3.3’ de gösterilmiştir.



Şekil 3.3 Malzemenin manyetize edilmesi

### 3.3. Manyetik Parçacıkların Uygulanması


Manyetize edilen malzeme yüzeyine veya içine manyetik parçacıklar uygulanır. Bu parçacıklar genellikle demir tozu veya titanyum dioksit gibi manyetik özelliklere sahip maddelerdir. Şekil 3.4’ de manyetik parçacık uygulanan malzemenin mor ışık altında alınan görüntüsü yer almaktadır.



Şekil 3.4 Manyetik parçacık uygulanan malzeme


### 3.4. Görsel İnceleme ve Görüntülerin Elde Edilmesi

Manyetik parçacıklar, malzeme üzerindeki kusurları ortaya çıkarmak için manyetik alan etkisiyle belirli bölgelerde toplanır. Muayene edilen malzeme ultraviyole (UV) ışığı altında veya uygun bir aydınlatma altında gözle incelenir. Manyetik parçacıkların toplandığı bölgelerde çatlaklar ve kusurlar belirginleşir. Manyetik parçacık uygulanan malzemenin görsel incelenmesi Şekil 3.5’ de verilmiştir.



Şekil 3.5 Görsel incelemeye alınan malzeme

Jetson Orin Nano üzerinde Raspberry Pi V2 kamera kullanılarak görüntüler elde edilmiştir. İlk aşamada, Jetson Orin Nano kitinin donanımsal kurulumu tamamlanmış ve cihaz Ubuntu tabanlı işletim sistemiyle yapılandırılmıştır. Raspberry Pi V2 kameranın Jetson ile uyumlu çalışabilmesi için gerekli sürücüler yüklenmiş ve kamera modülü başarıyla tanıtılmıştır. Bu aşamada kullanılan platform 3D yazıcı ile hazırlanmış olup ilgili aşamalar Şekil 3.6’ da verilmiştir.



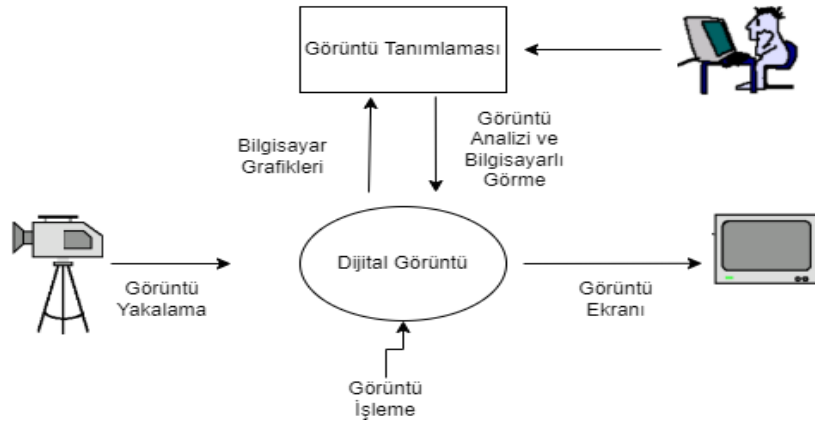
Şekil 3.6 Görüntülerin elde edilmesi için hazırlanan platform

## 4. YÖNTEM

Manyetik parçacık testi ile elde edilen görüntülerdeki çatlakların tespit edilmesi için derin öğrenme tabanlı bir yaklaşım geliştirilmiştir. İlk olarak, manyetik parçacık testinden elde edilen görüntüler ön işleme tabi tutulmuş, gürültü giderme, kontrast artırma ve boyutlandırma gibi işlemler uygulanmıştır. Daha sonra, bu görüntüler Yönlendirilmiş Gradyanlar Histogramı ve morfolojik işlemler gibi özellik çıkarım teknikleri ile analiz edilmiştir.

### 4.1. Görüntü İşleme Teknikleri ve Uygulamaları

Resim oluşturma, belirli bir algoritma veya model kullanılarak dijital görüntülerin otomatik olarak yaratılması sürecidir. Dijital bir resim haline getirilmiş olan gerçek yaşamdaki görüntülerin, bir girdi resim olarak işlenerek, o resmin görüntü özelliklerinin değiştirilmesi sonucu farklı bir resim oluşturulmasıdır. Görüntü işleme, verilerin yakalanıp ölçme ve değerlendirme işleminden sonra, başka bir aygıtta okunabilir bir biçimde dönüştürülmesi ya da bir elektronik ortamdan başka bir elektronik ortama aktarılmasına yönelik bir çalışma olan “sinyal işlemeden” farklı bir işlemdir (Fernandez ve ark., 2005). Görüntü işleme teknolojisinde kullanılan genel yöntem sırasıyla; görüntünün elde edilmesi, görüntünün ön işlenmesi, görüntünün kısımlara ayrılması (segmentasyon), ölçüm ve yorumlama aşamalarından oluşmaktadır (Lu ve ark., 2017). Şekil 4.1’ de görüntü işleme süreci anlatılmaktadır.



Şekil 4.1 Görüntü işleme süreci

#### 4.1.1. Görüntü Edinme

Görüntü işleme işlemi, öncelikle bir görüntünün dijital formatta elde edilmesiyle başlar. Görüntü, kameralar, sensörler veya diğer optik aygıtlar aracılığıyla alınır ve bilgisayar

ortamında sayısal bir formata dönüştürülür. Şekil 4.2’ de görüntünün sayısallaştırılması gösterilmiştir.



Şekil 4.2 Sayısallaştırılmış resim

#### 4.1.2. Ön İşleme


Ön işleme adımı, elde edilen görüntünün kalitesini artırmak, gürültüyü azaltmak veya gereksiz detayları temizlemek için kullanılır. Bu adımda tipik olarak kontrast düzeltme, keskinleştirme, gürültü azaltma ve görüntü boyutunu düzenleme gibi işlemler gerçekleştirilir. Şekil 4.3’ de ön işleme yapılan resim gösterilmiştir.



Şekil 4.3 Ön işleme yapılan resim

#### 4.1.3. Özellik Çıkarma

Özellik çıkarma adımı, görüntüdeki belirli özellikleri veya desenleri tanımlamak için kullanılır. Bu adımda nesnelerin kenarları, köşeleri, renkler, dokular veya diğer önemli özellikler matematiksel olarak çıkarılır.




Şekil 4.4 Renk histogramı çıkarılması

R,G,B (kırmızı, yeşil, mavi) değerleri bir pikselin renklerini tanımlamak için kullanılan temel bileşendir. Bir resmin dijital ortamda piksellerden oluşur ve her piksel kırmızı, yeşil, mavi renk kanallarının belirli bir kombinasyonu ile temsil edilir. Her bir renk kanalı (R,G,B) 0-255 arasında bir değer alır. Bu değerlerin kombinasyonu ile her bir pikselin rengi belirlenir. Ön işleme yaptığımız resmin renk histogramı Şekil 4.4’ de gösterilmiş olup resmimizin ortalama RGB değeri [164.666, 139.455, 235.311] olarak bulunmuştur.

#### 4.1.4. Tanıma ve Sınıflandırma

Tanıma ve sınıflandırma adımında, özelliklerin analizi sonucunda elde edilen bilgiler kullanılarak görüntüdeki nesnelere tanımlanır veya sınıflandırılır. Bu adımda genellikle makine öğrenmesi veya yapay zekâ teknikleri kullanılarak öğrenme ve karar verme süreçleri gerçekleştirilir. Şekil 4.5’ de ön işlemeden geçirdiğimiz resmin üzerinde somunun tanıma ve sınıflandırma işlemine tabi tuttuk.

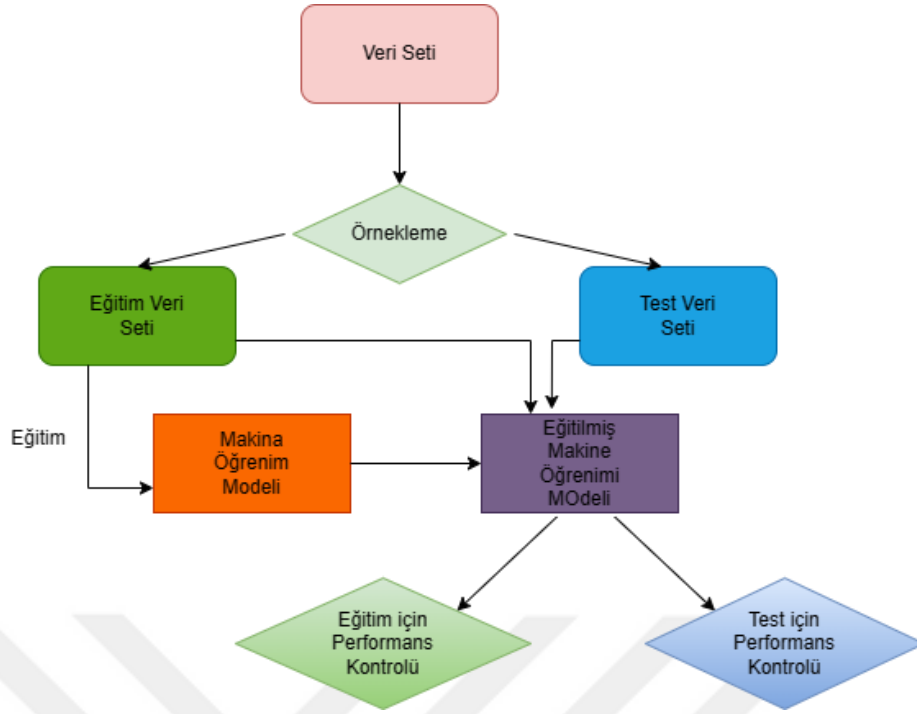


Şekil 4.5 Tanıma ve sınıflandırma

Bu çalışmada, görüntüler elde edilirken Jetson Orin Nano nun üzerinde bulunan raspberry pi V2 kullanılmıştır. Görüntüler alınırken manyetik parçacık testi uygulanan ve mor ışık altına tutulan bölgede dış ortamdan izole edilmiş bir şekilde görüntüler alınmıştır. Elde edilen görüntülerin çözünürlükleri 1510x1499 piksel olarak belirlenmiştir.

## 4.2. Makine Öğrenmesi

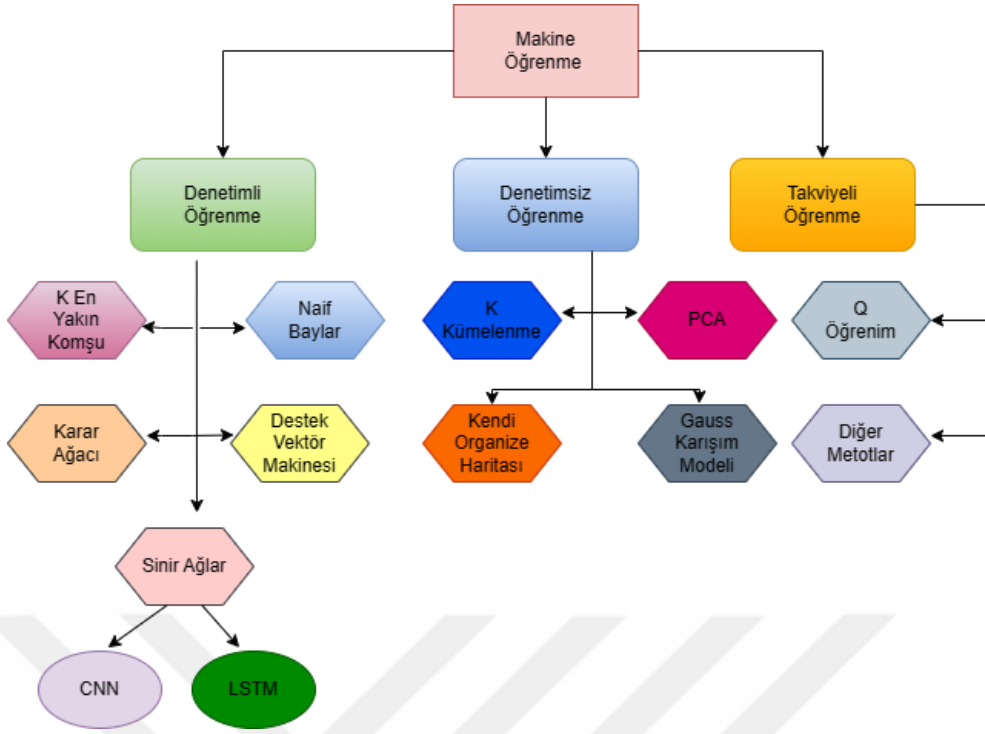
Yapay zekâ (AI), makinelerin insan beyni kadar akıllı olmasını ifade eder. Bilgisayar bilimlerinde yapay zekâ ‘akıllı araçların’ incelenmesi anlamına gelir bu da çevresini algılayan ve hedeflerine başarıyla ulaşma olasılığını en üst düzeye çıkaracak eylemlerde bulunan herhangi bir cihazdır. Öğrenme makinelerin hayati bir yönüdür bu nedenle makine öğrenimi yapay zekânın bir alt dalıdır. Makine öğrenimi (ML), karmaşık verilerdeki kalıpları ve ilişkileri tanımlamaya ve bu verilere dayanarak kararlar almaya yönelik esnek bir araç setidir. Makine öğrenimi çok geniş bir disiplindir (Ao ve ark., 2010). Başka bir tanımlama yapılabilirse makine öğrenimi, “çevredeki ortamdan öğrenerek insan zekâsını taklit etmek için tasarlanmış gelişen bir hesaplamalı algoritmadır.” Büyük bir veri olarak adlandırılan yeniçağ da çalışan atlar olarak da kabul ediliyor. Makine öğrenimine dayalı teknikler, örüntü tanıma, bilgisayarla görme, uzay aracı mühendisliği, finans, eğlence ve tıbbi uygulamalarda başarıyla uygulanmıştır (Ottucsák ve Walk, 2012). Makine öğrenimi, mevcut verilere dayalı tahminler yapmaya odaklanır. ML yöntemleri, bilgiyi doğrudan ayrıştırarak verilerden öğrenir. Bu yöntemlerin önceden belirlenmiş denklemleri veya çözümü bulan açıkça programlanmış kararları yoktur. Bu yöntemler temel olarak sadece verileri kullanarak çözümün yolunu oluşturur. ML algoritmaları, verilerdeki kalıpları veya örüntüleri bulur. Bu kalıpları kullanarak kararlar, tahminler veya tespitler yapar. Veri sayısı arttıkça performansları artar ve daha iyi sonuçlar verirler. Veri boyutu ve verilerdeki tutarlılık makine öğrenimi için çok önemlidir (Top, 2018). Şekil 4.10’ de makine öğreniminin nasıl çalıştığını göstermektedir.



Şekil 4.10 Makine öğreniminin çalışma mantığı

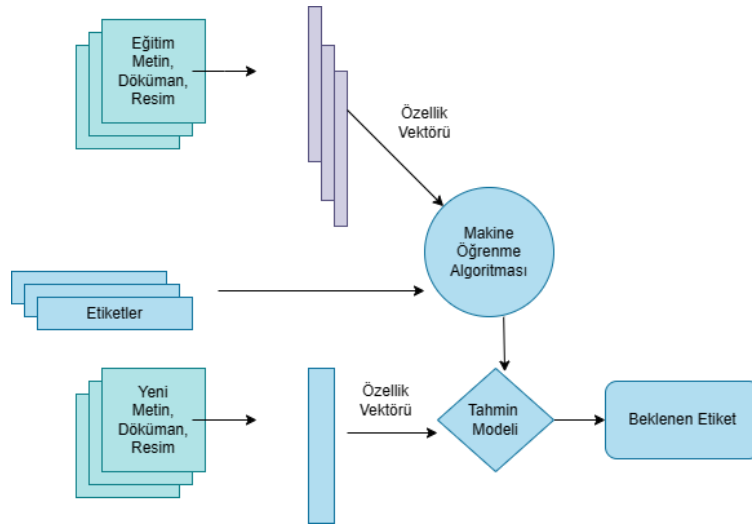
Makine öğrenmesi Yapay Zekâ (AI)'nin bir alt dalı olarak bilinir. Üç ana alt bölüme ayrılmıştır ve bu alt bölümlerin altında, makine öğrenimi hedeflerine ulaşmak için kullanılacak çeşitli algoritmalar vardır. Aşağıdaki Şekil 4.11' de makine öğrenimi sınıflandırması ve alt bölümleri göstermektedir.

Denetimli öğrenme, sınıflandırma problemlerinde en yaygın kullanılan tekniktir çünkü temel amacı, makinenin önceden belirlediğimiz bir sınıflandırma sistemini öğrenmesini sağlamaktır. Bu yöntem, genellikle beklenen çıktının bilindiği durumlarda kullanılır, ancak girdinin olasılık dağılımı tanımlanmaz. Bu işlem, özellikler ve etiketlerden oluşan veri kümesi sağlar. Ana görev, bir nesnenin özellikler kümesi tarafından verilen etiketini tahmin edebilen bir tahminci oluşturmaktır. Daha sonra öğrenme algoritması, doğru çıktılarla birlikte bir dizi özelliği girdi olarak alır ve hataları bulmak için gerçek çıktısını düzeltilmiş çıktılarla karşılaştırarak öğrenir. Daha sonra modeli buna göre değiştirir. Girdiler mevcut olduğu sürece oluşturulan modele ihtiyaç duyulmaz, ancak bazı girdi değerleri eksikse, modelin doğru bir tahmin yapabilmesi için bu eksikliklerin tamamlanması gerekir; aksi takdirde doğru sonuçlar elde edilemez.



Şekil 4.11 Makine öğrenimi sınıflandırması

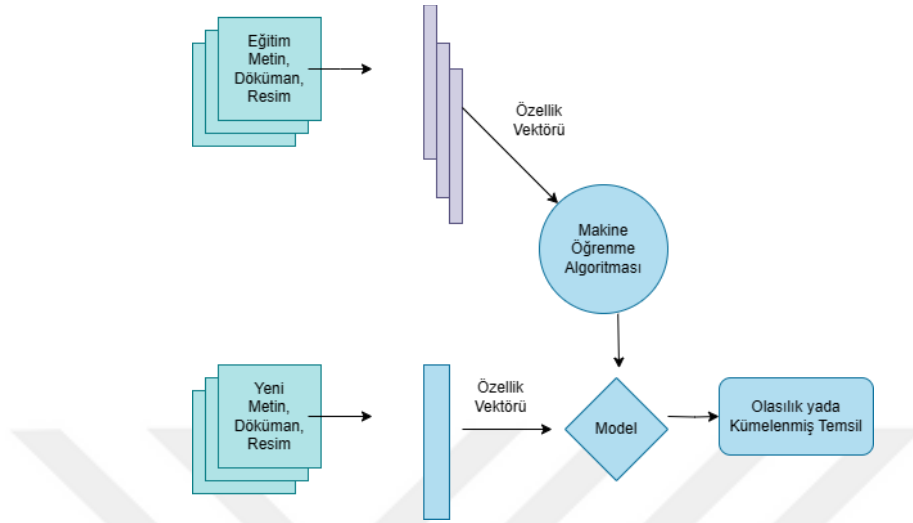
Denetimli öğrenme, tarafsız ağlar ve karar ağaçları için eğitimde en yaygın tekniktir. Bunların her ikisi de önceden belirlenmiş sınıflandırmanın verdiği bilgilere bağlıdır (Kotsiantis ve ark., 2007). Denetimli makine öğrenme modeli Şekil 4.12’ de gösterilmektedir.



Şekil 4.12 Denetimli öğrenme modeli

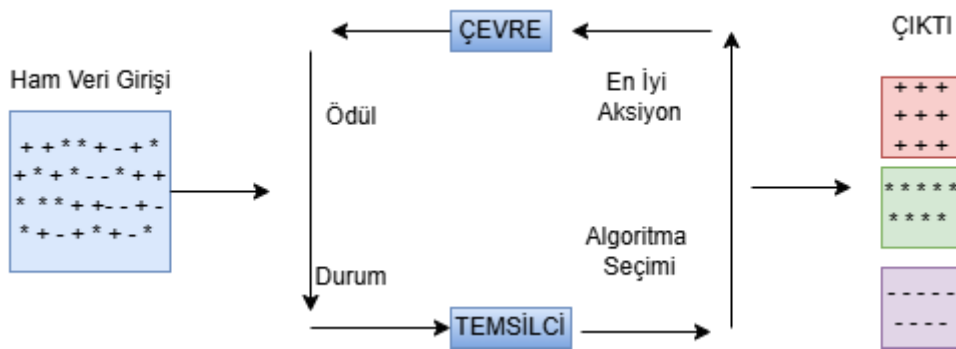
Denetimsiz makine öğrenmesi, makine öğrenmesinde denetimli öğrenmeden sonra, sonuçların nasıl görüneceğine dair çok az fikri olan veya hatta bazen hiçbir fikri olmayan sorunları veya durumları ele almayı sağlayan ikinci tür makine öğrenmesi algoritmasıdır

(Marcher ve ark., 2020). Denetimsiz öğrenmede, yapılan tahminlerin sonuçlarına dayalı geri bildirimlerin türetilmesi mevcut değildir. Şekil 4.13’ de denetimsiz makine öğreniminin çalışmasını göstermektedir.



Şekil 4.13 Denetimsiz öğrenme modeli

Takviyeli öğrenme, temsilcilerin ödül sistemi aracılığıyla öğrendiği bir tür öğrenmedir. Her ne kadar başlangıç ve bitiş noktaları olsa da, ajan (yani öğrenen sistemin kendisi) amacına ulaşmak için en kısa ve doğru yolları kullanmaya çalışır. Temsilci doğru yollardan geçtiğinde kendisine olumlu ödüller verilir. Ancak yanlış yollardan geçmek olumsuz ödüller anlamına gelir. Öğrenme hedefe giden yolda gerçekleşir (Sirmaçek, 2007). Şekil 4.14’de takviyeli makine öğrenimi şeması gösterilmektedir.



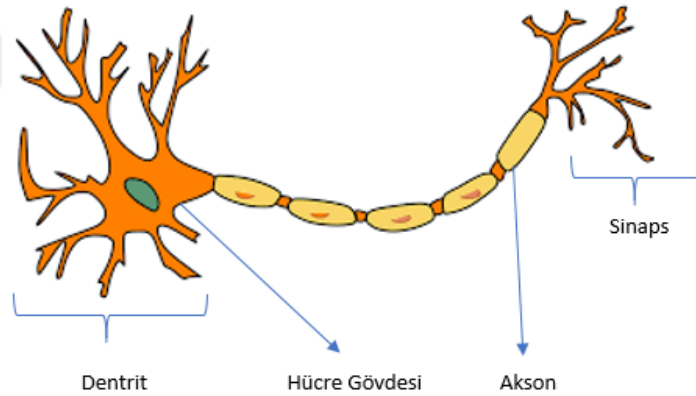
Şekil 4.14 Takviyeli öğrenme şeması

#### 4.2.1. Yapay Sinir Ağları

İnsan beyni, insanların başarılı olduğu bilişsel, algısal ve kontrol görevlerinde başarılı olabilecek devasa sinir ağlarına sahiptir. Beyin, hesaplama açısından zorlu algısal eylemleri

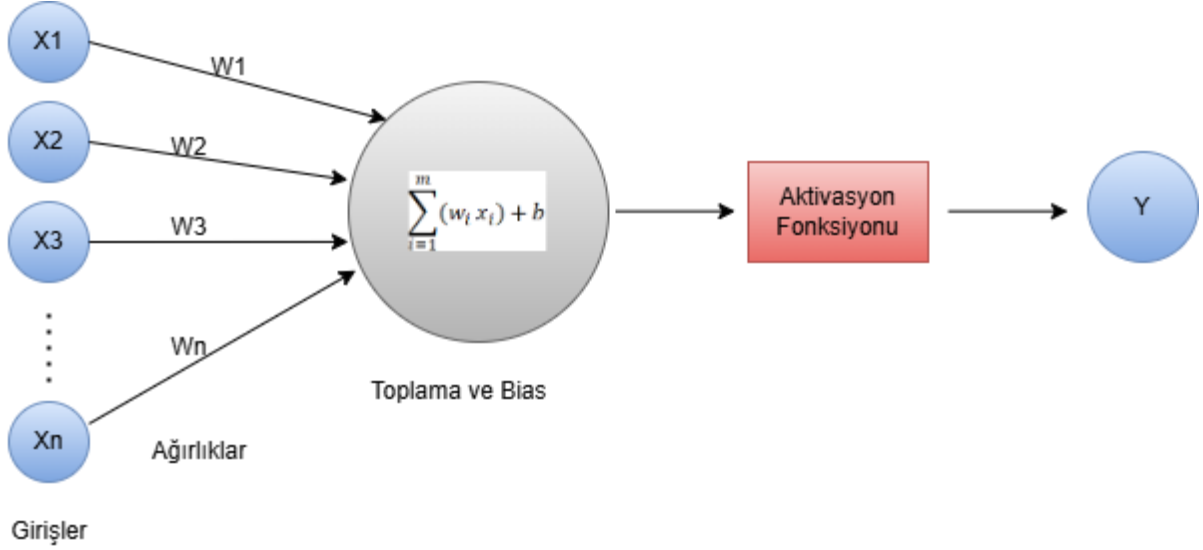
(örneğin, yüzlerin tanınması, konuşma) ve kontrol faaliyetlerini (örneğin, vücut hareketleri ve vücut işlevleri) gerçekleştirme yeteneğine sahiptir. İnsan beyni birbirine bağlı 10 milyardan fazla nörondan oluşan bir koleksiyondur. Her nöron, bilgiyi almak, işlemek ve iletmek için biyokimyasal reaksiyonları kullanan bir hücredir (Abraham, 2004). Sinir sistemi, nöron adı verilen hücrelerden oluşur. Bu hücrelerin dentrit ve akson olmak üzere iki ucu ve hücre gövdesi vardır. Dışarıdan gelen bir uyarı sonucunda, sinir hücrelerindeki sodyum-potasyum iyonları elektrokimyasal değişim yaratır ve bu değişim elektriksel potansiyel oluşturur. Bu potansiyele implus denir. İmpuls dentritler sayesinde algılanır ve hücre gövdesine iletilir. Daha sonra bu implus sinyali aksonlar ile diğer sinir hücresine iletilir.

Aksonların başka sinir hücresine bağlanması akson ucu ile olur. Bu uç, diğer nöronun hücre gövdesine bağlanır. Bu bağlantıya sinaps denir. Öğrenmeyi sağlayan yapı sinapslardır. İnsanların deneyimlemesi, gözlemlemesi gibi olaylar sonucunda bu sinaptik bağlantılar ayarlanır veya yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Şekil 4.15’ de bir sinir hücresinin yapısı gösterilmiştir.



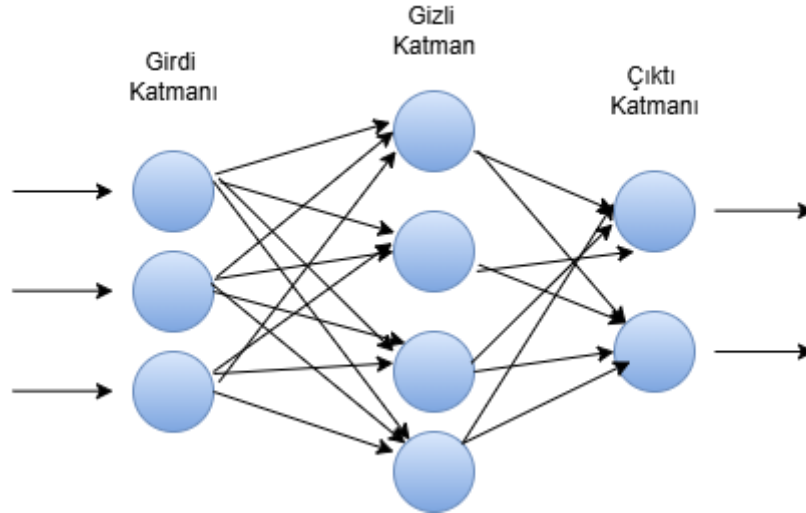
Şekil 4.15 Sinir hücresi yapısı

Yapay sinir ağlarında durum buna benzer şekildedir. Yapay nöronlar, bilgi girişi (input), bilgi çıkışı (output), her bir girişin ağırlığı, toplam fonksiyonu ve aktivasyon fonksiyonundan oluşur. Bunlara ek olarak bir de her nöron için bias adı verilen ek bir giriş vardır. Dentritlerin karşılığı girişler, aksonun karşılığı çıkış, sinapsın karşılığı ağırlık ve bias değerleri, hücre gövdesinin karşılığı toplam ve aktivasyon fonksiyonudur. Buradan yapay sinir ağlarında öğrenmenin ağırlık ve bias değerleri ile gerçekleştiği sonucunu çıkarabiliriz. Şekil 4.16’de yapay sinir ağı modeli yer almaktadır.



Şekil 4.16 Yapay sinir hücresi

YSA, verileri tahmin etme, sınıflandırma ve eşleştirme konusunda olağanüstü bir yeteneğe sahiptir. Bu ağlar farklı şekillerde bölümlere ayrılmıştır, en basit ve en yaygın kullanılanı çok katmanlı algılayıcı (MLP) sinir ağıdır. Bu ağlar, insan beyni ve matematiksel ilişki kalıplarını takip ederek çıktıyı küçük hatalarla doğru tahmin etmek için girdi verileri arasındaki karmaşık ilişkiyi anlar (Chen ve ark., 2021). Şekil 4.17’de çok katmanlı bir yapay sinir ağı gösterilmektedir.



Şekil 4.17 Çok katmanlı yapay sinir ağı

#### 4.2.2. Derin Öğrenme

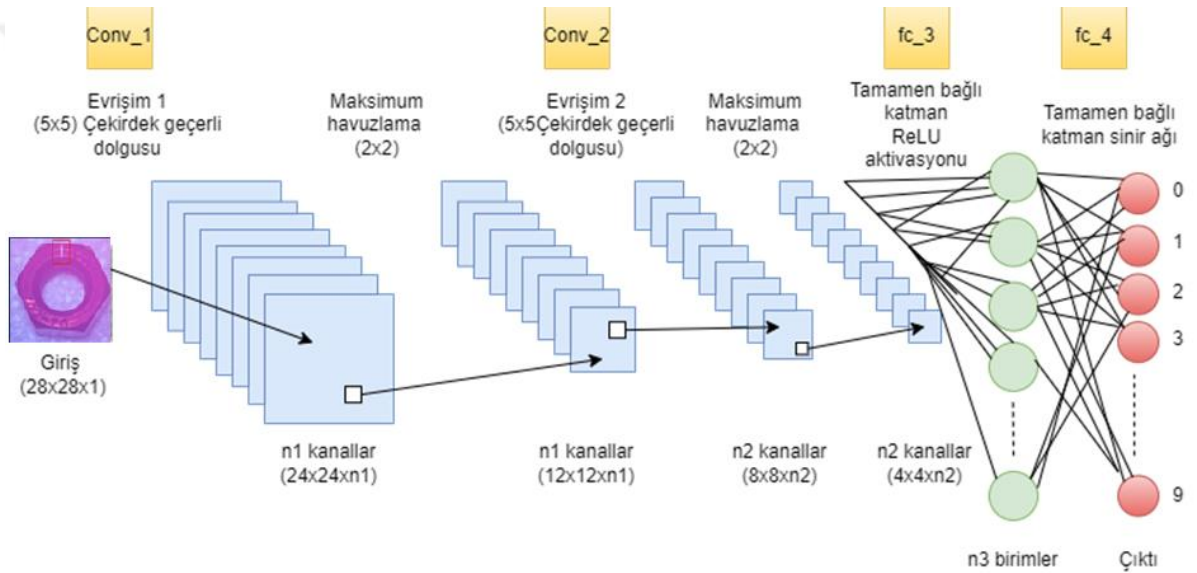
Derin öğrenme (DL), yapay sinir ağları üzerine kurulu bir makine öğrenme tekniğidir ve karmaşık verileri öğrenmek için kullanılır. Derin öğrenme büyük veri havuzundan desenler tanımak, özellik çıkarmak, görüntüleri tanımlamak ve nihai olarak da bu veriler ışığında belli bir mantık çerçevesinde tahminlerde bulunmak için kullanılır. Derin öğrenme birden fazla işlem katmanından oluşan hesaplama modellerinin, birden fazla soyutlama düzeyine sahip veri temsillerini öğrenmesine olanak tanır. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama gibi diğer birçok alanda en son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, bir makinenin her katmandaki temsili önceki katmandaki temsilden hesaplamak için kullanılan dahili parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder. Derin evrişimli ağlar görüntü, video, konuşma ve sesin işlenmesinde çığır açıcı gelişmelere yol açarken, yinelenen ağlar metin ve konuşma gibi sıralı verilere ışık tutmuştur (Leung ve ark., 2014).

Temsil öğrenimi, bir makinenin ham verilerle beslenmesine ve algılama veya sınıflandırma için gereken temsilleri otomatik olarak keşfetmesine olanak tanıyan bir dizi yöntemdir. Derin öğrenme yöntemleri, her biri bir düzeydeki temsili (ham girdiden başlayarak) daha yüksek, biraz daha soyut bir seviyedeki bir temsile dönüştüren basit ancak doğrusal olmayan modüllerin oluşturulmasıyla elde edilen, birden fazla temsil düzeyine sahip temsil-öğrenme yöntemleridir (Krizhevsky ve ark., 2012).

Örneğin bir görüntü, bir piksel değerleri dizisi biçiminde gelir ve birinci temsil katmanındaki öğrenilen özellikler, tipik olarak görüntüdeki belirli yönlerde ve konumlarda kenarların varlığını veya yokluğunu temsil eder. İkinci katman tipik olarak, kenar konumlarındaki küçük değişikliklere bakılmaksızın, kenarların belirli düzenlemelerini tespit ederek motifleri tespit eder. Üçüncü katman, motifleri tanıdık nesnelerin parçalarına karşılık gelen daha büyük kombinasyonlar halinde bir araya getirebilir ve sonraki katmanlar, nesnelere bu parçaların kombinasyonları olarak algılayabilir. Derin öğrenmenin temel özelliği, bu özellik katmanlarının insan mühendisler tarafından tasarlanmamış olmasıdır: genel amaçlı bir öğrenme prosedürü kullanılarak verilerden öğrenilirler (Hinton ve ark., 2012).

#### 4.2.2.1. Evrişimsel Sinir Ağları

Evrişimli sinir ağları (CNN), milyonlarca parametreyle başa çıkabilen ve 2 boyutlu bir görüntü girerek onu filtreler/çekirdek ile evriştirerek ve çıktı hacimleri üreterek hesaplama maliyetinden tasarruf edebilen güçlü bir derin öğrenme algoritmasıdır (LeCun ve ark., 2015). CNN, girdi görüntülerini alır ve bunları filtreler veya çekirdeklerle dönüştürerek özellikleri çıkaran derin öğrenme algoritmalarıdır. Bir  $N \times N$  görüntüsü  $f \times f$  filtresiyle evrilir ve bu evrişim işlemi görüntünün tamamında aynı özelliği öğrenir (Zeiler ve Fergus, 2014). Şekil 4.19'de evrişimsel sinir ağının genel yapısı gösterilmiştir.




Şekil 4.19 Evrişimsel sinir ağı yapısı

##### 4.2.2.1.1. Evrişimsel Katman

Evrişim katmanı, bir CNN'nin ayrılmaz yapı taşı olarak kabul edilir. Evrişimsel katmanın işlevi özellikleri tanımlamak ve bunlara yanıt vermektir. Üç boyutlu bir giriş tensörünün işlenmesi ve bir dizi uyarlanabilir filtre veya çekirdek aracılığıyla bir çıkış tensörünün oluşturulmasıyla gerçekleştirilir. Her filtre, özünde, giriş tensörünün genişliğini ve yüksekliğini tarar ve filtrenin elemanları ile giriş arasında bir nokta çarpım hesaplaması gerçekleştirir. Sonuç, filtrenin her mekânsal konumda nasıl tepki verdiğini ortaya koyan iki boyutlu bir aktivasyon haritasıdır. Ağ öğrendikçe filtreler, kenar veya belirli bir renk kontrastı

gibi belirli görsel özelliklerin tanınması üzerine etkinleşecek şekilde ayarlanır (Khan ve ark., 2018). Şekil 4.20’de evrişimsel katman mimarisi gösterilmektedir.




Şekil 4.20 Evrişimsel katman mimarisi

Evrişimde başlangıç matrisi,  $M \times N$  boyutunda, çekirdek olarak da bilinen bir filtredir. Bu filtre, işlevlerini değiştiren öğrenilebilir parametrelerden (çekirdek ağırlıkları) oluşur. İkinci matris görüntünün sınırlı bir kısmıdır. Bu matrisler arasındaki nokta çarpım, filtrenin giriş görüntüsü üzerinde kaydırılmasıyla oluşur; filtre ile görüntünün kısıtlı kısmı arasında hesaplanan nokta çarpımı, filtre boyutuyla ( $M \times N$ ) sınırlıdır. Bu süreç, bir görüntüdeki köşeler, kenarlar ve diğer önemli bilgiler gibi temel özellikleri vurgulayan, özellik haritası veya evrilmiş özellik olarak bilinen bir sonuç üretir. Pikseller arasındaki uzamsal ilişkinin korunması özellik haritası için çok önemlidir. Evrişim katmanı daha sonra çıktısını bir sonraki katmana aktarır ancak doğrudan bir sonraki katmana ilerlemez. Bunun yerine çıktı, ReLU gibi doğrusal olmayan bir aktivasyon fonksiyonu deneyimler ve ortaya çıkan çıktıyı bir sonraki katmana iletir.

#### 4.2.2.1.2. Havuzlama Katmanı

Bir havuzlama katmanı, giriş verilerinin boyutlarını azaltmak için bir evrişim katmanını takip eder. Evrişim ve havuzlama katmanları genellikle çiftler oluşturur ve birlikte çalışır. Evrişimli özellik haritası büyüktür ve hesaplama maliyetini ve aşırı uyum olasılığını artırabilir; boyutunun küçültülmesi önemlidir. Bunu başarmak, girdi matrisinde havuzlama bölgesi olarak da bilinen sınırlı bir bölgenin analiz edilmesini ve baskın özelliklerinin çıkarılmasını içerir. Bu çıkarma iki şekilde gerçekleşebilir: ortalama havuzlama veya


maksimum havuzlama. Ortalama havuzlamada havuzlama bölgesindeki tüm değerlerin ortalaması hesaplanırken, maksimum havuzlamada havuzlama bölgesindeki maksimum değer dikkate alınır. Böyle bir işlemin gerçekleştirilmesiyle ortaya çıkan matris, giriş matrisinin ana özelliklerini daha az boyutta içerir veya başka bir deyişle, evrişim katmanı tarafından çıkarılan özellikleri özetler. Şekil 4.21’ de havuzlama katmanı gösterilmiştir.



Şekil 4.21 Havuzlama katmanı


#### 4.2.2.1.3. Tam Bağlı Katman

Tam bağlantılı katmana kadar ağ yalnızca ilgili özellikleri çıkarılır ve boyutları küçültülür; ancak herhangi bir sınıflandırma gerçekleşmez. Giriş görüntüsünün tek sütunlu bir vektör halinde düzleştirilmesi, sınıflandırma için geleneksel, tamamen bağlantılı, yoğun, ileri beslemeli bir sinir ağının kullanılmasına olanak tanır. Tamamen bağlı bir katmanda, bir katmandaki düğümler bir sonraki katmandaki diğer tüm düğümlere bağlanır. Şekil 4.22’ de birbirine bağlı katmanların yapısı gösterilmiştir.



Şekil 4.22 Birbirine bağlı katmanlar

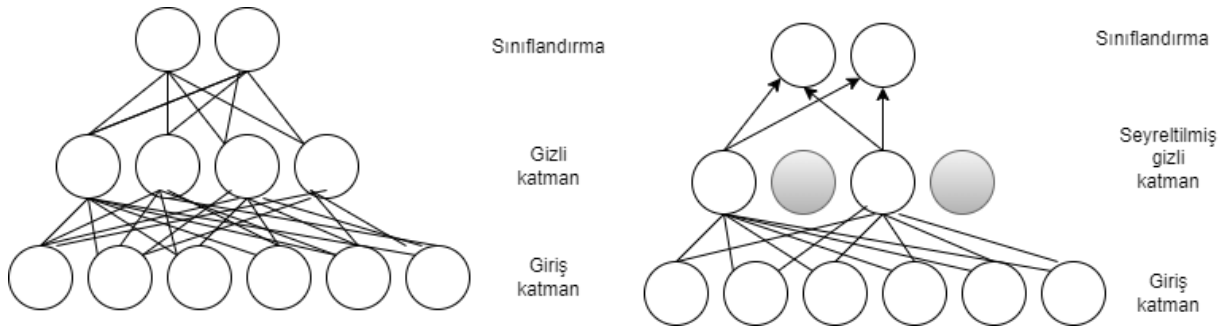
Tamamen birbirine bağılı birden fazla katman, bir çerçevedeki verilere benzer şekilde düzleştirilmiş vektörü işler ve görüntü sınıflandırması için önemli özellikleri ayırt eder. Çıktı katmanının hemen öncesine konumlandırılarak süreci tamamlarlar ve doğru sınıflandırma için özellik çıkarımından sonra modeli hassaslaştırırlar. Şekil 4.22’ de giriş görüntüsü ile tam bağılı katman çıkarım evreleri gösterilmiştir.



Şekil 4.22 Tam bağılı katman çıkarımı

#### 4.2.2.1.4. Seyreltme Katmanı

Sinir ağlarını düzenlemek, aşırı uyumu azaltmak için önemli bir görevdir. Evrişimli sinir ağlarında seyreltme genellikle bağılı katmanlara uygulanır (Srivastava ve ark., 2014). Seyreltme yaklaşımında, her bir gizli birimin ağ performansına farklı katkıları olmasına rağmen, her bir gizli birim, eğitim aşaması sırasında sabit bir  $p$  ihmal edilme olasılığını paylaşır. Özellikle evrişim katmanında aktivasyon değerinin yüksek olduğu bir birimin silinmesi büyük bilgi kaybına yol açabilecek ve eğitim sırasında ağ performansının düşmesine yol açabilecek önemli bir özelliğe işaret etmektedir. Aksine, düşük aktivasyon değerine sahip bir birim, eğitim sırasında küçük bir katkı değeri verir ve sonuçta geri yayılım aşamasında küçük miktarda hata gradyanı alır. Dolayısıyla bu birimin genel ağ performansına öncekine göre daha az etki ettiğini rahatlıkla söyleyebiliriz (Han ve ark., 2015).



Şekil 4.23 Seyreltme katmanı kullanmadan önce ve kullandıktan sonra

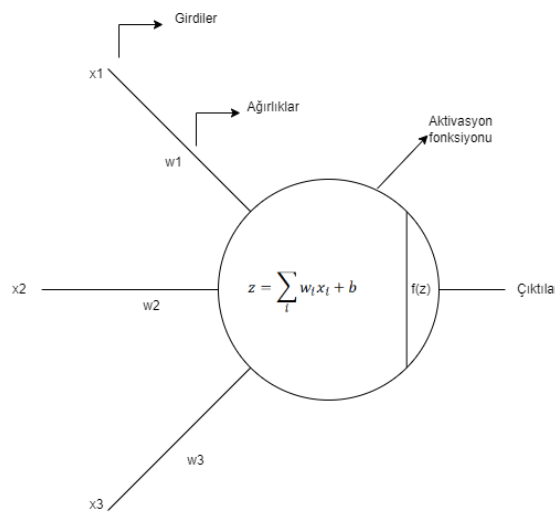
Tamamen bağlantılı katmanla ilgili bir sorun, yoğun mimarisinin modelin eğitim veri kümesini fazlasıyla öğrenmesine, yani veriye "ezberlemesine" neden olabilmesidir. Bu

durum, modelin yeni ve görülmemiş veriler üzerinde düşük performans göstermesine yol açar. Bir seyreltme katmanı, bu sorunu çözmek için rastgele birkaç nöronu ağdan çıkarır. Örneğin, 0,15'lik bir bırakma değeri, nöronların %15'inin ağdan ayrılmasına neden olabilir ve bu da modelin eğitim sırasında aşırı uyum sağlamamasını sağlar. Farkı görebilmemiz için Şekil 4.23' de seyreltme katmanı kullanmadan önce ve kullandıktan sonraki yapı gösterilmiştir.

#### 4.2.2.1.5. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonları derin evrişimli sinir ağlarında önemli roller oynar. Aktivasyon fonksiyonu, özellikleri korurken gereksiz verileri kaldırmak için doğrusal olmayan faktörleri ekler, "aktif nöron özelliğini" korur ve bu özellikleri, karmaşık doğrusal olmayan problemi çözmek için sinir ağının esaslı olan doğrusal olmayan işlevlerle eşleştirir (Maas ve ark., 2013). Aktivasyon fonksiyonu evrişim sinir ağının önemli bir parçasıdır. Evrişim sinir ağının üç aşamasında, evrişim, alt örnekleme ve tam bağlantıda, hesaplanan özellikleri haritalandırmak için genellikle doğrusal olmayan bir aktivasyon fonksiyonu kullanılır. Aktivasyon fonksiyonunun matematiksel formülü Şekil 4.24' de verilmiştir.

$$F(x) = akt(\sum_i(w * x + b)) \quad (4.1)$$




Şekil 4.24 Aktivasyon fonksiyonunun matematiksel formülü

Denklem 4.1' de verildiği gibi,  $x$  girdileri için  $W$  ağırlıkları çarpımını hesaplar ve  $b$  bias değeri ekleyerek bir  $F(x)$  çıktısı üretir. Evrişim sinir ağlarını oluşturmak için çeşitli aktivasyon fonksiyonları uygulanmıştır. Bunlar; ikili adım fonksiyonu, ReLU, Sigmoid, Hiperbolik tanjant, Softmax'dir.


İkili adım aktivasyon fonksiyonu; bir aktivasyon fonksiyonumuz olduğunda, dikkate almamız gereken en önemli şey eşik bazlı sınıflandırıcıdır; bu, doğrusal dönüşümün değerinin nöronu aktive etmesi gerekip gerekmediği veya aktivasyon fonksiyonuna girdinin belirli bir değerden büyük olması durumunda bir nöronun aktive olacağını söyleyebiliriz anlamına gelir: bu eşik değeri, aksi takdirde devre dışı bırakılır. Bu durumda çıktı bir sonraki katmana girdi olarak beslenmez. İkili adım fonksiyonu, var olan en basit aktivasyon fonksiyonudur (Glorot ve Bengio, 2010). İkili adım fonksiyonunun gradyanı sıfırdır, bu da geriye yayılma adımında bir engele neden olabilir, yani  $f(x)$ 'in  $x$  'e göre türevini hesaplırsak sıfıra eşittir. İkili adım aktivasyon fonksiyonunun formülasyonu Denklem 4.2' de verilmiştir. Bu formülün grafiği ise Şekil 4.25' da verilmiştir.

$$f(x) = 1, x \geq 0 \text{ ve } f(x) = 0, x < 0 \quad (4.2)$$



Şekil 4.25 İkili adım fonksiyonu

ReLU aktivasyon fonksiyonu en yaygın kullanılanıdır. ReLU'nun hesaplaması kolaydır, elde edilmesi basittir ve yakınsama hızına sahiptir bu nedenle gradyan kaybolma problemlerini etkili bir şekilde hafifletebilir ve eğitimden sonra sinir ağları için biyolojik nöron aktivasyonunun doğasına daha uygun olarak belirli seyrek özellikler sağlayabilir (Glorot ve Bengio; 2010).



Şekil 4.26 ReLU fonksiyonunun grafiği


Gördüğünüz gibi ReLU yarı düzeltilmiş  $z$  sıfırdan küçük olduğunda  $f(z)$  sıfırdır ve  $z$  sıfırın üzerinde veya sıfıra eşit olduğunda  $f(z)$   $z$ 'ye eşittir. Fonksiyon ve türevinin her ikisi de monotondur. Ancak sorun, tüm negatif değerlerin hemen sıfıra düşmesidir, bu da modelin verilere uygun şekilde uyum sağlama veya verilerden eğitim alma yeteneğini azaltır. Bu, ReLU aktivasyon fonksiyonuna verilen herhangi bir negatif girişin, değeri grafikte hemen sıfıra çevirdiği ve bunun da negatif değerleri uygun şekilde eşlemeyerek ortaya çıkan grafiği etkilediği anlamına gelir. Şekil 4.26' da ReLU grafiği verilmiştir.

Sigmoid aktivasyon fonksiyonu etkinleştirme değerinin hesaplanması için kullanılır. Örneğin birçok durumda sigmoid işlevi, sinirsel hesaplamaların hesaplama açısından en pahalı kısmını oluşturur. Sigmoid fonksiyonunun gerçekleştirilmesindeki en önemli problem yükün işlenmesidir. Birçok uygulamada bu sorunun üstesinden gelmek için arama tablosu kullanılır. Aktivasyon fonksiyonu  $f(net)$  nöron çıktısının değerini sınırlamak için kullanılır (Duman ve Erdem, 2003). Bu aktivasyon fonksiyonu şu denklemlerle verilmektedir:

$$f1(net) = \frac{1}{1+e^{-net}} \quad (4.3)$$

Bu sinir ağında kullanılan yaklaşım şu fonksiyonla verilir:

$$f2(net) = \frac{1}{2} \left( \frac{net}{1+net} + 1 \right) \quad (4.4)$$




Şekil 4.27 Sigmoid aktivasyon fonksiyonu

Şekil 4.27’ de iki fonksiyonun F1(x) , F2(x) çıkış eğrisini göstermektedir. Bu, iki fonksiyonun yaklaşık olarak aynı fonksiyon olduğunu gösterir.

Hiperbolik tanjant fonksiyonu Sigmoid işlevine benzer şekilde Tanh işlevi, girişi -1 ile 1 arasında sıkıştırır. Tanh fonksiyonu sigmoid fonksiyonuna benzer ancak orijin etrafında simetriktir. Bu, önceki katmanlardan gelen ve bir sonraki katmana girdi olarak beslenecek olan farklı çıktı işaretleriyle sonuçlanır. Hem sigmoid hem de Tanh aktivasyon fonksiyonları ileri beslemeli yapay sinir ağlarında kullanılır (Lu ve Chen, 2005). Hiperbolik tanjant aktivasyon fonksiyonunun matematiksel formülasyonu Denklem 4.4’ te verilmiştir.

$$f(x) = 2sigmoid(2x) - 1 \quad (4.5)$$



Şekil 4.28 Hiperbolik tanjant fonksiyonu(IJAST, 2020)

Şekil 4.28’ de hiperbolik tanjant fonksiyonu grafiği verilmiştir. Buna göre Tanh fonksiyonu sürekli ve türevlenebilirdir ve değerleri -1 ila 1 aralığındadır. Sigmoid fonksiyonuyla karşılaştırıldığında Tanh fonksiyonunun eğimi daha diktir. Tanh, belirli bir yönde değişmekle

sınırlı olmayan gradyanlara sahip olması ve ayrıca sıfır merkezli olması nedeniyle sigmoid fonksiyona göre daha çok tercih edilir.

Softmax fonksiyonu birden fazla sigmoid fonksiyonunun birleşimidir. Bir sigmoid fonksiyonunun 0 ile 1 aralığında değerler döndürür, bunlar belirli bir sınıfın veri noktalarının olasılıkları olarak ele alınabilir. Softmax fonksiyonu ikili sınıflandırma için kullanılan sigmoid fonksiyonlardan farklı olarak çok sınıflı sınıflandırma problemlerinde kullanılabilir. Fonksiyon, tüm bireysel sınıfların her veri noktası için olasılığı döndürür. Softmax aktivasyon fonksiyonunun matematiksel formülasyonu Denklem 4.5' te verilmiştir.

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad for \ j = 1, \dots, K \quad (4.6)$$

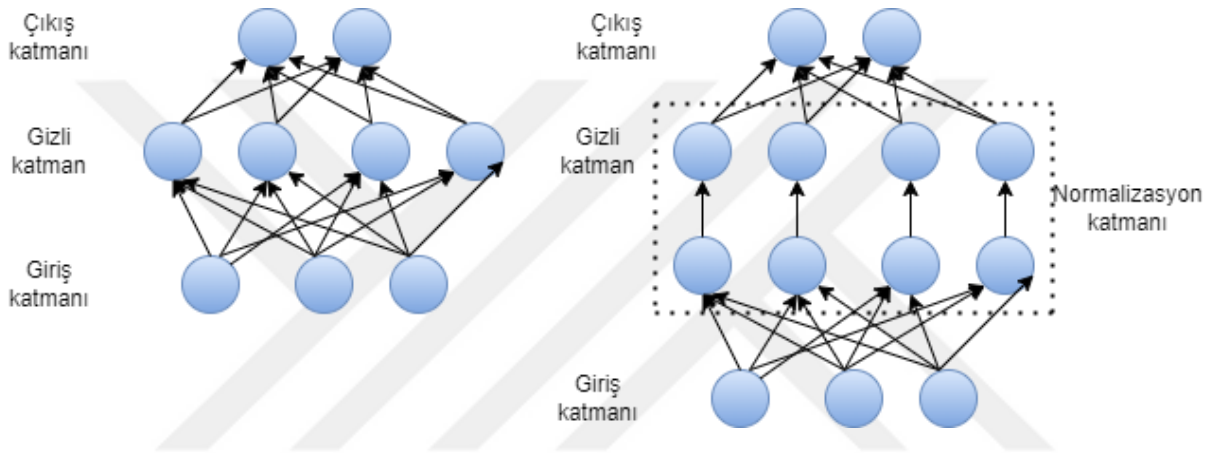
Denklem 4.6' da  $\sigma$  softmax,  $z$  giriş vektörü,  $e^{z_j}$  giriş vektörü için standart üstel fonksiyon,  $K$  çok sınıflı sınıflandırıcıdaki sınıf sayısı,  $e^{z_k}$  ise çıkış vektörü için standart üstel fonksiyonunu ifade etmektedir. Çoklu sınıf sınıflandırması için bir ağ veya model oluşturduğumuzda, ağın çıktı katmanı, hedefteki sınıf sayısı ile aynı sayıda nörona sahip olacaktır. Softmax işlevi, gerçek sayılar vektörünü olasılık vektörüne dönüştürür. Sonuçtaki her olasılık  $[0,1]$  aralığındadır ve olasılıkların toplamı 1'dir.

Doğru bir aktivasyon fonksiyonu seçilmesi daha iyi performans ve daha az hatalı sonuçlar elde etmemize neden olur. Uygun aktivasyon fonksiyonu seçerken bir ağdaki gizli katmanların sayısı, eğitim yöntemleri, hiperparametre ayarlama gibi pek çok şeyin dikkate alınması gerekir. Herhangi bir aktivasyon fonksiyonunu seçmek için genel bir kural yoktur ancak aktivasyon fonksiyonunun seçimi bağlama bağlıdır, yani gerçekleştirilecek göreve bağlıdır. Farklı aktivasyon fonksiyonlarının kendilerine göre avantajları ve dezavantajları vardır ve bu, tasarladığımız sistemin türüne bağlıdır.

#### 4.2.2.1.6. Normalizasyon Katmanları

Derin sinir ağlarında gizli katmanın girdilerinin dağılımı eğitim sırasında sürekli olarak değişecektir. Bu iç ortak değişken kayması olarak kabul edilir. Genel olarak yeni dağılım, aktivasyon fonksiyonunun aralığının üst ve alt sınırlarına kademeli olarak yaklaşır, bu da geri yayılım sırasında sığ gizli katmanların gradyanının azalmasına ve kaybolmasına yol açabilir. Bu nedenle derin sinir ağlarının yakınsaması giderek daha yavaştır (Li ve ark.,

2016). Toplu normalleştirme (BN), girdilerin dağılımını, ortalaması 0 ve varyansı 1 olan standart normal dağılıma dönüştürebilir. Bu dönüştürme, dağılımın aktivasyon fonksiyonunun hassas aralığına düşmesini sağlar; bu, girdideki küçük değişiklik anlamına gelir. Kayıp fonksiyonunda büyük bir değişikliğe yol açabilir. Ayrıca bu, gradyanı daha büyük hale getirir ve gradyan dağılımı problemini ortadan kaldırır. Daha büyük eğitim, derin sinir ağlarının yakınsamasının daha hızlı olduğu anlamına gelir ve bu da eğitim sürecini büyük ölçüde hızlandırır (Ioffe ve Szegedy, 2015). Şekil 4.29’ da normalizasyon katman yapısı gösterilmektedir.



Şekil 4.29 Normalizasyon katmanı yapısı

#### 4.2.2.1.7. Eğitim Tur Sayısı (Epoch)

Kısaca epoch sayısı, öğrenme algoritmasının tüm eğitim veri kümesi boyunca kaç kez çalışacağını tanımlayan bir hiperparametredir. Model eğitilirken verilerin tamamı aynı anda eğitime katılmaz. Belli sayıda parçalar halinde eğitimde yer alırlar. İlk parça eğitilir, modelin başarımı test edilir, başarıma göre geriye yayılım ile ağırlıklar güncellenir. Daha sonra yeni eğitim kümesi ile model tekrar eğitilip ağırlıklar tekrar güncellenir. Bu işlem her bir eğitim adımında tekrarlanarak model için en uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine “epoch” denilmektedir (Brownlee, 2016). Başarımı etkileyen faktörlerden biri de ne zaman eğitim sürecinin durdurulacağıdır. Çünkü epoch sayısı arttıkça, ağlar eğitim örneklerine aşırı uyum sağlama eğilimidir. Bununla birlikte minimum epoch sayısı; konunun doğasına, veri seti arasındaki varyansa ve eğitim verileri ile test verileri arasındaki benzerliğe büyük ölçüde bağlıdır (Özgenel, 2018).

#### **4.2.2.1.8. Hiper-parametre**

Hiperparametreler, modelin eğitim sürecini ve sonuçlarını etkileyen, ancak model tarafından doğrudan öğrenilmeyen parametrelerdir. Bu parametreler, modelin yapısını, eğitim algoritmasını ve optimizasyon stratejisini belirler. Örnek olarak, derin öğrenme modelinin mimarisi (katman sayısı, katman türleri), öğrenme oranı, optimizasyon algoritması, büyüklüğü, epoch sayısı, ağırlık başlatma yöntemleri, düzenleme parametreleri ve daha fazlası hiperparametreler arasında yer alır. Bu hiperparametrelerin optimal değerlerini bulmak, modelin doğruluğunu, genelleme yeteneğini ve performansını artırmak için önemlidir. Ancak, bu genellikle deneme yanılma yoluyla yapılır ve doğru hiperparametrelerin seçilmesi, genellikle zaman alıcı ve zorlu bir süreçtir.

#### **4.2.2.1.9. Mini Batch Boyutu**

Derin öğrenme uygulamalarında, veri setinde bulunan tüm verileri aynı anda işleyerek öğrenme, zaman ve bellek açısından maliyetli bir işittir. Çünkü öğrenmenin her iterasyonunda geriye yayılım işlemi ile ağı üzerinde geriye dönük olarak gradyan hesaplaması yapılmakta ve ağırlık değerleri bu şekilde güncellenmektedir. Bu hesaplama işleminde veri sayısı ne kadar fazla ise hesaplama da o oranda fazla sürmektedir. Bu problemi çözmek için; veri seti küçük gruplara ayrılmakta ve öğrenme işlemi seçilen bu küçük gruplar üzerinde yapılmaktadır. Bu şekilde birden fazla girdinin parçalar halinde işlenmesi “mini-batch” olarak adlandırılmaktadır.

#### **4.2.2.1.10. Öğrenme Hızı**

Öğrenme Hızı (Learning Rate), derin sinir ağlarının etkili eğitimi için ayarlanması gereken önemli bir hiperparametredir. LR, derin öğrenme modelinin eğitimi sırasında ağırlıkların ne kadar hızlı veya yavaş güncelleneceğini belirleyen bir hiperparametredir. Modelin her güncelleme adımında, öğrenme oranı ağırlıkların ne kadar değişeceğini kontrol eder. Bir öğrenme oranı seçilirken, çok büyük bir değer ağırlıkların sıçramasına neden olabilir, bu da modelin asla uyum sağlamayı öğrenememesine veya dengesiz bir şekilde davranmasına yol açabilir. Diğer yandan, çok küçük bir öğrenme oranı eğitim sürecini çok yavaşlatır ve yerel minimumlara sıkışıp kalma riskini artırabilir. Genellikle, başlangıçta küçük bir öğrenme oranı seçilir ve eğitim sürecindeki ilerlemeye göre ayarlanır. Deneme yanılma yoluyla, uygun bir öğrenme oranı belirlenir ve modelin daha hızlı ve daha verimli öğrenmesi sağlanır (Hochreiter ve ark., 2001). Öğrenme hızı çoğunlukla 0,1 ile 0,000001 arasında belirlenmektedir. Beklendiği gibi, tüm problemler için uygun bir öğrenme oranı değeri

tanımlamak mümkün değildir. Belirli bir problemdeki öğrenme oranı için optimal değer, farklı değerler için tahmin performansı gözlemlenerek aranmalıdır (Farahmand, 2022).

#### 4.2.2.1.11. Kayıp Fonksiyonu

Derin öğrenmeyi içeren yöntemlerde kayıp fonksiyonu (LF-Loss Function), optimizasyon sürecinde tahmin edilen ve gerçek değerler arasındaki farkı yansıtır ve derin öğrenme modellerinin genelleme kapasitesini ve doğruluğunu içerir, dolayısıyla derin öğrenmenin temelini oluşturur (Chen ve ark., 2016). LF, bir makine öğrenimi modelinin tahmin edilen çıktılarının gerçek çıktı etiketleriyle ne kadar iyi eşleştiğini ölçen bir işlevdir. LF, kaybı en aza indirerek modeli optimize etmek için kullanılır; bu, modelin eğitim verilerinde daha az hata yapması anlamına gelir. LF, makine öğrenimi sürecinin önemli bir parçasıdır çünkü modelin performansını değerlendirmenin bir yolunu sağlar ve modelin tahminlerinin gerçek çıktı etiketlerinden ne kadar farklı olduğunu göstererek optimizasyon sürecine rehberlik eder. Sinir ağlarında ortalama kare hatası, çapraz entropi kaybı ve menteşe kaybı gibi birkaç farklı kayıp fonksiyonu mevcuttur. Kayıp fonksiyonunun seçimi, modelin kullanıldığı görevin türüne ve kullanılan modelin türüne bağlıdır. Örneğin, ortalama karesel hata genellikle regresyon görevleri için kullanılırken, çapraz entropi kaybı genellikle sınıflandırma görevleri için kullanılır (Neyshabur ve ark., 2017).

Sınıfsal çapraz entropi en çok tercih edilen kayıp fonksiyonlarından biridir. Bu çalışmada kategorik çapraz entropi kayıp fonksiyonu tercih edilmiştir. İkili çapraz entropi kayıp fonksiyonunun geliştirilmiş hali ikili sınıflandırma problemine uygulanmıştır. Denklem 4.7 ve 4.8'de gösterilmektedir.

$$L(X_i, Y_i) = - \sum_{j=1}^c Y_{ij} * \log(p_{ij}) \quad (4.7)$$

$$Y_{ij} = \begin{cases} 1, & \text{Eğer } i \text{ eleman } j \text{ sınıftaysa} \\ 0, & \text{değilse} \end{cases} \quad (4.8)$$

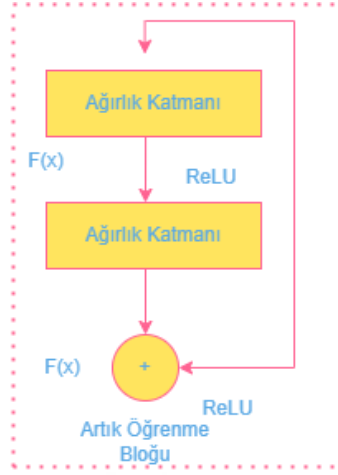
$Y_{ij}$  kategorik vektör ( $Y_{i1}, Y_{i2}, Y_{i3}, Y_{i4}, Y_{i5}, \dots, Y_{ic}$ ) ve  $p_{ij} = f(x_{ij})$  i. elemanların j. sınıfta olma olasılığını ifade eder.

#### 4.2.2.1.12. Ön Eğitimli VGG-16 Modeli

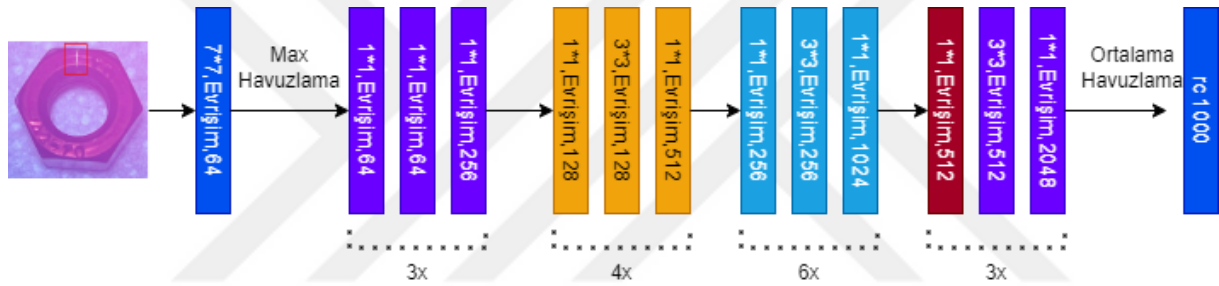
VGG-16 modeli, Şekil 4.30'da gösterildiği gibi 16 katmandan (13 evrişimli katman ve filtre boyutu 33 olan üç tamamen bağlı katman) oluşur. 13 evrişim katmanı beş gruba bölünmüştür ve her grubu bir maksimum havuzlama katmanı takip eder (Simonyan ve Zisserman, 2014). VGG-16 mimarisinin girişi 224x224 piksellik bir RGB görüntüsüdür. Girdi, evrişimli ve maksimum havuzlama katmanları olarak geçer ve sonunda bir (7, 7, 512)



1000 adet özellik elde edilir ve softmax sınıflandırıcısı eğitilir. Resnet-50 modelinin blok şeması Şekil 4.32’de ve mimarisi Şekil 4.33’de gösterilmiştir.



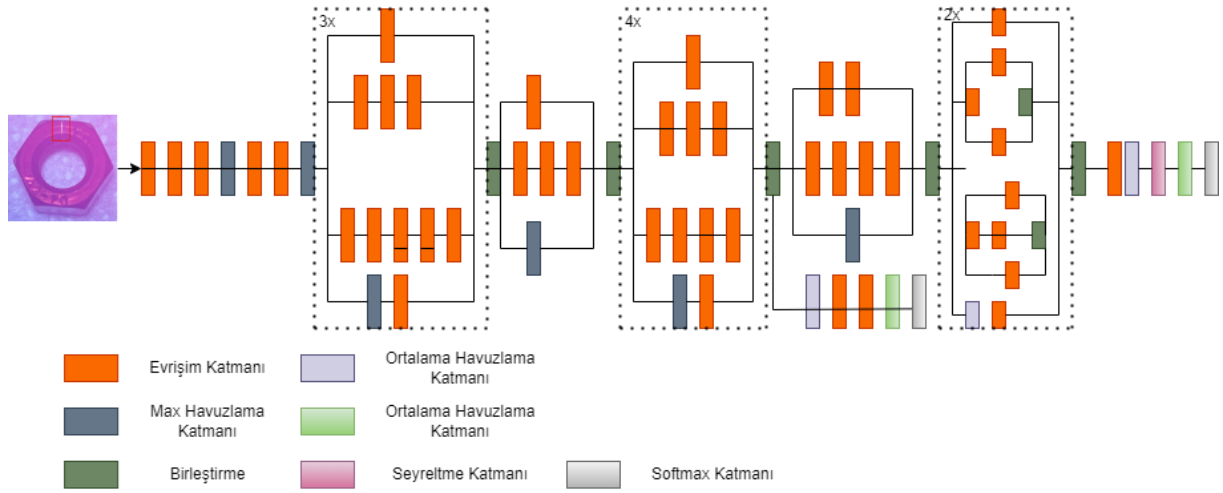
Şekil 4.32 Resnet-50 modelinin blok şeması



Şekil 4.33 Resnet-50 modelinin mimarisi

#### 4.2.2.1.15. Inception-V3 Modeli

Inception-V3 mimarisi 2012 yılında Google tarafından geliştirmiştir. Çoklu evrişim katmanlarından oluşmaktadır. Bu model 20 milyondan fazla parametre içermektedir. Modelin kendisi simetrik ve asimetrik yapı bloklarından oluşur; burada her blok çeşitli evrişimli, ortalama ve maksimum havuzlama, birleştirmeler, bırakmalar ve tam bağlantılı katmanlardan oluşur. Giriş verilerini  $1 \times 1$  evrişim katmanı ile işlemden geçirdikten sonra, veri evrişim katmanı kanalının her bir kanalından paralel olarak geçer. Tüm kanal çıktıları en sonda birleştirilerek derleme süreci tamamlanır. InceptionV2’den farklı olarak Inception-V3 ağında yardımcı sınıflandırıcının yalnızca evrişim katmanlarını haricinde tam bağlı katmanı da normalize etmesi ile ortaya çıkar. Ek olarak, toplu normalleştirme yaygın olarak kullanılır ve Inception-V3 ön eğitim modeline uygulanır (Szegedy ve ark., 2016). Inception-V3 modelinin mimarisi Şekil 4.34’ de gösterilmiştir.



Şekil 4.34 Inception-V3 modelinin mimarisi

#### 4.2.2.1.16. Optimizasyon Algoritmaları

Optimizasyon algoritmaları, makine öğrenimi ve derin öğrenme modellerinin eğitim sürecinde model parametrelerini güncelleyerek kayıp fonksiyonunu minimize etmeye çalışan matematiksel yöntemlerdir. Bu algoritmalar, modelin daha iyi tahminler yapabilmesi için parametreleri optimize eder.

##### 4.2.2.1.16.1. Stochastic Gradient Descent (SGD)

SGD, her iterasyonda bir örnek veya mini-batch kullanarak kayıp fonksiyonunun gradyanını hesaplar ve parametreleri bu gradyan doğrultusunda günceller. SGD' nin matematiksel formülasyonu Denklem 4.9' da gösterilmiştir.

$$\theta = \theta - \nabla_{\mu} J(\theta; x^{(i)}, y^{(i)}) \quad (4.9)$$

Burada,  $\theta$  model parametreleri,  $\mu$  öğrenme hızı,  $J$  kayıp fonksiyonu,  $x^{(i)}$  ve  $y^{(i)}$  sırasıyla giriş ve çıkış örnekleridir.

##### 4.2.2.1.16.2. Momentum

Momentum, önceki gradyanların üstel hareketli ortalamasını kullanarak optimizasyon sürecine hız kazandırır ve dalgalanmaları azaltır. Momentum optimizasyonunun matematiksel formülasyonu Denklem 4.10' da verilmiştir.

$$\vartheta_t = \gamma \vartheta_{t-1} + \nabla_{\mu} J(\theta) \quad (4.10)$$

$$\theta = \theta - \vartheta_t \quad (4.11)$$

Burada,  $\vartheta_t$  momentum terimi,  $\gamma$  momentum katsayısıdır.

#### 4.2.2.1.16.3. Nesterov Accelerated Gradient (NAG)

NAG, momentum yöntemini kullanırken gradyanı hesaplamak için bir adım ileriye bakar ve daha doğru güncellemeler yapar. NAG optimizasyonunun matematiksel formülü Denklem 4.11’de verilmiştir.

$$\vartheta_t = \gamma\vartheta_{t-1} + \nabla\mu J(\theta - \gamma\vartheta_{t-1}) \quad (4.12)$$

#### 4.2.2.1.16.4. AdaGrad

AdaGrad, her parametre için ayrı bir öğrenme hızı ayarlayarak sık karşılaşılan parametrelerin öğrenme hızını azaltır. Nadir özelliklerin öğrenmesini hızlandırır. AdaGrad optimizasyonunun matematiksel formülü Denklem 4.13’ de gösterilmiştir.

$$\theta_t = \theta_{t-1} - \frac{\mu}{\sqrt{G_{t,t} + \epsilon}} \nabla J(\theta) \quad (4.13)$$

Burada,  $G_{t,t}$  her parametrenin gradyanlarının karelerinin birikimli toplamıdır.

#### 4.2.2.1.16.5. RMSprop

RMSprop optimizasyon algoritması, her bir parametrenin öğrenme hızını adaptif olarak ayarlayarak daha dengeli ve verimli bir öğrenme süreci sağlar. RMSprop, gradyanların karelerinin üstel hareketli ortalamasını kullanır. RMSprop optimizasyonunun matematiksel formülü Denklem 4.14’ de gösterilmiştir.

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma)g_t^2 \quad (4.14)$$

Burada,  $E[g^2]_t$ :  $t$  zamanındaki gradyan karelerinin üstel hareketli ortalamasıdır.  $\gamma$ : Hareketli ortalama katsayısı (genellikle 0.9 gibi bir değere ayarlanır). Bu, geçmiş gradyan karelerinin ortalamaya ne kadar katkıda bulunduğunu belirler.  $E[g^2]_{t-1}$  Bir önceki adımda hesaplanan gradyan karelerinin üstel hareketli ortalamasıdır.  $g_t^2$  ise  $t$  zamanındaki gradyanın karesi. Bu, mevcut gradyan bilgisinin üstel hareketli ortalamaya ne kadar katkıda bulunduğunu belirler.

#### 4.2.2.1.16.6. Adam (Adaptive Moment Estimation)

Adam, hem AdaGrad hem de RMSprop’un avantajlarını birleştirir, her parametre için adaptif öğrenme hızları kullanır ve momentum terimleri ekler.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1)g_t \quad (4.15)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2)g_t^2 \quad (4.16)$$

$$m_t = \frac{m_t}{1 - \beta_1^t} \quad (4.17)$$

$$v_t = \frac{v_t}{1-\beta_2^t} \quad (4.18)$$

$$\theta = \theta - \frac{\mu m_t}{\sqrt{v_t + \epsilon}} \quad (4.19)$$

Adam optimizasyonunun matematiksel formülü Denklem 4.15-19' da gösterilmiştir.



## 5. DEĞERLENDİRME METRİKLERİ

Model değerlendirmesi yaptığımız çalışma için oluşturduğumuz algoritmaları değerlendirmemizi ve hangisinin daha başarılı sonuçlar verdiğini görmemiz açısından büyük öneme sahiptir. Model değerlendirmesi bize modelin nasıl bir performans gösterdiğini belirlemede yardımcı olur. Bir modelin doğruluğunu, hassasiyetini, duyarlılığını ve diğer performans değerlerini hesaplayarak hangi modelin gerçek dünya problemlerinde daha başarılı sonuçlar verdiğini anlamamız için makine öğrenme algoritmalarında farklı değerlendirme metrikleri kullanılmaktadır. Burada tez çalışmamız için farklı öğrenme modellerini kullanarak manyetik parçacık testi sonrası elde ettiğimiz görüntülerdeki çatlakların tespitini yapmada en iyi performansı sergileyen modeli tespit etmek olacaktır. Karşılaştırma yapacağımız modeller; VGG16, VGG19, Inception-V3 ve ResNet50'dir. Modelin genel performansını değerlendirmemiz aşırı öğrenmeyi (overfitting) veya az öğrenmeyi (underfitting) tespit etmemize yardımcı olur.

Tahmini değerler (predicted values) ve gerçek değerler (true values), makine öğrenimi ve derin öğrenme modellerinin performansını değerlendirmek için kullanılan iki temel bileşendir. Gerçek değerler, modelin tahmin etmeye çalıştığı hedef değişkenlerin doğru veya beklenen değerleridir. Bu değerler, genellikle bir eğitim veya test veri setinde etiketlenmiş olarak bulunur ve modelin tahminlerinin doğruluğunu değerlendirmek için kullanılır. Gerçek değerler, veri setinin doğrulama veya test bölümlerinde yer alan gözlem değerleridir. Tahmini değerler, modelin eğitim veya test veri setinde bulunan girdilere dayanarak ürettiği sonuçlardır. Bu değerler, modelin verdiği kararlar veya yaptığı tahminlerdir ve gerçek değerlerle karşılaştırılarak modelin performansı ölçülür.



Şekil 5.1 Doğruluk değerlendirme matrisi

### 5.1. Doğruluk (Accuracy)

Doğruluk, doğru tahminlerin toplam tahminlere oranıdır. Mümkün olduğunca yüksek olması daha iyidir. Denklem 5.1' deki şekilde tanımlanabilir.

$$Doğruluk = \frac{TP+TN}{TP+FN+FP+TN} \quad (5.1)$$

### 5.2. Kesinlik (Precision)

Kesinlik, pozitif tahminlerin ne kadarının gerçekten pozitif olduğunu gösterir. Denklem 5.2' deki şekilde tanımlanabilir.

$$Kesinlik = \frac{TP}{TP+FP} \quad (5.2)$$

### 5.3. Duyarlılık (Recall)

Duyarlılık, gerçek pozitiflerin ne kadarının doğru olarak tahmin edildiğini gösterir. Denklem 5.3' deki şekilde tanımlanabilir.

$$Duyarlılık = \frac{TP}{TP+FN} \quad (5.3)$$


### 5.4. F1 Skoru

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır. Denklem 5.4' deki şekilde tanımlanabilir.

$$F1 - Skor = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (5.4)$$

### 5.5. AUC-ROC Eğrisi

ROC eğrisi sınıflandırma performansının iki boyutlu bir ölçüsüdür. Olumlu örnekleri doğru şekilde sınıflandırma olasılığının, gerçek olumsuz örnekleri yanlış sınıflandırma oranına karşı grafiği olarak anlaşılabilir. Bu anlamda, bu eğri, sınıflandırıcının tüm sınıf dağılımları ve hata maliyetleri aralığındaki bir karşılaştırması olarak yorumlanabilir. Şekil 5.2' de, belirli bir sınıflandırıcının ROC eğrisinin bir örneğini göstermektedir. Çapraz çizgi, sınıfı rastgele tahmin eden bir sınıflandırıcının ROC eğrisine karşılık gelir ve eğri grafiğin sol üst köşesine yaklaştıkça performans artar. ROC eğrisinden elde edilen en sık kullanılan performans ölçüsü, genellikle AUC olarak gösterilen eğrinin altındaki alanın değeridir. AUC 1'e eşit olduğunda, eşik doğru seçilirse sınıflandırıcı mükemmel bir doğruluğa ulaşır ve sınıfı rastgele tahmin eden bir sınıflandırıcının ilişkili AUC'si 0,5'tir. AUC'nin bir diğer ilgi çekici noktası, sınıf etiketi elde etmek için kullanılan eşikten bağımsız olduğundan sınıflandırıcının genel davranışını tasvir etmesidir (Saul ve Roweis, 2003).



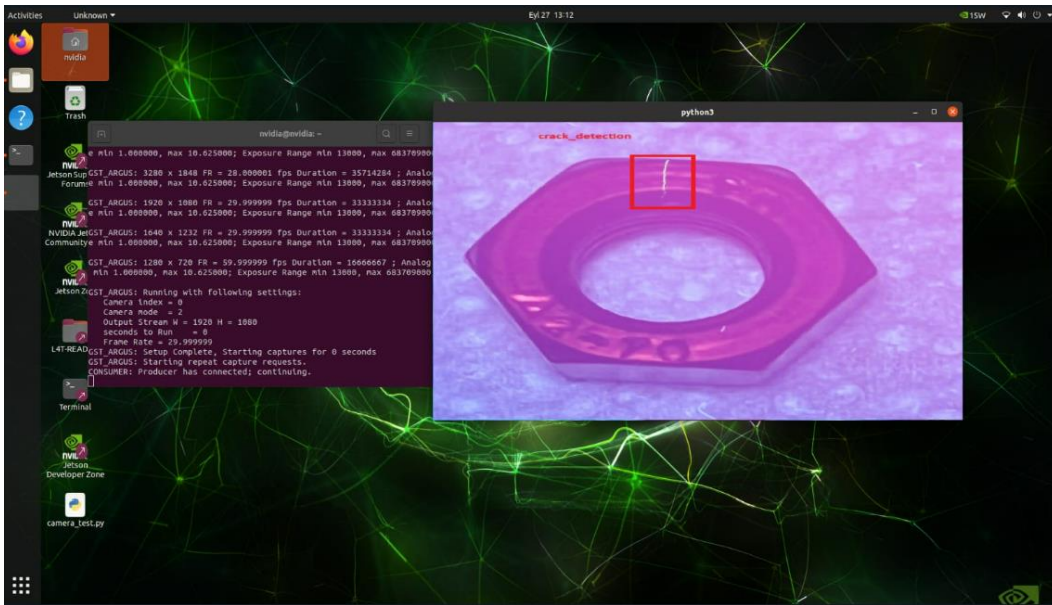
Şekil 5.2 ROC eğrisi örneği

Burada  $f(x)$  puanlama fonksiyonu olarak gösterilir bu makine öğreniminde sınıflandırıcının karar fonksiyonu en sık kullanılan puanlama fonksiyonudur.  $x^+$  ve  $x^-$  sırasıyla pozitif ve negatif örnekleri belirtir ve  $n^+$  ve  $n^-$  sırasıyla olumlu ve olumsuz örneklerde  $1_\pi$ ,  $\pi$  geçerliyse 1, aksi halde 0 olarak tanımlanır. Bu denklem, eğer bir  $f(x)$  sınıflandırıcısı şu şekilde ise:  $f(x_i^+) > f(x_j^-)$ ,  $\forall_i = 1, \dots, n^+, \forall_j = 1, \dots, n^-$  bu sınıflandırıcının AUC' si şöyledir: maksimum. pozitif örnekten daha üst sırada yer alan herhangi bir negatif örnek, AUC' nin azalmasına neden olur. Hata matrisinin köşegenlerinde yer alan değerlerin (doğru tahmin edilmiş piksellerin) toplamının tüm matris elemanları toplamına bölümü ile elde edilir. Matematiksel formülü Denklem 5.5' de verilmiştir (Yan ve ark., 2003).

$$AUC = \frac{\sum_{i=1}^{n^+} \sum_{j=1}^{n^-} 1_{f(x_i^+) > f(x_j^-)}}{mn} \quad (5.5)$$

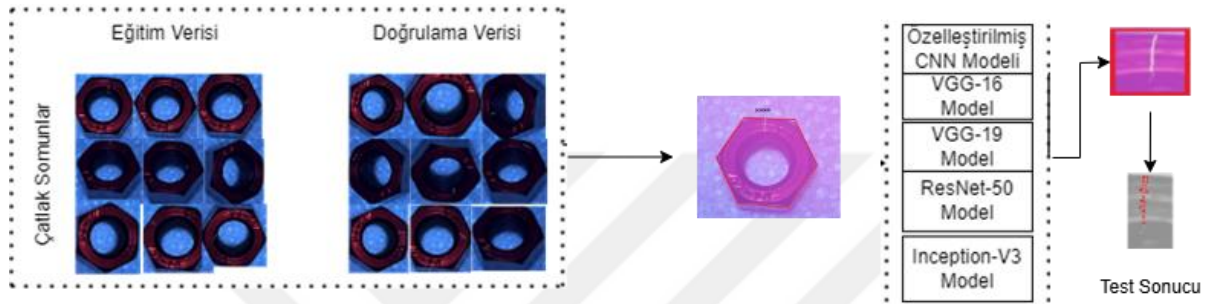
## 6. DENEYSEL ÇALIŞMALAR

Sistemin akış şeması Şekil 6.1’ de gösterilmektedir. İlk modül veri tabanı hazırlama adımını temsil eder. İkinci modül ise manyetik parçacık testi sonrası çatlak tespiti için derin öğrenme algoritmalarının mimarisini ve uygulamasını gösterir. Modellerin çeşitli metriklere göre değerlendirilmesi ve karşılaştırılması son modül de anlatılmıştır. Manyetik parçacık testi sonrası elde edilen görüntülerdeki çatlakların tespitine yönelik beş derin öğrenme modelinin performansı, girdi ve boyutu, model karmaşıklığı, eğitim doğruluğu, eğitim kaybı, doğrulama doğruluğu, doğrulama kaybı, doğruluk, hassasiyet, geri çağırma ve F1 puanına göre değerlendirildi. Evrişim katmanlarının sayısı ve her modelin parametreleri Çizelge 6.1’ de gösterilmiştir. Deneyler manyetik parçacık testi sonrası elde edilen görüntüler üzerinden oluşan farklı boyutlardaki üç farklı veri kümesinden oluşturulmuştur. Bu veri kümeleri çatlak olan görüntüler, çatlak olmayan görüntüler ve test görüntülerinden oluşmaktadır. Deneyler, D131L Jetson Orin Nano 8 GB yapay zeka kiti ve üzerinde bulunan Raspberry Pi V2 kamera ile Ubuntu işletim sistemi ile yapılmıştır. Tezimiz için gerekli veriler kameradan alınan canlı görüntüler Jetson Orin Nano üzerinde çalıştırılan modellerle analiz edilmiştir. Görüntüler gerçek zamanlı olarak işlenmiş ve olası çatlaklar başarıyla tespit edilmiştir. Jetson Orin Nano’ nun yüksek işlem gücü ve Raspberry Pi V2 kameranın kaliteli görüntü verileri sayesinde, manyetik parçacık testlerinden elde edilen çatlakların tespiti için hızlı ve etkili bir sistem geliştirilmiştir. Şekil 6.1’de Jetson Orin Nano üzerinden Raspberry V2 ile alınan görüntü gösterilmiştir.



Şekil 6.1 Jetson Orin Nano üzerinden alınan görüntü

Bu, sahada gerçek zamanlı olarak kullanılabilir bir çözüm sunarak süreçlerin verimliliğini artırmıştır. Bu deneyde beş farklı evrişimli sinir ağı modellerinden; özelleştirilmiş CNN, VGG-16, VGG-19, ResNet-50 ve Inception-V3 modelleri karşılaştırılmıştır. VGG modelleri önerilen modelden üç kat daha derindir ve yaklaşık on kat daha fazla ağı parametresine sahiptir. ResNet mimarisi VGG modeli mimarilere benzer fakat onlara göre daha derindir. ResNet modelinin karmaşıklığı ağı parametresine bakıldığında VGG'ye göre daha düşüktür. ResNet ve Inception-V3 modellerinin derinliği ve ağı parametreleri yaklaşık olarak aynıdır.



Şekil 6.1 Sistemin akış şeması

Çizelge 6.2' de 1. ve 25. Epoch' da eğitim doğruluğu, eğitim kaybı, doğrulama doğruluğu ve doğrulama kaybı sonuçları gösterilmiştir. Gösterildiği gibi modellerin kaybı 25. Epoch' da minimum seviyeye ulaştı. Beş model 25 epoch boyunca üç farklı değişen veri seti ile eğitildi. Çizelge 6.3' de gösterildiği gibi test doğruluğu, test kaybı, kesinlik, duyarlılık, F1 skoru puanı temel alınarak her model için en iyi performansı gösteren ağı seçildi. VGG-16 modeli diğer modellerin içerisinde en iyi performansı gösterdi 0.99' un üzerinde bir doğruluk elde etti.

Çizelge 6.1 Evrişimsel katman sayısı ve parametrelerle derin öğrenme modelleri

Derin Öğrenme Modelleri	Evrişimsel Katman Sayısı	Parametre Sayısı (Milyon)
Özelleştirilmiş CNN	5	5.1
VGG-16	16	14.7
VGG-19	19	20.01
ResNet-50	50	23.75
Inception V3	48	21.8

Test kaybı olarak en iyi performansı VGG-16 modelimiz gösterdi. F1 skoru ilk üç eğitim modelimizde çok yakın olmasına rağmen ResNet-50 daha düşük seviyede kalmıştır. Deneysel çalışmalarda kullanılan Özelleştirilmiş CNN, VGG-16, VGG-19, ResNet-50,

Inception-V3 modellerin epok sayısına göre zamana baęlı kayıp grafięi Őekil 6.2 – 6.6’ da verilmiŐtir.




Çizelge 6.2 Modellerin 1. ve 25. Epok eğitim doğruluğu/eğitim kaybı/doğrulama / kayıp


Modeller	Eğitim Doğruluğu		Eğitim Kaybı		Doğrulama		Kayıp	
	1 Epok	25 Epok	1 Epok	25 Epok	1 Epok	25 Epok	1 Epok	25 Epok
CNN Model	0,551	0,9745	0,6862	0,0818	0,7119	0,9798	0,6440	0,0580
<b>VGG-16</b>	<b>0,7111</b>	<b>0,9949</b>	<b>0,6268</b>	<b>0,0244</b>	<b>0,9702</b>	<b>0,9988</b>	<b>0,3642</b>	<b>0,0187</b>
VGG-19	0,6874	0,9966	0,6256	0,0222	0,9774	0,9988	0,3530	0,0188
ResNet-50	0,5283	0,9294	0,6874	0,2369	0,9655	0,9536	0,6418	0,2301
Inception-V3	0,9037	0,9993	0,2883	0,0098	0,9940	0,9964	0,0637	0,0280

Çizelge 6.3 Tüm modellerin deneysel sonuçları


Modeller	Test Doğruluğu		Test Kaybı		Kesinlik		Duyarlılık		F1 Skoru	
	Pozitif	Negatif	Pozitif	Negatif	Pozitif	Negatif	Pozitif	Negatif	Pozitif	Negatif
CNN	87,94 %	87,94 %	0,06511	0,06511	0,88	0,87	0,87	0,88	0,88	0,88
<b>VGG-16</b>	<b>89,33 %</b>	<b>89,33 %</b>	<b>0,03258</b>	<b>0,03258</b>	<b>0,89</b>	<b>0,90</b>	<b>0,90</b>	<b>0,89</b>	<b>0,89</b>	<b>0,89</b>
VGG-19	89,28 %	89,28 %	0,03424	0,03424	0,89	0,89	0,89	0,89	0,89	0,89
ResNet-50	84,72 %	84,72 %	0,22546	0,22546	0,89	0,81	0,80	0,89	0,84	0,85
Inception-V3	82,76%	82,76%	0,22546	0,22546	0,80	0,80	0,78	0,78	0,82	0,82




Şekil 6.2 Özelleştirilmiş CNN'nin zamana bağlı kayıp grafiği




Şekil 6.3 VGG-16'nın zamana bağlı kayıp grafiği



Şekil 6.4 VGG-19'un zamana bağlı kayıp grafiği




Şekil 6.5 ResNet-50'nin zamana bağlı kayıp grafiği




Şekil 6.6 Inception-V3'ün zamana bağlı kayıp grafiği

Karışıklık matrisi (confusion matrix), sınıflandırma modelinin performansını değerlendirmek için kullanılan önemli bir araçtır. Tahmin edilen sonuç ile gerçek değer karşılaştırılmaktadır. Burada model görüntüde çatlak olup olmadığını tahmin etmeye çalışıyor. TP' de model çatlak olan görüntüyü doğru bir şekilde çatlak olarak tahmin eder. TN' de model çatlak olmayan görüntüyü doğru bir şekilde çatlak değil olarak tahmin eder. FP' de ise model çatlak olmayan bir görüntüyü yanlış bir şekilde çatlak olarak tahmin eder. FN' de model çatlak olan bir görüntüyü yanlış bir şekilde çatlak değil olarak tahmin eder. Beş modelin karışıklık matrisleri şekil 6.7- 6.11' de gösterilmektedir.

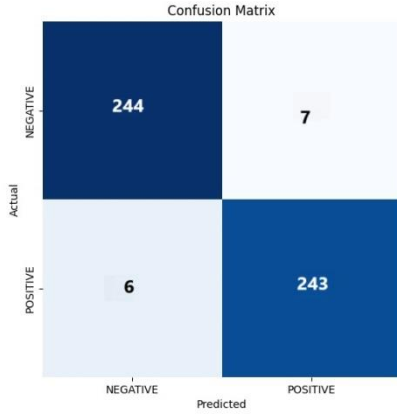
Bu bölümde, sınıflandırma modelimizin performansını değerlendirmek için AUC-ROC grafiğini kullandık. AUC-ROC grafiği, modelin pozitif ve negatif sınıfları ayırt etme yeteneğini ölçmek için önemli bir araçtır.




Şekil 6.7 Özelleştirilmiş CNN'nin karışıklık matrisi



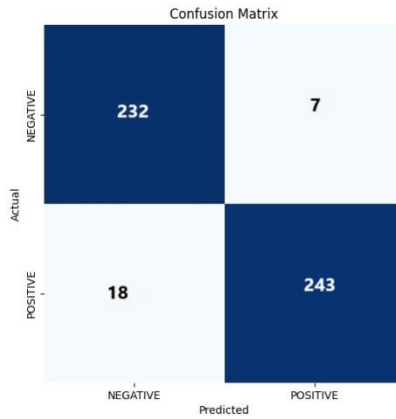
Şekil 6.8 VGG-16'nın karışıklık matrisi



Şekil 6.9 VGG-19'un karışıklık matrisi




Şekil 6.10 ResNet-50'nin karışıklık matrisi




Şekil 6.11 Inception-V3'ün karışıklık matrisi


Elde edilen sonuçlar, modelin sınıflandırma başarısını ve genel performansını özetlemektedir. Grafik üzerinden hesaplanan AUC değeri 0.9956 olarak bulunmuştur. Bu değer, modelin neredeyse mükemmel bir performansa sahip olduğunu ve pozitif ile negatif sınıflar arasında oldukça iyi bir ayırım yapabildiğini göstermektedir. Detaylı sonuçlar Şekil 6.12-6.16'da sunulmaktadır.




Şekil 6.12 Özelleştirilmiş CNN'nin AUC-ROC grafiği




Şekil 6.13 VGG-16'nin AUC-ROC grafiği



Şekil 6.14 VGG-19'un AUC-ROC grafiği




Şekil 6.15 ResNet-50'nin AUC-ROC grafiği




Şekil 6.16 Inception-V3'ün AUC-ROC grafiği

AUC-ROC grafiği, modellerin pozitif ve negatif sınıflarını ayırt etme yeteneğini gösteren önemli bir metrik olup, elde edilen AUC değerleri, modellerin sınıflandırma başarısını yansıtmaktadır. Genel olarak değerlendirildiğinde, VGG-19 ve Inception-V3 modelleri diğer modellere kıyasla daha üstün performans göstermiştir. Bu, daha derin yapılarının ve mimari tasarımlarının daha iyi genelleştirme kapasitesine sahip olduğunu düşündürmektedir. Ancak, Özelleştirilmiş CNN, VGG-16 ve ResNet-50 modelleri de oldukça rekabetçi sonuçlar sunmuş, etkileyici bir sınıflandırma performansı sergilemiştir.


Test doğruluğu bir modelin daha önce görmediği test veri kümesindeki tahminlerinin doğruluk oranını ifade eder. Modelin genelleme yeteneğini değerlendirmek için kullanılır. Model karşılaştırması için önemli bir metriktir. Farklı derin öğrenme mimarilerinin test doğruluğu üzerindeki etkisi, modelin derinliği, parametre sayısı, öğrenme kapasitesi ve veri setinin boyutuna göre değişir. Detaylı sonuçlar Şekil 6.17-6.21'de sunulmaktadır.




Şekil 6.17 CNN test doğruluğu grafiği




Şekil 6.18 VGG-19 test doğruluğu grafiği



Şekil 6.19 VGG-16 test doğruluğu grafiği



Şekil 6.20 ResNet-50 test doğruluğu grafiği



Şekil 6.21 Inception-V3 test doğruluğu grafiği

Modellerimiz test doğruluğu açısından değerlendirildiğinde VGG-16 mimarisinin klasik güçlü yönlerini yansıtan bir sonuç çıkmıştır. Derin yapısıyla oldukça iyi bir performans sergilemiş ve en yüksek doğruluğu sağlamıştır. VGG-19 ise VGG-16'ya çok yakın bir sonuç vermiştir. Bu durum, ekstra katmanların test doğruluğuna kayda değer bir katkı sağlamadığını gösteriyor. ResNet-50 ise residual bloklar, genellikle aşırı uyumu önler ve genelleme kabiliyetini artırır. Ancak burada daha az başarılı olması, veri setinin karmaşıklığı ya da boyutuyla ilgili olduğu değerlendirilmektedir. InceptionV3 ise VGG mimarilerine nazaran daha az başarı göstermiştir.

Çapraz doğrulama, bir makine öğrenimi modelinin doğruluğunu, geliştirme yeteneğini ve performansını daha sağlam bir şekilde değerlendirmek için kullanılan bir doğrulama yöntemidir. Veriler, eğitim ve test olarak bölünürken rastgele bir bölme yerine daha sistematik bir yaklaşım kullanılır. Veri seti yaklaşık eşit büyüklükte K alt gruba ayrılır. Veri setimizi için çapraz doğrulama oranı olarak K=5 belirledik. Eğitim ve test sürecinde çaprazlama işlemi K kez tekrarlandı böylece her bir çaprazlama bir kez test verisi olarak kullanıldı. Tüm çaprazlamalarda ortalama değer hesaplandı Çizelge 6.4' de sonuçlar gösterilmiştir.

**Çizelge 6.4** Tüm modellerin çapraz doğrulama sonuçları

<b>Model</b>	<b>Ortalama Doğruluk (%)</b>	<b>Standart Sapma (%)</b>
<b>CNN</b>	<b>87,52</b>	<b>+/-0,89</b>
<b>VGG-16</b>	<b>89,04</b>	<b>+/-0,71</b>
<b>VGG-19</b>	<b>88,87</b>	<b>+/-0,78</b>
<b>ResNet-50</b>	<b>84,03</b>	<b>+/-1.03</b>
<b>Inception-V3</b>	<b>82,67</b>	<b>+/-1.25</b>

CNN modeli, bu veri seti üzerinde genel olarak başarılı bir performans sergiliyor. Ancak doğruluğu, daha karmaşık modeller olan VGG-16 ve VGG-19'un biraz gerisinde kalıyor. Standart sapması düşük bir seviyede, bu da modelin farklı veri bölümlerinde tutarlı bir performans gösterdiğini işaret ediyor. VGG-16 modeli, en yüksek doğruluk oranına sahip. Özellikle büyük veri setlerinde, transfer öğrenme yöntemi ile oldukça etkili sonuçlar verebiliyor. Standart sapma oldukça düşük, bu da modelin her çaprazlamada tutarlı bir performans sergilediğini gösteriyor. VGG-16, hem yüksek doğruluğu hem de düşük sapması ile en başarılı model olarak öne çıkıyor. VGG-19 ise VGG-16'ya benzer bir performans sergiliyor ancak doğruluk oranı biraz daha düşük. Daha derin bir ağ yapısına sahip olmasına

rağmen, bu veri seti için VGG-16 kadar etkili deęil. ResNet-50'nin doęruluk oranı dięer modellerin gerisinde kalıyor. Bu durum, ResNet-50'nin veri setinin özelliklerini tam olarak öğrenememiş olabileceğini gösterebilir. ResNet-50'nin performansı nispeten düşük ve deęişken. Bunun sebebi modelin daha derin bir yapıya sahip olması ve bu veri seti için gereğinden fazla karmaşık olabilmesi olabilir. Inception-V3, düşük doęruluęu ve yüksek standart sapması nedeniyle bu veri seti için iyi bir seçim olmayacağı deęerlendirilmiştir.



## 7. SONUÇ VE ÖNERİLER

Malzemeler üzerindeki hasarın tespit edilmesi büyük öneme sahiptir. Metal yüzeyler için bu hasarın tespit edilmesi için çeşitli yöntemler geliştirilmiştir. Bunlardan biri de manyetik parçacık testi ile çatlak tespittir. Çatlakların erken tespiti, potansiyel kazaların önlenmesi açısından kritik öneme sahiptir. Kritik bileşenlerin düzenli olarak manyetik parçacık testi ile kontrol edilmesi, bu bileşenlerin ömrünü uzatır ve yatırım maliyetini düşürür. Bu tez çalışmasında derin öğrenme ile manyetik parçacık testi sonrası elde edilen görüntü üzerindeki çatlağın tespiti amaçlanmıştır. Bu da malzemenin üzerindeki çatlakların tespitinde büyük kolaylık sağlayacaktır. Tez çalışmasında derin öğrenme algoritmalarından özelleştirilmiş CNN, VGG-16, VGG-19, ResNet-50 ve Inception-V3 modelleri olmak üzere beş eğitim modeli kullanılmıştır. Bu modeller pozitif (çatlak olan), negatif (çatlak olmayan) ve test (hem çatlak hem de çatlak olmayan) görüntülerin bulunduğu veri seti kullanılarak manyetik parçacık testi sonrası elde edilen görüntülerin çatlak tespiti için değerlendirildi. Bu değerlendirme test doğruluğu, test kaybı, duyarlılık, kesinlik ve F1 skoru üzerine yapılmıştır. Karşılaştırılan modellerin performansı üzerindeki etkilerini araştırmak için epok sayısı, parametre sayısı, modelin katman sayısı gibi çeşitli faktörler değerlendirildi. 500 adet çatlak ve 500 adet çatlak olmayan somun görüntüsü testlerimizde veri seti olarak kullanılmıştır. Bu veri seti için epok sayısı kademeli olarak 25'e kadar artırılarak deneyler gerçekleştirildi. Deneysel sonuçlar, VGG16 modelinin test veri setinde %89.04 doğruluk oranı ile yüksek bir performans sergilediğini göstermiştir. Elde edilen bu sonuç, derin öğrenme modellerinin MPT yöntemlerinin doğruluğunu ve verimliliğini artırmak için büyük bir potansiyele sahip olduğunu ortaya koymaktadır. Özellikle VGG16 gibi güçlü ve derin mimariye sahip modellerin, yüzey kusurlarının doğru bir şekilde tespit edilmesinde etkili olduğu kanıtlanmıştır. VGG-16 eğitim modeli doğrulama ve test aşamalarında daha iyi doğruluk göstermiş ve model tarafından öğrenilen özellikler yüksek performansı garanti etmektedir.

Çalışmada en iyi doğruluk oranı VGG16 ile elde edilmiştir. VGG19, VGG16'ya oldukça yakın bir doğruluk oranı elde etmiş olmasına rağmen, daha derin yapısı ve hesaplama maliyetindeki artış nedeniyle bir miktar dezavantajlıdır. ResNet-50 ve Inception-V3 ise daha düşük doğruluk oranlarıyla, bu veri setinde VGG tabanlı modellere kıyasla performans olarak geride kalmıştır. Bu durum, artık bağlantıların ve karmaşık modüllerin bu veri setinde belirgin bir avantaj sağlamadığını göstermektedir. VGG16'nın sabit ve derin yapısı, veri setindeki

desenleri etkili bir şekilde öğrenmesini sağlamıştır. Özelleştirilmiş CNN, düşük hesaplama maliyetiyle avantajlıdır ancak doğruluk oranı açısından VGG16 ve VGG19 modellerin gerisinde kalmıştır. ResNet-50 ve Inception-V3 gibi modeller ise daha karmaşık olmalarına rağmen benzer doğruluk oranları sunmuştur. Inception-V3 ve ResNet-50 gibi daha karmaşık modeller, daha büyük ve çeşitli veri setlerinde daha iyi performans gösterebilir.

Gelecekte, daha büyük ve çeşitli veri setleri kullanılarak modellerin performansı artırılabilir. Ayrıca, farklı hibrit yaklaşımlar ve transfer öğrenme yöntemleri ile doğruluk oranları daha da iyileştirilebilir. Bu tez çalışması, endüstriyel uygulamalarda çatlak tespitinde derin öğrenme modellerinin kullanılabilirliğine önemli bir katkı sağlamaktadır.



## KAYNAKLAR

- Abraham, A., 2004, Meta learning evolutionary artificial neural networks, *Neurocomputing*, 56, 1-38.
- Ao, S.-I., Rieger, B. B. ve Amouzegar, M., 2010, Machine learning and systems engineering, Springer Science & Business Media, p.
- Brownlee, J., 2016, How to grid search hyperparameters for deep learning models in python with keras, *linea*]. *Disponibile en*.
- Chen, H., Liu, S., Magomedov, R. M. ve Davidyants, A. A., 2021, Optimization of inflow performance relationship curves for an oil reservoir by genetic algorithm coupled with artificial neural-intelligence networks, *Energy Reports*, 7, 3116-3124.
- Chen, L., Qu, H. ve Zhao, J., 2016, Generalized correntropy induced loss function for deep learning, *2016 International Joint Conference on Neural Networks (IJCNN)*, 1428-1433.
- DOĞAN, F. ve TÜRKÖĞLU, İ., 2018, Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması, *Sakarya University Journal of Computer and Information Sciences*, 1 (1), 10-21.
- Duman, F. ve Erdem, H., 2003, Hardware Implementation of Neural Networks on General Purpose Microcontroller, *IJCI Proc. of internat. Conf. on Signal Processing*.
- Farahmand, M., 2022, Bal peteğindeki hücrelerin tespit edilmesi için derin öğrenme yaklaşımlarının kullanılması.
- Fernandez, L., Castellero, C. ve Aguilera, J., 2005, An application of image analysis to dehydration of apple discs, *Journal of food engineering*, 67 (1-2), 185-193.
- Gehri, N., Mata-Falcón, J. ve Kaufmann, W., 2023, Experimental investigation of the shear response of large-scale fibre-reinforced concrete panels, *Engineering Structures*, 295, 116598.
- Glorot, X. ve Bengio, Y., Understanding the difficulty of training deep feedforward neural networks.
- Glorot, X. ve Bengio, Y., 2010, Understanding the difficulty of training deep feedforward neural networks, *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, 249-256.
- Han, S., Mao, H. ve Dally, W. J., 2015, Deep compression: Compressing deep neural networks with pruning, trained quantization and huffman coding, *arXiv preprint arXiv:1510.00149*.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A.-r., Jaitly, N., Senior, A., Vanhoucke, V., Nguyen, P. ve Sainath, T. N., 2012, Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups, *IEEE Signal processing magazine*, 29 (6), 82-97.
- Hochreiter, S., Bengio, Y., Frasconi, P. ve Schmidhuber, J., 2001, Gradient flow in recurrent nets: the difficulty of learning long-term dependencies, A field guide to dynamical recurrent neural networks. IEEE Press In.
- Ibrahim, A. A. M. ve Tapamo, J.-R., 2024, A Survey of Vision-Based Methods for Surface Defects' Detection and Classification in Steel Products, *Informatics*, 25.
- Ioffe, S. ve Szegedy, C., 2015, Batch normalization: Accelerating deep network training by reducing internal covariate shift, *International conference on machine learning*, 448-456.

- Khan, S., Rahmani, H., Shah, S. A. A., Bennamoun, M., Medioni, G. ve Dickinson, S., 2018, A guide to convolutional neural networks for computer vision.
- Kotsiantis, S. B., Zaharakis, I. ve Pintelas, P., 2007, Supervised machine learning: A review of classification techniques, *Emerging artificial intelligence applications in computer engineering*, 160 (1), 3-24.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *nature*, 521 (7553), 436-444.
- Leung, M. K., Xiong, H. Y., Lee, L. J. ve Frey, B. J., 2014, Deep learning of the tissue-regulated splicing code, *Bioinformatics*, 30 (12), i121-i129.
- Li, S., Zhou, M., Luo, X. ve You, Z.-H., 2016, Distributed winner-take-all in dynamic networks, *IEEE Transactions on Automatic Control*, 62 (2), 577-589.
- Lu, H., Li, Y., Zhang, Y., Chen, M., Serikawa, S. ve Kim, H., 2017, Underwater optical image processing: a comprehensive review, *Mobile networks and applications*, 22, 1204-1211.
- Lu, W. ve Chen, T., 2005, Dynamical behaviors of Cohen–Grossberg neural networks with discontinuous activation functions, *Neural Networks*, 18 (3), 231-242.
- Ma, T., Sun, Z. ve Chen, Q., 2018, Study on crack features in images of fluorescent magnetic particle inspection for railway wheelsets, *Insight-non-destructive testing and condition monitoring*, 60 (9), 519-524.
- Maas, A. L., Hannun, A. Y. ve Ng, A. Y., 2013, Rectifier nonlinearities improve neural network acoustic models, *Proc. icml*, 3.
- Marcher, T., Erharder, G. H. ve Winkler, M., 2020, Machine Learning in tunnelling–Capabilities and challenges, *Geomechanics and Tunnelling*, 13 (2), 191-198.
- Nebauer, C., 1998, Evaluation of convolutional neural networks for visual recognition, *IEEE transactions on neural networks*, 9 (4), 685-696.
- Neyshabur, B., Bhojanapalli, S., McAllester, D. ve Srebro, N., 2017, Exploring generalization in deep learning, *Advances in neural information processing systems*, 30.
- Ottucsák, G. ve Walk, H., 2012, Machine learning for financial engineering, World Scientific, p.
- Özgenel, Ç. F., 2018, Crack detection with deep learning: an exemplary study of data design in architecture.
- Saul, L. K. ve Roweis, S. T., 2003, Think globally, fit locally: unsupervised learning of low dimensional manifolds.
- Serrati, D. S., Machado, M. A., Oliveira, J. ve Santos, T. G., 2023, Non-destructive testing inspection for metal components produced using wire and arc additive manufacturing, *Metals*, 13 (4), 648.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.
- Sirmaçek, B., 2007, FPGA ile mobil robot için öğrenme algoritması modellenmesi, *Yüksek lisans tezi, Yıldız Teknik Üniversitesi, İstanbul [2] ALTUNIŞIK*.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, 15 (1), 1929-1958.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.

- Top, A. E., 2018, Classification of eeg signals using transfer learning on convolutional neural networks via spectrogram, *Ankara Yıldırım Beyazıt Üniversitesi Fen Bilimleri Enstitüsü*.
- Tout, K., Meguenani, A., Urban, J.-P. ve Cudel, C., 2021, Automated vision system for magnetic particle inspection of crankshafts using convolutional neural networks, *The International Journal of Advanced Manufacturing Technology*, 112, 3307-3326.
- Wang, J., Lin, J. ve Wang, Z., 2016, Efficient convolution architectures for convolutional neural network, *2016 8th International Conference on Wireless Communications & Signal Processing (WCSP)*, 1-5.
- Wu, Q., Qin, X., Dong, K., Shi, A. ve Hu, Z., 2023, A learning-based crack defect detection and 3D localization framework for automated fluorescent magnetic particle inspection, *Expert Systems with Applications*, 214, 118966.
- Yan, L., Dodier, R. H., Mozer, M. ve Wolniewicz, R. H., 2003, Optimizing classifier performance via an approximation to the Wilcoxon-Mann-Whitney statistic, *Proceedings of the 20th international conference on machine learning (icml-03)*, 848-855.
- Yang, Y., Yang, Y., Li, L., Chen, C. ve Min, Z., 2022, Automatic defect identification method for magnetic particle inspection of bearing rings based on visual characteristics and high-level features, *Applied Sciences*, 12 (3), 1293.
- Yu, F., 2015, Multi-scale context aggregation by dilated convolutions, *arXiv preprint arXiv:1511.07122*.
- Zeiler, M. D. ve Fergus, R., 2014, Visualizing and understanding convolutional networks, *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13*, 818-833.